

Université de Montréal

Les réseaux sociaux comme prédicteurs de la criminalité urbaine

par Simon Da Silva

École de criminologie
Faculté des arts et des sciences

Mémoire présenté
en vue de l'obtention du grade de maître ès sciences (M. sc.)
en Criminologie
option analyse criminologique

30 avril 2019

© Simon Da Silva, 2019

Résumé

La présente étude tente de déterminer l'importance d'analyser les crimes à des niveaux spatiaux et temporels de plus en plus précis. Aussi, une nouvelle source de données issue des réseaux sociaux, les *tweets*, est utilisée afin de prédire la répartition des crimes à Montréal en estimant la population réelle sur le territoire, et en la caractérisant selon son humeur. Des modèles multiniveaux Poisson sont utilisés afin de prédire les crimes contre la personne et les crimes contre les biens agrégés au segment de rue selon l'heure de la journée. Les résultats démontrent qu'il est primordial pour toute analyse de la criminalité à Montréal de tenir compte de la variance de la criminalité au niveau des micro-endroits et d'y incorporer des périodes intrajournalières. Aussi, la caractérisation de la population réelle de la ville a été identifiée comme une avenue prometteuse pour la prédiction des crimes. Finalement, la preuve de concept de l'utilisation de Twitter pour la prédiction de la criminalité est concluante, et suite à un balisage lié à la représentativité des utilisateurs de la plateforme, ces données issues des réseaux sociaux pourront être amenées à être utilisées par les acteurs en sécurité publique.

Mots-clés : analyse de la criminalité, analyse spatiale, analyse temporelle, population flottante, lag spatial, criminologie des endroits, analyse de l'humeur, réseaux sociaux, Twitter, analyse aoristique.

Abstract

The present study attempts to determine the importance of analyzing crime at increasingly precise spatial and temporal levels. Also, a source of data from social media, Twitter, is used to predict the distribution of crimes in Montréal by estimating the ambient population on the territory, and characterizing it according to its mood. Poisson multilevel models are used to predict violent and property crimes aggregated to the street segment by time of day. The results show that it is essential for any analysis of crime in Montreal to take into account the variance of crime at the micro-place and to incorporate intraday periods. Also, the characterization of the ambient population has been identified as a promising avenue for the prediction of crime. Finally, the study provides proof of concept of the use of Twitter for the prediction of criminality, and following a markup related to the representativity of the users of the platform, the data could be used by public safety actors.

Keywords : crime analysis, spatial analysis, temporal analysis, ambient population, spatial lag, criminology of place, sentiment analysis, social media, Twitter, aoristic analysis.

Table des matières

Résumé.....	i
Abstract.....	ii
Table des matières.....	iii
Liste des tableaux.....	v
Liste des figures.....	vi
Remerciements.....	vii
INTRODUCTION.....	1
CHAPITRE 1 : RECENSION DES ÉCRITS.....	3
1.1 La loi de la concentration.....	4
1.2 Le <i>hotspot policing</i>	5
1.2.1 La temporalité des <i>hotspots</i>	6
1.3 Expliquer les crimes au niveau des micro-endroits et Twitter.....	8
1.4 Théories.....	10
1.4.1 La théorie des activités routinières.....	11
1.4.2 <i>Crime pattern theory</i>	11
CHAPITRE 2 : PROBLÉMATIQUE.....	12
CHAPITRE 3 : MÉTHODOLOGIE.....	14
3.1 Données utilisées.....	15
3.1.1 Le problème de multicolinéarité entre les prédicteurs liés à l'humeur.....	17
3.2 Unité d'analyse.....	18
3.3 Le modèle multiniveau.....	19
3.3.1 La désorganisation sociale.....	22
3.3.2 Le lag spatial.....	23
CHAPITRE 4 : STRATÉGIE D'ANALYSE.....	24
CHAPITRE 5 : RÉSULTATS.....	27
5.1 Le lag spatial.....	28
5.2 Les modèles explicatifs multivariés.....	28
5.2.1 La prédiction de la criminalité selon l'heure de la journée.....	34

5.2.2 La prédiction de la criminalité selon l'humeur	38
CHAPITRE 6 : DISCUSSION	41
6.1 La dépendance entre les variables.....	42
6.2 Les grandes catégories de crimes et les <i>tweets</i>	43
6.3 L'importance de la temporalité intrajournalière	45
6.4 La désorganisation sociale	46
6.5 Les types et les catégories de crimes	47
CONCLUSION ET RETOMBÉES PRATIQUES	48
Les <i>tweets</i> d'un point de vue pratique.....	49
BIBLIOGRAPHIE	51

Liste des tableaux

Tableau I.	Corrélations de Spearman entre les proportions de <i>tweets</i> reliées à des catégories d'humeurs et à des polarités d'humeurs	17
Tableau II.	Part de la variance explicable par chaque niveau d'agrégation du modèle hiérarchique (%).	21
Tableau III.	Variance et moyenne des variables dépendantes	25
Tableau IV.	Modèle multiniveau Poisson 1 prédisant les crimes au segment de rue (coefficients beta non standardisés et (intervalles de confiance))	28
Tableau V.	Modèle multiniveau Poisson 2 prédisant les crimes au segment de rue (coefficients beta non standardisés et (intervalles de confiance))	30
Tableau VI.	Modèle multiniveau Poisson 3 prédisant les crimes au segment de rue (coefficients beta non standardisés et (intervalles de confiance))	32

Liste des figures

Figure 1.	Exemple de la structure de variables spatiales hiérarchiques	20
Figure 2.	Structure des variables spatiales et temporelles de l'étude.....	20
Figure 3.	Les betas non standardisés (± 2 erreurs standards) des catégories de la variable Heure des modèles prédisant les crimes contre la personne (Heure de référence = 6).....	34
Figure 4.	Les betas non standardisés (± 2 erreurs standards) des catégories de la variables Heure des modèles prédisant les crimes contre la propriété (Heure de référence = 6).....	35
Figure 5.	Les betas non standardisés (± 2 erreurs standards) des catégories de la variable Heure * Nombre de <i>tweets</i> du modèle prédisant les crimes contre la personne (Heure de référence = 6).....	36
Figure 6.	Les betas non standardisés (± 2 erreurs standards) des catégories de la variable Heure * Nombre de <i>tweets</i> du modèle prédisant les crimes contre la propriété (Heure de référence = 6).....	37
Figure 7.	Les betas non standardisés (± 2 erreurs standards) des deux polarités d'humeur du modèle prédisant les crimes contre la propriété.....	39
Figure 8.	Les betas non standardisés (± 2 erreurs standards) des six catégories d'humeur du modèle prédisant les crimes contre la propriété.....	40

Remerciements

Mon expérience à la maîtrise a été formidable, et je tiens à remercier quelques personnes qui m'ont soutenu durant mon parcours.

Merci à Rémi de m'avoir transmis sa passion pour l'analyse de la criminalité en milieu urbain et de m'avoir accompagné tout au long de mon projet de maîtrise.

Merci à Francis de m'avoir offert de nombreuses opportunités et expériences de recherche. Merci aussi de m'avoir guidé pour les analyses des données de Twitter.

Merci à Frédéric d'avoir été un responsable de programme qui tenait à notre réussite. Et merci de m'avoir aidé avec mes analyses multiniveau avec le logiciel HLM.

Merci à Mathieu Pigeon, professeur au département de mathématiques de l'UQÀM, de m'avoir aidé avec mes analyses statistiques plus avancées.

Merci à toute l'équipe de la section de Recherche et planification du Service de police de la ville de Montréal de m'avoir chaudement accueilli lors de mon stage. Merci à Maurizio d'avoir été un superviseur hors pair, à Romilda d'avoir été d'une aide précieuse, et à Sabrina d'avoir été une collègue et amie formidable.

