

plus particulièrement des algorithmes d'apprentissage ayant une certaine plausibilité biologique : les poids synaptique sont changés selon un critère hebbien, c'est-à-dire en fonction des activités pré- et postsynaptiques.

Ainsi, après une phase d'apprentissage qui consiste à modifier les paramètres, une machine généralise – elle a compris la règle – si elle donne la réponse appropriée pour tout exemple qui n'a pas été considéré lors de l'apprentissage.

Questions de ressources


Supposons que l'on arrive effectivement à adapter les paramètres, de sorte que la machine produise la sortie désirée pour chaque exemple donné lors de l'apprentissage : ce serait la preuve que, pour chaque exemple, la machine a mémorisé l'association entrée-sortie désirée. Une telle mémorisation est possible si les ressources de la machine sont suffisantes, c'est-à-dire si l'architecture est appropriée et si le nombre de paramètres adaptables est suffisamment grand. Cependant, si ces ressources sont vraiment très grandes, la machine apprend par cœur tout nouvel exemple donné : quelle que soit la sortie désirée, il existera toujours un choix des paramètres qui permet d'obtenir cette sortie, tout en gardant les bonnes sorties pour tous les exemples déjà appris. La machine ne généralise alors pas, puisque à chaque instant elle peut mémoriser un nouvel exemple.

En revanche, si les ressources de la machine sont limitées, la mémorisation d'un grand nombre d'exemples risque d'encombrer la mémoire, de sorte que, lors de la présentation d'un nouvel exemple, on ne peut plus modifier les paramètres sans remettre en cause l'apprentissage déjà effectué. Autrement dit, avant que soit donnée la réponse à reproduire (la sortie désirée), la machine a déjà une réponse prête, la seule possible compte tenu de ce qu'elle a déjà appris. En ce sens, la machine généralise.

Plus on donne d'informations sur la règle à découvrir, plus on restreint le domaine des valeurs admissibles pour les paramètres, mais plus on limite le nombre de règles nouvelles que la machine peut encore apprendre. Si l'architecture est adaptée, la machine peut apprendre la règle cachée : il existe au moins un choix des paramètres qui per-

met à la machine de reproduire la règle ; dans ce cas, la généralisation sera correcte. Sinon, la machine généralise, mais infère une mauvaise règle : la règle trouvée ne coïncide que partiellement avec celle qu'il fallait trouver.

Ainsi la capacité à généraliser, à catégoriser, commence là où s'arrête la capacité à apprendre par cœur, et un système aux ressources illimitées ne peut qu'apprendre bêtement. Cette notion de ressources est subtile, car on



7. LA RÉTROPROPAGATION DU GRADIENT est un algorithme d'apprentissage très utilisé. Son principe est schématisé ici. Après le choix de l'architecture du réseau, par exemple un réseau en couches avec une couche cachée (non représenté), on modifie les connexions entre les neurones (au centre, on a représenté les poids synaptiques par des plots de différentes hauteurs) pour que le réseau affiche une sortie désirée. On définit une fonction dite de coût, qui décrit la différence entre l'activité de sortie et l'activité désirée. Cette fonction est nulle si la sortie est celle que l'on désire. On présente alors des exemples au réseau, et, à chaque présentation, on modifie les connexions, de sorte que la sortie se rapproche de la sortie désirée. Par exemple, on présente ici un chiffre 7 ; le réseau réagit d'abord en affichant un 4 et un 7. On modifie alors les poids synaptiques (en rouge, c) et l'on présente à nouveau le chiffre 7 : le réseau réagit en affichant 7 et 1. Puis, quand on modifie encore les poids (d), le réseau détecte le 7. De proche en proche, la sortie se rapproche de la sortie voulue.

sait réaliser des systèmes dont un seul paramètre est modifiable et qui, pourtant, ont des ressources infinies dans le sens précédent (c'est-à-dire une capacité infinie à mémoriser).

Considérons, par exemple, les nombres réels 0,8 ; 2,2 ; 5,1, et cherchons à les classer en deux classes. En considérant le signe du sinus de leur produit par un nombre f , on parvient à grouper ces nombres comme on le désire. Par exemple, si f est égal à $\pi/2$, 0,8 et 5,1 seront dans la première classe, tandis que 2,2 sera dans la seconde. Si f est égal à π , 0,8 et 2,2 seront dans la première classe et 5,1 dans la seconde. Ainsi, en choisissant convenablement f (le paramètre ajustable), on arrive à réaliser n'importe quel classement au choix. Ce procédé qui n'utilise qu'un seul paramètre s'applique généralement à un nombre quelconque de nombres à classer

Pour estimer les ressources, on utilise aujourd'hui un nombre de paramètres effectifs nommé dimension de Vapnik-Chervonenkis, du nom des deux chercheurs russes qui ont introduit cette notion dans les années 1970. Cette dimension est parfois infinie, comme dans l'exemple précédent, mais, dans la plupart des cas et, notamment, pour les réseaux de neurones, elle est de l'ordre de grandeur du nombre de paramètres modifiables. Notons que, pour la plupart des machines à apprendre, on ne sait pas calculer exactement cette dimension...

