

# Le développement de la richesse lexicale en langue de scolarisation et en langue d'origine<sup>1</sup>

**Audrey BONVIN**

Université de Fribourg

Département de plurilinguisme et didactique des langues étrangères

Rue de Rome 1, 1700 Fribourg, Suisse

audrey.bonvin2@unifr.ch

This paper compares short narrative and argumentative texts written by migrant Portuguese-speaking children in Switzerland to those written by Portuguese-speaking children living in Portugal as well as French-speaking and German-speaking children in Switzerland. This contribution focuses on human intuitive perception of the richness of vocabulary. Our corpus comprises of 3,060 French, German and Portuguese texts written by children aged 8 to 10 at three different time points. The texts were assessed online by 574 untrained adult French, German and Portuguese native speakers. Results of these ratings were modelled by group of children, time of data collection and type of text. The analysis revealed that the scores for each group increased between the first and third time point. Portuguese children in Switzerland tend to score lower than children in the other comparison groups, but the size and probability of these differences differed according to the language, the time when the data were collected, and the type of text. Potential didactic implications of the results are discussed.

## **Keywords:**

lexical richness, bilingualism, narrative texts, argumentative texts, heritage language, language of schooling, human ratings, longitudinal study.

## **Mots-clés:**

richesse lexicale, bilinguisme, récits narratifs, textes argumentatifs, langue d'origine, langue de scolarisation, évaluations humaines, étude longitudinale.

## **1. Introduction**

### *1.1 Description de la population portugaise en Suisse*

Les habitants d'origine portugaise constituent la troisième population étrangère en Suisse (Office fédéral de la statistique, s.d.). Celle-ci est par ailleurs très attachée à sa langue et culture d'origine (Fibbi et al. 2010). Selon les chiffres reportés par Fibbi et al. (2010: 87, 104-105), "environ 70% des enfants en âge de scolarité obligatoire fréquentent les cours de langue et culture portugaises". Selon le recensement de 2013-2015, la grande majorité des Portugais déclarent le portugais comme étant la langue la plus fréquemment parlée à la maison<sup>2</sup>.

---

<sup>1</sup> Cette étude s'inscrit dans le projet "Productions écrites d'enfants issus de la migration", financé par le Centre scientifique de compétence sur le plurilinguisme (Fribourg). Merci à Raphael Berthele, Amelia Lambelet et Jan Vanhove pour leurs précieux conseils et commentaires sur cette étude, aux lecteurs anonymes et aux éditeurs pour leurs propositions constructives sur une version précédente de cet article ainsi qu'à tous les participants qui ont rendu cette étude possible.

<sup>2</sup> Le genre masculin est utilisé pour désigner des personnes des deux genres dans le seul but de ne pas alourdir le texte.

Une autre caractéristique des migrants portugais s'avère leur bas niveau de formation en comparaison à d'autres migrants en Suisse. En effet, la proportion de résidents portugais de plus de 15 ans qui ont comme plus haut niveau de formation l'école obligatoire est élevée (cf. chiffres du recensement de 2015; Fibbi et al. 2010: 42-43). Cette tendance se poursuit dans la nouvelle génération avec une surreprésentation des enfants d'origine portugaise "dans les classes spéciales au primaire, dans les filières à exigences élémentaires au niveau secondaire I, ainsi que dans les « solutions transitoires » lors du passage à la scolarité postobligatoire" (Fibbi et al. 2010: 41).

Ces informations invitent à questionner les facteurs potentiels de la non-réussite scolaire des enfants d'origine portugaise. Une entrée pour l'étude de cette question est d'essayer de comprendre si cette population présente des particularités au niveau de la littéracie, et si oui, en quoi celles-ci consistent.

Dans cet article, nous étudions la richesse du vocabulaire de productions écrites d'élèves âgés de 8 à 10 ans. Nous nous concentrons sur la richesse perçue intuitivement par des locuteurs natifs de la langue en question. La perception commune nous paraît importante, car ce sont des personnes et non pas des algorithmes qui évaluent habituellement le vocabulaire des élèves à l'école (mais aussi dans d'autres situations formelles plus tard). Pour clarifier l'intérêt de cette étude dans son contexte disciplinaire, nous résumons tout d'abord des résultats généraux de recherches sur le développement du lexique, puis mettrons le focus sur les connaissances concernant les élèves-cibles.

## *1.2 Le vocabulaire chez les enfants bilingues*

Malgré une description plus ou moins universelle des grandes étapes du développement lexical, on assiste à des variations individuelles qu'il s'agisse d'enfants monolingues ou plurilingues. Cette hétérogénéité tend par ailleurs à augmenter avec le temps. En effet, plus un enfant grandit, plus son vocabulaire se diversifiera selon son environnement et ses activités (Unsworth 2016).

En ce qui concerne le développement bilingue en particulier, certaines études montrent que les étapes fondamentales de l'acquisition du langage sont similaires à celles des enfants monolingues, tandis que d'autres études dénoncent un retard par rapport à la norme monolingue. Malgré certains résultats pouvant paraître contradictoires, ce qui ressort de plusieurs études sur le développement de la taille du vocabulaire d'enfants bilingues entre un an et dix ans est qu'ils ne présentent pas de retard par rapport aux monolingues si on considère leurs deux langues ensemble (en termes de vocabulaire total, soit la somme des tous les mots connus ou de vocabulaire conceptuel, soit la somme de concepts lexicaux connus dans au moins une langue). Par contre, ils disposent en moyenne de moins de vocabulaire dans chacune des langues séparément que des monolingues correspondants, en particulier si la quantité

de l'input se trouve en-dessous d'un certain seuil (Klassert 2011: 107-108; Hoff et al. 2012; Unsworth 2016).

Les différences de taille du vocabulaire entre les groupes, si on prend en compte une seule langue, peuvent varier selon la thématique. Bialystok et al. (2010) ont comparé la taille du vocabulaire réceptif en anglais de 772 enfants monolingues et 966 bilingues à différents âges. Des différences significatives entre les groupes ont été observées pour le vocabulaire spécifique à la maison, mais pas pour le vocabulaire spécifique à l'école.

Précisons encore que l'interprétation des résultats de recherche sur le développement du vocabulaire chez les bilingues dépend de plusieurs facteurs, méthodologiques entre autres. Pour ne citer qu'un exemple, De Houwer et al. (2013) discutent d'une problématique récurrente, celle de ne pas toujours disposer de groupes bilingues et monolingues comparables au niveau des variables démographiques et socioéconomiques. De ce fait, non pas forcément le bilinguisme lui-même, mais plutôt d'autres caractéristiques propres aux différents groupes pourraient expliquer certaines différences parfois reportées au niveau de la taille du vocabulaire (De Houwer et al. 2013).

### *1.3 La richesse du vocabulaire du groupe cible*

Lorsqu'on s'intéresse à la richesse lexicale dans des textes produits plus ou moins librement, nous constatons d'abord un manque d'études auprès des locuteurs proches de notre groupe cible, soit les enfants bilingues issus de groupes non privilégiés et en âge de scolarisation<sup>3</sup>.

Une des rares études est celle de Gharibi et Boers (2017) qui ont analysé de manière transversale la richesse lexicale dans des textes narratifs oraux en farsi. Ces récits avaient été produits par 25 bilingues d'origine iranienne en Australie et par 25 monolingues en Iran âgés de 6 à 18 ans. La richesse lexicale y a été opérationnalisée au moyen d'une mesure de diversité lexicale (Measure of Textual Lexical Diversity, ci-après MTLTD, McCarthy & Jarvis 2010), soit la proportion de non répétition, ainsi qu'au moyen d'une mesure de l'utilisation de mots de basse fréquence (aussi appelée sophistication lexicale). Les auteurs ont observé de meilleurs résultats auprès des monolingues que des bilingues, surtout pour la mesure de fréquence. L'âge biologique, ainsi que l'âge d'immigration étaient des prédicteurs importants. Toutefois, la richesse du vocabulaire n'a pas été analysée dans la langue de scolarisation, l'anglais, où l'on aurait pu attendre moins de différences, pour des raisons d'input.