Un dernier et grand merci à ma copine, mes parents et mes amis qui m'ont encouragé et qui ont cru en moi du début jusqu'à la fin. Je vous en serai éternellement reconnaissant.

INTRODUCTION

La Section de recherche et planification du Service de police de la ville de Montréal a pour mission d'appuyer le travail policier et de développer des projets stratégiques dans le domaine de la sécurité urbaine (SPVM, 2018).

Il est important pour la section de connaître et d'appliquer les stratégies à la fine pointe des connaissances scientifiques en criminologie, en sociologie et en démographie. Un de ses principaux mandats est de générer le profil de la criminalité à Montréal, et d'identifier les facteurs explicatifs de celui-ci.

Depuis quelques années, l'analyse spatiotemporelle de la criminalité évolue à un rythme effréné. La disponibilité et l'utilisation grandissante d'outils technologiques d'analyse spatiale permettent cette évolution. Les outils d'analyse spatiale permettent donc de faire avancer les connaissances en criminologie à un rythme jamais vu (Townsend et Wortley, 2016) et de soutenir le travail policier à l'aide de données probantes et toujours plus précises. Le SPVM se veut à l'avant-garde des avancements en analyses spatiales, autant technologiques que relatifs aux connaissances du domaine.

Dans ce projet, en collaboration avec la Section de recherche et de planification du SPVM, on présente la répartition de la criminalité à Montréal de la manière la plus précise à ce jour, en utilisant des procédés permettant d'identifier la répartition des crimes au niveau des micro-endroits et pour des temporalités intrajournalières. De plus, des facteurs explicatifs de la criminalité sont générés à partir de données issues des réseaux sociaux. Au final, une méthodologie robuste est développée pour l'analyse spatiotemporelle fine de la criminalité urbaine, et une nouvelle source de donnée, les *tweets*, est mise à l'épreuve dans un contexte de prédiction de la criminalité.

CHAPITRE 1 : RECENSION DES ÉCRITS

La criminologie des endroits (*criminology of place* en anglais) est une branche de la criminologie qui « nous pousse à examiner et à comprendre pourquoi le crime se produit à un endroit spécifique plutôt que de concentrer nos intérêts sur les préoccupations plus traditionnelles des criminologues, soit les raisons pour lesquelles certains types spécifiques de personnes commettent des crimes » (Weisburd, 2015; 134).

Selon Weisburd (2015), il s'agit d'une branche de la criminologie qui ne reçoit pas assez d'attention. L'auteur a analysé l'entièreté des études empiriques publiées dans le journal *Criminology* entre 1990 et 2014. Bien que la proportion d'articles s'intéressant aux places microgéographiques soit passé de 2,6% au début des années 1990 à plus de 6% entre 2010 et 2014, celle-ci demeure très faible. L'auteur milite pour que la communauté scientifique s'y intéresse plus. Son principal argument : la force empirique de la loi de la concentration. Il y a du potentiel à s'intéresser à cette branche de la criminologie afin de d'enrichir nos connaissances sur la criminalité et contribuer significativement à la prévention de celle-ci.

Dans les prochaines sections, la loi de la concentration va être présentée, ainsi que son implication pour le *hotspot policing*. Différentes stratégies visant à rendre le *hotspot policing* le plus efficace possible vont être explorées.

1.1 La loi de la concentration

On peut qualifier la loi de la concentration comme la loi la plus importante de la criminologie des endroits. Clarke et Eck (2005) ont invoqué le principe du 80:20, soit que 80% d'un problème est expliqué par 20% des causes potentielles. Dans le contexte des analyses spatiales en criminologie, on stipule que 20% des endroits sont responsables de 80% des crimes, c'est-à-dire que la criminalité serait concentrée dans une minorité d'endroits. Les premières études s'intéressant au phénomène ont analysé la provenance (l'adresse) des appels d'urgence. Sherman, Gartin et Buerger (1989) ont trouvé que 3,5% des adresses à Minneapolis produisaient 50% des appels d'urgence pour une année. Du côté du Royaume-Uni, on a trouvé qu'aussi peu qu'1% des résidences étaient victimes de 42% des entrées par effraction (Budd, 2001).

La loi de la concentration a également été testée au niveau du segment de rue, et ce dans plusieurs villes du monde. Andresen et Malleson (2011) ont observé qu'à Vancouver, environ 50% des vols de voiture ont lieu dans 5% des segments de rue de la ville. Weisburd (2015) a effectué une analyse de la concentration de plusieurs types de crimes pour plusieurs villes aux États-Unis et en Israël et a trouvé qu'entre 0,4% et 1,6% des segments de rues étaient responsables de 25% des crimes. De plus, il a analysé les changements temporels des concentrations pour des périodes de 10 ans et plus et est arrivé à la conclusion que, malgré des fluctuations significatives au niveau du nombre de crimes, la concentration de ceux-ci restait stable au fil des années. En effet, la loi de la concentration est caractérisée par une grande stabilité temporelle. Curman, Andresen et Brantingham (2015) ont confirmé la stabilité temporelle (pour un période de 16 ans) de la concentration des événements criminels à Vancouver. Braga, Hureau et Papachristos (2010) ont analysé la violence avec arme à feu de 1980 à 2008 et ont observé une grande stabilité de la concentration de ces événements criminels.

Dans son article, Weisburd (2015;135) a établi une définition de la loi de la concentration, qui est devenue une référence pour les criminologues (Rosser, Davies, Bowers, Johnson et Cheng, 2017) : « pour une mesure définie du crime d'une unité microgéographique particulière, la concentration de la criminalité sera caractérisée par un pourcentage petit et restreint pour une proportion cumulative de crimes ». Autrement dit, la majorité des crimes est concentrée à une minorité d'endroits.

On peut facilement penser aux implications pratiques d'une telle loi. En effet, les endroits où les crimes sont concentrés représentent des cibles parfaites pour les activités de prévention (Rosser, Davies, Bowers, Johnson et Cheng, 2017). Si le crime est concentré à des endroits spécifiques, il est naturel que les activités policières et autres activités de prévention soient aussi concentrées (Weisburd, 2015).

1.2 Le *hotspot policing*

La concentration de la criminalité est souvent qualifiée de *hotspot* (point chaud) (Weisburd et Telep, 2014) et de nombreux articles scientifiques se sont intéressés au *hotspot policing*, soit

l'activité policière basée sur des interventions qui ciblent les endroits où les crimes se concentrent (Ratcliffe, 2004). L'efficacité du *hotspot policing* n'est plus à débattre. Le National Research Council aux États-Unis (2004) a déjà, il y a 15 ans, établi que de concentrer l'effort des policiers sur les *hotspots* de crimes est une méthode dont l'efficacité a été prouvée. De plus, Weisburd et Telep (2014) affirment que de démontrer l'efficacité du *hotspot policing* n'est plus suffisant pour se faire publier dans une revue scientifique. Il existe tout de même différentes stratégies pour s'attaquer aux *hotspots* de criminalité, et certaines sont plus efficaces que d'autres.

À la base, il y a la stratégie de la simple présence. Une patrouille peut tout simplement être présente au point chaud et le nombre de crimes et d'incidents diminuera (Sherman et Weisburd, 1995). Bien qu'efficace, cette manière de faire ne fait pas le poids contre une approche axée sur la résolution de problème, qui entraînerait des réductions de la criminalité plus de deux fois plus importantes (Braga, Papachristos et Hureau, 2012). L'approche par résolution de problème se caractérise par l'identification et l'analyse des circonstances sous-jacentes aux problèmes criminels (Eck et Spelman, 1987). Elle est considérée comme l'approche de *hotspot policing* la plus efficace pour le moment, bien que d'autres avenues prometteuses commencent à être explorées, telle la concentration des efforts sur les délinquants connus (Ratcliffe, Groff, Haberman et Sorg, 2012).

