



HAL
open science

Enseignement de l'apprentissage automatique à destination d'ingénieur×e×s généralistes

Frédéric Sur

► **To cite this version:**

Frédéric Sur. Enseignement de l'apprentissage automatique à destination d'ingénieur×e×s généralistes. Academic Journal of Civil Engineering, 2023, 41 (2), pp.100-105. 10.26168/ajce.41.2.10 . hal-04213203

HAL Id: hal-04213203

<https://hal.science/hal-04213203>

Submitted on 5 Apr 2024

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.



Distributed under a Creative Commons Attribution 4.0 International License

Enseignement de l'apprentissage automatique à destination d'ingénieur·e·s généralistes

Frédéric Sur¹

¹ Responsable du cours de tronc commun « Introduction à l'apprentissage automatique » à Mines Nancy. Laboratoire Lorrain de Recherche en Informatique et ses Applications (LORIA), Université de Lorraine, CNRS, Inria. Campus scientifique BP 239, 54506 Vandœuvre-lès-Nancy cedex. members.loria.fr/FSur/

RÉSUMÉ L'apprentissage automatique est la discipline scientifique au cœur des récents et fulgurants succès de l'intelligence artificielle dans de nombreux domaines. Dans cet article, nous proposons un retour d'expérience sur l'enseignement de l'apprentissage automatique à destination d'ingénieur·e·s généralistes, dans le cadre d'un cours de tronc commun scientifique de la formation « Ingénieur Civil des Mines » de l'École des Mines de Nancy. L'objectif est de proposer un cours pertinent pour les élèves-ingénieur·e·s quel que soit le département scientifique choisi, grâce auquel ils et elles sauront mettre en application les principaux modèles d'apprentissage sur des données réelles variées et s'appuyer sur leur compréhension des fondements de la discipline pour identifier les limites pratiques, tout en ayant conscience des questions éthiques potentiellement soulevées.

Mots-clefs intelligence artificielle, apprentissage automatique, école d'ingénieurs, Mines Nancy

I. INTRODUCTION

En l'espace de quelques années, « intelligence artificielle » (IA) est devenu un terme omniprésent dans les médias, les discours politiques et marketing... et les offres d'emploi destinées aux ingénieurs. Cette explosion tient aux succès rencontrés dans de nombreux secteurs d'activité par l'apprentissage automatique (ou apprentissage machine, *machine learning*), discipline scientifique qui permet à des ordinateurs « d'apprendre » à partir de données numériques. Au niveau national, l'Etat a lancé en 2018 le programme national de recherche en intelligence artificielle (PNRIA) se traduisant par des appels à projets ciblés de l'Agence Nationale de la Recherche (ANR), des chaires académiques, ou les Instituts Interdisciplinaires d'Intelligence Artificielle (3IA). De manière concomitante, le « rapport Villani » (Villani et al., 2018) dresse le tableau des forces et faiblesses de la France et les perspectives d'avenir. Une partie importante du rapport concerne la formation : il s'agit de créer de nouveaux cursus en mettant l'accent sur l'interdisciplinarité. On peut noter que les écoles d'ingénieurs font l'objet d'une mention particulière : « Les formations en mathématiques et en informatique existantes, qui rassemblent les briques de base utiles à l'intelligence artificielle, devraient s'orienter naturellement vers

l'enseignement de l'intelligence artificielle. C'est le cas pour les écoles d'ingénieurs qui, déjà, mettent sur pied des formations spécifiques sur ce sujet. »

L'École des Mines de Nancy s'est emparée de la question dès 2018-2019 sous la responsabilité de la direction des formations et de la direction scientifique : un groupe de travail constitué d'enseignants, étudiants, *alumni*, et partenaires industriels a été chargé de réfléchir à l'intégration des thématiques IA dans la formation de Mines Nancy. Il est apparu qu'« intelligence artificielle » ne correspond pas réellement à un contenu académique au périmètre bien délimité, et que bon nombre de cours ou projets de différentes natures dans l'offre de formation relèvent déjà de cette thématique : si on se réfère à (Russel & Norvig, 2016), recherche opérationnelle, théorie des jeux, logique, représentation de connaissances, inférence statistique, algorithmique, optimisation, vision par ordinateur, robotique... font déjà partie du cursus sous une forme ou une autre. Il apparaît néanmoins que l'élément central de la révolution de l'IA dans les dernières années, à savoir l'apprentissage automatique, s'il est enseigné depuis 2018 aux élèves-ingénieurs du département Génie Industriel et Mathématiques Appliquées (un des cinq départements scientifiques de l'école), devrait être introduit au tronc commun scientifique. Il ne s'agit plus seulement de former des spécialistes, mathématiciens ou informaticiens, mais de sensibiliser tous les élèves-ingénieurs de Mines Nancy aux questions scientifiques, techniques, et éthiques de l'apprentissage automatique, dans une optique interdisciplinaire. Ce nouveau cours semble d'autant plus important que toutes les disciplines scientifiques sont à présent bousculées par l'IA (Larousserie, 2022) : du laboratoire académique au service de recherche et développement d'un grand groupe en passant par les jeunes entreprises innovantes, les approches basées sur les données sont omniprésentes. À Mines Nancy, ce constat se traduit par un nombre grandissant de projets ou de stages « à coloration IA » dans lesquels les étudiants sont encadrés par des partenaires industriels ou académiques. Nous vivons par ailleurs dans un monde d'IA ubiquitaire (on peut citer les assistants vocaux, les caméras de surveillance dites intelligentes, les aides à la décision algorithmique, la traduction automatique...), et les diplômés de Mines Nancy seront amenés à décider du déploiement de « solutions IA » ou à développer ces méthodes eux-mêmes.

