

Intelligence artificielle : défis scientifiques et attentes socio-économiques

Par Stephan CLÉMENÇON

Professeur de mathématiques appliquées à Télécom-ParisTech,
Institut Mines-Télécom

Il faut reconnaître que l'accélération considérable des progrès réalisés ces dernières années dans les domaines, par exemple, de la vision par ordinateur, de la reconnaissance vocale ou de la recherche automatique d'information, est essentiellement le fait d'avancées spectaculaires en matière d'infrastructures de calcul et de stockage des données. Aussi n'est-il pas surprenant de retrouver aux avant-postes des applications les géants du Web, acteurs majeurs du développement de ces technologies, prompts à convertir l'information portée par les masses de données accumulées en nouveaux produits ou services. En effet, en *machine-learning*, une machine réalise automatiquement une tâche (la reconnaissance d'un objet spécifique apparaissant dans une image, par exemple) au moyen d'un programme, « appris » en résolvant la version statistique d'un problème d'optimisation rendant compte de l'efficacité générale de règles figurant dans un catalogue complexe et formulées à partir de données relatives à un grand nombre d'observations. Des images auxquelles sont attribués des labels indiquent la présence ou l'absence de l'objet dans l'image, pour reprendre l'exemple précédent d'« apprentissage supervisé », caractéristique des applications de la « reconnaissance de forme ». La disponibilité d'exemples (que la machine peut elle-même solliciter dans certains cas pour mieux apprendre), stockés sous forme de bases de mégadonnées et offrant une description quasi exhaustive de la variabilité du phénomène à analyser, combinée à la puissance de calcul des *clusters* d'ordinateurs modernes permettant de mettre en œuvre des programmes d'optimisation opérant sur des catalogues très complexes de règles prédictives, a permis de rendre véritablement effectives des méthodes d'apprentissages statistiques conçues vers la fin du XX^e siècle, théorisées en particulier par les mathématiciens russes V. Vapnik et A. Chervonenkis dans les années 1960 et préfigurées par l'algorithme du Perceptron de F. Rosenblatt dès les années 1950, la version la plus élémentaire des réseaux de neurones. Ces méthodes sont aujourd'hui à l'œuvre dans de nombreux « systèmes intelligents », pour des domaines aussi variés que la biométrie, le véhicule à délégation partielle, le diagnostic médical automatique, les moteurs de recommandation associés aux sites Web commerciaux ou les assistants virtuels.

L'ère du *Big data* et de l'intelligence artificielle généralisée a donc débuté grâce aux briques technologiques modernes qui nous permettent désormais de stocker et traiter de façon automatisée, dans des temps très courts, des données massives de nature et format divers, avec le succès grandissant des grandes entreprises du Web. Si celles-ci semblent en effet avoir été les premières à comprendre le rôle ubiquitaire que vont désormais jouer les données et les sciences et technologies de l'information, l'engouement pour le *machine-learning* s'étend à présent à presque tous les domaines (science, transports, énergie, médecine, sécurité, banque, assurance, commerce, etc.), au fur et à mesure que l'*Internet of Things* (IoT), l'usage généralisé de technologies d'analyse telles que la spectrométrie de masse ou le développement des solutions de type *Cloud* accroissent la disponibilité d'informations à la granularité de plus en plus fine. Les attentes sont considérables. L'intelligence artificielle permettrait de développer une médecine hautement personnalisée, allant jusqu'à adapter le traitement aux caractéristiques génétiques du patient, de concevoir des systèmes de maintenance prédictive des infrastructures complexes, tels que des réseaux de transport d'énergie ou des avions, détectant suffisamment tôt les « signaux faibles » annonciateurs

de dysfonctionnements, permettant ainsi le remplacement des composants avant leur probable défaillance et assurant une plus grande pérennité au service prodigué ou encore des véhicules de transport à la fois sûrs et totalement autonomes. Les opportunités sont indéniables et il est légitime d'espérer la mise au point d'applications performantes nourries par les mégadonnées. Cependant, l'intelligence artificielle ne tiendra vraiment ses promesses que si des défis scientifiques sont relevés. Avant d'être LA solution, le *machine-learning* pose un grand nombre de problèmes passionnants, pour les mathématiciens en particulier.

