



HAL
open science

Annotateurs volontaires investis et éthique de l'annotation de lettres de suicidés

Kevin Bretonnel Cohen, John P. Pestian,, Karën Fort

► To cite this version:

Kevin Bretonnel Cohen, John P. Pestian,, Karën Fort. Annotateurs volontaires investis et éthique de l'annotation de lettres de suicidés. ETeRNAL (Ethique et Traitement Automatique des Langues), Jun 2015, Caen, France. hal-01159052

HAL Id: hal-01159052

<https://inria.hal.science/hal-01159052v1>

Submitted on 2 Jun 2015

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Annotateurs volontaires investis et éthique de l'annotation de lettres de suicidés

K. Bretonnel Cohen¹ John P. Pestian² Karën Fort³

(1) University of Colorado, Denver

(2) Cincinnati Children's Hospital Medical Center, University of Cincinnati, Cincinnati

(3) Université Paris-Sorbonne / STIH

kevin.cohen@gmail.com, john.pestian@cchmc.org, karen.fort@paris-sorbonne.fr

Résumé. Cet article présente une perspective éthique sur le projet décrit dans (Pestian *et al.*, 2012b). La campagne d'annotation en question a visé à produire un corpus de lettres de suicidés annotées en émotions. Les annotateurs étaient soit des parents ou des amis de suicidés, soit des professionnels de la santé mentale. Nous appelons ces annotateurs bénévoles, volontaires pour faire avancer la recherche, des *volontaires investis*. Ce projet soulève un certain nombre de questions éthiques, notamment en ce qui concerne le rôle de l'empathie des annotateurs, les effets possibles sur ceux-ci et les utilisations potentielles des résultats obtenus. Nous concluons par une analyse du corpus du point de vue de la *Charte Éthique et Big Data*.

Abstract.

Annotating suicide notes : ethical issues at a glance.

According to the World Health Organization, 800,000 people die of suicide every year. About 20% of them leave a written message. This paper discusses a corpus of such messages. The corpus was annotated with reference to the emotions expressed in the notes. The annotators were family or friends of someone who had died by suicide, or mental health professionals. We refer to these non-coercively and altruistically motivated annotators as *vested volunteers*. A number of ethical issues are explored with this task and group of annotators, including the role of empathy, possible effects on the annotators, and the uses that might be made of the products of the annotation project. We conclude considering the project from the point of view of the *Ethics and Big Data Charter*.

Mots-clés : lettres de suicidés, éthique, annotation, myriadisation, corpus.

Keywords: suicide notes, ethics, annotation, crowdsourcing, corpus.

1 Introduction

Selon l'Organisation Mondiale de la Santé (OMS), chaque année dans le monde, plus de 800 000 personnes se donnent la mort¹. Environ 20 % d'entre elles laissent un message écrit (on peut citer par exemple, (Volant, 1990) 664 sur 3 450 et (Fédération française de psychiatrie, 2001), 200 sur 621). On parle en anglais de *suicide note*. Nous utiliserons ici le terme de *lettre*, reprenant à notre compte la remarque à ce sujet d'Éric Volant (Volant, 1990) :

Elles sont bien davantage qu'un simple mot qu'on laisse traîner [...]. Même s'il ne s'agit que d'un griffonnage, il a un but défini pour son auteur, et mérite donc pleinement le statut de lettre.

Un certain nombre de chercheurs ont étudié différents aspects de ces lettres, dans le but d'aider à la prévention du suicide. L'analyse que nous présentons ici concerne un projet de recherche de ce type, mené aux États-Unis, qui a donné lieu à la constitution et à l'annotation en émotions d'un corpus de lettres de suicidés. Ce projet est détaillé dans (Pestian *et al.*, 2012b).

Les lettres de ce corpus ont été annotées par des volontaires qui ont eu une expérience concrète du suicide, soit parce qu'un membre de leur famille ou un de leurs amis s'est suicidé, soit parce qu'ils sont des professionnels de la santé mentale.

Ceux-ci ont participé au projet bénévolement, sans contrainte, pour faire avancer les travaux des scientifiques dans ce domaine. Pour rendre compte à la fois de cette volonté et de leur rapport personnel au suicide, nous les appelons « volontaires

1. Voir <http://www.who.int/mediacentre/news/releases/2014/suicide-prevention-report/fr/>.

investis » (*vested volunteers*).