Il a donc été décidé au printemps 2020 de créer un cours de tronc commun de six séances intitulé « Introduction à l'apprentissage automatique » au premier semestre de la seconde année (Bac+4) de la formation Ingénieur Civil des Mines, dès l'automne 2020. Ce cours suit chronologiquement un cours intitulé « Analyse de données », qui traite pour sa part des aspects statistiques des sciences des données.

II. UN ENSEIGNEMENT DE TRONC COMMUN POUR DES INGÉNIEURS GÉNÉRALISTES

A. Objectifs pédagogiques

Les élèves-ingénieurs de la filière Ingénieur Civil des Mines sont pour leur grande majorité issus de classes préparatoires scientifiques. Mines Nancy formant des ingénieurs généralistes, le tronc commun scientifique est large et comprend, pour ce qui concerne les enseignements d'informatique et mathématiques, des cours de probabilités, statistique, analyse numérique, programmation Python, algorithmique et recherche opérationnelle, sans évoquer les

enseignements de sciences physiques où les étudiants pratiquent la modélisation mathématique. C'est grâce à ce corpus de connaissances riche qu'il est possible de proposer un cours d'apprentissage automatique significatif en seulement six séances.

Les objectifs pédagogiques du cours sont triples :

- comprendre les principes fondamentaux de l'apprentissage automatique ;
- mettre en œuvre des modèles d'apprentissage sur des données réelles issues de différents domaines d'application ;
- interroger la pertinence des modèles, leurs biais implicites éventuels, et les impacts sociétaux potentiels.

Ces objectifs doivent permettre aux étudiants d'être davantage autonomes dans les projets scientifiques ou industriels dès la deuxième année d'études, d'être rapidement opérationnels dans un stage, de mieux décoder le discours politique ou marketing autour de l'IA, et d'approfondir dans des cours spécialisés pour ceux qui le désirent, à Mines Nancy ou dans d'autres formations en France ou à l'étranger. Chacune des six séances est organisée sous la forme d'un cours en amphithéâtre d'une heure suivi de travaux dirigés (TD) en salle machine pendant deux heures. Les étudiants doivent lire une vingtaine de pages d'un polycopié avant chaque séance. Au début des TD, un questionnaire à choix multiples constitué de quelques questions simples est proposé sur la plate-forme Moodle de l'Université de Lorraine afin de vérifier le travail régulier de chacun.

Le lecteur intéressé par le contenu détaillé du cours pourra consulter tout le matériel pédagogique (polycopié, supports de cours et de travaux dirigés) disponible librement en ligne (Sur, 2023). Le cours a été construit essentiellement sur la base de trois ouvrages de référence (Bishop, 2006), (Efron et Hastie, 2008), (Goodfellow, Bengio, & Courville, 2016), ainsi que sur les innombrables ressources disponibles sur Internet. En quelques mots, les choix suivants ont été faits.

- Dans le cadre d'un cours de tronc commun, le but est de dresser un panorama large de l'apprentissage automatique, sans se focaliser sur quelques modèles spectaculaires à la mode qui ne seraient utiles que dans des domaines d'applications spécifiques.
- Le cours traite de problèmes fondamentaux comme la théorie statistique de la décision, le dilemme biais-fluctuation, les notions de sous- ou sur-apprentissage et de régularisation, ou la malédiction de la dimension. Il semble important d'évoquer ces problèmes même sans y consacrer beaucoup de temps afin de dépasser une utilisation des modèles de l'apprentissage en boîte noire.
- Les modèles de l'apprentissage détaillés dans le cours sont les approches de régression *ridge* ou Lasso (pour faire suite à la régression linéaire vue en cours de statistiques), les techniques de classification non-supervisée (*clustering*), les classifieurs aux plus proches voisins, le classifieur naïf de Bayes, celui de la régression logistique, les machines à vecteurs-supports (permettant d'introduire la très riche astuce du noyau), les réseaux de neurones artificiels, et les réseaux convolutifs (*convolutional neural networks*, CNN) pour terminer sur les applications modernes à l'origine de la révolution en marche depuis une dizaine d'années.

