

Tuteurs intelligents : boucler la boucle

Benoît Choffin – Yolaine Bourda – Fabrice Popineau
LRI – UMR 8359

Jeanne Parmentier – Institut Villebon-Georges Charpak

Claude Chaudet – Webster University (Suisse)

Jill-Jênn Vie – RIKEN AIP (Japon)

Journée « IA pour l'éducation », PFIA 2018
Nancy, 4 juillet 2018



Introduction

Cours traditionnel

Relative homogénéité (acquis, classe d'âge,...) des apprenants
Présence continue d'un enseignant...
...qui adapte « en temps réel » son cours (fond/forme) au groupe d'élèves

Collecte fastidieuse et sujette à erreurs des données d'apprentissage
Adaptation réservée au niveau de la classe

Éducation en ligne

Forte hétérogénéité des apprenants

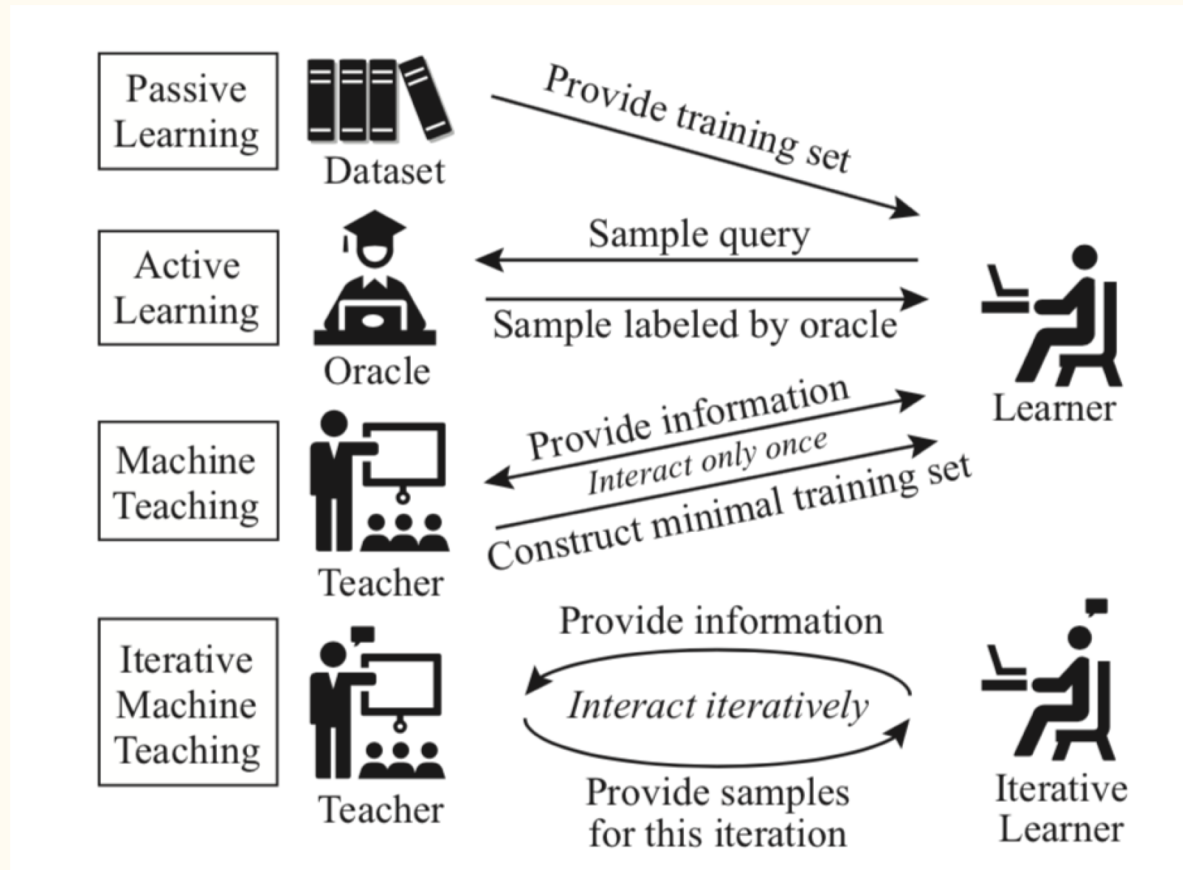
Présence plus sporadique du professeur
Pas ou peu d'adaptation de l'enseignement : « one-size-fits-all »

