

L'actualité des Learning Analytics : quelques éléments d'un débat

DANIEL PERAYA

Faculté de psychologie et des sciences de l'éducation
Université de Genève
Suisse
daniel.peraya@unige.ch

ABSTRACT

This article reports on a debate conducted in 2019 in the “Débat-discussion” section of the four issues of the journal Distance and Mediation of Knowledge (DMS-DMK). Each year, the section is the site of a thematic debate which opens in the first of the four annual issues with a framing text. It offers a critical review of the recent literature devoted to the chosen theme: it analyzes its potential, the challenges and the prospects, particularly for distance learning. During the following three issues, fellow specialists in the field are invited to react, to debate based on their epistemological positioning, their disciplinary affiliation, their research and their experience. The article presents a synthesis, albeit partial, of the debate that Learning Analytics were the subject of in the review during the year 2019: it focuses on epistemological, methodological and ethical arguments.

KEYWORDS

Learning Analytics, epistemology, methodology, ethics

RÉSUMÉ

Cet article rend compte d'un débat mené en 2019 dans la rubrique « Débat-discussion » des quatre numéros de la revue Distances et Médiations des Savoirs (DMS-DMK). Chaque année, la rubrique est le lieu d'un débat thématique qui s'ouvre dans le premier des quatre numéros annuels par un texte de cadrage. Celui-ci propose une revue critique de la littérature récente consacrée à la problématique choisie : il en analyse le potentiel, les enjeux et les perspectives, particulièrement pour la formation à distance. Durant les trois numéros suivants, des collègues spécialistes du domaine sont invités à réagir, à débattre à partir de leur positionnement épistémologique, de leur appartenance disciplinaire, de leurs

recherches et de leur expérience. L'article présente une synthèse, certes partielle, du débat dont les Learning Analytics ont fait l'objet au sein de la revue durant l'année 2019 : elle s'attache aux argumentations épistémologiques, méthodologiques et éthiques.

MOTS-CLÉS

Analytique de l'apprentissage instrumenté, épistémologie, méthodologie éthique

AVERTISSEMENT

Cette contribution n'est pas une production entièrement originale : elle puise sa source dans la rubrique « Débat-discussion » de la revue *Distances et Médiations des Savoirs* (DMS-DMK) (numéros 25, 26, 27 et 28, 2019). Chaque année, la rubrique est le lieu d'un débat thématique qui s'ouvre dans le premier des quatre numéros annuels de la revue par un texte de cadrage. Celui-ci propose une revue critique de la littérature récente consacrée à la problématique choisie : il en analyse le potentiel, les enjeux et les perspectives, particulièrement pour la formation à distance. Durant les trois numéros suivants, des collègues spécialistes du domaine sont invités à réagir à ce texte, à en débattre à partir de leur propre positionnement épistémologique, de leur appartenance disciplinaire, de leurs recherches et de leur expérience d'enseignant et de chercheur.

Durant l'année 2019, le débat a été consacré aux *Learning Analytics* (LA) (Peraya, 2019a). Cette problématique est importante, car elle interroge l'épistémologie autant que les méthodes des sciences humaines et sociales (SHS). Les collègues invités à participer à ce débat étaient des chercheuses et des chercheurs soit confirmés soit en début de carrière, appartenant à de champs disciplinaires complémentaires : sociologie, informatique, psychologie, sciences de l'éducation ou de l'information, technologies éducatives. Ils avaient en commun d'être : a) des enseignants-chercheurs ; b) d'utiliser les applications basées sur les LA dans leurs dispositifs de formation entièrement ou partiellement à distance ; c) de mener des recherches sur le potentiel des LA pour améliorer le processus d'apprentissage (tableaux de bord, identification des élèves présentant un « risque » d'abandon, personnalisation des parcours et de l'accompagnement, etc.).

Nous présenterons ici une synthèse, certes partielle, du débat dont les LA ont fait l'objet au sein de la revue, mais nous la pensons néanmoins représentative de celui-ci. À cette occasion, nous avons restructuré la présentation de certains arguments et parfois reformulé certains de ceux-ci ; en effet, la confrontation et la prise de distance – une année s'est écoulée depuis la publication du texte de cadrage – ont largement enrichi le débat, rendant ce travail indispensable.

Le lecteur s'en rendra vite compte, ce débat, qui reste d'actualité dans le champ de la formation instrumentée et des sciences de l'éducation, possède une portée bien plus générale. Pour preuve, Bastin et Tubaro ont conduit une réflexion semblable à celle de DMS, en sociologie, à l'occasion de la publication d'un numéro spécial de la *Revue Française de Sociologie. Le moment big data des sciences sociales* (2018). La problématique soulève des questions qui relèvent de l'épistémologie, de la méthodologie, de l'éthique, de la gouvernance, de l'économique et de la politique. C'est aussi dans cette ouverture et cette complexité que réside l'intérêt de cette contribution.

BREF HISTORIQUE

Depuis le milieu des années 90, l'intérêt pour les *Learning Analytics* ne cesse de grandir dans le champ de la formation et de l'apprentissage et particulièrement dans celui de la formation entièrement ou partiellement à distance. Et l'on comprend bien pourquoi : « La promesse de fond des LA est la possibilité, par l'accès à des grandes masses de données, de mieux saisir les processus d'apprentissage et potentiellement, de les améliorer » (Tubaro, 2019, § 2). Les méthodes, héritées du courant qui s'est constitué dans les années 80 sous le nom de *Knowledge Discovery in Databases*, permettent en effet grâce à la puissance de calcul de l'informatique et à des traitements statistiques sophistiqués (*Data Mining* ou fouille des données) de produire des connaissances sur le comportement des utilisateurs à propos desquels sont recueillies les données.

En Angleterre dans les années 90 naît le courant de l'*Evidence-Based Education* à la suite du courant de l'*Evidence Based Medecine* (Peraya, 2019a). Dès ce moment, les méthodes issues du *Data Mining* sont popularisées dans le monde de la recherche en éducation notamment à cause de leur développement et de leurs succès dans le marketing et le monde de l'entreprise. Dans le premier cas, il s'agit de mieux connaître les habitudes, les goûts des consommateurs afin de personnaliser l'offre de vente qui leur est destinée (*one-to-one relationship*) tandis que dans le second, les *Business Analytics* ont pour objectif de fournir des connaissances utiles à la prise des décisions relatives à la gestion de l'entreprise. On retrouve d'ailleurs cette tendance aujourd'hui sous le terme d'*Academic Analytics*, défini comme « *the process of evaluating and analysing organisational data received from university systems for reporting and decision-making reasons* » (Campbell, DeBlois, & Oblinger, 2007). Plusieurs facteurs ont contribué à renforcer ce courant : le succès rencontré par les plateformes numériques d'apprentissage et, depuis les années 2000, leur large diffusion suivie quelque dix années plus tard par l'explosion des MOOCs.

Historiquement, deux grandes communautés internationales se sont développées : d'une part, l'*Educational Data Mining* avec, dès 2009, la revue *Journal of Educational Data Mining*; d'autre part, la *Society for Learning Analytics Research* (SoLAR, dès 2011) qui possède

sa revue, le *Journal of Learning Analytics*, et sa propre conférence internationale *Learning Analytic for Knowledge* (LAK). La première s'attache à la conception d'algorithmes et vise ainsi à donner aux logiciels la capacité de prédire les résultats d'un apprenant et de personnaliser sa stratégie d'apprentissage, tandis que pour la seconde, il s'agit de modéliser et de visualiser les résultats des analyses des données qui doivent alors être transmises aux acteurs de l'apprentissage (apprenant, personnels d'éducation, enseignants, etc.). Dans le premier cas, il s'agit donc « de réduire progressivement le système d'apprentissage à ses composantes principales, en modélisant séparément les apprenants, les tuteurs, les domaines enseignés » (Labarthe & Luengo, 2016, p. 9), tandis que les chercheurs de la communauté SoLAR privilégieraient une approche systémique qui viserait à rendre les acteurs plus autonomes. En d'autres termes, pour ces auteurs, les résultats des recherches de la communauté EDM se trouvent réinvestis dans la machine, tandis que ceux de SoLAR sont restitués aux acteurs, notamment sous la forme de visualisations, de tableaux de bord, etc. (cité par Peraya, 2019a, § 14).