Nous allons maintenant résumer quelques résultats à propos du développement de la richesse lexicale des élèves en question dans l'étude

---

<sup>3</sup> Le terme bilingue est employé dans cet article puisque nous étudions les deux langues dominantes des élèves d'origine portugaise en Suisse. Ceci n'empêche pas que certains enfants parlent plus que deux langues. D'ailleurs, les enfants scolarisés en Suisse allemande doivent acquérir, à côté de l'allemand standard, au moins une variété du suisse-allemand.

présente. Ceci est possible, car les productions écrites servant de base aux évaluations sont issues d'un projet antérieur de l'Institut de plurilinguisme (Université de Fribourg et Haute Ecole Pédagogique de Fribourg) (HELASCOT, Berthele & Lambelet 2017)<sup>4</sup>. Ce projet longitudinal visait à décrire le développement de la bi-littéracie d'enfants issus de la migration portugaise. Différentes données avaient été récoltées auprès des élèves, dont des rédactions (narrations et argumentations) qui ont été réutilisées pour des analyses de richesse lexicale dans le cadre du présent projet.

Dans une étude précédente, nous avons étudié la richesse lexicale en langue de scolarisation des élèves portugais en Suisse en la comparant à celle d'autres élèves du paysage scolaire suisse (Bonvin et al. 2018)<sup>5</sup>. La richesse lexicale y a été évaluée de manière automatique, d'une part au moyen de la mesure de diversité lexicale MTLD et d'autre part, au moyen d'une mesure de fréquence des mots, partant du principe que plus un texte contient des mots rares, plus il est riche. Les résultats ont montré une augmentation générale de la diversité lexicale, mais pas de l'utilisation des mots de basse fréquence. De plus, des différences entre les élèves portugais et les élèves des groupes de comparaison ont été trouvées pour la diversité et cela en particulier dans les textes argumentatifs en allemand: les élèves d'origine portugaise obtiennent des résultats moins bons que leurs pairs des classes de comparaison. Cependant, derrière ces différences observées en termes de moyennes entre lusophones et élèves des groupes de comparaison, de grands chevauchements en termes de déviation standard ont été constatés entre les différents groupes d'élèves.

Ce résultat nous a amené à reconsidérer l'hétérogénéité des élèves dans les groupes de comparaison (cf. note de bas de page 5), car cela aurait pu influencer les résultats. Pour ce faire, nous avons découpé l'échantillon en trois groupes: enfants bilingues lusophones, enfants bilingues non lusophones et enfants monolingues en langue de scolarité. Les résultats de ces analyses complémentaires montrent que les enfants bilingues portugais de notre échantillon obtiennent en moyenne de moins bons scores de diversité lexicale (MTLD) que les enfants bilingues d'autres origines, en particulier en Suisse allemande. Pour ces derniers, la moyenne des scores est d'ailleurs proche de celle des enfants monolingues. Le corpus HELSACOT contenant également des tâches de compréhension écrite, des analyses similaires ont été effectuées pour cette compétence. Là, l'image est sensiblement différente. Par exemple, les moyennes des résultats des bilingues non-lusophones, en compréhension

---

<sup>4</sup> <http://www.institut-plurilinguisme.ch/fr/content/langue-dorigine-et-langue-scolarisation> (consulté le 09.08.2019)

<sup>5</sup> Ces groupes de comparaison sont composés de classes de l'enseignement régulier en Suisse romande et Suisse allemande et contiennent donc un certain nombre d'enfants issus de la migration (intra-suisse et étrangère) en sus des monolingues (cf. Desgrappes & Lambelet 2017).

écrite en allemand, sont plus proches de celles des bilingues lusophones que des monolingues (Lambelet et al. 2018). Notons cependant que ces résultats sont de nature descriptive uniquement. Les effets de la classe sur les scores n'ont donc pas été contrôlés bien qu'ils aient pu jouer un rôle, puisque les bilingues non lusophones et les monolingues provenaient des mêmes classes (Vanhove 2015).

#### *1.4 Les compétences générales en littéracie du groupe cible*

Dans le cadre du projet HELASCOT, des analyses de compétences textuelles globales ont été conduites sur les textes argumentatifs et narratifs dans les trois langues au moyen d'une grille d'évaluation. Les auteurs ont observé une amélioration des compétences textuelles au cours du temps pour tous les groupes d'élèves et genres de textes. En ce qui concerne l'allemand, des différences entre les groupes à l'avantage des élèves de comparaison sont apparues pour les deux genres de textes. Celles-ci sont cependant plus nettes pour les textes argumentatifs. Pour les textes en français, les lusophones ne se différencient pas clairement des groupes de comparaison francophones. Pour le portugais, les élèves lusophones scolarisés en Suisse ont obtenu de moins bons scores que les élèves scolarisés au Portugal (Desgrippes et al. 2017).

Concernant la compréhension écrite, Pestana et al. (2017) ont également observé des scores moins élevés en langue de scolarisation pour les enfants lusophones, par rapport aux enfants de comparaison en Suisse alémanique.

## **2. Questions de recherche et hypothèses**

Pour l'article présent, nous continuons l'analyse du développement lexical des lusophones et des élèves de comparaison commencée dans les deux articles précédents (Bonvin et al. 2018; Lambelet et al. 2018) en incluant, en plus de nouvelles questions de recherche, deux aspects novateurs: la prise en compte des deux langues des bilingues lusophones et la perception humaine de la richesse du vocabulaire.

Plus spécifiquement, nos questions de recherche sont les suivantes:

Q1. Observe-t-on des différences en termes de vitesse du développement de la richesse du vocabulaire (telle que mesurée par les évaluations humaines) entre les enfants issus de la migration portugaise en Suisse romande ou Suisse alémanique et les enfants des groupes de comparaison suisses et portugais?

Q2: Les différences entre les groupes d'élèves dépendent-elles du genre textuel (argumentatif ou narratif)?

Q3. Les enfants issus de la migration portugaise se différencient-ils plus dans leur langue d'origine ou dans leur langue de scolarisation par rapport aux élèves des groupes de comparaison correspondants?

Q4. Les différences observées en langue de scolarisation entre les élèves bilingues lusophones et les élèves des groupes de comparaison sont-elles plus grandes pour les productions en allemand ou en français?

Hypothèses: les scores de richesse lexicale devraient augmenter au fil du temps. La richesse du vocabulaire en portugais se développera certainement plus rapidement chez les élèves scolarisés au Portugal. Par contre, nous n'avons pas d'hypothèse claire concernant la vitesse du développement dans les langues de scolarité. Les groupes de comparaison obtiendront probablement des scores en moyenne plus élevés que les groupes d'enfants d'origine portugaise en Suisse, en particulier pour les textes en portugais. Le portugais étant typologiquement plus proche du français que de l'allemand, nous nous attendons à des différences plus petites entre les groupes pour les textes en français que pour les textes en allemand. Quant au genre textuel, ces différences entre les groupes d'élèves pourraient être plus grandes pour les textes argumentatifs que narratifs, du moins pour les textes en allemand.

