



6e conférence conjointe Journées d'Études sur la Parole (JEP, 33e édition), Traitement Automatique des Langues Naturelles (TALN, 27e édition), Rencontre des Étudiants Chercheurs en Informatique pour le Traitement Automatique des Langues (RÉCITAL, 22e édition) (JEP-TALN-RÉCITAL) ¹

Actes de la 6e conférence conjointe Journées d'Études sur la Parole (JEP, 33e édition), Traitement Automatique des Langues Naturelles (TALN, 27e édition), Rencontre des Étudiants Chercheurs en Informatique pour le Traitement Automatique des Langues (RÉCITAL, 22e édition).

2e atelier Éthique et TRaitement Automatique des Langues (ETeRNAL)

Gilles Adda, Maxime Amblard, Karèn Fort (Éds.)

Nancy, France, 08-19 juin 2020

1. <https://jep-taln2020.loria.fr/>

Crédits : L'image utilisée en bannière est une photographie du vitrail « Roses et Mouettes », visible dans la maison Bergeret à Nancy. La [photographie](#) a été prise par Alexandre Prevot, diffusée sur flickr sous la licence [CC-BY-SA 2.0](#).

Le logo de la conférence a été créé par Annabelle Arena.

©2020 ATALA et AFCP

Avec le soutien de



Message des présidents de l’AFCP et de l’ATALA

En ce printemps 2020, et les circonstances exceptionnelles qui l’accompagnent, c’est avec une émotion toute particulière que nous vous convions à la 6e édition conjointe des Journées d’Études sur la Parole (JEP), de la Conférence sur le Traitement Automatique des Langues Naturelles (TALN) et des Rencontres des Étudiants Chercheurs en Informatique pour le Traitement Automatique des Langues (RECITAL). Après une première édition commune en 2002 (à Nancy, déjà!), et une expérience renouvelée avec succès en 2004, c’est désormais tous les quatre ans (Avignon 2008, Grenoble 2012) que se répète cet événement commun, attendu de pied ferme par les membres des deux communautés scientifiques voisines.

Cette édition 2020 est exceptionnelle, puisque dans le cadre des mesures sanitaires liées à la pandémie mondiale de COVID-19 (confinement strict, puis déconfinement progressif), la conférence ne peut avoir lieu à Nancy comme initialement prévu, mais se déroule à distance, sous forme virtuelle, soutenue par les technologies de l’information et de la communication. Nous remercions ici chaleureusement les organisateurs, Christophe Benzitoun, Chloé Braud, Laurine Huber, David Langlois, Slim Ouni et Sylvain Pogodalla, qui ont dû faire preuve de souplesse, d’inventivité, de détermination, de puissance de travail, et de tant d’autres qualités encore, afin de maintenir la conférence dans ces circonstances, en proposant un format inédit. Grâce aux différentes solutions mises en œuvre dans un délai court, la publication des communications scientifiques est assurée, structurée, et les échanges scientifiques sont favorisés, même à distance.

Bien entendu, nous regrettons tous que cette réunion JEP-TALN-RECITAL ne permette pas, comme ses prédécesseurs, de nouer ou renforcer les liens sociaux entre les différents membres de nos communautés respectives – chercheurs, jeunes et moins jeunes, académiques et industriels, professionnels et étudiants – autour d’une passionnante discussion scientifique ou d’un mémorable événement social. . . Notre conviction est qu’il est indispensable de maintenir à l’avenir de tels lieux d’échanges dans le domaine francophone, afin bien sûr de permettre aux jeunes diplômés de venir présenter leurs travaux et poser leurs questions sans la barrière de la langue, mais aussi de dynamiser nos communautés, de renforcer les échanges et les collaborations, et d’ouvrir la discussion autour des enjeux d’avenir, qui questionnent plus que jamais la place de la science et des scientifiques dans notre société.

Lors de la précédente édition, nous nous interrogeons sur les phénomènes et tendances liés à l’apprentissage profond et sur leurs impacts sur les domaines de la Parole et du TAL. Force est de constater que l’engouement pour ces approches dans nos domaines a permis un retour sur le devant de la scène des domaines liés à l’Intelligence Artificielle, animant parfois un débat tant philosophique que technique sur la place de la machine dans la société, notamment à travers le questionnement sur la vie privée de l’utilisateur. Ces questionnements impactent tant la Parole que le TAL, d’une part sur la place de la gestion des données, d’autre part sur les modèles eux-mêmes. Malgré ces questionnements, nous constatons que les acquis et les expertises perdurent, et les nouvelles approches liées à l’apprentissage profond ont permis un rapprochement des domaines de la Parole et du TAL, sans les dénaturer, à la manière des conférences JEP-TALN-RECITAL qui créent un espace plus grand d’échange et d’enrichissement réciproques.

Nous terminons ces quelques mots d’ouverture en remerciant l’ensemble des personnes qui ont rendu possible cet événement qui restera, nous l’espérons, riche et passionnant, malgré les circonstances. L’ATALA et l’AFCP tiennent tout d’abord à réitérer leurs remerciements aux organisateurs des JEP, de TALN et de RECITAL, qui sont parvenus à maintenir le cap à travers vents et marées. Nos remerciements vont également à l’ensemble des membres des comités de programme, dont le travail et l’implication ont permis de garantir la qualité et la cohérence du programme finalement retenu. Un grand merci aux relecteurs pour le temps et le soin qu’ils ont dédiés à ce travail anonyme et indispensable. Ils se reflètent dans la qualité des soumissions que chacun pourra découvrir sur le site de la conférence.