Il est important de se rappeler que l'efficacité du *hotspot policing* a seulement été prouvée dans de grandes villes. Une des grandes limites de l'approche est que l'on connaît mal la modélisation de la loi de la concentration en milieu plus rural et, du même coup, de l'effet que pourrait avoir une activité policière plus concentrée (Weisburd et Telep, 2014). Aussi, une grande limite des études s'intéressant au *hotspot policing* est qu'elles tiennent rarement compte de la temporalité « fine » des points chauds de crimes (Ratcliffe, 2004).

1.2.1 La temporalité des *hotspots*

Bien que la stabilité temporelle de la concentration de la criminalité ait été prouvée au niveau des années et au niveau des villes, les choses se compliquent lorsqu'on s'attarde à une temporalité plus « fine ». Haberman, Sorg et Ratcliffe (2017) ont analysé la répartition des vols de rue à Philadelphie selon l'heure de la journée, la journée de la semaine et la saison.

Bien que la loi de la concentration ait tenu, certains micro-endroits étaient propices aux vols en tout temps, alors que d'autres l'étaient seulement à certaines périodes. Ratcliffe (2004) incorpore la temporalité à la définition de *hotspot* et distingue trois types de *hotspots* selon leur comportement temporel au cours d'une journée :

Points chauds diffus : ce sont des points chauds où des événements criminels pourraient survenir à tout moment de la journée

Points chauds concentrés : ce sont des points chauds où des événements criminels pourraient survenir à tout moment de la journée, mais il y a des moments où il y a plus de chances que cela arrive.

Points chauds aigus : Ce sont des points chauds qui sont actifs à certains moments précis de la journée. Il est rare qu'un crime soit commis hors de ces moments précis.

Il est important de tenir compte de la temporalité pour les corps policiers qui utilisent le *hotspot policing*. En effet, il n'est d'aucune utilité de poster une patrouille en pleine nuit à un endroit chaud où la majorité des crimes sont commis au milieu de la journée (Ratcliffe, 2004). La manière la plus facile de représenter la temporalité à l'intérieur d'une journée, de par son accessibilité dans les données policières, est d'utiliser le quart de travail des policiers, soit le jour, le soir et la nuit. Cependant, elle contient deux limites importantes. Premièrement, un crime enregistré à un certain quart n'a pas nécessairement été commis durant cette période. Par exemple, un citoyen qui entre chez lui le soir et se rend compte que quelqu'un s'y est introduit pendant son absence va appeler la police et celle-ci va enregistrer l'entrée par effraction dans le quart de soir. On peut cependant penser que le crime a été commis pendant le jour, alors que la victime était absente. Ainsi, la temporalité du crime est basée sur l'enregistrement de celui-ci plutôt que sa commission, ce qui n'est pas souhaitable. Deuxièmement, les quarts de travail représentent une période de huit heures, et il est possible de se demander si un *hotspot* identifié au quart de travail près ne pourrait pas être désagrégé à l'heure près et démontrer des concentrations différentes à l'intérieur de ce huit heures. Kopper (1995) a démontré qu'une présence policière de 15 minutes à un *hotspot* de crime est le temps idéal de patrouille; on peut penser que de tenter d'identifier un point « critique » d'un *hotspot*

précis – plus précis qu’un quart de huit heures – pourrait s’avérer intéressant pour les forces de l’ordre.

D’autres auteurs ont tenté d’utiliser des temporalités autres que le quart de travail (Haberman et Ratcliffe, 2015; Haberman, Sorg et Ratcliffe, 2017). Haberman et Ratcliffe (2015) ont analysé l’*American Time Use Survey*, qui présente les activités de l’Américain typique durant la journée, et ont divisé celle-ci en quatre périodes non-égales qui reflètent les activités routinières de la population. L’utilisation de cette technique contient deux limites importantes. Premièrement, elle néglige les variations entre les individus. Par exemple, certains travaillent en journée et d’autres le soir ou la nuit; il y a lieu de se demander à quel point une seule routine représente l’ensemble des citoyens. Deuxièmement, elle se base sur les activités routinières des Américains, et il est difficile de savoir si celles-ci sont généralisables à d’autres populations.

Récemment, Wheeler et Haberman (2018) ont analysé les voies de fait et les braquages à l’heure de la journée près à Seattle, et ont pu apprécier des fluctuations propres à certaines heures précises. Cela nous pousse à croire que d’analyser la criminalité à une résolution temporelle très précise permette de faire ressortir des patrons intéressants et jusqu’ici inexplorés.

En somme, l’intervention basée sur le *hotspot policing* paraît d’abord simple et efficace, mais si les policiers veulent que leurs interventions aient le meilleur effet possible, les choses se compliquent. Ainsi, il semble important de tenir compte de la temporalité des *hotspots* et, si l’on veut appliquer l’approche par résolution de problème, qui entraîne la réduction de la criminalité la plus importante, il faut être en mesure d’identifier des facteurs explicatifs de celle-ci.

1.3 Expliquer les crimes au niveau des micro-endroits et Twitter

En ouverture de leur article, Haberman, Sorg et Ratcliffe (2017) affirment qu’il y a un manque de littérature sur le profil spatiotemporel des crimes, et plus précisément sur les variables indépendantes qui pourraient prédire les concentrations spatiales des crimes au niveau micro et à différentes échelles de temporalité. C’est un obstacle important au développement

d'interventions et de programmes au niveau des micro-endroits; les facteurs explicatifs ont peu été étudiés.

Ce manque de variables explicatives au niveau d'agrégation microscopique pousse les chercheurs à en développer. Récemment, certains auteurs se sont intéressés aux données issues des médias sociaux. Plus précisément, les messages envoyés sur Twitter – les *tweets* – ont fait l'objet d'analyses diverses afin de dégager des informations pertinentes à la prédiction et à l'explication des crimes dans les grandes villes. Ceux-ci sont disponibles en données ouvertes, et chaque *tweet* est relié à des données spatiotemporelles extrêmement précises.

Les premiers éléments analysables des *tweets* sont leurs coordonnées géographiques (Andresen et Malleson, 2016). En enregistrant où les *tweets* sont envoyés sur un territoire, il est possible de créer une distribution des *tweets* sur celui-ci, qui peut être utilisée comme *proxy* pour la distribution de la population; la logique étant que plus il y a de *tweets* envoyés à un endroit, plus on s'attend à ce qu'il y ait de personnes présentes à celui-ci. La population est une variable couramment utilisée en analyse spatiale de la criminalité. Pour comparer la criminalité entre les territoires, on fait souvent appel à un taux de criminalité. Plus il y a de personnes présentes sur un territoire, plus on s'attend à ce qu'il y ait de crimes commis, car le nombre de victimes et/ou d'auteurs potentiels est plus élevé. Le taux de criminalité est défini ainsi par Gibbs et Erickson (1976) :

$$\frac{C}{P}$$

Où

C : Le nombre de crimes

P : La population à risque, soit le nombre de personnes potentiellement à risque d'être impliquées dans un acte criminel (*auteurs et/ou victimes*).