### **3. Méthode**

#### *3.1 Corpus de textes à évaluer*

Les textes, dont la richesse du vocabulaire a été évaluée, proviennent du projet longitudinal mentionné dans les chapitres 1.3 et 1.4 (projet HELASCOT, Berthele & Lambelet 2017). Rappelons qu'en plus des élèves portugais en Suisse allemande et Suisse romande, le corpus possède des groupes de comparaison constitués de classes de l'enseignement régulier en Suisse romande, en Suisse alémanique et au Portugal.

Ces élèves ont rédigé deux types de textes à trois reprises dans leur langue de scolarisation (le français, l'allemand ou le portugais), ainsi que dans leur langue d'origine (pour les deux groupes d'enfants d'origine portugaise en Suisse).

Les récoltes ont eu lieu en début de 3<sup>e</sup> année primaire, en fin de 3<sup>e</sup> année, et en fin de 4<sup>e</sup> année. Les instructions reçues par les élèves étaient les mêmes aux trois récoltes de données (cf. ci-dessous).

Lettre argumentative	Récit narratif
<b>Préfères-tu voyager en voiture ou en avion?</b>	<b>Ta dernière course d'école</b>
<p>Ta tante t'a invité pour passer les vacances avec elle. Elle n'a pas encore décidé du moyen de transport et veut savoir ton opinion.</p> <p><b>Préfères-tu voyager en voiture ou en avion?</b></p> <p>Ecris une lettre à ta tante où tu lui expliques ce que tu préfères. N'oublie pas de lui donner <b>au moins trois raisons</b> pour lesquelles tu préfères l'avion ou la voiture.</p> <p><b>Essaie de la convaincre!</b></p>	<p>Le prochain numéro d'un magazine pour enfants sera consacré aux courses d'école. Tu vas écrire un article pour ce magazine pour y raconter ta dernière course d'école.</p> <p><b>Repense à ta dernière course d'école: où es-tu allé? Qu'est-ce qui s'est passé? Qu'as-tu fait pendant cette sortie de classe depuis le début jusqu'à la fin de la journée?</b></p> <p>Raconte aux lecteurs du magazine le plus possible de détails sur cette journée.</p>

Fig. 1. Instructions pour les productions écrites en langue de scolarisation. Les versions allemande et française sont identiques. La version en portugais est similaire aux deux autres versions, avec des variations sur le thème, le destinataire de la lettre et les choix argumentatifs.

Ces instructions ont été rédigées de manière à répondre aux normes HarmoS pour la compétence "écriture" (Desgrippes et al. 2017)<sup>6</sup>. Nous pouvons donc nous attendre à ce que les productions récoltées dans le cadre du projet HELASCOT soient proches des performances scolaires habituelles de ces enfants. Le fait d'avoir des instructions similaires pour tous les élèves permet en outre une comparabilité entre groupes, malgré de grandes variations entre élèves en termes de longueur des productions.

### 3.2 Profil des élèves qui ont produits les textes à évaluer

Desgrippes & Lambelet (2017) ont étudié le contexte social et linguistique des élèves qui ont participé au projet HELASCOT au moyen de questionnaires remplis par les parents. Les autrices ont constaté que l'importance de la langue portugaise se retrouve dans la vie quotidienne des élèves lusophones en Suisse. En effet, selon les résultats issus des questionnaires, la majorité de ces enfants seraient en contact avec la langue de scolarisation moins de 50% du temps avant leur entrée à l'école enfantine. Après l'entrée à l'école primaire, la moyenne estimée se situe autour de 50% du temps. Le niveau de formation généralement bas chez les migrants lusophones, mentionné dans l'introduction, se retrouve aussi dans cette population. Le niveau autoévalué des compétences langagières des parents est plus élevé pour le français (familles vivant en Suisse romande) que pour l'allemand (familles vivant en Suisse allemande). La grande majorité des enfants d'origine portugaise suivent les

<sup>6</sup> Seul les descripteurs HarmoS (accord intercantonal sur l'harmonisation de la scolarité obligatoire) ont été pris en considération, car ceux du plan d'études portugais langue d'héritage n'étaient pas assez précis pour les besoins du projet HELASCOT (cf. Desgrippes & Lambelet 2017: 62-63). Desgrippes et al. (2017) précisent que les descripteurs pour le portugais ne sont pas en contradiction avec les normes HarmoS.

cours de langue et de culture d'origine, avec une proportion plus élevée dans l'échantillon suisse allemand (Desgrippes & Lambelet 2017).

### 3.3 Préparation des textes à évaluer

Les productions écrites digitalisées dans le cadre du projet HELASCOT ont été préparées et formatées de façon spécifique pour le projet sur la richesse lexicale. Les étapes de cette transformation sont résumées ci-dessous. Pour les lecteurs intéressés à plus de détails à propos des chapitres 3.3, 3.4 et 3.5, nous renvoyons à notre document de travail (Vanhove 2018) ainsi qu'aux ressources disponibles en ligne (entre autres : textes à évaluer, plateforme internet et données récoltées lors des évaluations en ligne) (Vanhove et al. 2019b).

Tous les textes ont été rendus anonymes par un remplacement des noms propres par LIEU, PRENOM, NOM ou MARQUE. Afin de minimiser l'influence de facteurs autres que lexicaux, les textes ont été corrigés en termes d'orthographe, de syntaxe, de ponctuation, et dans certains cas de sémantique par trois collaborateurs scientifiques au minimum par texte.

Les mots étrangers, utilisés sporadiquement, généralement en anglais ou dans l'autre langue du locuteur bilingue, n'ont pas été traduits. Nous avons ajouté une exception à cette règle pour les textes en allemand qui contiennent un nombre important de mots en suisse-allemand, dont la proximité à leur correspondant en allemand standard varie (p.ex. *Flugi* → *Flugzeug* (avion), *grillieren* → *grillen* (faire une grillade), *Goalli* → *Torhüter* (gardien), *Znüni* → *Pausenbrot* (collation du matin)). Bien que ces mots constituent une manifestation intéressante des ressources lexicales des élèves, ils ont été traduits en allemand standard, car leur présence peut rendre l'évaluation par des locuteurs germanophones qui ne parlent pas le suisse-allemand problématique.

Certains textes ont été supprimés du corpus initial pour les raisons suivantes:

- Les textes étaient trop courts.
- L'enfant a recopié la consigne de la tâche.
- Le texte n'a pas été majoritairement rédigé dans la langue cible, mais dans l'autre langue de l'élève.
- Le texte manque fortement de cohérence et de cohésion.

Au final, 3060 textes ont été retenus pour les évaluations de la richesse du vocabulaire. La longueur médiane de ces textes varie entre 33 et 39 mots selon la langue (min. 9 mots, max. 284 mots).

Puisqu'il était impensable de donner un millier de textes à évaluer aux mêmes personnes, ces textes ont été répartis en 20 sets par langue. Chaque set comprenait entre 50 et 52 textes selon la langue.

	Français	Allemand	Portugais
Nombre de sets	20	20	20
Nombre de textes par set	50	51	52
Nombre total de textes	1000	1020	1040
Longueur médiane des textes en nombre d'occurrences	37	33	39

Fig. 2. Caractéristiques des textes et leur échantillonnage.

Ces sets ont été compilés en répartissant différentes variables propres aux textes de la manière la plus équilibrée possible (pour la répartition exacte, voir Vanhove 2018: 75-76):

- Le nombre de textes écrits par des enfants lusophones bilingues, par rapport au nombre de textes écrits par des enfants des groupes de comparaison.
- Le nombre de textes argumentatifs par rapport au nombre de textes narratifs.
- Le nombre de textes rédigés à chacune des trois récoltes de données.
- Les différents textes écrits par le même enfant ne sont pas regroupés dans un même set.