En conclusion, cette 6e édition conjointe JEP-TALN-RECITAL est exceptionnelle parce qu’elle se tient dans un contexte de crise généralisée — crise sanitaire, économique, voire sociale et politique. Mais nous

formons le vœu qu'elle reste également dans les annales pour la qualité des échanges scientifiques qu'elle aura suscités, et pour le message envoyé à nos communautés scientifiques et à la société dans son ensemble, un message de détermination et de confiance en l'avenir, où la science et les nouvelles technologies restent au service de l'humain.

Véronique Delvaux, présidente de l'Association Francophone de la Communication Parlée
Christophe Servan, président de l'Association pour le Traitement Automatique des Langues

Préface

L’atelier ETeRNAL 2 — Éthique et TRaitemeNt Automatique des Langues — fait suite à une première édition qui s’est tenue à TALN en 2015. Il est soutenu par le projet OLKi, projet de recherche académique, financé par l’I-SITE Lorraine Université d’Excellence (PIA3). Les questions que nous souhaitons voir aborder concernent aussi bien les apports du TAL à l’éthique que nos responsabilités en tant que producteurs d’outils. Nous ne pouvons en effet pas faire semblant de ne pas savoir que ceux-ci rendent possibles des abus, des actes criminels, des violations des droits individuels.

Le Traitement Automatique des Langues et de la parole (TALP) est au cœur des enjeux éthiques du XXI^e siècle : accès aux données personnelles et protection de la vie privée, traitement (et croisement) des masses de données, délocalisation et production participative sont autant de problématiques qui sont en lien direct avec les applications que nous développons.

L’atelier est confronté comme tout le monde à la crise du Covid-19. Nous avons décidé de le maintenir et de faire vivre la thématique en utilisant d’autres modalités, avec des temps majoritairement asynchrones (présentation invitée, commentaires et réponses sur les articles), et des moments synchrones (réponses à des questions et expérience collaborative).

L’atelier souhaite fournir un espace de réflexion ouvert et interactif. Il rassemble cinq articles. Deux d’entre eux s’intéressent à la notion de biais et comment les identifier. Les trois autres ouvrent sur des problématiques moins directes pour notre champ disciplinaire soit parce que nos pratiques sont peu développées dans ce sens, par exemple avec la réplique d’expériences, soit parce que les questions sont émergentes, comme l’article sur les contenus que l’on retrouve sur le web. La démultiplication des outils et ressources mis à disposition nous interroge tant sur la possibilité de disposer des résultats que sur les contenus qu’on y trouve. Est-ce que les résultats de la science sont accessibles ? Est-ce que tout le web peut être considéré comme à disposition ? Le dernier article donne une perspective historique à une question primordiale, l’utilisation des résultats de la reconnaissance de la parole dans le monde judiciaire. Avons-nous réussi à faire entendre les limites de notre production scientifique ?

L’atelier est également une opportunité pour l’organisation d’une expérience collective sur l’évaluation des biais de perception. À partir d’une expérience accessible en ligne, Aurélie Névéal, CR CNRS au Limsi, a accepté d’organiser la passation collective des tests et de rendre accessible les résultats. Il ne s’agit pas tant de vérifier que nous sommes biaisés, nous le savons tous, mais de mesurer à quel point nous le sommes. L’expérience porte sur la mise en avant de processus inconscients généralement nourris par les clichés véhiculés par les stéréotypes. L’objectif est de faire prendre conscience de l’existence de ces biais au sein de notre communauté. L’expérience portera plus particulièrement sur la prise en compte du genre dans le contexte scientifique.

Par ailleurs, l’atelier a souhaité inviter Dirk Hovy, associate professor d’informatique à l’Université Bocconi à Milan. Dirk Hovy travaille sur les liens entre langue, société et apprentissage automatique. C’est en particulier un spécialiste des questions d’éthique pour le TALP. Dans son exposé, il reviendra sur l’influence prise par les systèmes automatiques depuis l’utilisation massive des réseaux de neurones. Ces outils restent massivement considérés comme des boîtes noires, sans que les biais qu’ils créent ou amplifient soient réellement pris en compte. Son exposé détaille le nouveau rôle dont les scientifiques du TALP ont hérité et qu’ils doivent maintenant tenir dans toute sa complexité.

Au travers de ces différentes modalités, articles, exposé et expérience collective, l’atelier ETeRNAL cherche à aborder la diversité de ces questions complexes, trop souvent mise de côté par la communauté scientifique pour des raisons compréhensibles.

Gilles Adda, Maxime Amblard et Karën Fort

Table des matières

Pratiques d'évaluation en ASR et biais de performance	1
<i>Mahault Garnerin, Solange Rossato, Laurent Besacier</i>	
Comment arpenter sans mètre : les scores de résolution de chaînes de coréférences sont-ils des métriques ?	10
<i>Adam Lion-Bouton, Loïc Grobol, Jean-Yves Antoine, Sylvie Billot, Anaïs Lefevvre-Halftermeyer</i>	
Que recèlent les données textuelles issues du web ?	19
<i>Adrien Barbaresi, Gaël Lejeune</i>	
Répliquer et étendre pour l'alsacien "Étiquetage en parties du discours de langues peu dotées par spécialisation des plongements lexicaux"	29
<i>Alice Millour, Karën Fort, Pierre Magistry</i>	
1990-2020 : retours sur 30 ans d'échanges autour de l'identification de voix en milieu judiciaire	38
<i>Jean-Francois Bonastre</i>	