Ce type de projet pose un certain nombre de questions éthiques, que l'appel à des volontaires investis rend encore plus saillantes. Il en va ainsi du rôle de l'empathie de l'annotateur, des effets potentiels sur celui-ci, des sources de biais et des utilisations possibles des résultats de l'étude.

1.1 Une foule (limitée) de volontaires

Le terme anglais *crowdsourcing* est défini par le dictionnaire en ligne Merriam-Webster comme « la pratique consistant à obtenir le service désiré, qu'il s'agisse d'une idée ou de contenu, en sollicitant les contributions d'un grand groupe de personnes, en particulier de la communauté des internautes plutôt que des employés ou fournisseurs traditionnels² ». Ce mot valise très expressif, formé de foule (*crowd*) et de délocalisation (*outsourcing*), se délave à la traduction. Nous le traduirons ici par myriadisation³.

Ces dernières années, la myriadisation est devenue une méthode populaire de construction de ressources langagières, en particulier dans le cadre de la recherche en Traitement Automatique des Langues (TAL). Cet essor n'a pas été sans poser des questions éthiques. Ainsi, (Fort *et al.*, 2011) présente une critique détaillée de l'utilisation d'Amazon Mechanical Turk, une plate-forme de travail parcellisé qui permet l'exploitation de travailleurs de pays en développement. Les conditions de travail des *Turkers* ont d'ailleurs fait l'objet d'études sur le terrain qui confirment cette exploitation (Gupta *et al.*, 2014).

D'autres méthodes de myriadisation, plus satisfaisantes éthiquement, se sont développées en parallèle. Parmi celles-ci, les jeux ayant un but (*Games With A Purpose*) proposent de produire des ressources en jouant. Le premier de ces jeux pour les ressources langagières est à notre connaissance JeuxDeMots (Lafourcade & Joubert, 2008), qui crée un réseau lexical en français. *Phrase Detectives* (Chamberlain *et al.*, 2008) a quant à lui été utilisé pour annoter des anaphores dans un corpus en anglais. Plus récemment, *ZombiLingo* (Fort *et al.*, 2014) permet l'annotation en syntaxe de dépendances d'un corpus en français.

Le point commun entre JeuxDeMots, ZombiLingo et d'autres formes de myriadisation comme Wikipédia ou le Projet Gutenberg est le bénévolat. Les participants savent qu'ils ne seront pas rémunérés⁴. Ils sont motivés par l'aspect ludique du jeu ou par l'envie de participer à un projet de bien commun ou de recherche. Dans ce dernier cas, on parle alors de sciences participatives. Un exemple de projet de science participative sans aspect particulièrement ludique est *Vigie Nature* développé au Muséum National d'Histoire Naturelle (Couvét *et al.*, 2011).

À la différence de ces projets, la campagne d'annotation en discussion ici n'a rien de plaisant. La motivation des participants est donc simplement d'aider à faire avancer la recherche sur le sujet du suicide. Une autre différence est que l'appel à participation a été limité à certaines communautés (voir section 2.2) et n'a pas été totalement ouvert.

1.2 Une annotation discriminante

Les lettres de suicidés ont fait l'objet d'un nombre de recherches considérable (Shneidman & Farberow, 1957b; Osgood & Walker, 1959; Tuckman *et al.*, 1959; Schneidman, 1981; Leenaars, 1988; Baume *et al.*, 1997; Brevard *et al.*, 1990; Ho *et al.*, 1998; O'Connor & Leenaars, 2004; Olson, 2005).

Le domaine tel que nous le connaissons aujourd'hui a vu le jour lorsque Edwin Shneidman a découvert un gisement de lettres de suicidés dans les bureaux du Coroner du comté de Los Angeles. Sa découverte a été complétée par la création d'un corpus témoin : il a demandé (pour des raisons pratiques) à des travailleurs syndiqués d'écrire la lettre qu'ils écriraient s'ils voulaient se suicider (Shneidman & Farberow, 1957a). La notion de contrôle en suicidologie est complexe (Pestian, 2010), les participants « témoins » ont cependant été sélectionnés pour correspondre aux suicidés en termes d'âge, de genre, de religion et de nationalité (tous américains).