Deux textes d'entraînement ont été ajoutés dans chaque set. Ces derniers étaient identiques au sein de tous les sets de textes dans la même langue.

### 3.4 Plateforme d'évaluation

Les textes ont été évalués en ligne (Fig. 3). Une plateforme internet similaire pour chacune des trois langues a été produite. Le mode d'évaluation des textes et la plateforme d'évaluation ont été pilotés en différentes étapes (Vanhove 2018: 79-80; Bonvin & Lambelet 2019).

Les évaluateurs ont dans un premier temps rempli un questionnaire biographique portant sur leur(s) "langue(s) maternelle(s)", leur niveau d'éducation, leur pays, leur genre et leur âge. Ensuite, ils ont continué avec l'évaluation des textes. Ils n'ont reçu aucune définition de la "richesse du vocabulaire" et ont été encouragés à utiliser leur intuition linguistique: *l'exercice peut sembler difficile, ce qui est normal; c'est votre perception intuitive de la richesse du vocabulaire qui nous intéresse. Essayez donc de ne pas trop réfléchir, mais tâchez d'être consistant.* Par ailleurs, la seule information à propos du profil des enfants qui leur a été divulguée est leur âge approximatif (entre 8 et 10 ans).

Afin d'obtenir un nombre comparable d'évaluations par texte, chaque évaluateur a automatiquement été assigné au set évalué le moins souvent dans la langue

choisie au moment de sa connexion sur la plateforme. Les textes au sein d'un même set ont été présentés à chaque évaluateur dans un ordre aléatoire différent, sauf pour les deux textes d'entraînement à la tâche qui étaient logiquement toujours présentés en premier.

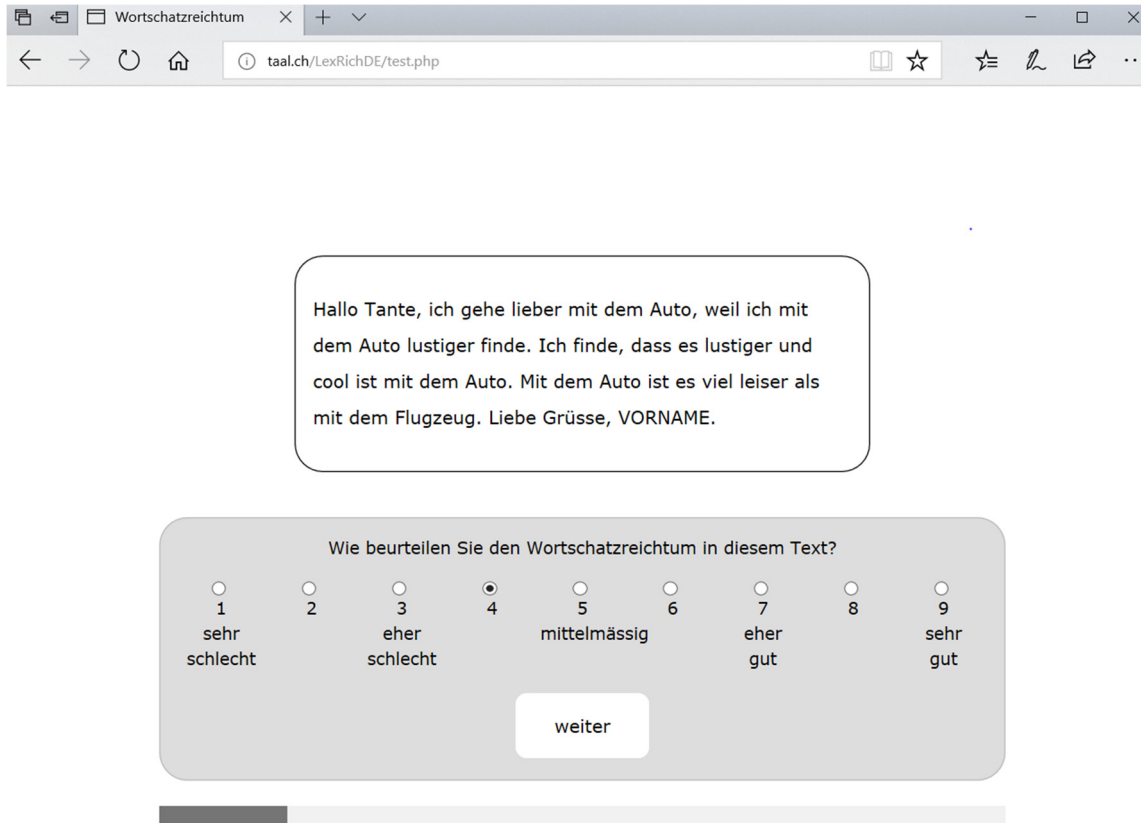


Fig. 3. Interface d'évaluation, version allemande.

### 3.5 Caractéristiques des évaluateurs et des évaluations

Les évaluateurs ont été recrutés au sein des réseaux professionnels et personnels des collaborateurs du projet *Productions écrites d'enfants issus de la migration*. Ces évaluateurs étaient volontaires, non entraînés et non rémunérés.

Parmi toutes les personnes s'étant connectées à la plateforme, seules celles qui ont évalué au moins 48 textes, qui se considèrent comme natives dans la langue en question et qui ne présentent pas de schéma d'évaluation douteux ont été retenues pour cette étude<sup>7</sup>. Au total, il s'agit de 146 francophones, 322 germanophones et 106 lusophones. L'exclusion des autres évaluateurs implique que le nombre d'évaluations par set varie malgré les précautions prises (chapitre 3.4). Les textes en allemand ont ainsi été évalués en moyenne par

<sup>7</sup> Par schéma d'évaluation douteux, nous entendons par exemple le fait d'attribuer constamment la même note ou d'alterner de façon régulière entre deux ou trois notes (cf. Vanhove 2018: 72).

16.1 personnes (min. = 11; max. = 18), les textes en français ont été évalués en moyenne par 7.3 personnes (min. = 4; max. = 9) et ceux en portugais par une moyenne de 5.3 personnes (min. = 3; max. = 6).

Les évaluateurs francophones (âge médian: 27) proviennent principalement de Suisse (83) et de France (50). Les germanophones (âge médian: 25) habitent majoritairement en Suisse (254) et en Allemagne (46). Les lusophones (âge médian: 35) vivent principalement au Portugal (48) et en Suisse (38). La proportion d'enseignants varie de 14% (pour les évaluateurs lusophones) à 26% (pour les évaluateurs germanophones). La proportion d'étudiants est plus élevée pour les langues de scolarisation (47% pour le français et 57% pour l'allemand) que pour la langue d'origine, le portugais (21%). Ces étudiants proviennent majoritairement de disciplines linguistiques ou didactiques. Par ailleurs, le pourcentage de linguistes se situe entre 8% et 10%. Finalement, la proportion d'hommes est de 21% pour le français, 17% pour l'allemand et 29% pour le portugais.

Les deux exemples ci-dessous illustrent les cas d'évaluation le plus bas (1) et le plus haut (2) en français:

(1) Chère tante, je préfère l'avion porque nous on va rapidement. Moi, veux pas la voiture porque on va moins vite. Marque une cruz. oui ou non. Salut. (Texte argumentatif par un enfant d'origine portugaise lors de la première récolte de données)

Moyenne (7 évaluateurs): 1.57

(2) Pendant le camp vert, nous sommes allés au cirque NOM à LIEU et il y avait une contorsionniste qui prenait des poses impossibles, des trapézistes qui nous ont fait frémir en voltigeant au-dessus de nos têtes, des clowns hilarants, de beaux chevaux bien dressés et même, des éléphants ! C'était vraiment super. (Texte narratif par un enfant du groupe de comparaison lors de la troisième récolte de données)

Moyenne (9 évaluateurs): 8.67

## 4. Résultats

Pour les lecteurs intéressés par des détails, les fichiers avec les scores par texte, ainsi que le script des analyses effectués avec le software R sont disponibles en ligne (<https://osf.io/fd5jn/>).