- Problèmes de **désengagement** et **désaffection** massifs (même si diversité des contextes d'enseignement)

Collecte aisée des données d'apprentissage
Adaptation possible au niveau de l'étudiant (« résoudre le problème 2-sigma », [Bloom, 1984])



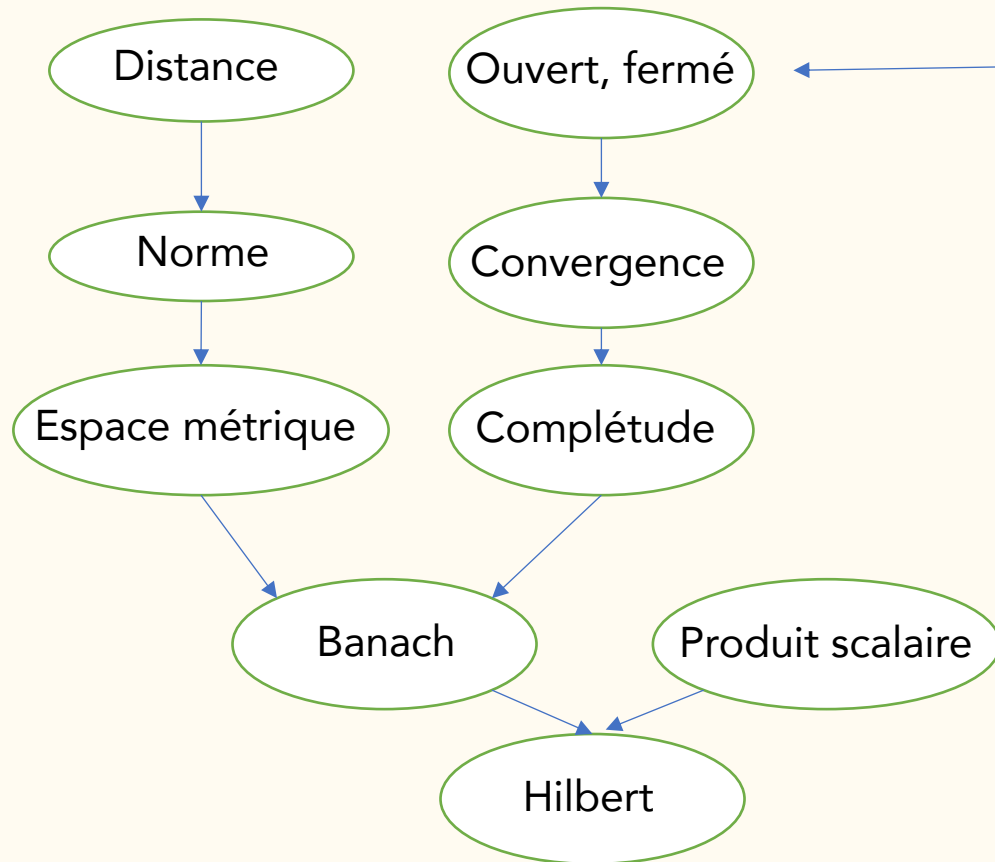
Une typologie des protocoles d'apprentissage



Source : [Liu et al., 2017a]

