

Comment les réseaux neuronaux modifient le développement des logiciels automobiles



Auteurs :

Martin Schleicher, Vice-président exécutif Business Management Elektrobit
Dr.-Ing. Sorin Mihai Grigorescu, Directeur du Centre technique d'Intelligence Artificielle Elektrobit

L'apprentissage machine et les réseaux neuronaux profonds, qui constituent l'approche de pointe actuelle de l'intelligence artificielle, jouent un rôle important dans le développement de logiciels visant à permettre la conduite automatisée. L'article ci-après se concentre sur les différentes approches et scénarios de ces algorithmes d'auto-apprentissage et réseaux neuronaux et présente comment ces technologies sont utilisées pour le développement de logiciels embarqués de conduite automatisée.

Le développement de logiciels pour la conduite automatisée doit relever divers défis parmi lesquels les limites de la portée des capteurs ego, de l'absence d'informations sur les infrastructures, qui ne peuvent être déduites des observations des capteurs embarqués, ainsi que des résultats incomplets ou non concluants des algorithmes de reconnaissance. Une approche viable pour faire face à ces situations consiste à prendre en charge le logiciel embarqué classique grâce aux résultats de l'apprentissage machine ou des réseaux neuronaux profonds. Les solutions d'IA par exemple peuvent être utilisées pour dévier les stratégies de conduite d'une grande quantité de données d'entrée issues d'environnements non structurés, ou même pour prévoir des conditions de circulation avec un horizon temporel de plusieurs secondes.

Le concept de l'apprentissage machine introduit toutefois d'autres degrés de complexité dans le développement des logiciels automobiles. Afin de rendre cette intégration aussi fluide et simple que possible, nous avons développé une plate-forme scientifique de données conçue pour la construction de moteurs d'intelligence artificielle dans différents domaines automobiles tels que les systèmes de conduite hautement automatisés et finalement autonomes.

L'architecture de la plate-forme scientifique de données, illustrée à la figure 1, suit les deux principales opérations d'un processus de conception d'apprentissage approfondi : **la formation** et **l'inférence**, ainsi que les couches supplémentaires d'intégration matérielle et d'amélioration des performances. Un plan de travail spécifique de la plate-forme scientifique des données d'IA est mis en place pour la formation, le prototypage et le développement du système. Il s'appuie sur les méthodes et outils existants et considère les algorithmes d'IA comme des boîtes à outils dans la plate-forme scientifique de données d'EB.




Figure 1 : Plate-forme scientifique de données d'EB

Organisation et utilisation d'énormes quantités de données d'apprentissage

L'apprentissage des algorithmes d'auto-apprentissage a besoin de milliers d'échantillons d'objets alimentant le réseau neuronal. L'algorithme apprend alors une nouvelle capacité en renforçant les prédictions correctes et en corrigeant les mauvaises. Cependant, la taille et le nombre d'échantillons d'objets, généralement énormes, posent des défis supplémentaires. Pour l'ADAS et le développement de la conduite automatisée, les données d'apprentissage sont généralement générées par des essais routiers réels et simulés – couvrant souvent des milliards de kilomètres d'essai et générant ainsi des téraoctets, voire des exaoctets d'échantillons. Les énormes quantités de données qui en résultent doivent être organisées, testées et validées. Ceci est réalisé à l'aide d'une nouvelle chaîne d'outils de validation basée sur le cloud. Elle s'appuie sur une base de données centrale basée sur le cloud permettant d'ordonner d'énormes collectes de données et également d'utiliser et de réutiliser des données d'apprentissage importantes. Conçue comme un outil de validation unique, elle

accélère le développement en prenant en charge la génération de données, l'étiquetage, la découverte de données et l'exécution de tests via un portail Web convivial et intuitif.

L'utilisation du cloud à cette fin autorise un degré de flexibilité et d'évolutivité très élevé. Des interfaces ouvertes permettent à cette solution innovante de s'adapter aux différentes boîtes à outils des partenaires. Cette solution comporte de nombreux détails pratiques comme l'amélioration et l'étiquetage semi-automatique des données ou une hiérarchisation intelligente autour des données chaudes, froides et « gelées ». Grâce à une approche flexible et à la demande, les clients doivent uniquement payer pour la puissance de calcul et les fonctionnalités dont ils ont réellement besoin. Cette approche permet d'économiser du temps et de l'argent sur les plans de l'apprentissage d'IA et des données de test.

L'apprentissage unique facilite l'apprentissage des systèmes d'apprentissage machine

Pour simplifier également l'apprentissage réel des réseaux neuronaux profonds, nous avons également développé un algorithme d'apprentissage unique utile. Il a été conçu pour contourner l'étape d'annotation manuelle qui est typiquement requise pour l'apprentissage des systèmes d'apprentissage machine. Son principal atout réside dans l'approvisionnement de résultats viables, même avec des ensembles de données d'apprentissage relativement petits. Pour ce faire, l'algorithme utilise des objets uniques, ou motifs génériques, en guise de données d'entrée. De plus, un petit ensemble d'échantillons de régularisation est utilisé pour générer de nouvelles données synthétiques. Ce processus de génération est assuré par un générateur de généralisation et par un cadre d'optimisation d'objectifs multiples. L'approche d'apprentissage unique qui en résulte peut être appliquée avec succès à divers défis comme la perception de l'environnement visuel dans les systèmes de conduite autonomes.