Ces données ont servi dans de nombreuses expériences qui ont montré qu'« il est possible de distinguer entre de vraies lettres de suicidés et des simulacres, et, encore plus important, que les lettres de suicidés se caractérisent généralement par une logique dichotomique, davantage d'hostilité et d'auto-critique, de noms spécifiques et d'instructions aux survivants,

2. *the practice of obtaining needed services, ideas, or content by soliciting contributions from a large group of people and especially from the online community rather than from traditional employees or suppliers* (Merriam-Webster, consulte en avril 2015)

3. Cette traduction a été proposée par Gilles Adda dans (Sagot *et al.*, 2011).

4. Le cas de *Phrase Detectives* est un peu différent, car les joueurs peuvent gagner des bons d'achat.

	Moy. des lettres (écart type)	Moy. des lettres simulées (écart type)	Signif.
Nb phrases	9,242 (8,058)	4,848 (3,308)	0,001
Fréquence max. d'un mot	7,909 (6,090)	4,212 (3,525)	0,002
Nb caractères hors mot	13,182 (11,078)	7,212 (7,039)	0,004
Niveau de lisibilité Flesch-Kinkaid	4,719 (2,142)	6,517 (2,994)	0,008

TABLE 1 – Quelques spécificités des lettres de suicidés par rapport à des lettres simulées.

moins de signes de réflexion sur ce que l'autre pense, et plus d'usage des différents sens du mot "amour" » (Shneidman, 1973).

Nous présentons ci-dessous deux lettres d'adieux au monde⁵ écrites par des hommes américains :

Please call my children first Can't Take much more Love you all to much gone to See Mary I can't live without Mary this pain + misery is to much Love all you kids forgive me ain't going to Die in Hosp. Like Mom Love Dad

(Leenaars, 1988)

I'm sorry, but somewhere I lost the road, and in my struggle to find it again, I just got further and further away. There should be little sadness, and no searching for who is at fault; for the act and the result are not sad, and no one is at fault. My only sorrow is for my parents who will not easily be able to accept that this is so much better for me. Please folks, it's all right, really it is. 1 :30 p.m.-The ultimate adventure begins! Car to Helen or Ray (needs a tune up). Money to Max and Sylvia. Furniture to George. I wanted to be too many things, and greatness besides-it was a hopeless task. I never managed to learn to really love another person-only to make the sounds of it. I never could believe what my society taught me to believe, yet I could never manage to quite find the truth. 2 :15 p.m.-:-I am about to will myself to stop my heart beat and respiration. This is a very mystical experience. I have no fear. That surprises me. I thought I would be terrified. Soon I will know what death is like-how many people out there can say that?

(Shneidman, 1973)

La première de ces lettres est relativement typique, puisqu'elle contient des verbes à l'impératif et l'expression d'une souffrance.

La seconde a été écrite par un psychiatre de 31 ans qui s'est donné la mort en prenant des barbituriques. Il a été trouvé dans une forêt du mid-Ouest américain. Cette deuxième lettre est moins typique, car elle ne mentionne pas de souffrance (du moins pas explicitement). Elle contient cependant elle-aussi des formes à l'impératif.

Le tableau 1 présente un certain nombre d'autres caractéristiques des véritables lettres de suicidés par rapport à des lettres simulées. Nous nous limitons ici aux spécificités les plus significatives ($p < 0,01$ ou moins).

Il est à noter que les lettres prises en compte dans ces chiffres ont été écrites par des Américains et qu'il faut donc se garder de généraliser à d'autres cultures, y compris d'autres pays anglo-saxons.

Le corpus de lettres dont il est question ici a été annoté en émotions, afin d'affiner l'analyse de ces lettres et aller au-delà de la simple classification entre « vraie » et « fausse » lettre de suicidé.

2 Matériels et méthodes

2.1 Création du corpus

Les 1 319 lettres du corpus ont été collectées entre 1950 et 2012 par Edwin Shneidman (UCLA), et John Pestian, du Centre médical des enfants de l'hôpital de Cincinnati (CCHMC). La mise en place de la base de données a commencé

5. Nous utilisons ici à dessein le terme employé par (Volant, 1990).

en 2009 et a reçu l'aval des institutions (CCHMC's Institutional Review Board). Chaque lettre a été scannée dans le module spécialisé (*Suicide Note Module*) de la plate-forme de décision clinique CHRISTINE. Les lettres ont ensuite été transcrites par un transcripateur professionnel et chacune a été relue par trois relecteurs en parallèle. Leurs instructions étaient de corriger les erreurs de transcription mais de laisser les erreurs d'origine, telles que les fautes d'orthographe, de grammaire, etc.