La population résidentielle est le type de population le plus couramment utilisé, de par la disponibilité de la donnée. Cependant, le taux de crimes par résidents n'est pas une mesure précise lors d'analyses intra-urbaines, où la population se déplace facilement d'un territoire

(par exemple un quartier) à l'autre. Ainsi, si l'on prend en exemple le Centre-Ville de Montréal, seulement 23 000 personnes y résident, mais plus de 350 000 y transitent chaque jour (Guthrie, 2010). Ces personnes qui transitent sont appelées « visiteurs », et elles peuvent potentiellement être victimes ou auteurs d'actes criminels. Ne pas tenir compte des visiteurs dans le taux de criminalité serait donc une erreur, car on ne tient pas compte de l'entière de la population à risque. Pour bien représenter un phénomène criminel, on doit donc tenir compte de la population réelle d'un territoire à un moment donné. On qualifie cette population réelle de *population flottante*, soit le nombre de personnes présentes sur un territoire, sans nécessairement y résider (Boivin, 2013). Une difficulté rencontrée par les chercheurs est de générer des informations permettant de déterminer une population flottante pour un territoire. Certains auteurs, tels Felson et Boivin (2015) avec les sondages de déplacement, ont estimé la population flottante de grandes villes pour une journée typique. L'avantage des *tweets* est de pouvoir tenir compte des fluctuations intrajournalières de cette population, chose qui n'est pas possible avec les autres sources de données.

Le contenu de *tweets* est une autre composante qui peut s'avérer intéressante. L'analyse de l'humeur issue de *tweets* a été tentée par d'autres disciplines; par exemple pour prédire les résultats d'élections (Birmingham et Smeaton, 2011) ou les fluctuations des marchés boursiers (Bollen, Mao et Zeng, 2011). Chen et ses collègues (2015) ont défini l'humeur selon une échelle de polarité, -1 reflétant une humeur très négative et +1 une humeur très positive.

En somme, l'analyse de *tweets*, bien que toujours considérée comme exploratoire, permet de générer des facteurs explicatifs de la criminalité qui peuvent s'avérer intéressants pour l'explication des *hotspots* de crimes à Montréal. Notamment, plusieurs disciplines présentent l'humeur tirée des *tweets* comme un facteur intéressant pour analyser le comportement humain, et Andresen et Malleson (2016) proposent d'utiliser la géolocalisation et la temporalité des *tweets* afin de générer de l'information sur la population flottante.

1.4 Théories

Certaines théories se prêtent bien à l'analyse de la criminalité au niveau des micro-endroits, et peuvent servir de bases très intéressantes à l'interprétation des résultats.

1.4.1 La théorie des activités routinières

La théorie des activités routinières (Cohen et Felson, 1979) est une approche issue de l'écologie humaine. La routine des personnes détermine ce que les personnes font durant la journée et où elles sont. Ces mouvements dans la ville créent des concentrations de personnes à certains endroits et l'absence de personnes à d'autres. Selon la théorie, un crime est commis lorsqu'un délinquant motivé rencontre une cible potentielle en l'absence d'un gardien qui pourrait empêcher la commission du crime. Ces trois acteurs sont sujets à des contraintes; la routine influence le *quand* des activités, mais pas nécessairement *où* elles sont complétées (Rosser, Davies, Bowers, Johnson, Cheng, 2016).

1.4.2 *Crime pattern theory*

La théorie du *crime pattern* vient compléter la théorie des activités routinières (Brantingham et Brantingham, 1993; Rosser, Davies, Bowers, Johnson, Cheng, 2016). La théorie considère les habitudes de déplacement liées aux activités routinières et amène le concept d'espace des activités. La familiarité se développe autour de ces espaces d'activité. Pour le délinquant motivé, la familiarité lui donne conscience des opportunités criminelles potentielles et joue sur son calcul de coûts/bénéfices (Clarke et Cornish, 1985). Les délinquants vont commettre leurs crimes autour des espaces d'activités.

CHAPITRE 2 : PROBLÉMATIQUE

Le *hotspot policing* est un type d'intervention très prisé par les milieux policiers et qui a fait ses preuves. Il est toutefois possible de l'améliorer et de viser de meilleurs résultats. On s'intéresse à mieux comprendre la distribution des *hotspots* de crimes dans une grande ville à l'aide de données ouvertes de Twitter. L'analyse de *tweets* permet de générer des facteurs explicatifs à la répartition spatiotemporelle de la criminalité.

La loi de la concentration stipule que la majorité des crimes est concentrée à une minorité d'endroits. Elle a été testée de manière rigoureuse et a permis de justifier l'utilisation du *hotspot policing* par les forces de l'ordre. Ce type d'intervention s'est avéré très efficace, surtout si les policiers adoptent une approche par résolution de problème. Cependant, peu de chercheurs se sont intéressés à la temporalité des *hotspots*. Ainsi, il y a certains endroits où il y a toujours des crimes, d'autres où il y a constamment des crimes, mais certaines périodes sont plus propices que d'autres et, finalement, certains endroits où il y a seulement des crimes à certains moments précis. L'approche par résolution de problème est l'approche la plus efficace, mais aussi la plus complexe à mettre en place. En effet, des facteurs expliquant la présence de *hotspots* doivent être mis de l'avant. Pour ce faire, certains chercheurs se sont intéressés à l'analyse des *tweets*, qui a pour but de générer des facteurs explicatifs à la concentration spatiotemporelle précise de la criminalité.

La visée de cette recherche est double. Premièrement, le but est de présenter un portrait précis de la distribution de la criminalité à Montréal en identifiant des *hotspots* de crimes au niveau des micro-endroits et en tenant compte des fluctuations temporelles de ces *hotspots*. En second lieu, il va être tenté d'expliquer cette distribution de la criminalité par l'analyse de *tweets*, plus précisément de l'humeur caractérisant ceux-ci ainsi que de leur localisation géographique. Il est donc possible d'estimer une population flottante et de la caractériser.

CHAPITRE 3 : MÉTHODOLOGIE

Dans cette section, les données utilisées pour mener à bien les deux objectifs de l'étude vont être présentées. De plus, le choix des agrégations spatiales et temporelles choisies est justifié et les méthodes utilisées pour les agrégations sont décrites. Finalement, les analyses mettant en lien les *tweets* et les crimes sont explorées.

3.1 Données utilisées

Les données de crime proviennent de la base de données interne d'un grand corps de police canadien. Tous les crimes contre la personne et contre la propriété enregistrés entre 2011 et 2017 dans une grande ville canadienne sont utilisés pour l'étude. L'utilisation des deux grandes catégories de crimes n'est pas une méthode optimale. En effet, Haberman (2017) a testé le chevauchement des *hotspots* de 11 types de crimes différents et est arrivé à la conclusion qu'ils ne se chevauchaient pas beaucoup, ce qui justifie des explications différentes pour différents types de crimes. Cependant, comme il va être présenté dans cette section, l'analyse spatiotemporelle très fine de la criminalité divise les variables dépendantes en de très nombreuses unités d'analyses, et un certain volume est nécessaire pour mener à bien les analyses. Le volume a été préféré à la précision. La même logique s'applique à l'utilisation de plusieurs années de crimes. Concernant cet élément cependant, Weisburd, Groff et Yang (2012) ont trouvé que la configuration de crimes au niveau des segments de rue était stable dans le temps. Au total, on dénombre 415 709 crimes, dont 99 622 contre la personne et 316 087 contre la propriété.

Il est important de rappeler les limites de l'utilisation de données policières, notamment le chiffre noir (Biderman et Reiss, 1967). La décision de la victime de rapporter ou non le crime à la police, les activités policières, le pouvoir discrétionnaire des policiers et autres peuvent influencer l'enregistrement ou non des crimes et creuser un écart entre les crimes officiels et les crimes réels. Ces éléments doivent être pris en compte lors de l'interprétation des résultats des analyses.

Les *tweets* renferment trois types de données essentiels aux analyses, soit des coordonnées géographiques, un temps d'envoi et des messages rattachés. Ceux-ci sont collectés à même le site de Twitter, et l'ensemble des *tweets* envoyés à l'échelle de la ville, de décembre 2016 à février 2017, ainsi qu'au mois d'août 2017, ont été enregistrés. Au total, on dénombre 499 510

tweets. Seuls 12,69% ont pu être géoréférenciés précisément et utilisés pour l'étude ($n = 63\ 392$).