Outils pour la modélisation du domaine

Graphe de prérequis



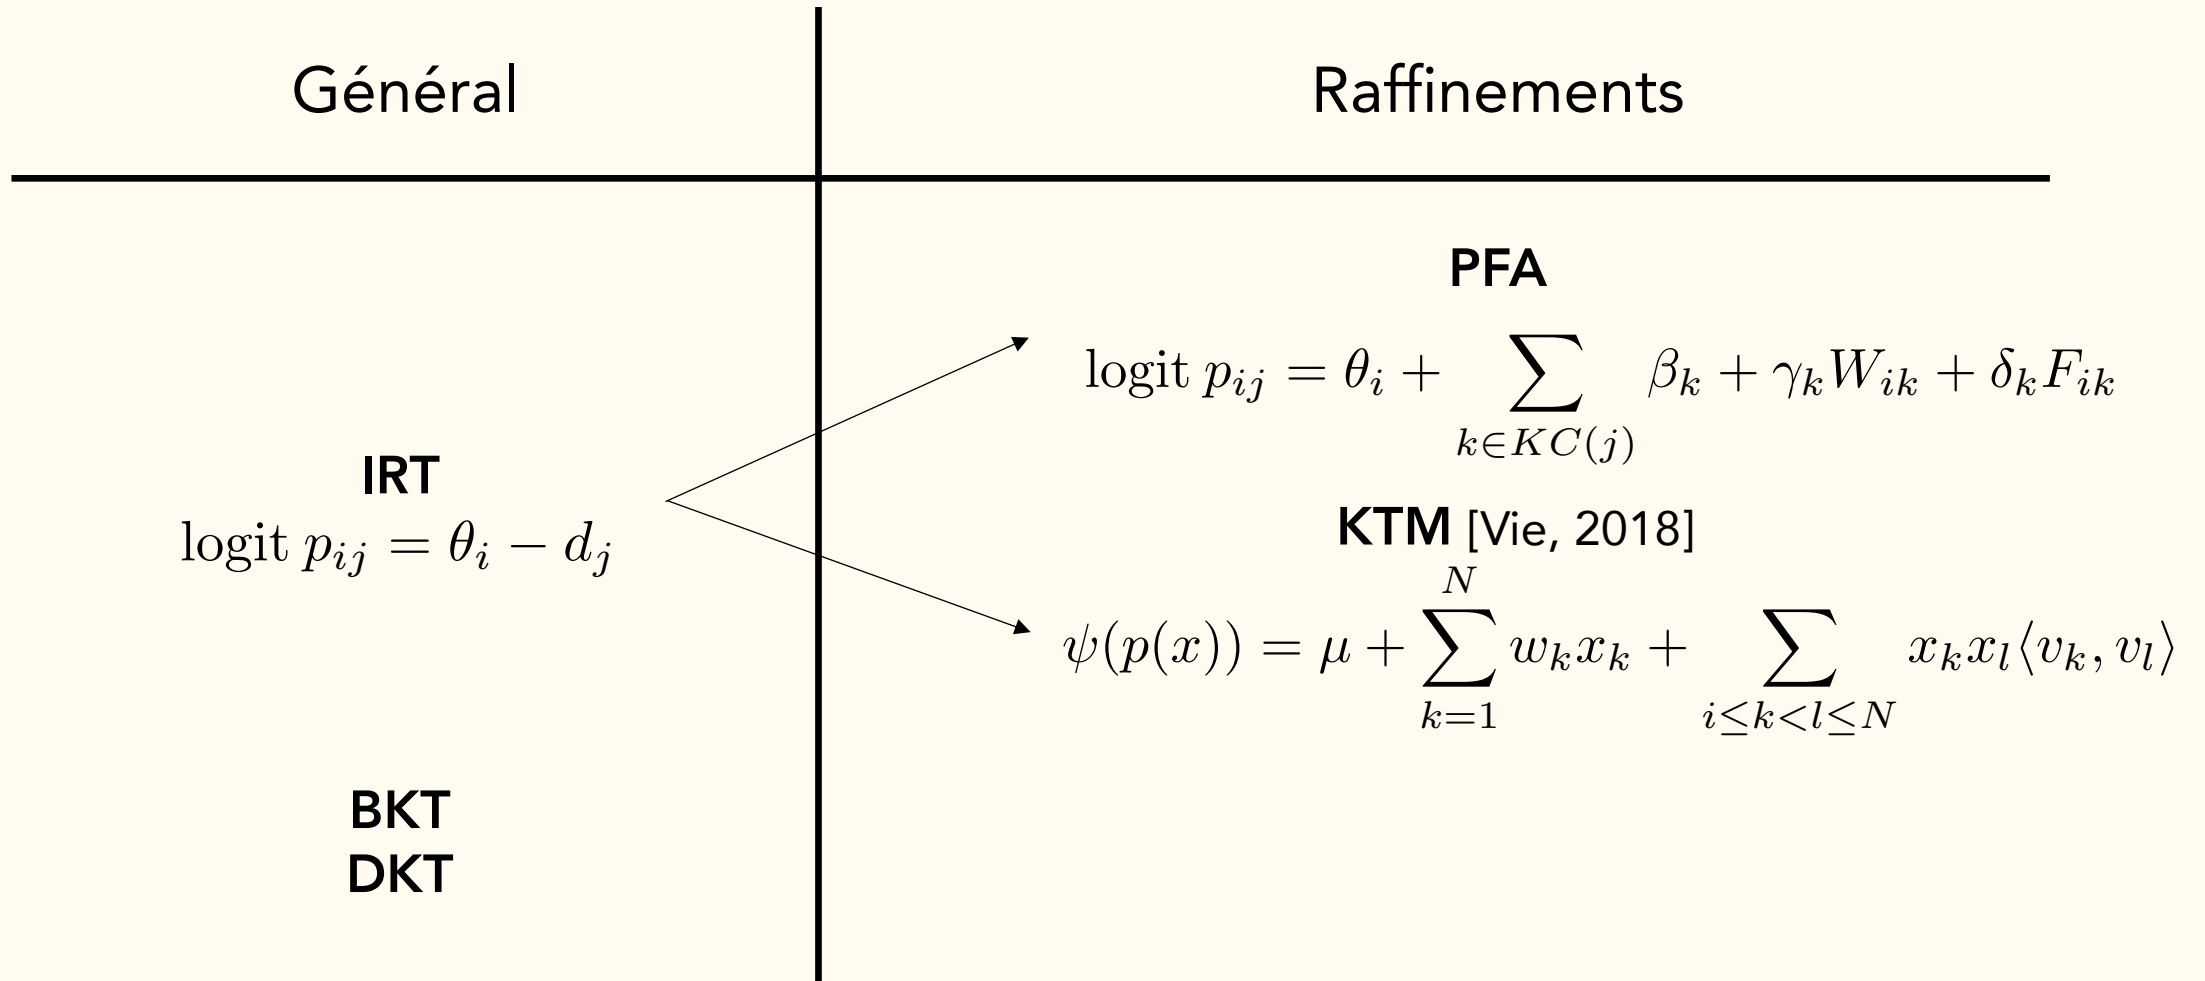
Q-matrice [Tatsuoka, 1983]