Afin de préserver la vie privée des suicidés, les lettres ont ensuite été anonymisées. Afin qu'elles restent utilisables par des systèmes par apprentissage supervisé, les informations retirées ont été remplacées par des valeurs équivalentes qui protègent la vie privée des individus. Ainsi, tous les prénoms de femmes ont été remplacés par « Jane » et tous les prénoms d'hommes par « John ». Tous les noms de famille ont quant à eux été remplacés par « Johnson ». Les dates ont été modifiées, tout en restant dans la même année. Par exemple, le « 18 novembre 2010 » a pu être changé en « 12 mai 2010 ». Enfin, toutes les adresses sont devenues « 3333 Burnet Ave., Cincinnati, OH 45229 ».

Chaque lettre du corpus d'entraînement et de test a été annotée par au moins trois annotateurs. Il leur était demandé d'identifier les émotions et expressions suivantes : maltraitance, colère, accusation, peur, culpabilité, désespoir, tristesse, pardon, joie, paix, espoir, amour, fierté, reconnaissance, instructions et informations. Une interface Web conçue spécialement a été utilisée pour collecter, gérer et arbitrer l'activité des annotateurs. Cet outil permet des annotations au niveau du mot et de la phrase. Il permet d'annoter un segment avec plusieurs concepts. Cette fonctionnalité a rendu impossible l'utilisation d'un simple coefficient Kappa pour calculer l'accord inter-annotateurs. Celui-ci a donc été calculé à l'aide de l'alpha de Krippendorff (Krippendorff, 1980, 2004), avec une distance de Dice. L'accord moyen mesuré a été de 0,54 (Pestian *et al.*, 2012a).

2.2 Recrutement des annotateurs

Par manque de financement, les annotateurs du projet ont été recrutés par *crowdsourcing* bénévole. Le choix a cependant été fait de limiter l'appel à participation à certaines personnes (il s'agit donc de *crowdsourcing* limité), dont le vécu pouvait être vecteur de motivation.

Ainsi, approximativement 1 500 membres de plusieurs communautés en ligne ont reçu une information concernant l'étude, soit directement par courriel, soit indirectement, *via* des pages Facebook de soutien. Les deux groupes les plus actifs dans ces communautés ont été les groupes de Karyl Chastain Beal *Families and Friends of Suicides* (Familles et amis de suicidés) et *Parents of Suicides* (Parents de suicidés), ainsi que *Suicide Awareness Voices of Education* (Voix pour l'éducation et la sensibilisation au suicide), un groupe dirigé par Dan Reidenberg, un psychiatre.

Le message envoyé aux participants potentiels contenait des informations concernant l'étude, ses sources de financement et ce qui était attendu des participants. Les volontaires ont été sélectionnés en deux étapes. La première a consisté à vérifier qu'ils remplissaient les critères fixés : avoir au moins 21 ans (la majorité légale aux États-Unis), être de langue maternelle anglaise et être prêt à lire et annoter 50 lettres de suicidés.

Dans un second temps, les participants ont reçu un courriel leur demandant de décrire leur relation à la personne suicidée, le temps passé depuis cette mort et si le ou la suicidé(e) avait été diagnostiqué(e) comme souffrant d'une maladie mentale.

2.3 Formation des annotateurs

Les annotateurs ont été formés par le biais d'une interface Web. Ils ont annoté 10 lettres jusqu'à atteindre une qualité minimale de 50 % d'accord observé avec la référence. Ils ont ensuite été invités à annoter 50 autres lettres.

Il est important de noter qu'ils ont été informés de la possibilité d'arrêter quand ils le souhaitaient, durant la formation ou pendant l'annotation. Des possibilités de soutien leur ont été proposées. Un « filet de sécurité » psychologique a été mis en place à deux niveaux : les organisateurs ont proposé un contact auprès de l'équivalent de SOS Suicide et les communautés de provenance des annotateurs leur ont fourni un soutien complémentaire.

2.4 Profils des annotateurs

L'annotateur type, dans ce projet, est une femme d'âge moyen, ayant fait des études et dont un membre de la famille proche s'est suicidé.