Une machine apprend par cœur tant que le nombre d'exemples à apprendre est inférieur à sa dimension de Vapnik-Chervonenkis, et elle commence à généraliser au-delà. Un apprentissage efficace par un réseau de neurones demande donc une architecture suffisamment complexe pour que la règle à apprendre soit effectivement réalisable par le réseau, mais une dimension de Vapnik-Chervonenkis pas trop grande, pour que l'apprentissage ne nécessite pas un trop grand nombre d'exemples : il s'agit de trouver le bon compromis, le réseau dont la complexité a le bon goût d'être bien adapté à la tâche à résoudre.

Ainsi, un réseau ou, plus généralement, une machine à apprendre qui a appris une règle est devenu un modèle pour cette règle ; il prédit le résultat de l'application de cette règle à tout nouvel exemple. On retrouve alors,

dans le cadre de la théorie de l'apprentissage, la notion classique du rasoir d'Occam : le bon modèle (la bonne théorie) est celui dont la complexité est assez grande pour rendre compte des observations, mais pas plus.

Intelligence et sensations

Si nous avons privilégié ici les capacités d'apprentissage des réseaux de neurones, bien d'autres aspects de l'intelligence sont aujourd'hui étudiés à l'aide de réseaux de neurones. Ainsi de nombreuses équipes s'intéressent à la modélisation des systèmes sensoriels. D'autres modélisent les contrôles sensori-moteurs ou explorent des applications en contrôle de systèmes (pilotage d'un véhicule par un réseau de neurones, par exemple).

On étudie notamment les possibilités offertes par la dynamique des réseaux et par une activité neuronale qui est sous forme de potentiels d'actions, d'impulsions brèves. Ainsi des expériences en neurosciences indiquent que la mise en activité synchrone de groupes de neurones peut avoir un rôle fonctionnel important : par exemple, quand on présente une barre qui se déplace dans le champ visuel et que l'on enregistre l'activité de neurones du cortex visuel, on observe que des neurones éloignés ont pourtant une activité synchrone ; on a compris que ces neurones synchrones participent au codage de la barre dans le cerveau. Si l'on présente maintenant des morceaux de barre qui activent les mêmes neurones, on observe que ces neurones sont encore actifs, mais que leurs activités ne sont pas synchrones. Ainsi le synchronisme est une indication que les neurones réagissent au même objet (voir la figure 6).

D'autres expériences de neuropsychologie, telles celles de S. Thorpe et de ses collègues de Toulouse, démontrent que la première vague d'impulsions engendrée par la présentation d'une image dans le champ visuel est suffisante pour détecter la présence ou non d'un animal dans une image. Dans certaines expériences, les neuropsychologues toulousains projettent à des sujets humains des images si rapidement que les sujets ne voient pas les détails, et ne peuvent qu'identifier globalement les images. On leur demande de maintenir un bouton enfoncé et de le relâcher quand un animal apparaît.

En mesurant le laps de temps entre la présentation des images et la réaction motrice des sujets, connaissant le temps de traitement dans chaque module cérébral ainsi que le temps de propagation des signaux nerveux, les psychologues ont montré que les réactions résultent d'un très petit nombre de traitements : on peut donc estimer le nombre de couches neuronales qui participent au comportement testé.

En mesurant l'activité du cerveau à l'aide d'électrodes posées sur le crâne (comme pour un électro-encéphalogramme), les neuropsychologues ont démontré que le système nerveux détecte la présence d'un animal dans l'image après seulement 150 millisecondes et que le cerveau n'utilise parfois que les toutes premières réactions des neurones stimulés.

Plus généralement, l'extrême efficacité algorithmique du système nerveux dans des tâches de reconnaissance de formes, qu'on ne sait absolument pas reproduire avec des modèles de réseaux de neurones classiques, pourrait résulter d'une utilisation astucieuse du codage par impulsions. Nous ne sommes pas à l'abri de très bonnes surprises à venir dans les toutes prochaines années...

Jean-Pierre NADAL est chercheur CNRS au Département de physique de l'École normale supérieure de Paris.

J. HERTZ, A. KROGH et R.G. PALMER, *Introduction to the Theory of Neural Computation*, Addison-Wesley, 1990.

G. HINTON, *Apprentissage et réseaux de neurones*, in *Pour La Science*, novembre 1992.

P. CHURCHLAND et T.J. SEJNOWSKI, *The Computational Brain*, MIT Press / Bradford Books, 1992.

J.-P. NADAL, *Réseaux de neurones : de la physique à la psychologie*, Armand Colin, 1993.

J. HÉRAULT et Ch. JUTTEN, *Réseaux neuronaux et traitement du signal*, Hermès, 1994.

M.A. ARBIB, *The Handbook of Brain Theory and Neural Networks*, Bradford Books / The MIT Press, 1995.

S. THORPE, F. FIZE et C. MARLOT, *Speed of Processing in the Human Visual System*, in *Nature*, vol. 381 pp. 520-522, 1996.