### 4.1 Analyses descriptives

Les analyses sont conduites sur la base de la moyenne des évaluations par texte, en tant que mesure de la perception commune de la richesse d'un texte (Vanhove et al. 2019a et b). Une illustration graphique permet dans un premier temps d'esquisser des réponses aux questions de recherche (Fig. 4).

Pour les langues de scolarisation, on assiste à un développement linéaire entre la première et la troisième récolte de données, pour tous les groupes d'élèves et les deux genres de textes. En portugais, il y a une évolution de la première à la troisième récolte, mais elle ne semble pas linéaire, puisque les textes de la

deuxième récolte n'obtiennent pas toujours une meilleure moyenne par rapport à la première récolte.

Si l'on regarde la médiane des boîtes à moustaches, les élèves de comparaison de chaque langue obtiennent de meilleurs scores que les élèves bilingues d'origine portugaise, même si les évaluateurs n'avaient aucune information sur la biographie linguistique des enfants. Une différence se dessine entre les langues de scolarisation suisses et la langue d'origine: alors qu'en français et en allemand, on observe beaucoup de chevauchements dans les résultats, les différences en portugais sont plus claires. De plus, la différence entre les lusophones en Suisse et ceux vivant au Portugal semble augmenter entre la première et la troisième récolte. Finalement, les différences entre les élèves d'origine portugaise et les élèves des groupes de comparaison paraît plus grande pour les textes argumentatifs que narratifs.

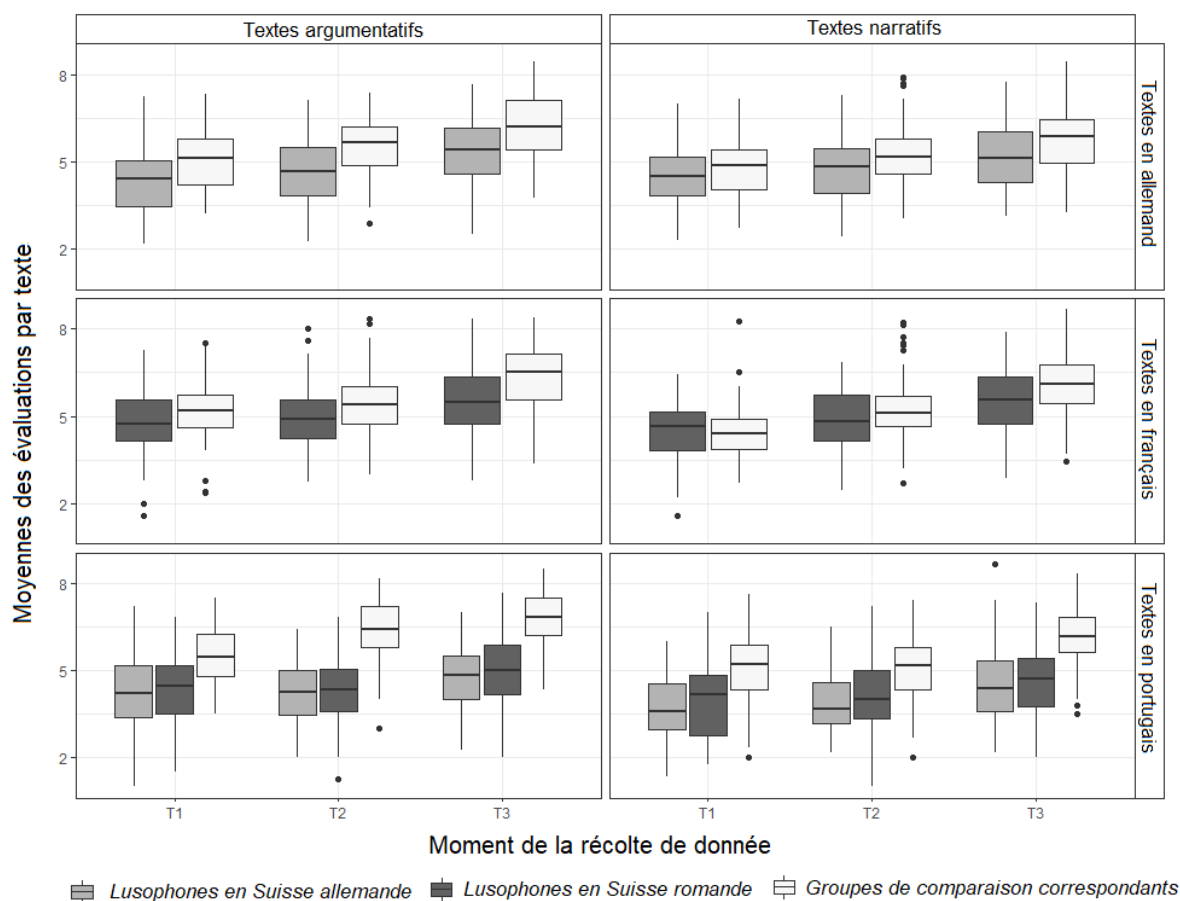


Fig. 4. Distribution des scores des évaluations humaines de la richesse du vocabulaire, organisés selon le groupe d'élèves, le moment de la récolte de données et le type de texte et la langue des textes.

## 4.2 Analyses statistiques

Nos données ne sont pas indépendantes. Tout d'abord, les différents sets de textes ont été évalués par différents groupes d'évaluateurs. Ceci pourrait

affecter les résultats, par exemple dans le cas où un groupe d'évaluateurs serait tendanciellement plus sévère que d'autres. Vanhove (2018: chapitre 9.3) a d'ailleurs constaté au moyen d'une corrélation intra-classe que les scores de richesse du vocabulaire semblent associés à un certain degré au groupe d'évaluateurs pour le portugais en particulier. À cela s'ajoute que chaque enfant a écrit plusieurs textes (12 au maximum) et nous pouvons nous attendre à ce que les différentes performances d'un même enfant soient liées entre elles à un certain degré. Le même raisonnement s'applique aussi au fait que les données ont été récoltées dans plusieurs classes. Par exemple, les différentes didactiques appliquées selon les classes (qui n'ont pas été observées) pourraient influencer l'utilisation du vocabulaire chez les élèves.

Ainsi, une analyse statistique (dans ce cas un modèle de régression à effets mixtes) permet de prendre en compte l'effet de ces variables dites aléatoires dans les résultats. En effet, en s'arrêtant aux résultats bruts (Fig. 4), nous risquons de sous-estimer l'incertitude autour des résultats. Dans l'optique de produire un seul modèle statistique pour répondre aux quatre questions de recherche et en raison de la complexité des données (certaines variables ont plus de deux niveaux), les statistiques bayésiennes ont été choisies<sup>8</sup>. Dans notre cas, celles-ci permettent de développer un modèle plus facilement interprétable que les statistiques fréquentistes habituelles<sup>9</sup>.

Pour ce faire, les résultats des évaluations humaines ont été modélisés comme une fonction du moment de la récolte des données, du genre textuel, du groupe d'élèves et de la langue (les prédicteurs qui nous intéressent et leurs interactions), tout en contrôlant l'effet des différentes classes d'où proviennent les élèves, de l'élève lui-même et du groupe d'évaluateurs (les effets aléatoires qui pourraient influencer les résultats et leurs interactions).

