

Deep learning pour la prévision du trafic routier

Jessica Martin

Etudiante en cinquième année GMM à l'INSA de Toulouse, j'ai effectué mon stage d'été à Paris et j'ai exploré la thématique du deep learning pour la prévision du trafic routier.

1. Le cadre de mon stage

J'ai effectué mon stage au sein de Mediamobile, une entreprise parisienne de moyenne taille issue d'un programme de recherche et développement avec des grands groupes comme Renault.

L'entreprise a maintenant comme activité principale l'info trafic. Elle collecte notamment par divers moyens des données GPS liées au trafic routier qu'elle transforme ensuite en informations exploitables : vitesses, débit, information sur des accidents etc. Cette information peut ensuite être revendue. L'entreprise a notamment de nombreux accords avec des constructeurs automobiles qui intègrent des systèmes de navigation dans leurs véhicules. Ces constructeurs paient pour que leurs véhicules reçoivent en temps réel les informations de navigation de Mediamobile.

Pour ma part j'ai travaillé dans l'équipe de R&D sous la tutelle d'un data scientist.

2. Prévoir le trafic routier : pourquoi ?

Une question que l'on me pose souvent vis à vis du stage est "pourquoi prédire le trafic routier?".

Il y a plusieurs raisons pour laquelle le développement d'un modèle de trafic routier serait profitable. Par exemple, savoir prédire le trafic permet aux municipalités de comprendre les flux de circulation dans leurs villes et peut-être de prendre des mesures adaptées. Savoir prédire le trafic c'est aussi en avoir développé une compréhension qui serait profitable pour tout le monde. Enfin, la principale conséquence d'un bon modèle de prévision de trafic serait l'accès pour les conducteurs à des calculateurs d'itinéraires donnant des temps estimés de parcours précis. Cela permettrait entre autre une réduction de la congestion des villes.

Cette problématique a d'autant plus de sens qu'à l'heure actuelle, un bon modèle n'existe pas. En fait développer un modèle qui soit bon n'est pas si compliqué, développer un modèle qui soit bon ET facilement exploitable à l'échelle industrielle l'est beaucoup plus. En plus, dans l'industrie à l'heure actuelle (pour la prévision à court terme) le modèle qui est utilisé principalement est celui de la propagation du temps réel :

trafic futur = trafic actuel.

Cela fait sens puisque la plupart du temps, le trafic routier a un comportement assez constant. Ce modèle est d'ailleurs très facile à implémenter. Mais aux périodes critiques (accident, formation de congestion etc.) cette façon de prévoir atteint ses limites.

Il y a donc un réel besoin d'un modèle de prévision, et c'était donc au centre de mon stage.

De façon plus précise, j'ai cherché à élaborer un modèle qui puisse pour une partie de route donnée, à un temps t donné, prévoir des vitesses sur la prochaine heure. Pour des raisons logistiques, ces prévisions étaient données par intervalle de 3 minutes donc je prévoyais 20 vitesses : celle dans trois minutes, celle dans six minutes . . . celle dans une heure. Cette prévision était donnée grâce aux vitesses passées sur la partie de route. J'ai tout d'abord restreint mon travail à une prévision sur le périphérique parisien.

Il me fallait un ou des indicateurs pour juger si mon modèle était bon. L'indicateur classique est le Root Mean Square Error (R.M.S.E.) qui quantifie l'écart brut entre ce qui s'est passé et ce qui a été prédit. Il faut qu'il tende vers 0 pour qu'un modèle soit bon. Cet indicateur est bien mais pas suffisant : il était souhaitable de savoir quantifier l'amélioration sur le modèle actuel de propagation du temps réel. Une innovation du stage a donc été de considérer un deuxième indicateur, le Q^2 , qui est négatif si le modèle fait pire que la prop. du temps réel, et entre 0 et 1 si le modèle fait mieux. Il fallait donc que cet indicateur tende vers 1.

J'ai développé les modèles en cherchant un compromis entre ces deux indicateurs.

3. Deep learning pour la prévision

Dernièrement, le deep learning a présenté de bons résultats dans la littérature pour la prévision du trafic routier. C'est la raison pour laquelle j'ai cherché à l'exploiter. Le terme deep learning est beaucoup utilisé au quotidien actuellement assez peu défini.

Pendant mon stage nous avons écrit au sein de Mediamobile un petit document de vulgarisation du deep learning, disponible ici : https://github.com/tomepel/What_is_Deep_Learning/blob/master/What%20is%20Deep%20Learning.pdf

Sinon pour faire court, je possédais pour plein de parties de routes en France et pour plein de moments t différents :

- des données de vitesses passées avant t

- les vitesses à $t + 3$ minutes, à $t + 6$ minutes ... à $t + 20$ minutes correspondant à ce que j'aurai voulu que le modèle prévoie

Je les donnais donc à l'ordinateur, qui lui cherchait alors à optimiser un modèle mathématique non linéaire et complexe ("réseau de neurones") qui permette de lier de la meilleure façon possible vitesses passées et futures.

Plusieurs types de réseaux de neurones existent, plus ou moins adaptées à différentes structures de données (images, données temporelles etc.). J'ai implémenté quatre modèles dont voici les noms et les nombres de paramètres :

Modèle	Paramètres
Feed Forward	284672
Convolutionnel	135824
Recurrent	8224
Physique	640

Les réseaux de neurones feed forward sont les plus simples, et s'adaptent à toutes les structures. Les réseaux convolutionnels sont particulièrement adaptés pour les images et les réseaux récurrents pour des données ayant une caractéristique temporelle (comme les miennes en l'occurrence).

Le modèle physique est un modèle basé sur des caractéristiques physiques du trafic, que j'ai développé pendant le stage. Il fait actuellement l'objet d'un brevet d'où le peu de détails.

5. Résultats

J'ai implémenté ces réseaux en Python. Je les tous ai implémenté de façon "brûte" (sans librairie spécifique) sauf le réseau convolutionnel pour lequel j'ai utilisé TensorFlow.

Sans surprise, le réseau convolutionnel était le plus mauvais pour la tâche de prévision. Son Q^2 était négatif et donc ce modèle ne bat pas la propagation du temps réel.

Les réseaux feed forward et récurrent ont présenté des performances similaires : Q^2 positif (0.2 environ) et R.M.S.E. en dessous de 0.1. J'ai retenu le réseau récurrent comme étant meilleur puisque celui ci comporte en plus beaucoup moins de paramètres. Le deep learning peut donc être performant pour la prévision de trafic routier.

Enfin tous ces modèles ont été battus par le modèle physique, à la fois en terme de Q^2 et en terme de R.M.S.E.. Le modèle physique est donc juste et simple (640 paramètres seulement) : c'est idéal pour une exploitation industrielle. Ce modèle possède par ailleurs des qualités de généralisation que j'ai découvert en fin de stage. Un modèle optimisé avec des données du périphérique toulousain est performant sur la prévision du trafic parisien. Un modèle optimisé sur Lyon

l'est aussi. Le modèle apprendrait donc des caractéristiques "inhérentes" au trafic.

Ce modèle devrait sous peu être rendu utilisable par le grand public, et fait encore l'objet d'améliorations par l'équipe de Mediamobile. Les résultats du stage sont présentés dans deux articles scientifiques, un d'entre eux est d'ailleurs déjà disponible en ligne. Ce stage a donc été riche en découvertes et a confirmé ma volonté de poursuivre dans la recherche mathématique après l'I.N.S.A..