Les deux premières données, soit les coordonnées géographiques et le temps d'envoi, sont des champs inclus dans les *tweets* collectés. Pour ce qui est des messages rattachés, on cherche à analyser l'humeur qui ressort de ceux-ci. Pour ce faire, le logiciel *R* est utilisé, avec la librairie *sentiment*. Il est possible d'analyser chaque *tweet* et de faire ressortir, à l'aide d'un algorithme, l'humeur générale de ceux-ci. En faisant suite aux études sur l'humeur, les *tweets* sont catégorisés selon deux polarités opposées, une positive et l'autre négative. Une démarche plus exploratoire va aussi être tentée. Ainsi, la librairie permet aussi de classifier l'humeur selon six catégories distinctes. Les *tweets* peuvent refléter de la colère, du dégoût, de la peur, de la joie, de la tristesse ou de la surprise. Il serait intéressant de combiner ces deux méthodes d'estimation de l'humeur afin de préciser l'effet de l'humeur sur le crime.

La librairie *sentiment* permet les deux types d'analyse d'humeur à l'aide de lexiques contenant plusieurs milliers de mots rattachés à une polarité et à une catégorie d'humeur, mais seulement en anglais. Cela pose problème, car les *tweets* récoltés pour l'étude contiennent aussi des *tweets* en français. Pour remédier à ce problème, des lexiques anglophones développés par le Conseil National de Recherche du Canada (CNRC) (Mohammad et Turney, 2013) ont été introduits manuellement dans la librairie *R*, ainsi que leur traduction francophone (Abdaoui, Azé, Bringay et Poncelet, 2016), réalisée par un groupe de chercheurs français. Au final, les *tweets* anglophones, francophones et bilingues ont pu être analysés.

Les données de géolocalisation permettent de générer un nombre de *tweets* par unité d'analyse et donc des concentrations de *tweets*, reflétant ainsi la concentration (et la distribution) de la population sur l'île. L'analyse du texte va permettre de créer plusieurs variables liées à l'humeur (deux pour la polarité et six pour les catégories d'humeurs). Une limite importante de l'utilisation des données de *Twitter* est à noter. Ainsi, il n'est pas encore clair si l'utilisation de *tweets* représente un biais populationnel important. On peut penser que la population qui utilise *Twitter* à Montréal n'est peut-être pas équivalente à la population en général sur l'île, que l'on tente ici d'analyser (Malleon et Andresen, 2012). L'utilisation des *tweets* est considérée une démarche exploratoire.

3.1.1 Le problème de multicollinéarité entre les prédicteurs liés à l'humeur

Tableau I. Corrélations de Spearman entre les proportions de *tweets* reliées à des catégories d'humeurs et à des polarités d'humeurs

	Colère	Dégoût	Peur	Joie	Négatif	Positif	Tristesse	Surprise
Colère								
Dégoût	0,189							
Peur	0,192	0,185						
Joie	0,217	0,201	0,240					
Négatif	0,404	0,348	0,490	0,319				
Positif	0,255	0,223	0,267	0,716	0,320			
Tristesse	0,206	0,187	0,219	0,290	0,614	0,331		
Surprise	0,195	0,182	0,213	0,243	0,258	0,431	0,228	

Toutes les corrélations sont significatives à $p < 0,001$

Avant d'aller plus loin, il est important de tenir compte de la colinéarité entre les variables indépendantes liées à l'humeur. Dans un modèle multivarié, si les prédicteurs sont corrélés entre eux, il devient difficile d'observer la relation indépendante entre chaque variable indépendante et la dépendante. Lorsqu'un prédicteur change, il crée aussi un changement des autres prédicteurs; ce qui fait que les variables indépendantes du modèle peuvent changer drastiquement dépendamment de laquelle est présente dans le modèle. Dans le tableau ci-haut, on note de fortes corrélations entre les deux groupes de variables d'humeurs, soit les deux polarités et les six catégories. La proportion de *tweets* positifs est principalement corrélée à la proportion de *tweets* de joie ($r = 0,716$) et à la proportion de *tweets* de surprise ($r = 0,431$), alors que la proportion de *tweets* négatifs est principalement corrélée à la proportion de *tweets* de colère ($r = 0,404$), la proportion de *tweets* de dégoût ($r = 0,348$), la proportion de *tweets* de peur ($r = 0,490$) et la proportion de *tweets* de tristesse ($r = 0,614$) (tous les $p < 0,001$). Il y aurait des méthodes statistiques qui permettraient de remédier aux effets de la colinéarité entre les variables indépendantes liées à l'humeur, mais d'un point de vue plus pratique, elles resteront, à leur essence même, toujours liées (Graham, 2003). Ainsi, inclure toutes les variables d'humeurs dans un même modèle reviendrait à évaluer l'impact d'humeurs semblables, mais présentées sous différentes formes.

Les polarités et les six catégories représentent donc deux méthodes qui permettent d'évaluer un même concept, l'humeur; cela supporte l'idée de les séparer en deux modèles distincts. Les différents modèles sont présentés plus en détails dans le chapitre 4 : *Stratégie d'analyse*.

3.2 Unité d'analyse

Les données issues des variables à l'étude sont agrégées au niveau spatial et au niveau temporel.

Au niveau spatial, les segments de rue ont été utilisés (n=45 099). Comme expliqué plus tôt, les crimes sont concentrés aux micro-endroits, et donc les *hotspots* de crimes sont très locaux (Weisburd, 2015). Plusieurs études confirment que les crimes sont majoritairement expliqués au segment de rue (plutôt qu'à d'autres zones plus grandes) (Groff et al., 2009; Andresen et Malleson, 2011; Weisburd et al., 2012; Steenbeck et Weisburd, 2016). Steenbeck et Weisburd (2016) ont comparé la variabilité des crimes aux segments de rue (micro-endroits) à celle aux quartiers (mésos) et aux districts (macro). Ils ont trouvé que la majorité de la variabilité de la criminalité (62%) était située au niveau des segments de rue, puis 6% pour les quartiers et 32% pour les districts.

Comme il a été expliqué plus tôt, il est important de tenir compte de la temporalité lors de l'analyse spatiale de la criminalité. Certains endroits peuvent être des *hotspots* de crimes à certains moments de la journée sans l'être à d'autres (Ratcliffe, 2004). D'un point de vue pratique, par exemple, il est fort peu efficace de déployer une patrouille à un certain endroit en début d'après-midi alors qu'il ne représente un risque important de criminalité qu'en soirée. Plus tôt, les limites des études ayant tenté d'inclure une temporalité journalière ont été soulevées. L'utilisation des quarts de travail des policiers reflète l'enregistrement des crimes plutôt que leur commission et est peu précis. Se baser sur les activités routinières est intéressant, mais les études se sont basées sur un sondage des États-Unis, qui ne sont pas nécessairement généralisables à la population canadienne.