Conceptuellement, nous avons tenu compte de la possibilité que les différents enfants varient dans le développement de leur vocabulaire, ainsi que de la possibilité que la richesse du vocabulaire varie pour le type de texte différemment selon les enfants. Idem pour les classes d'élèves. Nous avons également considéré l'éventualité que les groupes d'évaluateurs varient dans la notation des textes récoltés à différents moments, ainsi que la possibilité qu'ils évaluent différemment les deux genres de textes.

La fig. 5 illustre graphiquement les résultats statistiques et sert de support visuel pour la réponse à chacune des questions de recherche.

---

<sup>8</sup> L'objectif derrière le choix de n'employer qu'un modèle est de ne pas adapter les analyses en fonction de chaque question et donc d'éviter une potentielle manipulation non souhaitée/souhaitable des résultats. Pour les calculs, la fonction `brm` du package `brms` (Bürkner 2017) pour le programme R a été employée.

<sup>9</sup> Pour plus de détails concernant ce type d'analyse: <https://janhove.github.io/analysis/2018/12/20/contrasts-interactions> (consulté le 22.07.19).

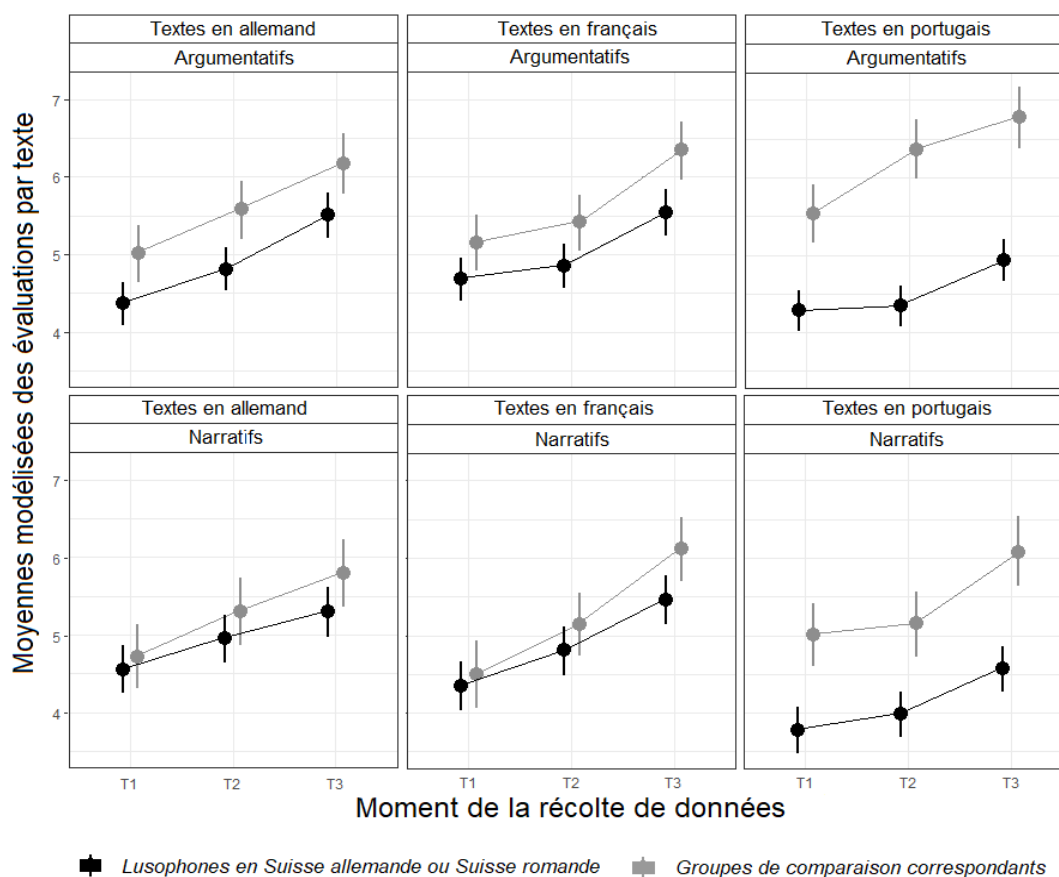


Fig. 5. Scores de richesse du vocabulaire modélisés avec leur incertitude (intervalle de 95%).

**Q1. Est-ce que la richesse du vocabulaire se développe plus rapidement chez les enfants bilingues lusophones ou chez les enfants de comparaison en langue de scolarisation et langue d'origine?**

Pour obtenir un score de progression moyenne du développement total, les moyennes modélisées des évaluations pour tous les textes écrits par les bilingues lusophones à T1 ont été soustraites de celle obtenues à T3. Idem pour les enfants des groupes de comparaison. Ensuite, ces deux valeurs ont été soustraites l'une à l'autre pour obtenir la différence moyenne. Ce calcul a été fait pour chaque langue séparément.

Langue des textes	Progression moyenne bilingues	Progression moyenne comparaison	Différence moyenne	Probabilité	Quantile 2,5%	Quantile 97,5%
Allemand	0.95	1.12	0.17	85%	-0.16	0.51
Français	0.98	1.41	0.42	99%	0.09	0.76
Portugais	0.73	1.16	0.43	100%	0.11	0.75

Fig. 6. Résultats statistiques concernant la progression entre la première et troisième récolte de données en réponse à la question 1.

Les résultats de la fig. 6 se lisent comme suit, à l'exemple de la deuxième ligne: la progression moyenne pour les bilingues portugais-français en français est de 0.98 points tandis qu'elle est de 1.41 pour le groupe de comparaison en Suisse romande. La différence moyenne entre ces progressions est de 0.42 en faveur du groupe de comparaison. Selon le modèle, il y a environ 99% de chance qu'il existe une différence en termes de vitesse du développement pour les textes écrits en français, à l'avantage du groupe de comparaison. Il y a 95% de chance pour que la taille de la différence soit entre 0.09 et 0.76 points.

L'image globale montre que les scores augmentent plus rapidement pour les élèves des groupes de comparaison que pour les élèves bilingues lusophones pour le français et le portugais. Les résultats pour l'allemand ne permettent pas d'affirmations claires dans ce sens<sup>10</sup> (voir aussi Fig. 5).

### Q2. Les différences observées dépendent-elles du genre textuel?

Pour des raisons de place et puisqu'il ne s'agit pas d'une question développementale, nous considérons uniquement les évaluations de la deuxième récolte. Les moyennes modélisées des évaluations ont été analysées séparément pour les textes narratifs et argumentatifs, pour chaque groupe d'élèves et chaque langue. Pour chaque langue et chaque type de texte, nous avons calculé la différence entre les résultats du groupe de comparaison et le groupe bilingue lusophone. Ensuite, les valeurs obtenues pour les textes argumentatifs et narratifs ont été soustraites l'une à l'autre pour obtenir la différence moyenne pour chaque langue.

Langue des textes	Différence - argumentatif	Différence - narratif	Différence moyenne	Probabilité	Quantile 2,5%	Quantile 97,5%
Allemand	0.77	0.35	0.43	98%	0	0.83
Français	0.56	0.34	0.22	85%	-0.2	0.62
Portugais	2.02	1.16	0.86	100%	0.42	1.29

Fig. 7. Résultats statistiques concernant les différences entre les groupes d'élèves en réponse à la question 2.