Dans les textes en langue française, on traduit souvent l'expression *Learning Analytics* par « analytique de l'apprentissage ». Nous préférons adopter en toute rigueur l'expression « analytique des données d'activités d'apprentissage instrumentées » pour les raisons suivantes. D'abord, cette formulation met l'accent sur le fait que les LA constituent un mode de traitement de données relatives aux d'activités instrumentées d'apprentissage ; en conséquence, elle marque clairement la distinction entre le traitement des données et l'analyse de l'objet lui-même, celui à propos duquel sont recueillies ces données. Ensuite, elle renvoie explicitement au cadre théorique de l'analyse de l'activité (Engeström, 1987; Leontiev, 1976). Enfin, elle indique que l'activité d'apprentissage se déroule dans un environnement numérique, une plateforme, un LMS, un EIAH, etc. L'apprentissage instrumenté n'est qu'un des lieux dans lesquels se réalisent les activités d'apprentissage de l'apprenant. L'expression « analytique de l'apprentissage instrumenté », utilisée dans le texte de cadrage (Peraya, 2019a), bien que moins précise, est plus courte : elle allège vraisemblablement la rédaction comme la lecture des textes. Elle nous semble donc un compromis acceptable.

Selon Azemard, Ben Henda et Hudrisier (2015), les LA constituent une « véritable mutation de notre potentiel d'analyse » (p. 3), une sorte de « retournement copernicien de l'intelligence d'analyse » (p. 8) dans la mesure où ils permettent de dégager de nouvelles connaissances, de formuler de nouvelles hypothèses et des façons de penser les problèmes jusque là inaccessibles à notre entendement. Les auteurs rappellent à ce propos le rôle de l'imprimerie et de ses progrès techniques pour la construction d'une connaissance et d'une intelligence collectives. Mais quelle est la nature de ce retournement et en quoi pose-t-il question pour de nombreux chercheurs en sciences humaines ? Les réponses à ces questions ainsi que les critiques les plus souvent formulées à l'encontre des LA relèvent de l'épistémologie, de la méthodologie ou

encore de l'éthique, voire simultanément de plusieurs de ces domaines à la fois. Tentons d'y voir plus clair.

LE POINT DE VUE ÉPISTÉMOLOGIQUE

L'irruption des LA dans le champ des sciences humaines, à la suite « du vaste mouvement de mise en données de la société » (Richard, 2018, p. 71) bouleverse les conceptions épistémiques traditionnelles qui en constituent la spécificité. Les *Learning Analytics* mettraient en question la dimension interprétative fondamentale des SHS (Azemard et al., 2015; Bastin & Tubaro, 2018; Pierrot, 2019). Les principes mêmes du *data mining*, de la fouille des données, sont en effet étrangers aux cadres et aux modèles théoriques des disciplines auxquelles la recherche recourt habituellement pour analyser le comportement humain telles que la linguistique, la psychologie ou la sociologie (Labarthe & Luengo, 2016).

Le premier niveau de critiques relève donc de l'épistémologie. Avec l'analyse des données massives, les modèles et les connaissances produites sont issus de l'exploration des données, du traitement automatique de celles-ci et non de théories ou de modèles préalablement construits par les disciplines des SHS. Les techniques statistiques utilisées, qui trouvent leur origine dans les méthodes d'analyse factorielle et de classification hiérarchisée de Benzécri (1973) ainsi que dans leurs développements ultérieurs, notamment les *Data Sciences*, aux confins des mathématiques, de la statistique et de l'informatique (Hayashi, 1998), permettent assurément « la découverte de modèles à l'aide d'un processus algorithmique d'exploration de modèles » (Saporta, s.d.). Mais dès lors, la recherche ne viserait plus à valider ou à tester des modèles construits *a priori*, mais bien à mettre en œuvre « une heuristique de la pertinence des relations liant des ensembles d'items automatiquement proposée par l'outil d'analyse » (Azemar et al., 2015, p. 8) découvrant des modèles *a posteriori*.

Le premier de ces arguments oppose les modèles de connaissance *a priori*, propres aux approches déductives – explicatives –, aux modèles *a posteriori* caractéristiques des approches inductives – compréhensives¹. Cette opposition n'est cependant pas irréductible comme le rappellent Azemar et al., citant Björn-Olav Dozo (2008) à propos de l'usage que fit Bourdieu, dans *La distinction* (1979), de l'analyse factorielle de correspondances (AFC) pour la description de l'espace social. Ce dernier écrivait à propos de l'AFC qu'elle « permet d'isoler, par partitions successives, différents ensembles cohérents de *préférences* qui trouvent leurs principes dans les systèmes

1 « L'analyseur "méthodologie" oppose traditionnellement les méthodologies conçues et validées *a priori* à celles conçues et validées *a posteriori*. Les premières seraient une exigence d'une épistémologie explicative pure et dure, les secondes d'une épistémologie compréhensive » (Paquay, Crahay, & De Ketele, 2006, p. 230).

de dispositions distincts et distinctifs, définis autant par la relation qu'ils entretiennent entre eux que par la relation qui les unit à leurs conditions sociales de production » (1979, p. 295).

La seconde critique porte sur le manque de lien entre les procédures de calcul ainsi que les modèles qu'elles produisent d'une part, et les modèles théoriques des SHS d'autre part. D'aucuns redoutent en effet que la démarche et les méthodes scientifiques d'analyse des données se voient remplacées « par des méthodes algorithmiques *sans lien fort avec les théories² sociales* » ou encore que l'esprit critique d'analyse, « l'apport épistémique de l'humain », se trouve supplanté par la puissance de calcul des algorithmes automatiques (Bastin & Tubaro, 2018, p. 375). Corrélativement, d'autres s'inquiètent de voir les gisements de données se substituer aux recueils de données classiques en sciences humaines, à savoir les données d'enquêtes, l'observation, quels qu'en soient la forme, les questionnaires et les différents types d'entretiens. Or ces méthodes, rappellent Bastin et Tubaro (2018, p. 376), ont constitué longtemps une forme de « juridiction sur tout un pan de connaissances ». La question sous-jacente est donc aussi celle de la confiance que l'on accorde aux interprétations proposées par l'algorithme et aux décisions qu'il prendrait automatiquement sur la base de ses interprétations.

En SHS comme en sciences de l'éducation (Pinard, Potvin, & Rousseau, 2004), il est aujourd'hui courant d'utiliser une méthode mixte, associant une approche inductive (approche compréhensive) par exemple dans les recherches à caractère exploratoire afin de mettre au jour des modèles ou des hypothèses qui peuvent, par la suite ensuite, faire l'objet d'une validation à l'occasion d'une recherche menée selon une approche déductive (approche explicative). Les intervenantes au débat ont toutes, sur ce point, adopté une position consensuelle en faveur d'une approche mixte de la recherche – inductive et déductive –, se basant sur des données souvent multimodales tant quantitatives que qualitatives³ – les traces des activités laissées par les apprenants dans un environnement numérique –, traitant celles-ci par des méthodes aussi bien quantitatives et qualitatives. Aussi, la fouille automatique des gisements de données doit-elle s'accompagner d'une approche plus classique d'analyse de données recueillies à travers les dispositifs de récolte plus conformes aux règles et aux savoir-faire traditionnels en SHS, tels que l'observation, l'enregistrement, les questionnaires et les différents types d'entretiens. Ces données comme leurs dispositifs de récolte ne se voient donc pas déclassés par les LA, tout au contraire. Dans ses recherches sur l'appropriation des usages du numérique par des jeunes, Pierrot (2019) complète et confronte les résultats de la fouille des données par l'analyse des données d'entretien,

2 Nous soulignons.

3 « Et n'oublions pas finalement qu'il y a plus de recherche avec des données mixtes qu'avec un seul type de données » (Paquay, Crahay, & De Ketele, 2006, p. 232).

montrant ainsi, d'une part, la nécessité de mettre en œuvre des approches multiples et, d'autre part, l'importance de la triangulation⁴ des méthodes et des données. Poellhuber et Roy (2019) rapportent, à propos de l'utilisation des tableaux de bord, l'intérêt de conseillers pédagogiques au niveau collégial⁵ pour les données qualitatives qui permettent de donner plus de sens aux traces ainsi que de contextualiser les micro-comportements analysés par les LA (§ 19).