Comme Wheeler et Haberman (2018), les crimes de cette étude sont divisés selon l'heure de la journée (n=24). Contrairement aux auteurs, qui ont étudié deux types de crimes (voies de fait et braquages) dont l'heure exacte de commission est souvent connue, cette étude s'intéresse à

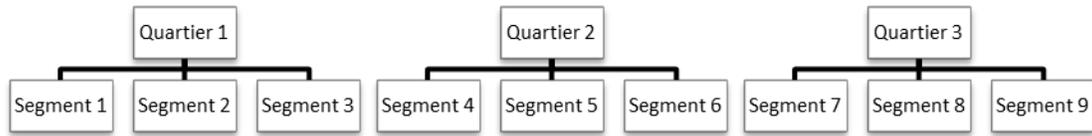
plusieurs types de crimes, dont certains sont parfois moins propices à avoir une heure de commission facilement identifiable pour la police. Par exemple, si quelqu'un rapporte une voiture volée, la police enregistre un temps de début (l'heure où la personne a quitté son véhicule) et un temps de fin (l'heure où la personne a constaté que son véhicule a été volé). Cela crée un intervalle de temps où le véhicule a pu être volé, et celui-ci peut être très grand. Pour remédier à ce problème, une prédiction de l'heure réelle de commission des délits à l'intérieur de l'intervalle *heure de début/heure de fin* va être tentée à l'aide de l'analyse dite *aoristic*. Elle consiste à diviser la probabilité qu'un crime soit commis par le nombre d'heures incluses dans l'intervalle début/fin, faire la somme de ces probabilités pour tous les crimes commis et créer une pondération temporelle pour une unité spatiale (Ratcliffe, 2000; Ratcliffe, 2002). Une courbe aoristique est donnée pour chaque catégorie de crime dans chaque unité géographique (ici le segment de rue) et permet de prédire l'heure de commission d'un délit avec l'intervalle fourni par les données policières. Ashby et Bowers (2013) ont comparé diverses méthodes de prédiction de l'heure de commission des délits et la méthode aoristique est celle qui offre la meilleure prédiction. Les crimes dont l'intervalle entre l'heure de début et l'heure de fin dépasse les 24 heures ont été retirés de la banque de données, car cela pourrait fausser la pondération donnée de l'analyse (voir Ratcliffe (2000, 673) pour plus de détails).

Au final, l'unité d'analyse est le segment de rue * l'heure de la journée. Cela permet d'avoir un portrait précis de la criminalité, autant spatial que temporel.

3.3 Le modèle multiniveau

Plusieurs études mettant de l'avant les segments de rue pour l'étude de la criminalité urbaine ont utilisé le modèle multiniveau (aussi appelé hiérarchique ou mixte). Comme expliqué à la section précédente, la majorité de la variance explicable du nombre de crimes est attribuée au segment de rue (Steenbeck et Weisburd, 2016; Schnell, Braga et Piza, 2017). Ces études tiennent toutefois compte des autres niveaux d'agrégation spatiale afin d'avoir un portrait plus complet du comportement criminel de la ville, et de contrôler la dépendance spatiale des segments de rue. Au premier niveau, on intègre les prédicteur de l'unité d'analyse, soit le segment de rue pour la majorité des études. Au deuxième niveau, on intègre les prédicteurs qui fluctuent à un niveau géographique plus agrégé, par exemple les quartiers d'une ville :

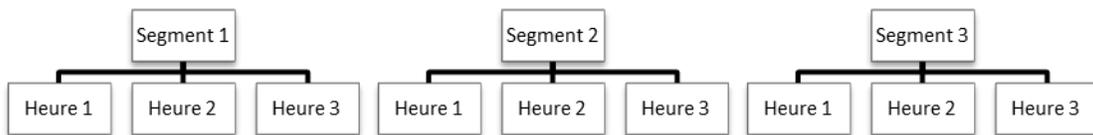
Figure 1. Exemple de la structure de variables spatiales hiérarchiques



Ainsi, même si le nombre de crimes est répertorié au niveau du segment de rue, il est possible d’analyser des facteurs explicatifs au niveau des quartiers, qui s’appliquent à leurs unités d’analyse (segments de rue) respectives.

Dans cette étude, l’unité d’analyse est le segment de rue selon l’heure de la journée, ce qui est un niveau encore plus précis que les autres études utilisant le modèle multiniveau pour l’étude du crime urbain.

Figure 2. Structure des variables spatiales et temporelles de l’étude



Comme on le voit dans la figure ci-dessus, le deuxième niveau de cette étude est le segment de rue, qui regroupe les 24 heures de la journée au premier niveau. Au final, on se retrouve avec 45 099 unités d’analyse au deuxième niveau (segments de rue) et 1 082 376 unités d’analyse au premier niveau (45 099 segments de rue * 24 heures de la journée).

Comme expliqué dans les autres travaux utilisant les modèles hiérarchiques, tenir compte de deux niveaux d’agrégation comporte deux avantages principaux.

Premièrement, l’approche multiniveau permet de respecter le postulat d’indépendance des unités d’analyses. Ainsi, les segments de rue selon l’heure de la journée ne sont pas complètement indépendants entre eux. Certaines unités d’analyse sont liées au même segment de rue, et ce lien peut expliquer le nombre de crimes commis. En introduisant le segment de

rue comme deuxième niveau (soit qui regroupe des unités du premier niveau), on tient compte de la non-indépendance des unités du premier niveau qui appartiennent au même segment.

Deuxièmement, il est possible de vérifier si l'utilisation d'un modèle multiniveau permet d'avoir un portrait plus complet de la criminalité. Il est possible de le vérifier avec le modèle des composantes de la variance, parfois référé comme « inconditionnel » ou « vide », qui compare l'apport de chaque niveau d'un modèle hiérarchique pour la prédiction de la variable dépendante. Il ne contient pas de prédicteur, l'ordonnée à l'origine est aléatoire et il permet de décomposer la variance totale de la variable dépendante entre les différents niveaux choisis. Ainsi, il est possible d'obtenir la part de variance du premier niveau (segments*heure) et celle du deuxième niveau (segments de rue).

Tableau II. Part de la variance explicable par chaque niveau d'agrégation du modèle hiérarchique (%)

Niveau	Part de la variance	
	Crimes contre la propriété	Crimes contre la personne
Segments de rue * Heure de la journée (niveau 1)	39,05	40,84
Segments de rue (niveau 2)	60,95	59,16

Pour les crimes contre la propriété, on observe qu'une majorité de la variance (60,95%) de la variance explicable se trouve au niveau des segments de rue, mais qu'une part non-négligeable est attribuée aux segments de rue selon l'heure de la journée (39,05%). Le constat est semblable pour les crimes contre la personne, avec des pourcentages de 59,16% et de 40,84%, respectivement. Il est ainsi possible de conclure que pour avoir un portrait complet du phénomène criminel au niveau des segments de rue à Montréal, il est primordial de tenir compte du temps de la journée. Aussi, les parts de variances sont départagées entre les deux niveaux hiérarchiques, ce qui confirme l'intérêt d'utiliser un modèle multiniveau.

L'analyse de l'effet des *tweets* est produite au premier niveau. D'autres prédicteurs sont introduits au deuxième niveau afin d'avoir un portrait plus complet de la criminalité de la ville.

3.3.1 La désorganisation sociale

Des prédicteurs issus de la théorie de la désorganisation sociale sont utilisés. Cette théorie a d'abord été introduite par Shaw et McKay (1942), et avait comme prémisse que les facteurs sociaux d'une communauté urbaine pouvaient perturber la structure de celle-ci et du même coup influencer la criminalité. Les trois facteurs structurels ont été mis de l'avant : l'hétérogénéité ethnique, le revenu et la mobilité résidentielle. Dans cette étude, les familles monoparentales sont ajoutées, et indiquent le degré de supervision parentale et de désavantage social (Boivin et Ouellet, 2011).

Ces données sociodémographiques ont été colligées à l'aide des données issues du recensement de 2016 de Statistiques Canada. Pour chaque secteur de recensement (n=530) de Montréal, soit de petites zones géographiques qui comptent une population entre 2500 et 8000 habitants (Statistiques Canada, 2018), les quatre facteurs ont été modélisés. On inclut donc le pourcentage de familles monoparentales, le pourcentage de la population sous le seuil de la pauvreté, le pourcentage de minorités visibles et le pourcentage de personnes ayant déménagé au cours des cinq années précédentes (mobilité résidentielle). Les études qui s'intéressent à la désorganisation sociale tentent souvent de prédire un taux de criminalité basé sur la population résidente. Les variables dépendantes de cette étude sont des nombres bruts de crime, et les limites d'un taux basé sur la population résidente ont été soulevées plus haut. La population résidente est donc plutôt introduite comme une variable indépendante et est elle aussi issue du recensement de 2016 de Statistiques Canada.