Le tableau 2 détaille les informations démographiques dont nous disposons sur les annotateurs du projet.

Genre	Homme	10 %
	Femme	90 %
Age	Moyenne	47,3 ans
	Écart type	11,2 ans
	Extrêmes	23–70 ans
Niveau d'études	Bac	26 %
	Bac+2	13 %
	Bac+3	23 %
	Bac+5	34 %
	Doctorat	4 %
Connexion au suicide	Survivant d'une perte	70 %
	Prof. de la santé mentale	18 %
	Autre	12 %
Temps passé depuis le suicide	0-2 ans	27 %
	3-5 ans	25 %
	6-10 ans	14 %
	11-15 ans	13 %
	16+ ans	12 %
Relation au suicidé	Enfant	31 %
	Frère/soeur	23 %
	Époux ou partenaire	15 %
	Parent	8 %
	Autre parent	9 %
	Ami(e)	5 %

TABLE 2 – Démographie des annotateurs

3 Résultats

3.1 Un corpus annoté unique, disponible pour la recherche

Le corpus est composé de 1 319 lettres, ce qui correspond à un total de 146 739 mots. La longueur moyenne d'une lettre est de 102,4 mots et l'écart type est de 112,2 mots : certaines lettres sont très courtes, d'autres très longues. À notre connaissance, il s'agit de loin du plus gros corpus existant de lettres de suicidés écrites en anglais. À titre de comparaison, (Brevard *et al.*, 1990) présente une étude de 20 lettres de suicidés et 20 lettres liées à une tentative de suicide, soit un total de 40 lettres. Les auteurs de (Joiner *et al.*, 2002) ont utilisé le même nombre de lettres, alors que ceux de (O'Connor & Leenaars, 2004) ont eu accès à 30 lettres en provenance d'Irlande et 30 des États-Unis. En ce qui concerne l'anglais, l'étude la plus large à notre connaissance a concerné 224 lettres de 154 sujets (Ho *et al.*, 1998). En ce qui concerne le français, 482 lettres en français ont été utilisées pour (Volant, 1990).

3.2 Des systèmes créés, identifiant les émotions

Une *shared task* a été organisée autour de ce corpus par le centre i2b2 (*Informatics for Integrating Biology and the Bedside*) aux États unis en 2011. Les participants ont mis au point des méthodes de TAL pour annoter les émotions exprimées dans les lettres. Cette *shared task* a regroupé 24 équipes, soit 106 scientifiques, en provenance d'Europe, d'Asie, et d'Amérique du nord. Ceux-ci ont présenté leurs résultats lors d'un atelier à la conférence annuelle de l'American Medical Informatics Association (Pestian *et al.*, 2012b).

Les performances s'étagent de 0,30 à 0,61 de F-mesure. Les actes de cette *shared task* ont été cités près de 60 fois au moment où nous écrivons ces lignes (avril 2015). L'impact de ce corpus en termes d'applications, de produits commerciaux, d'articles de recherche ou de brevets reste cependant inconnu à ce jour.

4 Discussion

4.1 Des biais probables, difficiles à réduire

Nous avons identifié un certain nombre de biais potentiels dans ce projet. Certains viennent des annotateurs, d'autres des chercheurs.

En ce qui concerne les annotateurs, il est possible que les survivants d'une perte et que les professionnels de la santé mentale influent sur la tâche du fait de différents biais émotionnels et cognitifs.

Ainsi, les survivants pourraient être inconsciemment motivés à trouver moins de preuves de souffrance et plus de joie dans les lettres de leurs parents. Les professionnels de la santé mentale pourraient eux être motivés à trouver davantage ou moins de preuves de l'issue fatale d'une maladie.

Il a été noté dans (Olson, 2005) que les lettres de suicidés peuvent avoir pour but soit de réduire la souffrance des survivants en allégeant leur culpabilité soit, au contraire, à l'alourdir en les accusant. Il est possible que les survivants et les professionnels de la santé mentale annotent les lettres d'adieux à la vie de manière différente, du fait d'une tentative inconsciente des premiers à alléger leur propre souffrance.

Nous n'avons malheureusement pas de réponse à ces questions, mais il est important d'avoir ces questions en tête lorsque l'on conçoit un tel projet d'annotation et lorsque l'on utilise le produit de ce projet.