En définitive, l'analytique de l'apprentissage instrumenté apparaît comme un des moyens de la recherche parmi d'autres. Mais cette complémentarité n'est pas simple à mettre en œuvre et elle soulève de nombreux problèmes méthodologiques, notamment la différence de nature des données recueillies ainsi que celle des tailles des corpus, souvent très déséquilibrées (notamment Luengo, 2019; Pierrot, 2019).

LA QUALITÉ DES DONNÉES

Le positionnement de la question

Comme la confiance que l'on peut accorder à un algorithme (nous reviendrons sur cet aspect plus loin dans le texte), la qualité des données est souvent mise en cause dans la littérature. Dans notre texte de cadrage (2019a), nous avons présenté une synthèse des principaux arguments critiques de nature méthodologique portés à l'encontre des LA⁶. Parmi ceux-ci, certains ne sont d'ailleurs pas étrangers à la posture épistémologique – ou disciplinaire, selon Poellhuber et Roy (2019) – des chercheurs.

Si les traces d'activités saisies automatiquement dans les environnements virtuels et leurs traitements par des algorithmes sont souvent créditées d'une certaine objectivité – d'une certaine scientificité ? – par rapport aux procédures de recueil et de traitement des données qualitatives fréquentes dans les SHS, une grande partie des critiques portées à l'encontre des LA concernent justement les critères de qualité des masses de données numériques recueillies. L'argumentaire se construit dans le prolongement des critiques épistémologiques évoquées ci-dessus et se fonde précisément sur les critères de qualité qui gouvernent la recherche scientifique en SHS en général, en sciences de l'éducation en particulier. Les méthodologues distinguent classiquement trois critères essentiels de qualité : la pertinence, la validité⁷ et la fiabilité (Paquay, Crahay, & De

4 « Essentiellement, la triangulation est supposée confirmer un résultat en montrant que les mesures indépendantes qu'on en a fait vont dans le même sens ou tout au moins ne le contredisent pas » (Huberman & Milles, 1991, p. 425).

5 L'enseignement collégial au Québec est un cycle de deux ans (DEC pré-universitaire) ou de trois années [DEC technique, qui débute après les cycles de scolarité primaire et secondaire (11 ans)], lorsque l'étudiant a normalement atteint l'âge de 16 ans.

6 Les paragraphes ci-dessous reprennent largement le texte de cadrage (Peraya, 2019, § 23-33).

7 Ces concepts apparaissent complexes et donnent lieu à de nombreuses définitions concurrentes. Par exemple, Van Der Maren propose une première définition qui ne semble pas distinguer

Ketele, 2006). Ceux-ci sont applicables aux trois étapes de la démarche recherche : la conceptualisation, le recueil et le traitement des données, enfin la communication des résultats. Nous nous intéresserons principalement, dans cette contribution, à la pertinence et à la validité des données très souvent mises en cause dans la littérature.

Pertinence des données

Les premières réticences envers les LA relèvent de la pertinence des données. Par exemple, Ouakrat et Mésangeau (2016), citant Plantin et Monnoyer-Smith (2013, p. 61), craignent que les hypothèses de recherche soient dépendantes de la nature des données disponibles dans les plateformes de distribution de MOOCs ou d'un LMS. Celles-ci sont en effet celles que l'environnement informatique rend disponibles et le chercheur n'a, dans la plupart des cas, aucune marge de négociation pour en obtenir d'autres, plus adaptées aux besoins particuliers de ses recherches. Bastin et Tubaro (2018), quant à eux, soulignent que les données pourraient être biaisées par les *Application Programming Interfaces* embarquées dans les plateformes, ces « boîtes noires », sur lesquelles, bien évidemment, le chercheur ne possède que très peu de contrôle – le plus souvent aucun – ce qui n'est pas sans poser de nombreux problèmes éthiques comme l'ont souligné unanimement les contributeurs et les contributrices au débat (voir ci-dessous).

On sait aussi que les traces, telles qu'elles sont saisies par les environnements, les « inscriptions » d'activités (Settouti et al., 2007) constituent rarement des données immédiatement utiles, pertinentes, pour les chercheurs. La nécessité d'une reconstruction des traces brutes, de leur modélisation, aux différents niveaux du processus de recherche, est d'ailleurs bien identifiée dans la littérature (notamment Champin, Mille, & Prié, 2013; Ouakrat & Mésangeau, 2016; Peraya et al., 2009; Pierrot, 2018; Rogers, 2015; Settouti et al., 2007; Tubaro, 2019). Même dans le cas des traitements « non supervisés », lorsque l'algorithme identifie automatiquement, à partir de données non annotées ou non étiquetées, les structures sous-jacentes au corpus, les données doivent être « nettoyées, triées, préparées » (Tubaro, 2019, §11).

Enfin, plusieurs auteurs relèvent que le traitement de données massives semblerait plus pertinent pour explorer et pour expliquer les comportements collectifs, ceux d'une cohorte par exemple, que les comportements individuels (Pulker, 2019). Boyer considère en effet que, par rapport aux données collectives, les données individuelles sont « parcimonieuses » : « Si l'on parle souvent de l'abondance des données

validité et pertinence : « La qualité du rapport des données aux concepts utilisés pour décrire ou analyser le problème. C'est la validité des données, ou leur pertinence, qui correspond à l'exigence pour les chercheurs du domaine, et pour le chercheur lui-même d'abord, de s'entendre pour dénommer, classer, catégoriser de la même manière les traces d'une activité » (2003, p. 22). Si l'on compare avec les critères de Paquay et al., il s'agirait ici de la validité conceptuelle (critère de validité appliqué à la première phase du processus de recherche celui de sa conceptualisation).

collectées, il faut bien garder à l'esprit qu'elles sont souvent parcimonieuses pour chaque apprenant. Comme en recommandation sociale, les outils de *Learning Analytics* pallient généralement le manque d'informations sur un utilisateur par l'exploitation des données des autres apprenants » (2019, § 14).

Ces différentes critiques appellent plusieurs commentaires. Tout d'abord, la question de la pertinence des données ne naît pas avec les *Learning Analytics*. Il s'agit d'une question méthodologique de portée générale qui vaut pour toute recherche, toute discipline et pour tous les types des données, qu'elles soient invoquées, provoquées ou suscitées dans l'interaction. Mais pourquoi alors cette question se pose-t-elle avec autant d'acuité dans le cas de l'usage des *Learning Analytics* en éducation ? D'abord, l'approche y encore est relativement récente et, en conséquence, on ne possède pas encore de suffisamment de recul pour pouvoir apprécier son impact, ses effets positifs et négatifs. Ensuite, les fondements épistémologiques des LA et des premiers domaines où se sont développées cette approche et ces techniques, le marketing et de la gestion commerciale (voir ci-dessus) ont fait naître une certaine méfiance à leur égard. Ensuite, les données issues des plateformes sont des données invoquées qui, par définition, préexistent à l'activité des chercheuses et des chercheurs et ceux-ci n'ont sur elles aucun contrôle. Que le choix des données n'appartienne pas aux chercheurs semble faire problème, bien plus que leur caractère invoqué.