- Les séances de travaux dirigés en salle machine permettent la mise en œuvre pratique des modèles vus en cours par l'intermédiaire de la bibliothèque Python scikit-learn (Pedregosa et al. 2011) et de la bibliothèque Tensorflow (Abadi et al. 2015) pour la séance dédiée aux CNN. Les travaux pratiques prennent la forme de carnets Jupyter. Tous ces outils sont des standards dans les milieux académiques et industriels et doivent être maîtrisés par un jeune ingénieur. Même s'ils sont guidés pour gagner du temps, les étudiants doivent être capables de choisir des modèles adaptés et de sélectionner un modèle et ses hyperparamètres de manière raisonnée. Les jeux de données utilisés concernent différentes disciplines afin de parler au plus grand nombre selon les centres d'intérêt de chacun.
- Chaque cours ou séance de travaux dirigés est l'occasion de questionner la pertinence des résultats et leurs implications sociétales. Sont ainsi évoqués des cas pratiques de modèles suggérant des décisions sexistes ou racistes issues de biais dans la base d'apprentissage, des communiqués de presse sensationnalistes ayant pour visée essentielle de faire monter un cours d'action, de dévoiements de l'éthique scientifique, de l'attitude des grandes compagnies qui possèdent données et ressources de calcul, et recrutent les scientifiques au risque d'assécher le milieu académique et privatiser la réflexion sur ces questions.

Une septième séance est consacrée au contrôle des connaissances. L'examen vise naturellement à vérifier que les objectifs pédagogiques sont atteints : une première partie traite de questions fondamentales, sans nécessiter une trop grande virtuosité mathématique, et une seconde partie traite d'un cas pratique proche de ceux vus lors des séances de TD.

B. Organisation pratique

Comme mentionné plus haut, chacune des six séances est constitué d'un cours en amphithéâtre pendant une heure, suivi de deux heures de travaux dirigés en salle machine. La pratique à Mines Nancy est que les étudiants lisent le polycopié avant d'assister au cours : celui-ci peut donc remettre en perspective le contenu du cours ou présenter des compléments d'information faisant la transition avec la mise en pratique qui suit. Les effectifs de la promotion de deuxième année font qu'il est nécessaire de constituer dix groupes de travaux dirigés... et recruter autant de collègues pour les encadrer. Le rôle des enseignants chargés des TD est très important, car ils sont l'interlocuteur privilégié des étudiants. Bien entendu, lorsqu'il s'agit de monter un nouveau cours de tronc commun, il est toujours indispensable de pouvoir compter sur une équipe pédagogique volontaire et dynamique. La difficulté dans le cas présent est que très peu de collègues étaient initialement spécialistes d'apprentissage automatique. Par ailleurs, l'objectif est de recruter aussi des enseignants non mathématiciens ou informaticiens, de manière à assurer une réelle interdisciplinarité dans le cours. Constituer l'équipe pédagogique s'est en fait avéré assez facile : au-delà de collègues spécialistes naturellement intéressés, certains collègues voyaient là l'opportunité d'approfondir des connaissances utiles pour leur recherche en géosciences, en sciences des matériaux, ou dans des domaines de l'informatique où l'apprentissage automatique commençait à apparaître.

Dans ce cadre, il apparaît indispensable de préparer en amont des supports de cours détaillés, que ce soit le photocopié ou des sujets de travaux dirigés avec des corrections complètes.

C. Difficultés rencontrées

Ce cours de tronc commun a été inauguré à l'automne 2020 en « distanciel » intégral... Les premiers retours des étudiants ont été malgré tout positifs : ceci tient bien entendu à leur travail et à l'énergie déployée par les collègues pour animer les travaux dirigés, mais aussi à l'utilisation des logiciels libres facilitant l'installation de tout le nécessaire pour travailler sur un ordinateur personnel par l'intermédiaire de la distribution Anaconda.

L'année 2022-2023 représente donc la seconde session « normale » du cours. Le contenu est riche et s'appuie fortement sur les cours de tronc commun de mathématiques et d'informatique, sans s'appesantir sur des rappels faute de temps. Bien entendu, les étudiants ayant éprouvé des difficultés dans certains de ces cours doivent remobiliser des acquis fragiles, ce qui leur pose parfois des difficultés. Même s'ils ne sont pas nécessairement les plus en difficulté, il ne faut pas oublier les étudiants admis sur titre en deuxième année, qui n'ont pas suivi ces cours.