Composantes de connaissance (KC)

0	0.1	0	0.9	0	0
0.3	0	0	0	0.7	0
0.25	0.7	0	0	0	0.05
0	0	1	0	0	0
0	0.1	0.15	0.6	0	0.15

Exercices

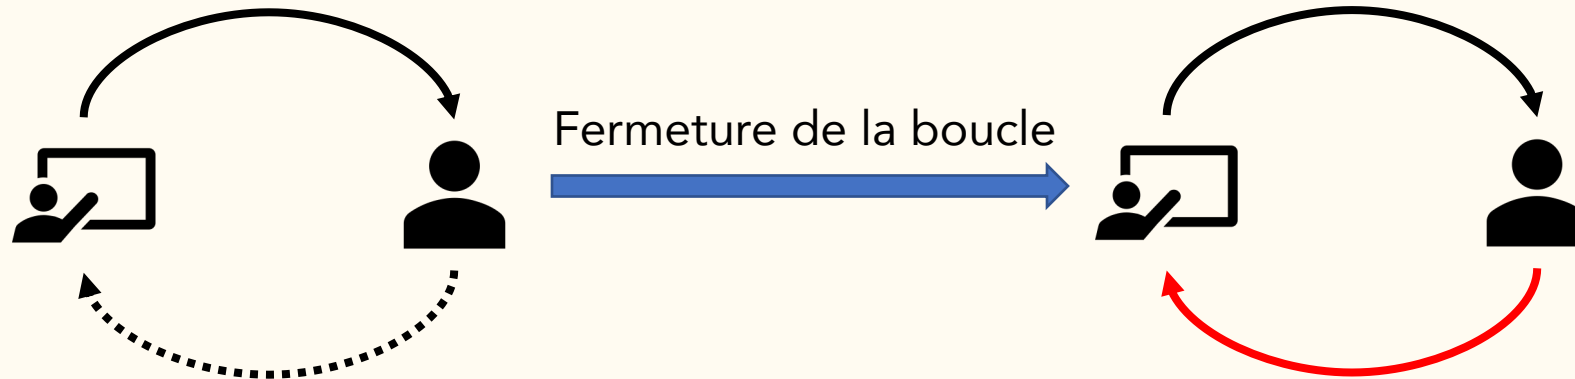
Modélisations de l'apprenant



Passive Learning : problèmes

- **Problèmes** principaux :
 - Données d'entraînement
 - Potentiellement **biaisées** par divers facteurs : préférences des apprenants, suivi de la trame d'un cours
 - Peuvent **manquer de variabilité** [Doroudi et al., 2017]
 - **Reproduction des biais** de la base d'apprentissage par les algorithmes
 - « Démarrage à froid »
 - Apprenant
 - Item
 - Comment réagir face à un apprenant dont le comportement est éloigné de ceux observés dans les données d'entraînement ?
 - Problème de l'interpolation ⇒ risque de ralentir le processus d'optimisation de l'apprentissage humain

De la boucle ouverte à la boucle fermée



Tuteur (artificiel)