Validité des données

D'autres critiques, très nombreuses, concernent le caractère superficiel, formel et incomplet des données que traitent les LA. On est loin en effet « de la richesse des bases de données classiques, comme les enquêtes menées depuis longtemps en sociologie, construites précisément pour les besoins de l'analyse et, par là, plus aptes à aider l'interprétation, malgré leur petite taille et leur caractère déclaratif » (Tubaro, 2019, § 7). Ouakrat et Mésangeau (2016) expliquent, quant à eux, que ces données « demeurent une traduction très partielle et limitée des pratiques. Elles décrivent des liens sociaux de façon restreinte et circonscrite et ne représentent qu'un pan de l'activité des individus. De plus, elles ont tendance à effacer le contexte social et biographique dans lequel s'inscrivent les individus pour se concentrer sur une forme particulière de l'activité, celle qui peut être enregistrée. Les traces captées et rendues disponibles aux chercheurs en sciences de l'information et de la communication sont construites et redéfinies par les modalités de prélèvement et de mise en forme de l'information » (§ 2). Il faut donc « re-socialiser » les données numériques ainsi que les indicateurs construits à base de traces par une approche qualitative plus classique » (ibid.). De surcroît, cette caractéristique serait d'autant plus importante que « plus les données sont massives, plus elles sont factuelles » (Peraya & Luendo, 2019, § 17; Pulker, 2019). Ces critiques sont fondamentales, car elles visent, en réalité, la validité même des

données, autrement dit, leur capacité à mesurer « exactement ce qu'elles sont censées mesurer » (Jones, 2000, p. 29).

Poellhuber et Roy (2019) ne partagent pas cette critique. Se fondant vraisemblablement sur les propos de Ouakrat et Mésangeau, cités ci-dessus, ils estiment que cette question permet de discriminer fondamentalement des postures épistémologiques et disciplinaires différentes : ils opposent leur posture de chercheurs « venus du domaine des sciences sociales et ayant été formés à une démarche de modélisation statistique » (§ 3) à celle de certains chercheurs des sciences de l'information « qui considèrent que la réduction des informations correspond à une perte de données » (ibid.)⁸. Au contraire, pour ces deux auteurs, « cette perte permet plutôt une contextualisation pratique d'actions qui doivent révéler quelque chose sur le processus d'apprentissage » (ibid.). On peut d'ailleurs se demander si, formulé en ces termes, le débat est bien posé. En effet, la critique ne porte pas sur la perte de données, mais sur celle du sens, en tout cas partiel, de celles-ci (Peraya, 2019b).

Dans leur recherche sur l'engagement comportemental des participants à un MOOC, ces deux auteurs construisent leur objet de recherche en termes « de participation et d'indicateurs observables de cette participation », ils postulent que « l'activité dans les traces correspond de près au concept d'engagement, et plus particulièrement au concept d'engagement comportemental » (2019, § 4), ils considèrent que les traces correspondent à l'enregistrement d'activités menées par l'apprenant et qu'elles peuvent être assimilées aux « observations réalisées dans les classes à des comportements de participation observables » (2019, ibid.). Aussi, les traces peuvent-elles être considérées comme les marques observables de l'engagement ou du désengagement comportemental de l'apprenant dans une tâche.

Quelle que soit la robustesse du modèle théorique de l'engagement mobilisé dans ce type de recherches, nous ne pensons pas que cette critique puisse être réfutée en son principe par ces postulats initiaux. Rien ne permet en effet de dire que les traces numériques sont effectivement assimilables aux comportements observés en situation de classe réelle. S'il s'agit d'une hypothèse de travail, elle mériterait d'être testée. Ensuite, c'est peut-être dans le fondement positiviste de cette posture que réside le risque de biais de la validité méthodologique des données d'autant que la validité théorique d'une recherche n'implique pas forcément sa validité méthodologique (Paquay, Crahay, & De Ketele, 2006).

En effet, du point de vue strictement méthodologique, l'observation d'un fait, on

8 Á bien lire cet argument, il contient plusieurs implicites facilement réfutables : les sciences de l'information et de la communication n'appartiendraient pas aux SHS d'une part et, d'autre part, les auteurs concernés n'auraient pas été formés à la modélisation statistique. Le premier peut l'être par principe, puisque les sciences de l'infocom appartiennent de fait aux SHS tandis que le second se fonde sur un présupposé : ceux qui réfutent la validité des traces numériques n'ont pas de formation à la modélisation statistique sans savoir si, en réalité, ils l'ont ou non.

le sait, ne livre automatiquement ni le sens que lui attribue celui qui en est l'agent dans le contexte (personnel, académique, social) où il est observé ni le sens que le chercheur lui attribue en fonction de son modèle, de son construit théorique. Les auteurs se voient donc amenés à reconnaître que si l'engagement comportemental correspond aux signes visibles et observables de l'engagement ou du désengagement dans une tâche, ils sont « normalement aussi un signe de l'engagement cognitif... mais pas toujours » (2019, § 5). La trace pourrait donc n'être qu'indice formel, superficiel et trompeur.

Romero (2019) apporte dans sa contribution un exemple significatif de traces d'un comportement certes observable, mais dont le sens pour les apprenants apparaît en définitive très différent de celui que lui attribuent l'enseignant et le chercheur. L'auteure s'intéresse à la perception du temps de réponse des apprenants dans les contextes d'apprentissage médiatisé, qui sont au centre des études de chronémie, définie comme l'étude de la temporalité dans les interactions par Bruneau (2007, cité par Romero, 2019, § 4). Elle mentionne l'existence de nombreuses recherches ayant pour objectif de « mettre en relation le temps de fréquentation de l'apprenant avec (la prédiction de) ses résultats d'apprentissage » (Goda et al., 2015, cité par Romero, 2019, § 3). Le « comportement temporel » est analysé à partir des interactions avec le dispositif de formation à partir d'indicateurs tels que le délai de réponse, la fréquence des interactions ou encore l'analyse du temps consacré à la tâche, qui peuvent être considérés comme le signe d'une bonne régulation de celle-ci ou, au contraire, de procrastination » (2019, § 3). Lorsque ce délai de réponses est long, il est le plus souvent interprété par les enseignants comme de la procrastination et conduit souvent ces derniers à adopter des jugements négatifs à l'égard de ces étudiants susceptibles de nuire à son image (Westgate et al., 2017). Or deux raisons bien différentes peuvent expliquer ces « retards ». Tout d'abord, les conditions de vie et de travail de l'étudiant peuvent entrer en conflit avec les contraintes des horaires académiques. Cette situation est bien documentée et connue depuis fort longtemps des équipes pédagogiques de formations à distance. Une seconde explication émerge des résultats des recherches que présentent ces derniers auteurs : « ils font état de différents types de procrastination, dont certains sont délibérément adoptés afin de favoriser une forme de productivité (« *productive procrastination* ») visant à réduire les incertitudes liées à la réalisation de la tâche » (Romero, 2019, *ibid.*).