Il est à noter que les variables du recensement utilisées ne sont disponibles qu'au secteur de recensement près. Afin de les introduire dans le deuxième niveau de notre modèle, soit le segment de rue, les données sont désagrégées. Ainsi, tous les segments de rue appartenant au même secteur de recensement ont les mêmes valeurs en ce qui a trait aux variables de désorganisation sociale.

3.3.2 Le lag spatial

Une dernière variable est ajoutée au deuxième niveau, soit le lag spatial. Introduit par Anselin (1988), le lag spatial représente la moyenne des valeurs avoisinantes pour une valeur spatiale donnée. Ainsi, il est souvent constaté que des variables définies spatialement sont corrélées entre elles, et donc qu'elles ne respectent pas le postulat d'indépendance. Ici, on se demande si les crimes étudiés sont corrélés au niveau du segment de rue. Pour répondre à cette question, le I de Moran est utilisé, soit une mesure d'autocorrélation qui va permettre de déterminer si le nombre de crimes d'un segment est corrélé au nombre de crime des segments avoisinants.

Pour déterminer si un segment est avoisinant, des matrices de distance sont utilisées. Ainsi, tous les segments situés à un rayon de x mètres ou moins sont considérés avoisinants. Le I de Moran a été calculé pour chaque incrément de 50 mètres jusqu'à une distance maximale de 500 mètres et bien qu'une corrélation significative ait été trouvée pour chaque, la plus importante était à 100 mètres; et ce autant pour les crimes contre la personne que les crimes contre la propriété. La corrélation était de 0,169 pour les crimes contre la personne et de 0,229 pour les crimes contre la propriété ($p < 0,001$). Les corrélations positives et modérées indiquent que les segments de rue sont entourés d'autres segments avec des niveaux semblables de crimes. Cela soutient l'idée que les crimes sont concentrés au niveau de segments de rue et confirme qu'il y a un problème de dépendance spatiale au deuxième niveau d'agrégation. Pour résoudre ce problème, on introduit un lag spatial comme variable indépendante au deuxième niveau. Un lag spatial est généré pour chaque catégorie de crime, et la limite de 100 mètres, là où l'autocorrélation est la plus élevée, est déterminée. La dépendance spatiale est donc contrôlée et le postulat d'indépendance est respecté.

CHAPITRE 4 : STRATÉGIE D'ANALYSE

L'analyse multivariée des crimes sera effectuée à l'aide de modèles Poisson, plutôt que les modèles linéaires couramment utilisés. Avec près d'1,1 million d'unités d'analyse (45 099 segments de rue * 24 heures de la journée), plusieurs de celles-ci ne contiennent pas de crime et, en général, leur valeur est très petite. Ainsi, la distribution des deux types de crimes est caractérisée par une asymétrie positive, un mode à zéro et de petites valeurs, et est donc mieux prédite par un modèle de type Poisson (Osgood, 2000). Bien qu'elles suivent une distribution Poisson, les variables dépendantes ne respectent pas deux postulats incontournables de celle-ci. Des ajustements doivent être faits.

Premièrement, le modèle Poisson n'est utilisable qu'avec une variable dépendante composée d'entiers. Or, la méthode aoristique, utilisée pour prédire l'heure de commission exacte des événements criminels, a transformé les deux variables dépendantes d'entiers à des nombres décimaux. Pour pouvoir utiliser un modèle Poisson, tous les nombres décimaux ont été arrondis à l'entier le plus près.

Deuxièmement, le modèle Poisson présuppose que la variance et la moyenne de la variable dépendante sont égales.

Tableau III. Variance et moyenne des variables dépendantes

	Variance	Moyenne
Crimes contre la propriété	2,46	0,26
Crimes contre la personne	0,23	0,11

Le tableau 3 indique que ce postulat n'est pas respecté. Pour les deux variables, la variance est plus élevée que la moyenne, ce qui témoigne d'une surdispersion des données. Pour remédier à ce problème, la méthode d'estimation du modèle, qui est habituellement le maximum de vraisemblance, est modifiée. On utilise plutôt la quasi-vraisemblance pénalisée restreinte, qui

permet de contrôler pour la surdispersion et d'ainsi respecter le postulat de Poisson. Cette méthode d'estimation ne permet pas de comparer des modèles entre eux.

Au final, des modèles Poisson multiniveau multivariés sont mis de l'avant. Au deuxième niveau, les variables liées à la désorganisation sociale et le lag spatial sont introduites. Au premier niveau, les variables liées aux *tweets*, soit les polarités, les six catégories d'humeurs et le nombre de *tweets* sont introduites, ainsi que les heures de la journée.

Trois modèles sont présentés :

- 1- Le premier modèle contient les variables de deuxième niveau, le nombre de *tweets*, les variables de polarités et les heures de la journée;
- 2- Le deuxième modèle est identique au premier, mis à part que les variables de polarité sont remplacées par les variables liées aux six catégories d'humeurs;
- 3- Le troisième modèle n'inclut aucune variable de la polarité ou de catégorie d'humeur, et introduit l'interaction entre le nombre de *tweets* et les heures de la journée.

On remarque que les variables du deuxième niveau ainsi que les heures de la journée sont présentes dans tous les modèles et permettront de tirer des conclusions sur la désorganisation sociale, sur l'utilité du lag spatial et sur l'influence de l'heure de la journée sur le nombre de crimes. Dans le premier modèle et le deuxième modèle, différentes variables d'humeur sont présentes et permettront de mieux comprendre la relation entre l'humeur et la criminalité. Le nombre de *tweets* est présent dans les trois modèles. Dans le troisième modèle, il est possible de considérer son effet par lui-même, et dans les deux premiers modèles il est possible de considérer son effet lorsque l'humeur est prise en compte. Finalement, l'effet des *tweets* selon l'heure de la journée est exploré à l'aide du troisième modèle.

CHAPITRE 5 : RÉSULTATS

Comme expliqué précédemment, deux modèles sont présentés pour présenter les effets des humeurs sur la criminalité, soit un présentant les six catégories d’humeurs et l’autre les polarités d’humeurs. Un troisième modèle est présenté afin d’explorer les effets du nombre de *tweets* sur les crimes selon l’heure de la journée. Des graphiques sont également présentés afin de comparer la force de prédiction des variables indépendantes.

5.1 Le lag spatial

Pour l’ensemble des modèles et pour les deux grandes catégories de crimes, le lag spatial était significatif. Ainsi, cette influence des segments avoisinants sur le segment étudié démontre la dépendance entre les unités spatiales avoisinantes et le besoin de tenir compte du lag spatial pour toute analyse contenant des données spatiales.

5.2 Les modèles explicatifs multivariés

Le modèle 1 incorpore les variables sociodémographiques et le lag spatial au deuxième niveau, ainsi que le nombre de *tweets*, les polarités de *tweets* et les heures de la journée au premier niveau.

