

# Les machinistes de la traduction

Coca, condor, puma, lama, pampa : même le français a emprunté au quechua. Pourtant, la diffusion de cette langue sud-américaine s'amenuise. Par Martin Bieri

Le quechua est une famille de langues autochtones sud-américaines, parlées aujourd'hui par quelque dix millions de personnes dans les Andes. « A long terme, le quechua est menacé, affirme Martin Volk, professeur à l'Institut de linguistique computationnelle de l'Université de Zurich. C'est un idiome peu prestigieux, celui des classes rurales défavorisées. » Beaucoup d'enfants grandissent bilingues : le quechua est la langue de leurs parents et de leurs grands-parents, l'espagnol celle des médias, de l'enseignement et de l'ascension sociale. Martin Volk et son équipe poursuivent l'objectif suivant : rendre plus perméables les frontières entre les deux univers linguistiques et soutenir ainsi l'idiome indigène. Pour ce faire, ils mettent au point un programme de traduction automatique de l'espagnol en quechua. Il se présentera sous la forme d'un site Internet qui devrait être aussi confortable à utiliser que Google Translate.

## Variante la mieux documentée

Le quechua ne s'écrit que depuis la conquête de l'Amérique latine par les Espagnols, et aujourd'hui encore, il n'existe qu'une littérature limitée, car aucune de ses variantes n'a pu s'imposer comme langue standard. L'équipe de l'Université de Zurich a choisi le quechua de la province péruvienne de Cuzco étant donné qu'il s'agit de la variante la mieux documentée.

Les systèmes de traduction automatique sont souvent basés sur des méthodes statistiques. Ils déterminent des séquences interlangues de mots en fonction de leur fréquence et comparent pour ce faire deux grands ensembles de textes. D'autres systèmes, fondés sur des règles, analysent les

structures grammaticales, identifient des schémas et les représentent sous la forme d'arbres syntaxiques, qui sont alors transférés de la langue source à la langue cible. Pour la traduction de l'espagnol en quechua, seul un système à base de règles entre en ligne de compte, faute de textes parallèles dans les deux langues. Cependant, l'équipe de Zurich intègre après coup la statistique comme instrument de contrôle, combinant ainsi les deux systèmes. Par ailleurs, la paire linguistique espagnol-quechua est comparée à la paire espagnol-allemand, typologiquement plus similaire, afin de prédire l'amélioration de la qualité de la traduction si la comparabilité statistique devait augmenter. Plus il y a de textes, plus le programme s'améliore. Les linguistes zurichois collaborent étroitement avec des scientifiques de Cuzco auxquels le système

sera remis pour qu'ils continuent à le développer.

Le projet comporte un autre produit important : un ensemble de textes qui seront traduits par des êtres humains et mis aussi à disposition sur Internet. « Nous montrons la langue en train d'être utilisée », explique Martin Volk. Un mot en particulier n'est pas seulement traduit mais également affiché avec son paradigme flexionnel. En termes de langage et de traduction, l'ordinateur s'approche ainsi de la compétence humaine, même si cette dernière reste bien supérieure à celle de la machine. Le chercheur ne croit pas, d'ailleurs, que cette donne changera bientôt. Mais il est convaincu que la technologie linguistique est susceptible de contribuer à renforcer une langue, en la combinant avec d'autres idiomes.



Bilinguisme dans la ville péruvienne de Cuzco. Le nom de l'hôtel est écrit en espagnol et en quechua. Photo : Martin Volk