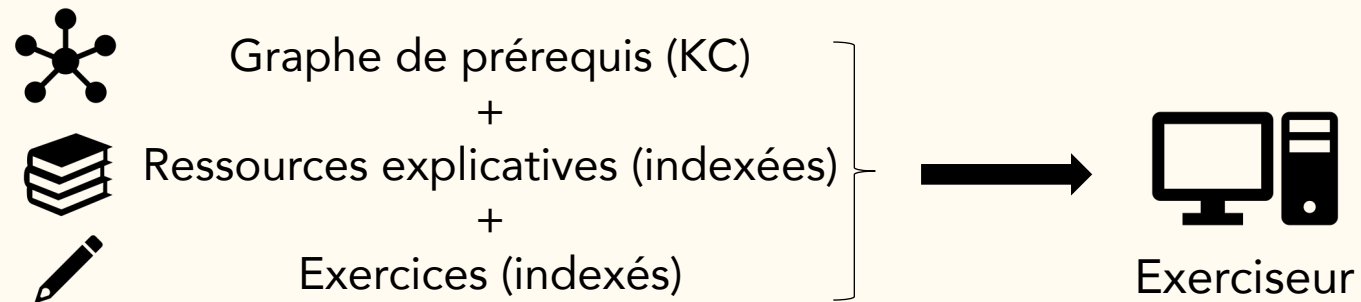
Apprenant

Iterative Machine Teaching

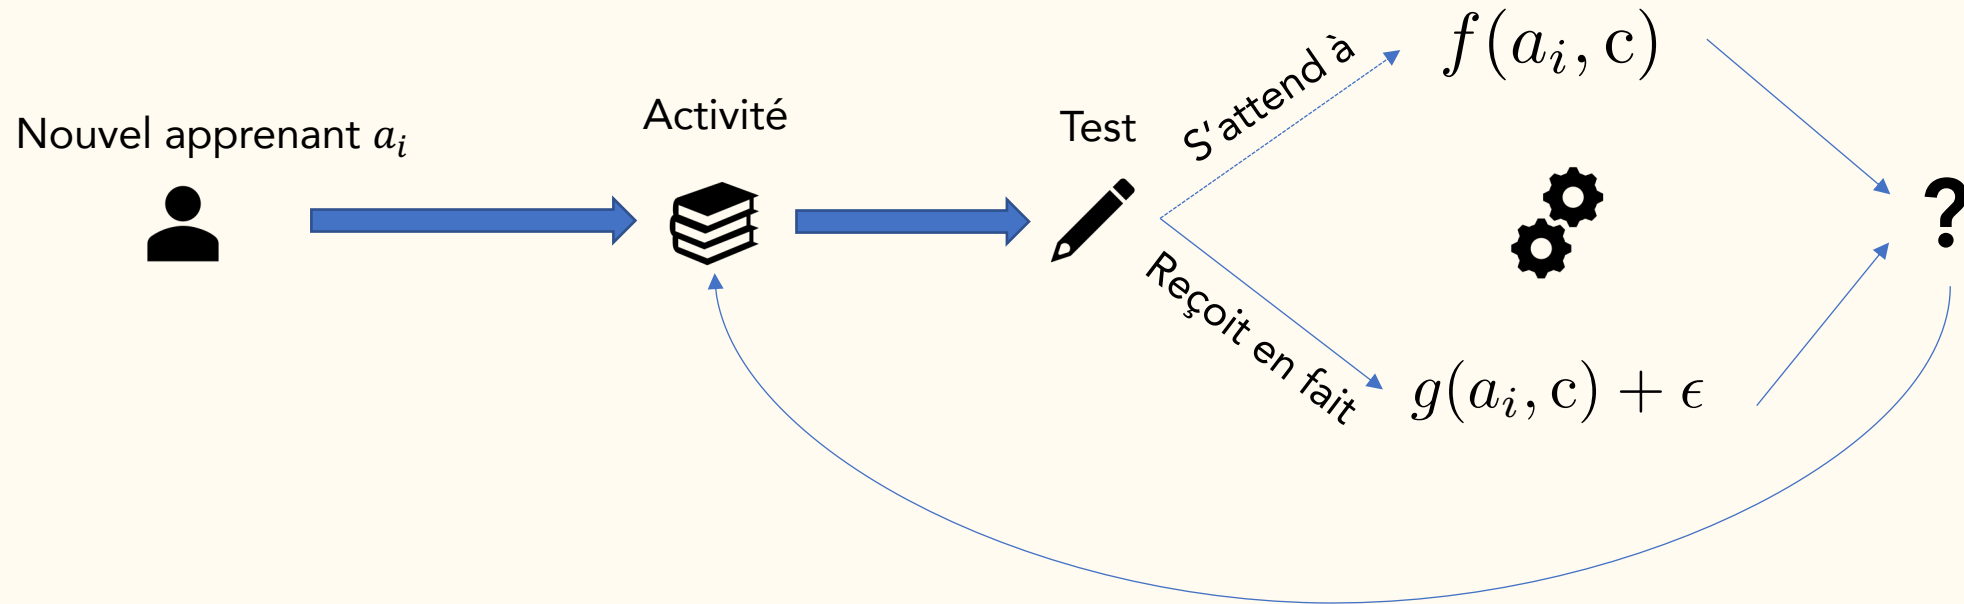
- Machine Teaching [Zhu, 2015] = inverse du Machine Learning
 - Origine : recherche automatique du jeu de données **optimal**/minimal pour apprendre à un algorithme un concept donné (e.g. une catégorie à prédire en classification binaire)
 - Extension à l'apprentissage humain [Zhu, 2015; Milli et al., 2017]:
 - Hypothèse (forte) : les êtres humains apprennent comme un algorithme de machine learning (e.g. SVM)
- Iterative Machine Teaching [Liu et al., 2017a] : accent sur protocole interaction apprenant/tuteur
 - Extension du Machine Teaching (« batch ») à un contexte itératif
 - Itératif \Rightarrow stratégies interprétables et pédagogiques [Milli et al., 2017]
 - À chaque étape, le modèle « enseignant » fournit au modèle « apprenant » un exemple (x^t, y^t) pour le faire converger le plus vite vers le modèle « enseignant » (considéré optimal)
 - L'enseignant peut avoir accès à différents niveaux d'information sur
 - la façon dont l'apprenant apprend (méthode d'optimisation, taux d'apprentissage $\eta_t \dots$);
 - où l'apprenant en est (e.g. w^t).
 - Implique différentes stratégies d'enseignement et performances
 - **Notre contexte de choix** car **attention fine** à la réponse de l'apprenant et utilisation optimale de cette information