Il convient également de gérer l'hétérogénéité des attentes : les étudiants au profil « matheux » veulent des démonstrations mathématiques, ceux au profil « geek » voudraient plus d'autonomie pour développer leurs codes, d'autres voudraient des cas d'application dédiés à leur domaine de prédilection... Le cours tente de répondre à ces attentes en proposant de nombreux compléments facultatifs.

Enfin, et ceci n'étonnera pas les enseignants en informatique, une (heureusement) petite minorité d'étudiants fait preuve d'un manque de familiarité avec l'informatique assez étonnant. Difficile de commencer sereinement une séance de TP lorsqu'on ne sait pas où sont ses fichiers, sans parler de ligne de commandes. On peut se demander comment ces étudiants appréhendent l'informatique en général et l'IA en particulier dans la vie de tous les jours.

III. PISTES D'ÉVOLUTION

Si le cours semble avoir atteint un rythme de croisière, des pistes pourraient tout de même être explorées s'il était amené à prendre davantage d'ampleur. Tout d'abord, prendre plus de temps pour des rappels mathématiques ou informatique dans le contexte de l'apprentissage automatique semblerait profitable. Ensuite, certaines questions importantes ne sont pas évoquées dans le cours faute de temps, comme la réduction de la dimension des observations ou la visualisation de données. Les techniques ensemblistes d'apprentissage (forêts aléatoires, *boosting*) mériteraient également d'être traitées. Enfin, les résultats très récents sur la génération d'images avec Stable Diffusion ou l'agent conversationnel ChatGPT d'OpenAI laissent anticiper une nouvelle révolution d'usages dans de nombreux domaines. Ceci n'est pas sans susciter des inquiétudes légitimes quant à l'usage de ces outils qui pourrait être imaginé. Introduire les techniques modernes de l'apprentissage profond (*deep learning*) dans un cours de tronc commun semble donc de plus en plus pertinent. D'un point de vue pratique, permettre l'utilisation d'un centre de calcul mutualisant les moyens matériels serait sans doute judicieux. Des ressources matérielles et humaines conséquentes sont cependant indispensables dans ce cas.

IV. CONCLUSION

Nous avons décrit l'expérience de l'École des Mines de Nancy dans l'enseignement de l'apprentissage automatique dans un cours de tronc commun scientifique. Introduire ce cours permet aux élèves-ingénieurs de mieux appréhender les projets scientifiques et industriels qui peuvent leur être proposés dans leur scolarité à l'école, réinvestir ces connaissances dans leurs stages en entreprise, ou approfondir par la suite dans des cursus dédiés. Si l'accent est mis sur la pratique de l'analyse de données réelles, les fondements théoriques ne sont pas négligés afin de dépasser un usage naïf en boîte noire des techniques modernes de l'intelligence artificielle.

Remerciements. Je souhaite remercier l'équipe de direction de l'École des Mines de Nancy pour la confiance accordée, ainsi que tous les collègues et étudiants impliqués pour avoir grandement contribué à l'amélioration continue du cours et du matériel pédagogique.

Remarque. Dans le corps du texte, le masculin est utilisé à titre épïcène.

REFERENCES

Abadi, M. et al (2015). TensorFlow: Large-scale machine learning on heterogeneous systems, Software available from [tensorflow.org](https://www.tensorflow.org).

Bishop, C. (2006). Pattern recognition and machine learning. Springer.

Efron B. & Hastie, T (2008). Computer age statistical inference. Cambridge University Press. <https://hastie.su.domains/CASI/>

Goodfellow I., Bengio Y., & Courville A (2016). Deep learning. MIT Press. <http://www.deeplearningbook.org>

Larousserie, D. (2022). L'intelligence artificielle, nouveau moteur de la recherche scientifique. *Le Monde, supplément sciences et médecine*, 26 octobre 2022.

Pedregosa, F. et al. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830. Software available from <https://scikit-learn.org/stable/>

Russel, S. & Norvig, P (2016). Artificial Intelligence : A Modern Approach. Prentice Hall, 3rd edition.

Sur, F. (2023). Introduction à l'apprentissage automatique. *Cours de tronc commun scientifique FICM 2A*, École des Mines de Nancy. <https://members.loria.fr/FSur/enseignement/apprauto/>

Villani, C., Bonnet Y., Berthet, C., Levin, F., Schoenauer, M., Cornut, A.-C., & Rondepierre B. (2018). Donner un sens à l'intelligence artificielle. Pour une stratégie nationale et européenne. *Rapport pour le premier ministre*. <https://www.vie-publique.fr/rapport/37225-donner-un-sens-lintelligence-artificielle-pour-une-strategie-nation>