De plus, comme pour la validation des systèmes de conduite automatisée, notre plate-forme scientifique de données utilise des réseaux neuronaux profonds pour scanner les données enregistrées de véhicules d'essai et enrichir automatiquement ces données avec des métadonnées telles que des informations sur les conditions météorologiques ou routières. Grâce à cette méthode, l'effort requis par les développeurs à la recherche de scènes de conduite adaptées à leurs besoins peut être considérablement réduit.

Au sein de notre plate-forme scientifique de données, les fonctions de formation et de génération de données décrites font partie du plan de travail de la plate-forme scientifique de données d'IA mentionnée précédemment. Ce plan de travail comprend également des outils et des environnements de prototypage et de développement logiciel ainsi que des boîtes à outils dédiées notamment à la compréhension du contexte de conduite, chargés de classer le contexte de conduite à partir d'informations de fusion de grille, ou à l'arbitrage de comportement, pour apporter une compréhension du contexte et une optimisation stratégique à partir de représentations du monde réel sous forme de grille. Autre exemple de boîte à outils disponible dans cette architecture : un environnement de simulation de conduite destiné à l'apprentissage, à l'évaluation et au test des algorithmes d'IA dans un simulateur virtuel.

Mise en œuvre des applications des modèles appris

Lorsqu'il s'agit de déployer les modèles appris dans des applications réelles, les moteurs d'inférence de la plate-forme scientifique de données représentent des wrappers pour les modèles formés, voir figure 2. Chaque wrapper encapsule un algorithme d'IA comme la

compréhension du contexte de conduite, la génération de données synthétiques, la détection et la reconnaissance d'objets ou la segmentation sémantique de la scène de conduite. Les wrappers sont exportés sous forme de bibliothèques liées dynamiquement et référencés dans les filtres implémentés. L'une des idées de base sur lesquelles repose la plate-forme scientifique de données est la modularisation qui incorpore des modules séparés pour chaque composante de l'intelligence artificielle. Cette approche encapsule des fonctionnalités d'apprentissage profond au sein de l'application et aide les développeurs à accéder facilement aux méthodes existantes et à les tester ou à mettre en œuvre leurs propres solutions pour leurs problèmes spécifiques.




Figure 2 : De l'encombrement et de l'acquisition des données jusqu'au déploiement et à l'évaluation des dispositifs de périphérie

Exemple de wrapper de déploiement d'applications : le composant ADTF (Automotive Data and Time-triggered Framework). Il utilise la date et les intervalles de temps comme référence pour comprendre le contexte de conduite. Par exemple, l'itinéraire prévu nécessite deux minutes de conduite en ville avant d'atteindre l'autoroute. Le contexte déterminé est représenté sous forme de métadonnées pour les intervalles respectifs (p. ex. ville ou autoroute).

La compréhension du contexte respectif est assurée par le Deep Grid Net (DGN). Le DGN incorpore une représentation de l'environnement de conduite apprise basée sur les grilles d'occupation obtenues à partir des données brutes du LIDAR. L'algorithme classe ensuite le contenu de chacune de ces grilles d'occupation, fournissant ainsi le contexte requis. Les candidats aux nouvelles catégories de grilles d'occupation pourraient être des chantiers de construction, des entrées ou sorties d'autoroute, des situations de fusion de voies ou des accidents. En raison de l'évolutivité des DGN, ces ajouts peuvent alors être directement implémentés dans l'algorithme.

Un champ d'application important de ce concept concerne l'estimation de trajectoire - un ensemble d'opérations de perception, de planification et d'action qui définissent la trajectoire que la voiture va suivre. Pour ce faire, un réseau neuronal profond chargé de planifier la perception estime la trajectoire souhaitée du véhicule sur un horizon de prévision fini. L'algorithme estime une séquence de situations optimales. Pour mettre en œuvre le contrôle de mouvement, les situations prédites peuvent ensuite être utilisées comme entrée dans un contrôleur prédictif de modèle.

Le contexte de conduite prédit est également utilisé pour passer d'une stratégie de conduite à une autre, qui peut être mise en œuvre au sein d'une plate-forme logicielle de conduite automatisée. Il peut être utilisé par ailleurs pour d'autres tâches de conduite automatisée comme la perception des scènes de conduite ou la planification de différentes stratégies de conduite automatisée.

Conclusion

Notre plate-forme scientifique de données a été conçue afin de prendre en charge les logiciels embarqués classiques grâce aux résultats de l'apprentissage machine ou des réseaux neuronaux profonds. Elle intègre des outils d'organisation et d'utilisation des données et des moteurs de formation qui sont utilisés pour déployer les résultats d'apprentissage machine (algorithmes d'IA) dans des applications réelles. De plus, une chaîne d'outils de validation basée sur le cloud permet de générer des données d'apprentissage d'IA. Les outils et plates-formes mentionnés peuvent accélérer et améliorer sensiblement le développement de fonctions de conduite hautement automatisées et autonomes.