Ainsi, dans ce projet, des différences ont été observées entre les différents types d'annotateurs. Une analyse préliminaire suggère en effet que les volontaires non professionnels identifient un variété moindre d'émotions que les professionnels de la santé mentale.

"We conjecture that part of this difference is due to psychological phenomenology. That is, each annotator has a psychological perspective that he/she brings to emotionally-charged data and this phenomenology causes a natural variation. [...] Whether our use of vested volunteers biased the interoperation, we are not sure." (Pestian *et al.*, 2012b)

Il est également possible que les chercheurs eux-mêmes aient pu inconsciemment biaiser les résultats. Ainsi, un des membres du projet est lui-même un parent proche d'une personne qui s'est suicidée. Il est de ce fait difficile d'identifier clairement les biais introduits dans la conception et l'analyse du projet, mais la question mérite d'être posée.

Quoi qu'il en soit, le travail en équipe participe à limiter ce type d'influence et à protéger le psychisme des uns et des autres, en leur permettant d'échanger sur leur ressenti et d'identifier ainsi plus facilement les biais qui en découlent.

4.2 L'empathie en question

Lire et annoter des lettres de suicidés n'est pas une tâche facile. Il est probable que pour la mener à bien les annotateurs doivent être amenés à faire appel à leur empathie, mais également à en réprimer une partie pour se protéger psychologiquement.

En théorie, cela ne devrait pas être différent d'autres situations où l'empathie est nécessaire, comme dans le cas de soins psychiatriques. Ainsi, (Capuzzi & Golden, 2013) souligne la nécessité d'une relation empathique entre le thérapeute et ses patients adolescents et (McLaughlin, 2007) insiste sur le rôle de l'empathie dans les réactions thérapeutiques face au comportement suicidaire. Cependant, dans le cas de cette campagne les annotateurs n'étaient pas formés à cela, ce qui a pu affecter leur capacité à gérer leurs sentiments et les effets secondaires de la campagne. Nous rappelons que les annotateurs pouvaient arrêter n'importe quand s'ils avaient des difficultés (cette option leur était rappelée) et que différentes options leur étaient proposées pour du soutien psychologique.

Les chercheurs qui ont organisé la campagne ont également été touchés, voire bouleversés par leur contact avec ce corpus. De fait, les chercheurs les plus impliqués dans le projet ont l'obligation d'avoir un suivi psychiatrique ou religieux tous les trimestres. Par ailleurs, une rotation régulière du personnel a lieu entre les différents projets.

4.3 Des utilisations potentiellement dangereuses des données

Les questions éthiques liées aux applications possibles d'un projet de recherche se posent sans doute dans tout le domaine informatique (Ermann *et al.*, 1997; Friedman, 1997; Martin & Weltz, 1999), et il n'y a aucune raison de penser que le domaine du TAL fasse exception.

Cependant, ce projet est particulier en ce qu'il touche à la mort et au respect de la volonté.

Les conséquences de l'utilisation des technologies issues de ce corpus pourraient être particulièrement sévères, comme l'hospitalisation injustifiée, l'emprisonnement, etc. Il est en effet assez facile d'imaginer l'utilisation qui pourrait être faite de technologies issues de ce corpus par des gouvernements pour lesquels la psychiatrie serait un outil d'oppression des dissidents comme, à une certaine époque, l'Union soviétique, où l'abus de diagnostics psychiatriques était massif (British Medical Association, 1992).

Les buts recherchés eux-mêmes posent question. En effet, est-ce qu'une intervention pour éviter un suicide ne porte pas atteinte au droit de mourir ? C'est une question connue des scientifiques travaillant (ou ayant travaillé) sur le sujet. Ainsi, Joiner remarque que les psychiatres avec qui il a travaillé « respectaient l'autonomie finale des personnes, y compris leur liberté de se donner la mort si c'était ce qu'elles souhaitaient vraiment »⁶ (Joiner, 2009). L'un des chercheurs les plus connus du domaine (Edwin Shneidman) dit également «...vous me demandez, eh bien, combien de suicides vous voulez, je répondrais que je n'en veux aucun, mais je veux que la liberté de se suicider existe »⁷ (Pestian, 2010).