Utilité des données

Certains contributeurs soulèvent un critère complémentaire pour évaluer la qualité des données récoltées, celui de leur utilité. Celui-ci va à l'encontre de la tendance évoquée par Pierrot (2019) d'un « toujours plus de données » que l'on peut observer dans de nombreuses recherches. Poellhuber et Roy affirment que « l'argument d'utilité

des données et variables ciblées devrait prévaloir sur celui d'exhaustivité » (2019, § 11). Tubaro explique qu'il faut aussi bien souvent faire « un arbitrage entre la taille et la richesse des bases de données » (Tubaro, 2019, §7). A. Boyer parle, quant à elle, de « données indispensables dans un contexte d'apprentissage donné » (2019, § 8) : « Schématiquement, l'utilité d'une donnée consiste à déterminer ce que la donnée apporte relativement à ce qu'elle coûte, que ce soit en termes monétaires, éthiques, complexité de collecte ou niveau de performances » (Boyer, 2019, § 8). Plus précisément, il s'agit donc de se poser des questions de ce type : n'est-il pas préférable de se passer de certaines données, parce que leur coût éthique est supérieur au bénéfice qu'elles permettent en termes de performances ? Ne vaut-il pas mieux gagner ou conserver la confiance des utilisateurs en renonçant à certaines données personnelles quitte à perdre éventuellement de la précision dans les résultats ? (ibid.) La pertinence de ces questions apparaît notamment lors de la conception et de la mise en œuvre d'algorithmes de prédiction. Il s'agit dans ce cas d'évaluer l'importance relative, la « qualification », d'une donnée particulière (absence ; 10%, en plus ou en moins), sur les performances du logiciel et la perception de cette différence par les utilisateurs. Il est cependant difficile de donner une réponse générique à ces questions dans la mesure où, souligne Boyer, l'utilité d'une donnée ne peut s'évaluer que par rapport au contexte particulier de chacune de situation, « des sources de données disponibles, des besoins en performances des utilisateurs et de leur ressenti » (ibid.).

Enfin, la notion d'utilité de la donnée possède le mérite de mettre en évidence la problématique des coûts « cachés » éthiques, mais aussi monétaires des LA, rarement pris en compte dans les recherches. Du point de vue financier, Tubaro (2019) signale les coûts élevés de recueil, de stockage, de traitement des données massives (d'étiquetage, de recueil, de préparation et de tri) ainsi que ceux de la maintenance des plateformes. L'auteure indique que ces coûts génèrent de plus de grandes disparités entre les institutions publiques de recherche et les géants du numérique ainsi que des inégalités entre les universités plus ou moins bien dotées :

« Pour stocker de grandes bases de données et faire tourner des algorithmes parfois très gourmands en puissance de calcul, des équipements informatiques coûteux sont nécessaires. On constate depuis quelques années l'impossibilité pour la recherche publique de concurrencer les grandes multinationales du numérique, plus riches en données ainsi qu'en infrastructures computationnelles. La mise en place et la maintenance d'environnements virtuels d'apprentissage sont aussi très coûteuses, et génère des inégalités entre fournisseurs. Dans le cas des MOOCs par exemple, l'avantage des grandes universités américaines comme Stanford et MIT est évident, d'autant plus qu'elles peuvent compter sur une audience internationale très large du fait de l'usage de la langue anglaise, qui leur permet de mieux maîtriser leurs coûts moyens (Banerjee & Duflo, 2014). D'autres établissements moins

bien ressourceés optent souvent pour des solutions plus modestes, au prix d'une performance technique plus faible et d'un accès à des bases de données de plus petite taille » (2019, § 10).

Une ouverture méthodologique : épaisseur et hétérogénéité des données

De toute évidence parmi les contributeurs et les contributrices, il existe un consensus quant à la nécessité de renforcer les qualités des données. La multiplication et la diversification de celles-ci relativement à chaque objet et à chaque comportement étudiés ainsi que des approches méthodologiques constituent la piste la plus prometteuse. Dans cette perspective, Luengo propose les notions complémentaires d'« épaisseur » et d'« hétérogénéité » de la donnée. Pour nous, il s'agit de propositions intéressantes en ce qu'elles contribuent à expliciter les critères de qualité du processus de recherche :

« À propos des données, je parle souvent de « données épaisses ». Je m'explique. Ce qui me gêne dans de nombreuses recherches utilisant les LA, menées en dehors d'une perspective et d'une équipe pluridisciplinaires, c'est qu'elles cherchent à valider des démarches, des procédures, des méthodes statistiques et/ou algorithmiques, mais qui ne font pas apparaître un intérêt suffisant du point de vue de l'apprentissage et de l'enseignement. Par exemple, quand on travaille sur la notion de décrochage dans les MOOCs, se baser uniquement sur les traces d'utilisation des vidéos, les logs de connexions me semble insuffisant dans la mesure où l'on ne prend en compte ni le contexte pédagogique, ni le contenu de la vidéo ni l'activité d'appropriation de celui-ci par l'apprenant » (Peraya & Luengo, 2019, § 8).

Pour Luengo, une donnée *épaisse* est une donnée qui « décrit de la façon la plus détaillée, la plus fine aussi, l'activité de l'apprenant dans un environnement numérique comme un EIAH. C'est une donnée qui permet de reconstituer la sémantique de l'action qui est liée au processus d'apprentissage » (ibid.). Quant à l'hétérogénéité de la donnée, l'auteure la définit comme suit : « Il s'agit de multiplier les traces qui décrivent une action de l'apprenant afin d'enrichir le plus possible la description de celle-ci, autrement dit de lui donner cette épaisseur. Il convient donc de croiser plusieurs traces de nature différente relative à la même action de l'apprenant » (ibid.). Cette conception s'applique particulièrement aux EIAH qui constituent le principal contexte d'observation de l'auteure : dans ceux-ci, il est possible, par exemple, de savoir précisément ce qu'a fait l'apprenant – construire un point, un segment, déplacer un objet, par exemple – et de décrire les gestes qu'il a effectués, les événements qui se sont déroulés et ce qu'il a lui-même regardé durant ce temps. Les données recueillies dans un EIAH auront plus d'épaisseur que celles qui le sont dans un MOOC, car « les premiers sont plus orientés vers l'apprentissage et vers la recherche plus que vers la diffusion à grande échelle :

leur ingénierie est donc différente » (ibid.). De plus, la prise en compte du contexte – la description et la connaissance de tous ses dimensions telles que les objectifs, les approches pédagogiques, les publics, l'ingénierie, les environnements, etc. – dans lequel se déroule l'apprentissage est essentielle pour deux raisons. Tout d'abord, elle contribue à doter la donnée d'une partie de son épaisseur et deuxièmement, elle « définit le domaine de validité de la recherche, mais elle constitue aussi l'une des conditions de sa répliquabilité et, par conséquent, de sa validité scientifique » (ibid.).

Les questions d'ordre méthodologique sont profondément liées aux aspects épistémiques que nous avons évoqués au début de ce texte, mais elles font émerger aussi d'autres questions, d'ordre éthique cette fois, comme celles de la transparence des algorithmes, des biais, des discriminations et des inégalités qu'ils peuvent induire ou encore de l'utilisation des données personnelles dans le respect des droits de la personne.

POUR UNE ÉTHIQUE DES LA ET DES ALGORITHMES

Les problèmes d'éthique évoqués à propos des algorithmes ou des LA concernent essentiellement les biais, la transparence des procédures propres à chaque étape du processus et la responsabilité des acteurs comme l'expliquent tous les contributeurs de la rubrique.

Des biais inévitables ?

Si l'on excepte la manipulation des données visant à influencer l'opinion publique à des fins commerciales ou politiques (on se souviendra du scandale lié à *Cambridge Analytica* lors des dernières élections présidentielles américaines), l'une des inquiétudes des chercheur(e)s comme d'ailleurs du grand public se cristallise autour de l'algorithme et de la confiance que l'on peut lui accorder. Il existe des exemples connus, car ils ont défrayé les milieux professionnels et la presse grand public, d'algorithmes qui ont introduit des biais dans les résultats et ont, en conséquence, entraîné des discriminations sociales ou raciales.