La fig. 7 est à interpréter comme suit, pour la première ligne par exemple: la différence moyenne entre le groupe de comparaison et les bilingues portugais-allemand pour les textes argumentatifs en allemand est de 0.77 points, tandis qu'elle est de 0.35 points pour les textes narratifs. La différence moyenne entre ces différences est de 0.43 points (avec erreur d'arrondissement). Selon le modèle, il y a environ 98% de chance pour que la différence entre les bilingues portugais-allemand et les élèves de comparaison en Suisse allemande soit plus

<sup>10</sup> Nous prenons la limite plus ou moins arbitraire de 95% de probabilité pour considérer une différence entre les groupes comme manifeste.

grande pour les scores des textes argumentatifs que pour les récits narratifs. Il y a 95% de chance que la taille de cette différence soit entre 0 et 0.83 points.

Ainsi, la différence entre les groupes d'élèves est plus grande pour les textes argumentatifs que narratifs, écrits en allemand et en portugais. Les résultats pour le français ne permettent pas de tirer des conclusions claires (voir aussi Fig. 5).

*Q3. Les enfants issus de la migration portugaise se différencient-ils plus dans leur langue d'origine ou dans leur langue de scolarisation par rapport aux groupes de comparaison?*

Nous nous limitons ici aux performances finales, sans différencier les régions linguistiques en Suisse. Nous considérons la moyenne modélisée des évaluations pour les textes argumentatifs et narratifs des élèves bilingues à T3, ainsi que pour les textes correspondants des élèves de comparaison.

La différence moyenne entre le groupe de comparaison et les bilingues lusophones pour les textes en langue de scolarisation (allemand et français) à T3 est de 0.66 points, tandis qu'elle est de 1.67 points pour les textes en portugais. La différence moyenne entre ces différences est alors de 1.02 points. Selon le modèle, il y a 100% de chance pour que la différence entre les bilingues portugais et les élèves de comparaison à T3 soit plus grande pour les textes en portugais que pour les textes en langue de scolarisation. Il y a 95% de chance que la taille de cette différence soit entre 0.57 et 1.45 points.

*Q4. Les différences observées en langue de scolarisation entre les élèves bilingues lusophones et les élèves des groupes de comparaison sont-elles plus grandes pour les productions en allemand ou en français?*

Nous nous intéressons ici d'abord à la première récolte de données, puisque c'est au début de la scolarité qu'il pourrait y avoir le plus de différences. Sur la base des moyennes modélisées pour les deux types de textes ensemble à T1, nous avons calculé la différence entre les textes en allemand respectivement en français, écrits par le groupe de comparaison et le groupe bilingue portugais.

La différence moyenne entre le groupe de comparaison et les bilingues lusophones pour les textes en allemand à T1 est de 0.41 points, tandis qu'elle est de 0.31 pour les textes en français. Ceci équivaut à une différence moyenne de 0.1 points entre ces différences.

Selon le modèle, il y a environ 67% de chance pour que les différences au sein des groupes soient plus grandes pour les textes en allemand que pour les textes en français et il y a 95% de chance pour que la taille de la différence soit entre -0.37 et 0.58 points.

Par précaution, nous avons également regardé ce qu'il se passe à la troisième récolte de données. Là, nous avons obtenu un résultat inverse, mais également peu concluant au niveau des probabilités.

## 5. Conclusions et discussion

Malgré les précautions méthodologiques, les évaluateurs ont certainement été influencés par d'autres facteurs textuels que le vocabulaire, tels que la longueur des textes (Bonvin & Lambelet 2019). D'ailleurs, celle-ci augmente au fil du temps, tout comme les scores des évaluations (Vanhove et al. 2019a). De plus, la répartition des profils des évaluateurs, dont 8 à 10% sont des linguistes et la majorité des universitaires, ne correspond pas à celle de la population en général. Par conséquent, les évaluations récoltées devraient sensiblement différer de la richesse du vocabulaire perçue par tout un chacun. Elles pourraient se situer quelque part entre des évaluations intuitives/communes et des évaluations expertes/scolaires. De tels biais sont inévitables lorsqu'on cherche à capturer la perception humaine de manière quantitative.

Des différences probables concernant l'utilisation du vocabulaire entre les groupes d'élèves ont été mises en évidence par cette étude dans une perspective longitudinale. Cela, même si les évaluateurs n'étaient pas entraînés et qu'ils n'ont pas reçu de définition de la richesse du vocabulaire, ni d'informations précises sur les profils des élèves. Pour chaque groupe d'élèves et genre de texte, un développement positif de la richesse du vocabulaire, telle que perçue par les évaluateurs, a été observé. Ce résultat s'harmonise avec ceux obtenus au moyen d'algorithmes de diversité lexicale (MTLD, mais aussi Guiraud)<sup>11</sup> (Bonvin et al. 2018), ainsi qu'avec les résultats obtenus dans d'autres études du projet HELASCOT (Desgrippes et al. 2017; Pestana et al. 2017). La description des moyennes effectives a permis de constater des scores moins élevés dans les groupes cibles par rapport aux trois groupes de comparaison.

Les analyses statistiques ont toutefois apporté des nuances à ces résultats bruts. Nous avons constaté un développement plus rapide des groupes de comparaison par rapport aux groupes cibles pour les textes en français et en portugais. Cette différence de vitesse du développement était prévisible pour le portugais, puisque les enfants émigrés reçoivent moins d'input dans cet idiome que leurs pairs au Portugal. Qui plus est, la différence entre les scores obtenus par les élèves bilingues lusophones et les élèves des groupes de comparaison est plus élevée pour la langue d'origine que pour les langues de scolarité.

Ce résultat doit être interprété dans son contexte. Les tâches traitaient de thèmes quotidiens que les enfants abordent sûrement dans leurs deux langues, mais l'exercice de relater et d'argumenter par écrit est typiquement scolaire. Par conséquent, cette activité est probablement moins habituelle en langue d'origine. La question se pose de savoir si les différences en ce qui concerne le vocabulaire productif oral et le vocabulaire réceptif en portugais pourraient être

---

<sup>11</sup> La formule de Guiraud correspond au nombre de vocables (*type* en anglais) divisé par la racine carrée du nombre d'occurrences (*token* en anglais) (cf. Guiraud 1954).

moins importantes que celles observées à propos de l'utilisation écrite du vocabulaire. De plus, les variables sociolinguistiques des groupes portugais diffèrent, ce qui pourrait influencer les résultats. En effet, les élèves du Portugal proviennent de familles avec un statut socio-économique plus élevé que les élèves portugais en Suisse (Desgrippes & Lambelet 2017).

Pourquoi trouve-t-on des différences de vitesse de développement pour le français et moins clairement pour l'allemand? L'argument de la proximité typologique entre le français et le portugais, autrement dit que les élèves lusophones de Suisse allemande rattraperaient un retard, n'est pas soutenable ici puisque les analyses de la quatrième question n'ont pas montré d'effet de la proximité langagière. Une hypothèse explicative est l'existence de différences entre les groupes de comparaison suisses. D'après des analyses ad hoc, la vitesse du développement de la richesse du vocabulaire tend à être plus rapide dans les groupes de comparaison en Suisse romande qu'en Suisse allemande (avec une différence moyenne de progression de 0.29 points et une probabilité d'environ 93% pour qu'il y ait une différence entre les groupes de comparaison à l'avantage du groupe suisse romand). Néanmoins, il est méthodologiquement et conceptuellement contestable de comparer directement les résultats des différentes langues entre elles. Des pistes d'interprétations acceptables sont alors difficiles à trouver.

Finalement, le genre de texte s'est révélé décisif pour l'allemand et le portugais, car les différences entre les groupes sont plus grandes pour les textes argumentatifs que pour les textes narratifs, du moins à la deuxième récolte de données. Cette tendance des élèves lusophones en Suisse allemande à obtenir des scores plus bas pour l'argumentation se retrouvent également dans l'étude des compétences générales de rédaction basée sur les mêmes textes (Desgrippes et al. 2017).