5 Conclusion

Si nous considérons le corpus par rapport à la *Charte Éthique et Big Data*⁸ (Couillault *et al.*, 2014), nous constatons que les conditions de collecte et de distribution des données pour l'annotation sont en accord avec les suggestions éthiques sous-jacentes. La seule question en suspens est la section traitant des données liées aux contributeurs humains. Les trois sous-sections concernées sont les suivantes :

- *si un consentement a été demandé* Dans notre cas, les annotateurs ont clairement consenti à ce que leurs annotations soient distribuées, mais ce n'est évidemment pas le cas pour les auteurs des lettres.
- *si une trace matérielle existe de ce consentement* Le consentement des annotateurs a été obtenu par le biais d'une interaction électronique, suivie, lorsque le besoin s'en est fait sentir, de conversations téléphoniques ou d'échange de courriels.
- *la nature de l'information fournie afin que le consentement soit éclairé* Les annotateurs ont reçu une information lors de la phase initiale de recrutement par courriel (pour ceux qui ont été recrutés directement), puis au cours de la phase de formation (pour tous les annotateurs).

Nous avons présenté ici un certain nombre de questions éthiques liées à la construction d'un corpus de lettres de suicidés annoté en émotions. D'autres points pourraient encore être analysés, notamment en ce qui concerne l'expérience vécue par les annotateurs.

Nous pensons qu'une des leçons les plus importantes à retenir de ce projet est que les participants en contact avec ce type de matériau doivent avoir accès à différents types de soutien. Ainsi, dans un travail mené actuellement sur les adolescents suicidaires, les transcripteurs se voient proposé un suivi.

Enfin, la *Charte Éthique et Big Data* de ce corpus sera disponible prochainement.

6. "understood people's ultimate autonomy, including their freedom to occasion their own death if they really were committed to doing so".

7. "...you say to me, well how many suicides do you want, and I say I don't want any, but I want there to be the freedom to do it"

8. Voir : <http://wiki.ethique-big-data.org>.

Références

- BAUME P., CANTOR C. H. & ROLFE A. (1997). Cybersuicide : the role of interactive suicide notes on the internet. *Crisis : The Journal of Crisis Intervention and Suicide Prevention*, **18**(2), 73.
- BREVARD A., LESTER D. & YANG B. (1990). A comparison of suicide notes written by suicide completers and suicide attempters. *Crisis : The Journal of Crisis Intervention and Suicide Prevention*.
- BRITISH MEDICAL ASSOCIATION (1992). *Medicine betrayed : The participation of doctors in human rights abuses*. Zed books.
- CAPUZZI D. & GOLDEN L. (2013). *Preventing adolescent suicide*. Routledge.
- CHAMBERLAIN J., POESIO M. & KRUSCHWITZ U. (2008). Phrase Detectives : a web-based collaborative annotation game. In *Proceedings of the International Conference on Semantic Systems (I-Semantics'08)*.
- COUILLAULT A., FORT K., ADDA G. & DE MAZANCOURT H. (2014). Evaluating Corpora Documentation with regards to the Ethics and Big Data Charter. In *International Conference on Language Resources and Evaluation (LREC)*, Reykjavik, Islande.
- COUVET D., DEVICTOR V., JIGUET F. & JULLIARD R. (2011). Scientific contributions of extensive biodiversity monitoring. *C. R. Biologies*, **334**, 370–377.
- ERMANN M. D., WILLIAMS M. B. & SHAU F. M. S. (1997). *Computers, ethics, and society*. Oxford University Press.
- FÉDÉRATION FRANÇAISE DE PSYCHIATRIE (2001). *La crise suicidaire : reconnaître et prendre en charge*. John Libbey Eurotext.
- FORT K., ADDA G. & COHEN K. B. (2011). Amazon Mechanical Turk : Gold mine or coal mine ? *Computational Linguistics (editorial)*, **37**(2), 413–420.
- FORT K., GUILLAUME B. & CHASTANT H. (2014). Creating Zombilingo, a Game With A Purpose for dependency syntax annotation. In *Gamification for Information Retrieval (GamifIR'14) Workshop*, Amsterdam, Pays-Bas.
- FRIEDMAN B. (1997). *Human values and the design of computer technology*. Number 72. Cambridge University Press.
- GUPTA N., MARTIN D., HANRAHAN B. V. & O'NEILL J. (2014). Turk-life in india. In *Proceedings of the 18th International Conference on Supporting Group Work, GROUP '14*, p. 1–11, New York, NY, USA : ACM.
- HO T., YIP P. S., CHIU C. & HALLIDAY P. (1998). Suicide notes : what do they tell us ? *Acta Psychiatrica Scandinavica*, **98**(6), 467–473.
- JOINER T. (2009). *Why people die by suicide*. Harvard University Press.
- JOINER T. E., PETTIT J. W., WALKER R. L., VOELZ Z. R., CRUZ J., RUDD M. D. & LESTER D. (2002). Perceived burdensomeness and suicidality : Two studies on the suicide notes of those attempting and those completing suicide. *Journal of Social and Clinical Psychology*, **21**(5), 531–545.
- KRIPPENDORFF K. (1980). *Content Analysis : An Introduction to Its Methodology*, chapter 12. Sage : Beverly Hills, CA., USA.
- KRIPPENDORFF K. (2004). *Content Analysis : An Introduction to Its Methodology, second edition*, chapter 11. Sage : Thousand Oaks, CA., USA.
- LAFOURCADE M. & JOUBERT A. (2008). JeuxDeMots : un prototype ludique pour l'émergence de relations entre termes. In *Journées internationales d'Analyse statistique des Données Textuelles (JADT)*, Lyon, France.
- LEENAARS A. A. (1988). *Suicide notes : Predictive clues and patterns*. New York : Human Sciences Press.
- MARTIN C. D. & WELTZ E. Y. (1999). From awareness to action : Integrating ethics and social responsibility into the computer science curriculum. *ACM SIGCAS Computers and Society*, **29**(2), 6–14.
- MCLAUGHLIN C. (2007). *Suicide-related behaviour : Understanding, caring and therapeutic responses*. John Wiley & Sons.
- MERRIAM-WEBSTER (consulté en avril 2015). Définition du terme *Crowdsourcing*.
- OLSON L. M. (2005). *The use of suicide notes as an aid for understanding motive in completed suicides*. PhD thesis, Department of Health Promotion and Education, University of Utah.
- OSGOOD C. E. & WALKER E. G. (1959). Motivation and language behavior : A content analysis of suicide notes. *The Journal of Abnormal and Social Psychology*, **59**(1), 58.
- O'CONNOR R. C. & LEENAARS A. A. (2004). A thematic comparison of suicide notes drawn from northern ireland and the united states. *Current Psychology*, **22**(4), 339–347.