On se souvient du cas de l'algorithme de recrutement développé par Amazon en 2014 et abandonné en 2015, car il faisait de la discrimination à l'embauche (Dastin, 2018, cité par Gras, 2019 §7). Ayant été conçu sur la base des CV reçus par l'entreprise durant les dix dernières années, majoritairement des CV d'hommes, il rejetait ou déclassait les CV de femmes. Il y eut aussi ce concours international de beauté, *Beauty.Ai.2.0*⁹, organisé en 2016 par le groupe *Youth Laboratories* spécialisé dans l'apprentissage machine et soutenu par Microsoft. Parmi les 6000 personnes

9 Voir <http://beauty.ai/>

qui ont soumis leur photo, toutes jugées par des intelligences artificielles, des robots¹⁰, l'écrasante majorité des gagnants (44 personnes) était des personnes de type caucasien, « une poignée était des asiatiques et une seule personne avait la peau foncée » (le *Guardian*, cité par Cadot, 2016). Alex Zhavoronko, le directeur scientifique du programme, a invoqué le fait que « les données utilisées pour nourrir les algorithmes et procéder à leur apprentissage afin d'établir des normes d'attractivité de beauté ne prenaient pas suffisamment en compte les minorités » (Le Roy, 2016). Un algorithme est construit par des êtres humains : il reflète ou reproduit donc leurs opinions, leurs conceptions et leurs partis-pris ; ceux-ci se trouvent inscrits dans la base de données au moment de sa conception et se renforcent tout au long du processus d'apprentissage de l'intelligence artificielle.

Gras indique conclut à l'extrême difficulté d'éliminer les biais présents dans les données. Il indique aussi que cette préoccupation constitue une thématique de recherche « très populaire » depuis plusieurs années, ce qui montre l'importance de cette question (2019, § 7). Par ailleurs, il défend l'idée, dont la conclusion peut sembler peut-être naïve, selon laquelle « ce problème du biais des données et des algorithmes ne doit pas empêcher la recherche et l'innovation dans le domaine de l'apprentissage automatique. Il faut être conscient des limites de ces algorithmes qui ne font qu'imiter ce qu'ils observent, même partiellement, du comportement des humains. Je considère qu'il s'agit plutôt d'une opportunité pour révéler les iniquités de notre société, afin de les gommer pas à pas. Par exemple, maintenant que le biais dans les recrutements de la société Amazon est révélé, les recruteurs de la société ne vont-ils pas, même inconsciemment, prêter une attention particulière à ce biais ? » (2019, § 9).

Acculturation, transparence et responsabilité

Dans les pays de l'Union Européenne (UE), les données personnelles sont protégées depuis 2016 par le règlement général sur la protection des données (RGPD¹¹). Celui-ci se fonde sur le fait que tout(e) citoyen(ne) de l'UE « a droit à la protection des données à caractère personnel [le]/la concernant » (Commission nationale informatique et liberté - CNIL, 2018, § 1)¹². Il s'agit d'une part de protéger les données

10 « RYNKL, le premier d'entre eux, juge les photographies en notant les visages sur la base de leurs rides par rapport à leur âge. PIMPL attribue un score à un visage en analysant ses grains de beautés et sa pigmentation. MADIS attribue une note à un visage pour sa ressemblance avec celui de mannequins et d'acteurs du même groupe ethnique. Symmetry Master a cherché à évaluer, comme son nom l'indique, la symétrie du visage. AntiAgeist, enfin, compare l'âge réel de la personne à l'âge perçu » (Cadot, 2016).

11 Règlement no 2016/679. En anglais GDPR, General Data Protection Regulation.

12 Le RGPD « respecte tous les droits fondamentaux et observe les libertés et les principes reconnus par la Charte, consacrés par les traités [européens], en particulier le respect de la vie privée et familiale, du domicile et des communications, la protection des données à caractère personnel, la liberté de pensée, de conscience et de religion, la liberté d'expression et d'information, la liberté

à caractère personnel des personnes dont les données seront traitées et exploitées d'une part, de responsabiliser des acteurs, impliqués dans la collecte et le traitement de ces données. L'application du RGPD, rappelle B. Gras (2019), demande la mise en place d'une « gouvernance des données ». En France, dans un rapport qui fait suite à une consultation sur les enjeux éthiques des algorithmes et de l'intelligence artificielle, la CNIL a recommandé de former à l'éthique des LA et des algorithmes tous les « maillons de la chaîne algorithmique » (Demiaux, 2017, p. 54), autrement dit tous les acteurs impliqués dans la démarche: les professionnels, les concepteurs, les utilisateurs, les citoyens. Le texte rappelle que « Le citoyen est l'un des acteurs centraux des systèmes algorithmiques. D'une part, car les algorithmes ont un impact croissant sur son existence. D'autre part, parce qu'il est particulièrement bien placé pour en identifier les éventuelles dérives » (ibid.). Les contributeurs au débat mené dans DMS qui ont abordé cet aspect de la discussion, notamment A. Boyer, B. Gras et L. Pierrot, estiment qu'il est indispensable de développer une acculturation aux données, à l'informatique et à l'intelligence artificielle. Celle-ci serait fondée sur la transparence, l'accompagnement, la participation afin que chacun, quel que soit son rôle, soit capable de participer au processus en connaissance de cause, autrement dit en disposant « des clés de compréhension suffisantes pour se saisir des enjeux associés » (Pierrot, 2019, § 21). Une telle acculturation viserait à rendre les utilisateurs capables de donner leur « consentement libre et éclairé » avant tout usage des technologies, des plateformes et réseaux numériques (Poellhuber & Roy, 2019, §12). Mais cela suppose bien évidemment qu'en même temps tous les opérateurs de collecte et de traitement des données, qu'ils soient publics ou privés – on songe bien entendu aux GAFAs (Google, Apple, Facebook, Amazon)–, abandonnent leurs pratiques opaques actuelles et rédigent leurs formulaires de consentement de manière transparente, compréhensible et lisible pour les utilisateurs (ibid.).

Dans cette dernière perspective, nous voudrions signaler deux initiatives intéressantes : le serment d'Hippocrate pour *Data Scientist*¹³ et la Déclaration de Montréal pour une intelligence artificielle responsable¹⁴ qui proposent aux chercheurs de s'engager à titre individuel dans une démarche éthique fondée sur les valeurs, les recommandations et les principes fondateurs de chacune de ces deux chartes. Ces deux initiatives montrent la prise de conscience des acteurs universitaires et leur volonté d'inscrire leurs pratiques de recherche dans le cadre d'une gouvernance éthique des données.

Mais une gouvernance éthique des données demande encore d'autres conditions :

d'entreprise, le droit à un recours effectif et à accéder à un tribunal impartial, et la diversité culturelle, religieuse et linguistique » (Journal Officiel de l'UE, 2016, § 4).

13 Voir <https://hippocrate.tech/>

14 Voir <https://www.declarationmontreal-iaresponsable.com/>

la collaboration de toutes les parties concernées « un contexte organisationnel adapté, permettant l'implication d'acteurs multiples : des chercheurs issus de disciplines différentes, premièrement des sciences de l'éducation et de l'informatique (mais aussi, peut-être, du droit, de l'éthique, voire de la gestion ou de l'ergonomie), ainsi que des enseignants (*a priori*, dans toute discipline), des techniciens et/ou assistants, des responsables administratifs, et bien sûr des apprenants. » (Tubaro, 2019, § 15). La multidisciplinarité évoquée ici par Tubaro, est considérée par d'autres auteures (notamment Romero, 2019 ; Boyer, 2019) comme l'une des conditions indispensables à la réussite d'une démarche éthique et utile aux apprenants. Tubaro conclut : « Là aussi, le chemin peut être ardu, nécessitant une souplesse institutionnelle qui n'est pas toujours au rendez-vous, mais il faut essayer. » (2019, § 15).

Les tableaux de bord (TDB) : un exemple particulièrement intéressant d'utilisation des LA

La conception et le développement de tableaux de bord (*Learning Analytics Dashboard*) constituent un des sous-domaines très important de la recherche actuelle. Un TDB est en effet un dispositif essentiellement destiné, à recueillir des données massives relatives au comportement et au processus d'apprentissage des apprenants, à mieux identifier ces processus et comportements, enfin, sur cette base, à tenter de les améliorer. Comment alors, concrètement, procéder ? La réponse est complexe, car les situations et donc les problèmes qu'elles peuvent être bien différents selon les contextes (recherche ou enseignement), selon les finalités et les usages (description et compréhension de processus généraux, accompagnement et personnalisation du processus d'apprentissage individuel, prédiction et analyse des étudiants présentant un risque de décrochage, etc.).