Variété, Volume et Vitesse. S'ils sont généralement convoqués pour définir les *Big data*, les 3 « V » recouvrent aussi en partie ces challenges mathématiques et constituent un bon point de départ pour comprendre la nature de certains enjeux scientifiques en *machine-learning*. Le traitement mathématique des données n'est certes pas une chose nouvelle. Les statistiques se sont développées avec les sciences sociales dès le XVIII^e siècle, leur essor s'est ensuite poursuivi avec celui des sciences agronomiques, du contrôle de qualité dans l'industrie, de l'épidémiologie, des tests cliniques, de l'économétrie ou encore, plus récemment, du Web. À l'époque où les données étaient rares et coûteuses, collectées le plus souvent au moyen de questionnaires, la statistique « traditionnelle » reposait de façon cruciale sur l'expertise humaine pour le prétraitement des données et la modélisation de leur variabilité. Motivé à l'origine par les problèmes de reconnaissance de forme et stimulé par les sciences cognitives, le *machine-learning* ne consiste pas à simplement exploiter les données pour ajuster les paramètres d'un modèle plus ou moins rigide, spécifié à l'avance, mais à concevoir des algorithmes qui apprennent *automatiquement*, à partir d'exemples, le modèle le plus efficace dans un immense catalogue de modèles. L'efficacité d'algorithmes d'apprentissage, tels que les réseaux de neurones, les « *support vector machines* » ou les « forêts aléatoires », et la mise au point de solutions logicielles optimisées pour les mettre en œuvre ont contribué à populariser l'usage de ces méthodes dans les deux dernières décennies. Le *machine-learning* convoque de nombreux domaines des mathématiques appliquées : le point de vue probabiliste, bien sûr, qui fournit le bon langage pour décrire la variabilité des données, la formulation statistique des problèmes prédictifs, mais aussi, par exemple, l'optimisation ou le traitement de l'image et du signal, tant les problèmes qu'il permet d'aborder sont variés. La recherche est en particulier sans cesse stimulée par la nature et le format des données disponibles pour l'analyse, lesquelles évoluent avec les technologies permettant de les capturer. Les *Big data* évoquent d'abord les données du Web, le contenu des pages et les données de navigation : des images, des vidéos, du son, du texte, des usages et des relations sociales. On est souvent loin de la « matrice rectangulaire » de données, qui fut l'objet de prédilection des statisticiens au XX^e siècle, avec en ligne les individus représentatifs de la population étudiée et en colonne les quelques variables les décrivant. L'analyse « sémantique » des données textuelles sur le Web visait surtout à l'origine à indexer les documents pour faire fonctionner les moteurs de recherche et se bornait plus ou moins à un comptage renormalisé de l'occurrence de chaque mot d'un dictionnaire sur chaque page Web. Mais les applications récentes, comme l'analyse de sentiments ou d'opinions, ou les assistants virtuels, requièrent l'élaboration de modèles mathématiques beaucoup plus sophistiqués. Certaines données du Web, et, plus généralement, les données relatives au fonctionnement des réseaux sociaux, rendent également compte de relations entre objets ou individus, lesquelles se décrivent au moyen de graphes. Si la théorie des graphes aléatoires s'est développée dans la seconde moitié du XX^e siècle avec les travaux de grands mathématiciens tels que P. Erdős, qui ont permis de formuler une grande variété de problèmes traitant de la diffusion d'une information au sein d'un réseau ou de l'influence de certains agents du réseau, la technologie moderne nous permet d'observer aujourd'hui des graphes d'une taille et d'une richesse inédites. La complexité de leurs propriétés et leurs dimensions appellent de nouvelles méthodes pour comprendre leur structure, la dynamique de leur éventuelle évolution, pour les visualiser et exploiter exhaustivement l'information qu'ils portent. Ils constitueront sans doute encore longtemps un champ d'investigation pour les mathématiciens. Dans le même ordre d'idées,

l'analyse des données de préférences n'est pas un sujet nouveau et renvoie par exemple aux travaux précurseurs de Condorcet au XVIII^e siècle et à la théorie sociale du choix, mais, encore une fois, les données collectées aujourd'hui *via* les applications numériques, au moyen desquelles les utilisateurs peuvent désormais exprimer leurs préférences pour tel ou tel film ou tel ou tel produit, sont d'une nature très différente. Les préférences effectivement exprimées varient selon l'utilisateur et ne concernent en effet qu'un nombre d'objets très faible par rapport aux dimensions du catalogue. Il serait vain de chercher à modéliser les préférences sur l'ensemble du catalogue, le nombre de façons de ranger des objets par ordre de préférence explosant avec leur nombre. Les mathématiciens cherchent encore une représentation efficace de ce type de données, sur le modèle de la représentation en « ondelettes » pour les signaux, les images et les vidéos, à l'œuvre de manière très concrète dans la norme JPEG2000 par exemple, mais fondée auparavant sur des travaux approfondis dans le domaine de l'analyse numérique (qui ont récemment valu le prestigieux prix Abel au mathématicien Yves Meyer). La représentation parcimonieuse et adaptative de l'information (et de la mise au point d'algorithmes rapides pour la calculer) est une question majeure en mathématiques et la clé du traitement efficace des données. Une représentation sera jugée d'autant plus performante qu'elle permettra d'éliminer le « bruit », de mettre en exergue des structures caractéristiques (« *patterns* ») et d'accroître la performance prédictive des algorithmes d'apprentissage statistique nourris par les données ainsi formatées. Dans de nombreuses situations, les multiples couches des architectures de réseaux de neurones profonds fournissent par exemple des représentations facilitant l'ajustement de règles de prédiction aux bonnes capacités de généralisation. Mais à l'heure de la biométrie déployée sur *smartphone*, on attend aussi que la mise en œuvre des modèles prédictifs embarqués ne compromette pas l'autonomie des systèmes qui les hébergent et se conforme aux contraintes du temps quasi réel, ce qui fait surgir les questions de compression de l'information et des règles qui l'exploitent. L'avenir proche est d'ailleurs à l'IoT et, pour des applications telles que la maintenance prédictive des réseaux de transport, à l'élaboration de capteurs « intelligents », qui, mis en réseau, seront capables de définir la meilleure stratégie de partage de l'information et de répartition des tâches de calcul en fonction des données qu'ils collectent et des tâches à accomplir.

Les questions scientifiques sont nombreuses et, dans certains cas, le niveau de délégation qui sera accordé aux « systèmes intelligents » dépendra en grande partie des réponses que la recherche méthodologique apportera aux enjeux d'éthique (traitement des données personnelles respectueux de la vie privée) et de fiabilité. Cela renvoie au développement de techniques d'apprentissage statistique résistant à une éventuelle « contamination » d'une partie des données (provenant, par exemple, de biais de mesures ou d'une volonté de nuire au fonctionnement du système automatisé, comme on l'a suspecté pour les données du Web lors de la dernière campagne présidentielle aux États-Unis) et produisant des décisions interprétables par l'utilisateur final, l'humain. L'aventure ne fait que commencer.