- PESTIAN J. (2010). A conversation with edwin shneidman. *Suicide and Life-Threatening Behavior*, **40**(5), 516–523G.
- PESTIAN J. P., MATYKIEWICZ P. & LINN-GUST M. (2012a). What's in a note : construction of a suicide note corpus. *Biomedical informatics insights*, **5**, 1.
- PESTIAN J. P., MATYKIEWICZ P., LINN-GUST M., SOUTH B., UZUNER O., WIEBE J., COHEN K. B., HURDLE J. & BREW C. (2012b). Sentiment analysis of suicide notes : A shared task. *Biomedical Informatics Insights*, **5**, 3–16.
- SAGOT B., FORT K., ADDA G., MARIANI J. & LANG B. (2011). Un turc mécanique pour les ressources linguistiques : critique de la myriadisation du travail parcellisé. In *Actes de Traitement Automatique des Langues Naturelles (TALN)*, Montpellier, France. 12 pages.
- SCHNEIDMAN E. S. (1981). Suicide notes and tragic lives. *Suicide and Life-Threatening Behavior*.
- SHNEIDMAN E. S. (1973). Suicide notes reconsidered. *Psychiatry*, **36**(4), 379–394.
- SHNEIDMAN E. S. & FARBEROW N. L. (1957a). *Clues to suicide*, volume 56981. McGraw-Hill Companies.
- SHNEIDMAN E. S. & FARBEROW N. L. (1957b). Some comparisons between genuine and simulated suicide notes in terms of mowrer's concepts of discomfort and relief. *The Journal of general psychology*, **56**(2), 251–256.
- TUCKMAN J., KLEINER R. J. & LAVELL M. (1959). Emotional content of suicide notes. *American Journal of Psychiatry*, **116**(1), 59–63.
- VOLANT É. (1990). *Adieu, la vie... : étude des derniers messages laissés par des suicidés*. Bellarmin.