Le débat mené au sein de la rubrique « Débat-discussion » de DMS a permis le partage d'expériences et de pratiques souhaitables ou, en tout cas, se rapprochant de cet idéal de gouvernance éthique des données. Prenons quelques exemples. Une première proposition serait d'offrir aux apprenants une clause d'*opting out*, de désengagement du processus d'utilisation de leurs données, ce qui semble, pour des raisons techniques, plus facilement réalisable que lors de celui de la collecte de leurs données (Poellhuber & Roy, 2019, § 17). L'étudiant choisirait ainsi qui peut utiliser ses données personnelles. Gras, dans le cadre du projet DUNE EOLE¹⁵ financé par l'Agence nationale de la recherche française a accordé aux étudiants, en toute transparence, la possibilité de garder le contrôle des données personnelles les concernant : l'apprenant doit pouvoir accéder aux données brutes collectées le concernant, choisir les informations affichées sur son compte-rendu, contester et corriger les informations qu'il juge erronées ou imprécises et demander la suppression intégrale des données le concernant (2019, §

¹⁵ Voir <http://www.dune-eole.fr/>

9). Selon l'auteur, une utilisation des LA qui respecte ces principes de transparence doit être considérée comme éthique.

À travers ces comptes-rendus d'expériences, plusieurs tendances s'affirment clairement. D'abord, l'étudiant devrait être au centre du processus de conception et d'utilisation des TDB. Il devrait pouvoir personnaliser son tableau de bord et choisir d'afficher les données qui lui semblent pertinentes pour ses propres besoins d'apprentissage, ce qui suppose néanmoins, de sa part, une bonne maîtrise des processus d'autorégulation et d'autodétermination. Deuxièmement, en amont, il devrait être fortement impliqué dans le processus de conception des tableaux de bord. Dans le cadre du projet DUNE EOLE 103 étudiants de l'Université de Lorraine (1^{re} année de licence) ont ainsi participé à des discussions qui leur ont permis d'exprimer leurs souhaits, leurs attentes par rapport au TDB. De nombreuses idées et suggestions ont surgi de ces échanges : l'importance de la notification de chaque évolution, surtout à la baisse, des indicateurs du TDB ; la possibilité de personnaliser l'affichage des informations dans des formats différents en meilleure adéquation avec les besoins de chacun ; l'intégration d'indicateurs auxquels les concepteurs n'avaient pas songé ; la nécessité de clarifier la manière dont les indicateurs sont calculés ; la prise en compte des situations particulières comme le handicap, les cas de maladie, les conditions de travail de ceux qui sont déjà dans la vie professionnelle, la situation familiale et les enfants à charge, etc.) ; enfin, les informations affichées doivent demeurer motivantes pour l'étudiant (Gras, 2019, § 17).

Les principales préoccupations des participants au débat de la rubrique, ceux qui ont abordé cette question, rejoignent les souhaits des étudiants évoqués ci-dessus. Poellhuber & Roy (2019), par exemple, suggèrent que la construction des TDB s'appuie sur une conception « sur les principes de la théorie de l'autodétermination (Ryan & Deci, 2000), qui vise à faire en sorte que les choix et les comportements soient de plus en plus auto-régulés (plutôt qu'hétéro-régulés), ainsi que sur les principes de la psychologie positive, qui visent à favoriser le fonctionnement optimal des individus plutôt qu'à focaliser sur leurs manques. [...] Cela voudrait dire de laisser une large part de contrôle et de choix aux apprenants dans l'utilisation et la configuration des tableaux de bord qui les concernent. Cela signifierait aussi planifier des interventions qui visent à satisfaire les besoins de compétence, d'affiliation et de contrôle, et qui visent aussi à obtenir des effets positifs sur le plan du bien-être des apprenants. Cette posture aiderait peut-être à prévenir certaines des dérives possibles avec les analytiques » (§ 14). La position de ces deux auteurs pointe le rôle fondamental de la posture de l'enseignant comme des concepteurs du dispositif de recueil, de traitement, d'analyse des données et de restitution de l'information aux apprenants.

C'est sans doute aussi sur un changement de posture que se construit la vision d'une algorithmique « bienveillante » (Boyer, 2019, § 16), celle qui fonde le travail

de l'équipe KIWI du Laboratoire LORIA¹⁶ en France. Il s'agit essentiellement de valoriser les efforts, l'engagement et l'implication de l'apprenant dans les tâches d'apprentissage qu'il réalise. Concrètement, le score obtenu par l'apprenant ne peut jamais diminuer, il peut tout au plus « stagner » si l'apprenant est momentanément inactif. Par contre, il a une valeur relative, rapportée aux caractéristiques de chaque étudiant : « le gain de score dépend de l'activité que l'apprenant entreprend et de sa difficulté, du niveau de l'apprenant et du « risque » qu'il prend. Ainsi un élève « moyen » qui réussit un exercice difficile verra son score augmenter davantage qu'un « bon » élève qui fait ce même exercice » (Boyer, 2019, § 19). On sait que les algorithmes sont utilisés, souvent de manière efficace, comme des instruments de prédiction : ils permettent d'identifier les apprenants qui risquent de décrocher. Pourtant, lorsqu'un apprenant est détecté comme susceptible de décrocher, cette information ne lui est pas communiquée dans son tableau de personnel : « En effet, l'objectif de notre démarche est d'accompagner l'étudiant, pas de le stigmatiser » (Boyer, op. cit., § 20). Le seul destinataire du TDB est l'apprenant, il le consulte quand il veut, ou pas. Il peut modifier ou corriger certaines informations qu'il jugerait erronées et il peut décider avec qui il partage son TDB, que ce soient des pairs ou l'enseignant, etc. Voilà quelques exemples de mesures concrètes qui rendent l'algorithmique et sa pratique bienveillantes. Mais, le lecteur l'aura compris, la bienveillance de l'algorithme est d'abord celle de l'équipe pédagogique au sens large (développeurs, enseignants, informaticiens, ingénieurs pédagogiques, etc.).

CONCLUSION

La relecture des contributions au débat de la rubrique « Débat-discussion » et la synthèse que nous en avons donnée ici ne peuvent être considérées comme une revue de la littérature critique exhaustive. Le nombre de contributeurs et de contributrices demeure limité dans le contexte éditorial d'une telle démarche. De plus, d'autres contributeurs auraient pu être sollicités ; certain(e)s l'ont été, mais ont décliné l'invitation. Néanmoins, nous pensons qu'il s'agit là d'une vision fidèle du débat, mais aussi représentative de la problématique ainsi que de ses enjeux.

Nous laisserions volontiers le soin de conclure à deux des auteures ayant contribué au débat. Pulker tout d'abord qui, sur la base de l'analyse des pratiques des LA à l'*Open University* anglaise, écrit : « *Research and practice in LA in higher education have left more questions than have given answers on their impact on online and distance education* » (2019, § 2). Tubaro, quant à elle, espérait, dans sa contribution, avoir donné « une vision des *big data* en général, et des LA en particulier, qui sans se laisser emporter par les enthousiasmes

¹⁶ Université de Lorraine. Voir <https://www.loria.fr/fr/>

du début, reste optimiste quant aux opportunités ouvertes par ces nouvelles données et techniques » (2019, § 16).

Espérons que cet article contribue modestement à la diffusion de cette vision.