Une plateforme de recherche pour l'Iterative *Human Teaching* : notre *exerceur*

- Développement en cours d'un « **exerceur** », plateforme d'entraînement en ligne
 - Simple : à chaque étape, on fournit à l'apprenant un élément de cours ou un exercice;
 - Fonctionnement autonome : sélection automatique de l'action optimale en $t+1$
 - Générique : utilisable avec n'importe quel cours respectant
 - Une formalisation en graphe de composantes de connaissances (KC);
 - La dichotomie ressources/exercices.
 - Ouverte : à tous, élèves (entraînement) comme enseignants (utilisation pédagogique)
- **But** : évaluation de politiques ou de méthodes d'apprentissage de politiques « bouclant la boucle »



Fonctionnement simplifié de l'exerciseur



- Exemples de politiques à tester :
 - Rythme chrono-biologique : faire apprendre au tuteur à quel point les processus cognitifs de chaque étudiant en particulier sont sensibles à la période de la journée;
 - Espacement de l'apprentissage : faire apprendre au tuteur les paramètres déterminant l'effet d'espacement chez l'apprenant.

Questions de recherche

- Question primordiale : quels gains (s'il y en a) sont apportés par le tuteur intelligent [Riopel] ? Dans quelle dimension (mémoire, performance à court terme, rapidité de couverture du graphe...) ? Par rapport à quelle(s) *baseline(s)* ?
- À quel point peut-on combiner les données des autres étudiants (*crowdsourcing*) à la mesure de l'apprentissage de l'étudiant courant ? Comment ?
 - Existe-t-il des catégories (*clusters*) d'apprenants ou les variations entre étudiants sont-elles continues ?
- Comment utiliser les signaux reçus par le tuteur pour améliorer en retour les connaissances « expert » intégrées [Liu et al., 2017b] ?
 - Exemple : graphe de dépendances.
- Comment gérer la problématique liée à la dimension de l'espace de recherche ?
 - Importance du dialogue avec d'autres disciplines : sciences cognitives [Lindsey et al., 2013], sciences de l'éducation,...
 - Peut-on personnaliser/adapter des phénomènes généraux mis en évidence par les sciences cognitives, comme le *spacing* ?

Merci pour votre attention !

Questions



Références

- [Bloom, 1984] Bloom, B. S. (1984). The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. *Educational researcher*, 13(6), 4-16.
- [Liu et al., 2017a] Liu, W., Dai, B., Humayun, A., Tay, C., Yu, C., Smith, L. B., ... & Song, L. (2017). Iterative machine teaching. *arXiv preprint arXiv:1705.10470*.
- [Tatsuoka, 1983] Tatsuoka, K. K. (1983). Rule space: an approach for dealing with misconceptions based on item response theory. *Journal of Educational Measurement*, 20(4), 345–354.
- [Vie et al., 2017] Vie, J. J., Popineau, F., Bruillard, É., & Bourda, Y. (2017). A review of recent advances in adaptive assessment. In *Learning Analytics : Fundamentals, Applications, and Trends* (pp. 113-142). Springer, Cham.
- [Vie, 2018] Vie, J.-J. (2018). Deep Factorization Machines for Knowledge Tracing. *Proceedings of the Thirteenth Workshop on Innovative Use of NLP for Building Educational Applications*, 370-373.
- [Doroudi et al., 2017] Doroudi, S., Alevan, V., & Brunskill, E. (2017, April). Robust evaluation matrix: Towards a more principled offline exploration of instructional policies. In *Proceedings of the Fourth (2017) ACM Conference on Learning@ Scale* (pp. 3-12). ACM.



Références

- [Zhu, 2015] Zhu, X. (2015, January). Machine Teaching: An Inverse Problem to Machine Learning and an Approach Toward Optimal Education. In *AAAI* (pp. 4083-4087).
- [Milli et al., 2017] Milli, S., Abbeel, P., & Mordatch, I. (2017). Interpretable and Pedagogical Examples. *arXiv preprint arXiv:1711.00694*.
- [Liu et al., 2017b] Liu, R., & Koedinger, K. R. (2017). Closing the Loop: Automated Data-Driven Cognitive Model Discoveries Lead to Improved Instruction and Learning Gains. *Journal of Educational Data Mining*, 9(1), 25-41.
- [Lindsey et al., 2013] Lindsey, R. V., Mozer, M. C., Huggins, W. J., & Pashler, H. (2013). Optimizing instructional policies. In *Advances in Neural Information Processing Systems* (pp. 2778-2786).