

## Analyse et valorisation des images de circulation de la ville de Montréal

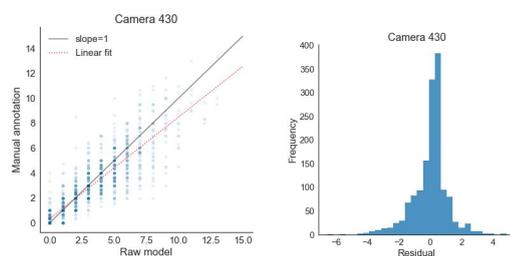
La ville est un milieu en changement constant selon des échelles de temps très différentes: variations de circulation à court et long terme, saisonnalité, conditions de la route changeant selon la météo, dégradation/réparation/modification du mobilier urbain. Toutes ces informations sont visibles sur les images des caméras telle que partagées par la ville de Montréal ici sur ce site <http://ville.montreal.qc.ca/circulation/>

Nous démontrons ici quelques cas d'usages permettant la valorisation de ces images en utilisant les réseaux de neurones convolutifs dont les performances sont de plus en plus impressionnantes. Comme ces images sont partagées en continu, elles nous permettent d'avoir des informations en temps quasi réelles avec un délai d'environ cinq minute. Nous présenterons premièrement nos résultats récemment publiés proposant une méthode d'analyse de variation de la circulation. Ensuite, nous présenterons notre projet en cours pour caractériser les types et le volume de véhicules lourds à partir de la détection d'objet. Finalement, nous montrerons comment la segmentation d'image nous permet de détecter les inondations.

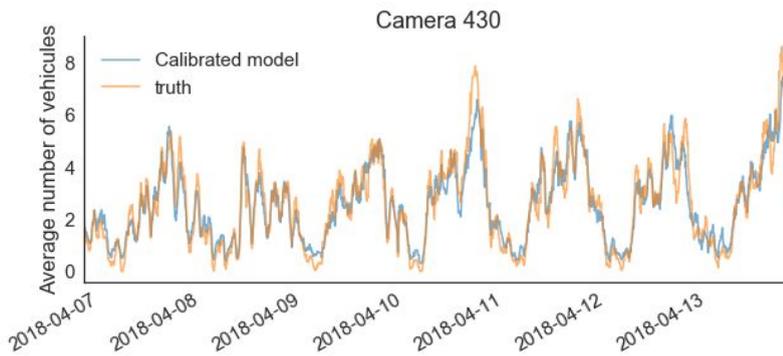
Notre première preuve de concept concerne le comptage de véhicule sur trois intersections connectées à la rue Notre-Dame de Montréal dont voici un exemple d'image:



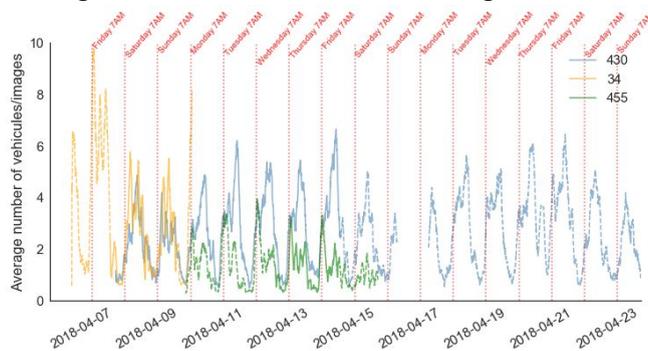
Pour notre comptage, nous utilisons le détecteur d'objet YOLO en utilisant les classes correspondant aux véhicules : "car", "bus" et "truck". Nous déterminons alors un comptage "brute" à l'intérieur d'une région d'intérêt telle que définie par les contours bleus dans l'image ci-haut. Ces comptages sont alors comparés à des annotations manuelles. Le comptage brute (raw model) VS le comptage issu des annotations manuelles est présenté dans les images suivantes pour une des trois caméras de notre preuve de concept:



La relation est modélisée par les paramètres provenant d'une régression linéaire (pointillées rouge sur l'image de gauche). Ainsi, nous pouvons corriger le comptage brute (raw) de YOLO par la pente C et l'intersection C0, tel que le nombre de véhicules dans l'image est modélisé par la relation  $C*N(\text{raw}) + C0$ , où N(raw) est le nombre de véhicules détectés par YOLO. L'erreur d'un tel modèle est de l'ordre d'une voiture par image pour la plupart des images (voir le graphique des résidus ci-haut à droite). Notons qu'il ne s'agit pas ici de comptage "absolu" puisque que tous les véhicules passant par le champs de visions ne sont pas visibles sur une image diffusée au cinq minute, mais si nous considérons ces images comme un échantillon aléatoire, nous pouvons présumer qu'un regroupement de ces images forment un échantillon représentatif des variations de circulations. Comme exemple de regroupement, nous montrons la moyenne glissante sur une fenêtre de deux heures sur le comptage corrigé et sur la "vérité" (les annotations manuelles) ci-dessous:

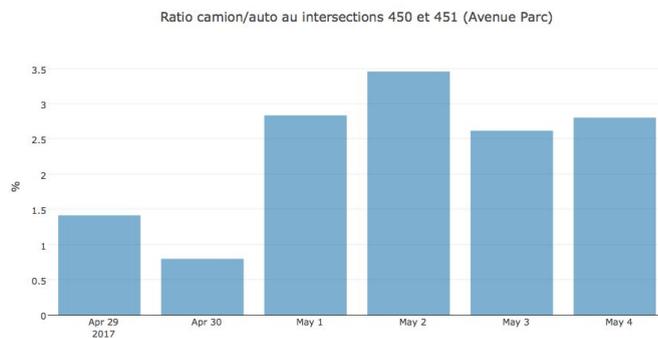
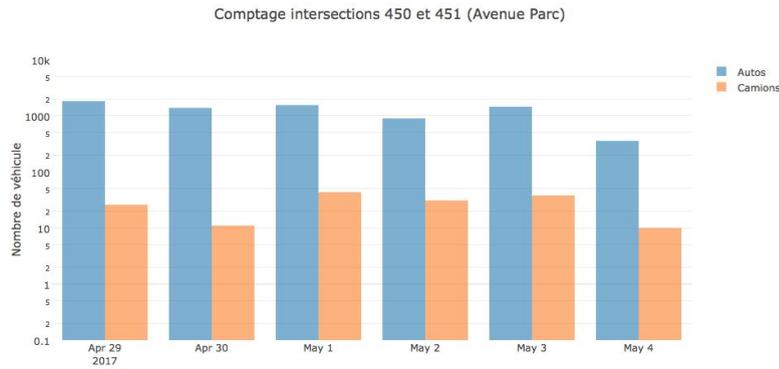


Nous présentons ensuite les comptages corrigés pour les trois caméras incluant les périodes non couvertes par les annotations (en pointillé). Nous ajoutons à 7h une ligne verticale rouge correspondant au début de l'heure de pointe, visible avec ces données.



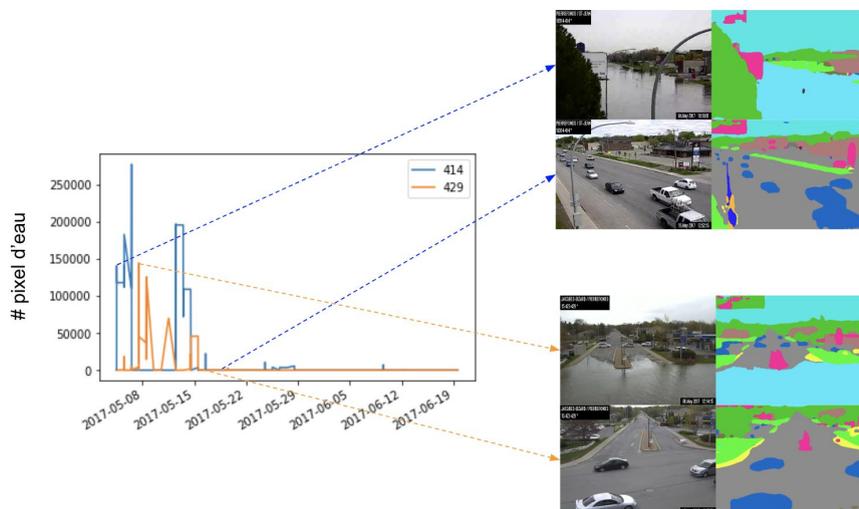
Notre deuxième preuve de concept présente notre analyse en cours, la détermination de la fraction de véhicules lourds dans la circulation. Cette information est particulièrement intéressante puisque, pour les collisions impliquant un véhicule lourd, la probabilité de décès ou de blessures sévères est plus élevée que lorsque la collision n'implique que des automobiles. Des données sur les déplacement des véhicules lourds sont essentielles pour décrire l'exposition, quantifier le risque et orienter les stratégies préventives<sup>1</sup>. Voici un comptage quotidien d'automobiles et de camion effectué manuellement

<sup>1</sup>Le Réseau-Sécurité, L'association Canadienne des Professionnels de la Sécurité Routière, Issue 4 2017, p. 12-13



Nous voyons que le ratio est plus bas la fin de semaine que la semaine. Nous prévoyons automatiser cette analyse à l'aide de réseaux de neurones convolutifs. YOLO a déjà une classe "truck", mais nous aurons probablement à entraîner pour avoir un meilleur contrôle sur la définition de véhicules lourd.

La troisième preuve de concept démontre comment les méthodes de segmentation d'images permettent de détecter des conditions routières dangereuses comme les inondations. Pour ce faire, nous utilisons la segmentation sémantique pour extraire le nombre de pixels de l'image couverte par l'eau. L'image ci-dessous présente deux séries temporelles (à gauche) du nombre de pixel en fonction du temps correspondant à deux caméras. À droite, on peut voir un exemple d'image avec et sans inondation pour les deux caméras.



Ce analyse permettra de détecter les épisodes d'inondation en temps quasi-réel et aussi d'en faire l'exploration sur l'historique des images.