RÉFÉRENCES

- Azemard, G., Ben Henda, M., & Hudrisier, H. (2015). *Les Big Data : Pistes de réflexion historiques, éthiques et épistémologiques pour l'appropriation sociale ; retours et attentes d'expérimentations en Learning Analytics*. Paper presented at the Conférence ORBICOM : Données ouvertes, Media et citoyenneté. Mexico : Universidad Iberoamericana. Retrieved from https://archivisic.ccsd.cnrs.fr/sic_01321534/document.
- Bastin, G., & Tubaro, P. (2018). Le moment BIG DATA des sciences sociales. *Revue Française de Sociologie*, 3(59), 375-394.
- Benzécri, J.-P. (1973). *L'analyse des données*. Paris: Dunod.
- Bourdieu, P. (1979). *La distinction. Critique sociale du jugement*. Paris: Minuit.
- Boyer, A. (2019). Quelques réflexions sur l'exploration des traces d'apprentissage. *Distances et Médiations des Savoirs*, 27. Retrieved from <http://journals.openedition.org/dms/4086>.
- Cadot, J. (2016). Beauty.AI : Un algorithme peut-il être raciste ? Retrieved from <https://www.numerama.com/tech/193524-beauty-ai-algorithme-etre-raciste.html>.
- Campbell J., DeBlois, P., & Oblinger, D. (2007). Academic Analytics: A new tool for a new era. *EDUCAUSE Review*, 42(4), 40-57.
- Champin, P.-A., Mille, A., & Prié, Y. (2013). Vers des traces numériques comme objets informatiques de premier niveau : Une approche par les traces modélisées. *Intellectia*, 59, 171-204.
- CNIL (2018). Le règlement général sur la protection des données – RGPD. Retrieved from <https://www.cnil.fr/fr/reglement-europeen-protection-donnees>.
- Demiaux, V. (2017). Comment permettre à l'homme de garder la main ? Les enjeux éthiques des algorithmes et de l'intelligence artificielle. CNIL. Retrieved from https://www.cnil.fr/sites/default/files/atoms/files/cnil_rapport_garder_la_main_web.pdf.
- Engeström, Y. (1987). *Learning by expanding: An activity-theoretical approach to developmental research*. Helsinki, Finland : Orienta-Kosultit Oy.
- Gras, B. (2019). Éthique des Learning Analytics. *Distances et Médiations des Savoirs*, 26. Retrieved from <http://journals.openedition.org/dms/3768>.
- Hayashi, C. (1998). What is Data Science? Fundamental concepts and a heuristic example. In C. Hayashi, K. Yajima, H. H. Bock, N. Ohsumi, Y. Tanaka & Y. Baba (Dir.), *Data Science, classification, and related methods*. In *Proceedings of the Fifth Conference of the International Federation of Classification Societies (IFCS-96)* (pp. 40-51). Springer : Japan.
- Huberman, M., & Milles, M. (1991). *Analyse des données qualitatives. Recueil de nouvelles méthodes*. Bruxelles: De Boeck.
- Jones, R.A. (2000). *Méthodes de recherches en sciences humaines*. Bruxelles: De Boeck.
- Journal Officiel de l'UE (2016). *Règlement (UE) 2016/679 du parlement européen et du conseil du 27 avril 2016*. Retrieved from <https://eur-lex.europa.eu/legal-content/FR/TXT/?uri=CELEX%3A32016R0679>.
- Labarthe, H., & Luengo, V. (2016). *L'analytique des apprentissages numériques*. Université de Paris 6,

- Laboratoire d'Informatique de Paris 6 (LIP6). Retrieved from [https:// hal.archives-ouvertes.fr/hal-01714229/document](https://hal.archives-ouvertes.fr/hal-01714229/document).
- Leontiev, A. (1976). *Le développement du psychisme*. Paris: Éditions sociales.
- Le Roy, S. (2016). Un concours de beauté mené par une IA jugée raciste. *L'AD*. Mis en ligne le 13 septembre. Retrieved from <https://www.ladn.eu/tech-a-suivre/data-big-et-smart/un-concours-de-beaute-mene-par-une-ia-jugee-raciste/>.
- Ouakrat, A., & Mésangeau, J. (2016). Resocialiser les traces d'activités numériques : une proposition qualitative pour les SIC. *Revue Française des Sciences de l'Information et de la Communication*, 8. Retrieved from <https://journals.openedition.org/rfsic/1795>.
- Paquay, L., Crahay, M., & De Ketele, J.-M. (2006). *L'analyse qualitative en éducation. Des pratiques de recherche aux critères de qualité. Hommage à Michael Huberman*. Bruxelles: De Boeck.
- Peraya, D. (2019a). Les *Learning Analytics* en question. *Distances et Médiations des Savoirs*, 25. Retrieved from [http:// journals.openedition.org/dms/3485](http://journals.openedition.org/dms/3485).
- Peraya, D. (2019b). Les *Learning Analytics* : Contraintes méthodologiques et « gouvernance » éthique des données. *Distances et Médiations des Savoirs*, 26. Retrieved from <http://journals.openedition.org/dms/3739>.
- Peraya, D., & Luengo, V. (2019). Les *Learning Analytics* vus par Vanda Luengo. *Distances et Médiations des Savoirs*, 27. Retrieved from <http://journals.openedition.org/dms/4096>.
- Peraya, D., Batier, C., Paquelin, D., Rizza, C., & Viera, M. (2009). Les traces d'usage et l'usage des traces : Le rôle des traces dans l'orientation stratégique des unités de développement de l'eLearning et des dispositifs hybrides dans l'enseignement supérieur. In F. Larose & A. Jaillet (Dir.), *Le numérique dans l'enseignement et la formation. Analyses, traces et usages* (pp. 37-80). Paris: L'Harmattan.
- Pierrot, L. (2018). *Circulation sociale des pratiques numériques juvéniles et genèse instrumentale*. Thèse de doctorat, Université de Poitiers, Poitiers, France).
- Pierrot, L. (2019). Les LA : Des réponses et des promesses. *Distances et Médiations des Savoirs*, 26. Retrieved from <http://journals.openedition.org/dms/3764>.
- Pinard, R., Potvin, P., & Rousseau, P. (2004). *Le choix d'une approche méthodologique mixte de recherche en éducation. Recherches Qualitatives*, 24, 58-80.
- Poellhuber, B., & Roy, N. (2019). Quelques réflexions en lien avec l'analytique de l'apprentissage. *Distances et Médiations des Savoirs*, 26. Retrieved from <http://journals.openedition.org/dms/3745>.
- Pulker, H. (2019). Learning Analytics to improve retention, Some critical questions. *Distances et Médiations des Savoirs*, 28. Retrieved from <http://journals.openedition.org/dms/4602>.
- Richard, C. (2018). Dans la boîte noire des algorithmes. Comment nous nous sommes rendus calculables. *Revue du Crieur*, 11, 68-85.
- Rogers, T. (2015). Critical realism and learning analytics research : Epistemological implications of an ontological foundation. In *LAK'15 Proceedings of the Fifth International Conference on Learning Analytics and Knowledge* (pp. 223-230). Retrieved from <https://dl.acm.org/citation.cfm?id=2723631>.
- Romero, M. (2019). Analyser les apprentissages à partir des traces. *Distances et Médiations des Savoirs*, 26. Retrieved from <http://journals.openedition.org/dms/3754>.
- Ryan, R. M., & Deci, E. L. (2000). Self-determination theory and the facilitation of intrinsic motivation, social development, and well-being. *American Psychologist*, 55(1), 68-78.

- Saporta, G. (s.d.). *Introduction au Data Mining et à l'apprentissage statistique*. Retrieved from <http://cedric.cnam.fr/~saporta/DM.pdf>.
- Settouti, L., Prié, Y., Marty, J., & Mille, A. (2007). *Vers des Systèmes à Base de Traces modélisées pour les EIAH*. Rapport de recherche RR-LIRIS-2007. Retrieved from <http://liris.cnrs.fr/publis/?id=2882>.
- Tubaro, P. (2019). *Les Learning Analytics vus par la sociologie. Distances et Médiations des Savoirs*, 28. Retrieved from <http://journals.openedition.org/dms/4608>.
- Westgate, E. C., Wormington, S. V., Oleson, K. C., & Lindgren, K. P. (2017). Productive procrastination: Academic procrastination style predicts academic and alcohol outcomes. *Journal of Applied Social Psychology*, 47(3), 124-135.