Dans une perspective didactique, les résultats concernant les différentes études sur ces textes suggèrent de regarder de plus près les compositions argumentatives pour les élèves bilingues parlant portugais et (suisse-) allemand. Ne s'agissant pas d'une recherche d'ordre didactique, nous limitons la discussion aux compétences pouvant partiellement expliquer les différences entre les groupes. Selon Vanhove et al. (2019a), l'indice de Guiraud représente plutôt bien les évaluations humaines dans les trois langues étudiées. Cette formule capture la diversité lexicale (soit le taux de non-répétition), mais son résultat corrèle fortement avec la longueur des textes (Vanhove et al. 2019a: 320). Ainsi, non seulement les textes empreints d'un vocabulaire varié, mais également les textes plus longs ont obtenu de meilleurs scores.

Mais de quel vocabulaire parle-t-on? Dans un volet qualitatif de ce projet, nous avons demandé à sept évaluateurs non entraînés, mais avec un niveau d'éducation universitaire, d'évaluer un petit nombre de textes de ce corpus en pensant à haute voix. Les répétitions de mêmes connecteurs dans certains

textes sont ressorties comme l'une des caractéristiques attribuées à un vocabulaire moins riche (Bonvin & Lambelet 2019). Ce constat suggère qu'à côté d'une utilisation variée et adéquate des mots de contenu, une maîtrise de l'emploi des mots fonctionnels et de la cohésion textuelle améliore la qualité lexicale perçue dans les rédactions.

Ces conclusions ne sont pas généralisables au-delà du groupe cible, car les caractéristiques du développement de la richesse lexicale d'autres bilingues pourraient varier. En effet, le niveau d'études des parents, le niveau linguistique des parents, et le temps de résidence en Suisse n'ont pas été modélisés dans cette recherche. Nous ne savons donc pas vraiment si les différences observées chez les élèves sont un effet du bilinguisme lui-même ou d'autres facteurs, tels que les pratiques de littéracie en dehors de l'école.

## BIBLIOGRAPHIE

- Berthele, R. & Lambelet, A. (2017). *Heritage and School Language Literacy Development in Migrant Children: Interdependence or independence?* Bristol: Multilingual Matters.
- Bialystok, E., Luk, G., Peets, K. F. & Yang, S. (2010). Receptive vocabulary differences in monlingual and bilingual children. *Bilingualism: Language and Cognition*, 13, 525-531.
- Bonvin, A. & Lambelet, A. (2019). Exploration empirique de la richesse lexicale: la perception humaine. *Linguistik online*, 100(7), 65-94.
- Bonvin, A., Vanhove, J., Berthele, R. & Lambelet, A. (2018). Die Entwicklung von produktiven lexikalischen Kompetenzen bei Schüler(innen) mit portugiesischem Migrationshintergrund in der Schweiz. *Zeitschrift für Interkulturellen Fremdsprachenunterricht*, 23(1).
- Bürkner, P. C. (2017). brms: An R package for Bayesian multilevel models using Stan. *Journal of Statistical Software*, 80(1), 1-28.
- De Houwer, A., Bornstein, M. H. & Putnick, D. L. (2013). A bilingual–monolingual comparison of young children's vocabulary size: Evidence from comprehension and production. *Applied Psycholinguistics*, 35(6), 1189-1211.
- Desgrippes, M. & Lambelet, A. (2017). On the sociolinguistic embedding of Portuguese heritage language speakers in Switzerland: Socio-economic status and home literacy environment (HELASCOT Project). In R. Berthele & A. Lambelet (éds.), *Heritage and school language literacy development in migrant children: Interdependence or independence?* (pp. 35-58). Bristol: Multilingual Matters.
- Desgrippes, M., Lambelet, A. & Vanhove, J. (2017). The development of argumentative and narrative writing skills in Portuguese heritage speakers in Switzerland (HELASCOT Project). In R. Berthele & A. Lambelet (éds.), *Heritage and school language literacy development in migrant children: Interdependence or independence?* (pp. 83-96). Bristol: Multilingual Matters.
- Fibbi, R., Bolzman, C., Fernandez, A., Gomensoro, A., Kaya, B., Maire, C., Merçay, C., Pecoraro, M. & Wanner, P. (2010). *Les Portugais en Suisse*. Bern-Wabern: Office fédéral des migrations. <https://www.sem.admin.ch/dam/data/sem/publiservice/publikationen/diaspora/diasporastudie-portugal-d.pdf> (consulté le 25.07.2019).
- Gharibi, K. & Boers, F. (2017). Influential factors in lexical richness of young heritage speakers' family language: Iranians in New Zealand. *International Journal of Bilingualism*, 23(2), 381-399.
- Guiraud, P. (1954). *Les caractères statistiques du vocabulaire. Essai de méthodologie*. Paris: Presses Universitaires de France.

- Hoff, E., Core, C., Place, S., Rumiche, R., Señor, M. & Parra, M. (2012). Dual language exposure and early bilingual development. *Journal of child language*, 39(1), 1-27.
- Klassert, A. (2011). *Lexikalische Fähigkeiten bilingualer Kinder mit Migrationshintergrund. Eine Studie zum Benennen von Nomen und Verben im Russischen und Deutschen*. Marburg: Philipps-Universität Marburg. <http://archiv.ub.uni-marburg.de/diss/z2011/0621/> (consulté le 20.08.2019)
- Lambelet, A., Bonvin, A. & Pestana, C. (2018). "Une fois, je suis été quelque part avec ma classe". Aperçu du développement des compétences textuelle et lexicale d'enfants plurilingues. In A. Blechschmidt & U. Schräpler (éds), *Mehrsprachigkeit in Sprachtherapie und Unterricht. Treffpunkt Logöpädie 5* (pp. 103-114). Basel: Schwabe.
- McCarthy, P. M. & Jarvis, S. (2010). MTL-D, voc-D, and HD-D: A validation study of sophisticated approaches to lexical diversity assessment. *Behavior Research Methods*, 42(2), 381-392.
- Office fédéral de la statistique. (s.d.). Population de nationalité étrangère. <https://www.bfs.admin.ch/bfs/fr/home/statistiques/population/migration-integration/nationalite-etrangere.html>.
- Pestana, C., Lambelet, A. & Vanhove, J. (2017). Reading comprehension development in Portuguese heritage speakers in Switzerland (project HELASCOT). In R. Berthele & A. Lambelet (éds.), *Heritage and school language literacy development in migrant children: Interdependence or independence?* (pp. 59-83). Bristol: Multilingual Matters.
- Unsworth, S. (2016). Quantity and quality of language input in bilingual language development. In E. Nicoladis & S. Montanari (éds), *Lifespan perspectives on bilingualism* (pp. 136-196). Berlin: De Gruyter.
- Vanhove, J. (2015). Analyzing randomized controlled interventions: Three notes for applied linguists. *Studies in Second Language Learning and Teaching*, 5(1), 135-152.
- Vanhove, J. (2018). Using text-based indices to predict human ratings of the lexical richness of short French, German, and Portuguese texts written by children (technical report). <https://osf.io/vw4pc/> (consulté le 20.08.2019).
- Vanhove, J., Bonvin, A., Lambelet, A. & Berthele, R. (2019a). Predicting perceptions of the lexical richness of short French, German, and Portuguese texts. *Journal of Writing Research*, 10(3), 499-525.
- Vanhove, J., Bonvin, A., Berthele, R. & Lambelet, A. (2019b). *The lexical richness of short French, German and Portuguese texts written by children*. (consulté le 06.01.2020).