Tableau IV. Modèle multiniveau Poisson 1 prédisant les crimes au segment de rue (coefficients beta non standardisés et (intervalles de confiance))

Variable	Crimes contre la personne	Crimes contre la propriété
Population résidente	-0,000** (1,000;1,000)	-0,000*** (1,000;1,000)
Familles monoparentales (%)	0,033*** (1,029;1,037)	0,016*** (1,012;1,021)
Pop sous le seuil pauvreté (%)	0,019*** (1,015;1,024)	0,026*** (1,021;1,032)
Minorité visibles (%)	-0,002* (0,997;1,000)	-0,008*** (0,991;0,994)
Mobilité résidentielle (%)	0,020*** (1,018;1,023)	0,025*** (1,023;1,028)
Lag spatial	0,088*** (1,082;1,102)	0,022*** (1,015;1,029)
Nombre de <i>tweets</i>	-0,003 (0,992;1,002)	0,009 (0,999;1,020)
P. de <i>tweets</i> négatifs	-0,000 (0,999;1,001)	0,002*** (1,001;1,003)
P. de <i>tweets</i> positifs	-0,001* (0,999;1,000)	0,001*** (1,001;1,002)
Heure 0	1,812*** (5,800;6,467)	1,117*** (2,975;3,137)
Heure 1	1,361*** (3,681;4,133)	0,757*** (2,061;2,206)
Heure 2	1,032*** (2,605;3,025)	0,623*** (1,785;1,945)

Heure 3	1,023*** (2,572;3,006)	0,539*** (1,656;1,776)
Heure 4	0,710*** (1,909;2,168)	0,356*** (1,393;1,463)
Heure 5	0,225*** (1,186;1,324)	0,129*** (1,115;1,161)
Heure 7	0,237*** (1,197;1,341)	0,031** (1,009;1,054)
Heure 8	0,620*** (1,746;1,980)	0,253*** (1,252;1,324)
Heure 9	0,816*** (2,127;2,405)	0,365*** (1,395;1,488)
Heure 10	1,005*** (2,570;2,902)	0,512*** (1,604;1,734)
Heure 11	1,083*** (2,782;3,138)	0,645*** (1,816;2,001)
Heure 12	1,214*** (3,170;3,573)	0,999*** (2,578;2,858)
Heure 13	1,190*** (3,098;3,487)	0,945*** (2,416;2,738)
Heure 14	1,229*** (3,221;3,625)	0,996*** (2,531;2,895)
Heure 15	1,359*** (3,669;4,131)	1,052*** (2,671;3,068)
Heure 16	1,385*** (3,768;4,234)	1,031*** (2,610;3,014)
Heure 17	1,383*** (3,768;4,218)	0,968*** (2,470;2,809)
Heure 18	1,387*** (3,781;4,234)	0,923*** (2,385;2,656)
Heure 19	1,397*** (3,821;4,280)	0,871*** (2,276;2,506)
Heure 20	1,423*** (3,918;4,392)	0,838*** (2,216;2,413)
Heure 21	1,403*** (3,844;4,302)	0,717*** (1,975;2,123)
Heure 22	1,361*** (3,689;4,121)	0,591*** (1,754;1,861)
Heure 23	1,276*** (3,386;3,787)	0,552*** (1,690;1,785)

*** p< 0,001 ** p< 0,01 * p< 0,05

Une première analyse peut être faite sur les crimes contre la personne. Tous les prédicteurs du deuxième niveau sont significatifs. La population résidente et le pourcentage de minorités visibles ont une relation négative avec les crimes contre la personne, alors que les autres prédicteurs sociodémographiques ont une relation positive. Pour ce qui est des trois prédicteurs liés aux *tweets*, seule la proportion de *tweets* positifs est significative, et elle a une relation négative avec les crimes contre la personne. Finalement, les catégories de la variable heure sont toutes significatives. Elles ont toutes un coefficient positif, comparativement à la valeur de référence (Heure 6), et surtout des valeurs assez différentes entre elles. Les coefficients fluctuent entre 0,225 (Heure 5) et 1,81 (Heure 0). On peut conclure que le nombre de crime est assez différent selon l'heure de la journée.

Dans le modèle des crimes contre la propriété, tous les prédicteurs du deuxième niveau sont significatifs à p<0,001. Comme pour les crimes contre la personne, les coefficients sont tous

positifs mis à part pour la population résidentielle et le pourcentage de minorités visibles. Pour ce qui est des variables reliées aux *tweets*, seul le nombre de *tweets* est non significatif; les deux polarités sont significatives à $p < 0,001$ et ont une relation positive avec le nombre de crimes. Finalement, les conclusions pour la variable heure sont les mêmes que pour le modèle des crimes contre la personne.

Tableau V. Modèle multiniveau Poisson 2 prédisant les crimes au segment de rue (coefficients beta non standardisés et (intervalles de confiance))

Variable	Crimes contre la personne	Crimes contre la propriété
Population résidente	-0,000** (1,000;1,000)	-0,000*** (1,000;1,000)
Familles monoparentales (%)	0,033*** (1,029;1,037)	0,016*** (1,012;1,021)
Pop sous le seuil pauvreté (%)	0,019*** (1,015;1,024)	0,026*** (1,021;1,032)
Minorité visibles (%)	-0,002* (0,997;1,000)	-0,008*** (0,991;0,994)
Mobilité résidentielle (%)	0,020*** (1,018;1,023)	0,026*** (1,023;1,028)
Lag spatial	0,088*** (1,082;1,102)	0,022*** (1,015;1,029)
Nombre de <i>tweets</i>	-0,003 (0,992;1,002)	0,010 (0,999;1,022)
P. de <i>tweets</i> de colère	0,000 (0,998;1,002)	0,003** (1,001;1,004)
P. de <i>tweets</i> de dégoût	-0,000 (0,997;1,002)	0,001 (1,000;1,002)
P. de <i>tweets</i> de peur	-0,000 (0,998;1,001)	0,002** (1,001;1,004)
P. de <i>tweets</i> de joie	-0,001 (0,998;1,000)	0,001** (1,000;1,002)
P. de <i>tweets</i> de tristesse	-0,001 (0,998;1,001)	0,001** (1,001;1,002)
P. de <i>tweets</i> de surprise	-0,001 (0,998;1,001)	0,001*** (1,000;1,002)
Heure 0	1,812*** (5,801;6,468)	1,117*** (2,976;3,138)
Heure 1	1,361*** (3,681;4,132)	0,758*** (2,062;2,207)
Heure 2	1,032*** (2,605;3,025)	0,621*** (1,784;1,943)
Heure 3	1,023*** (2,572;3,006)	0,539*** (1,656;1,775)
Heure 4	0,710*** (1,909;2,169)	0,356*** (1,393;1,463)
Heure 5	0,225*** (1,186;1,324)	0,129*** (1,115;1,162)
Heure 7	0,237*** (1,197;1,341)	0,030*** (1,008;1,053)
Heure 8	0,620*** (1,746;1,980)	0,255*** (1,254;1,327)
Heure 9	0,816*** (2,126;2,405)	0,367*** (1,398;1,490)
Heure 10	1,004*** (2,569;2,901)	0,513*** (1,608;1,737)
Heure 11	1,083*** (2,781;3,136)	0,647*** (1,821;2,005)
Heure 12	1,213*** (3,169;3,572)	1,001*** (2,586;2,865)
Heure 13	1,190*** (3,097;3,486)	0,946*** (2,422;2,738)
Heure 14	1,228*** (3,218;3,622)	0,999*** (2,540;2,901)
Heure 15	1,359*** (3,668;4,129)	1,054*** (2,679;3,073)

Heure 16	1,385*** (3,767;4,233)	1,034*** (2,618;3,021)
Heure 17	1,383*** (3,767;4,217)	0,970*** (2,475;2,813)
Heure 18	1,386*** (3,780;4,233)	0,927*** (2,394;2,665)
Heure 19	1,397*** (3,820;4,280)	0,874*** (2,284;2,515)
Heure 20	1,422*** (3,916;4,390)	0,840*** (2,221;2,418)
Heure 21	1,402*** (3,843;4,301)	0,719*** (1,980;2,128)
Heure 22	1,361*** (3,690;4,122)	0,593*** (1,756;1,864)
Heure 23	1,275*** (3,385;3,785)	0,553*** (1,692;1,787)

*** p< 0,001 ** p< 0,01 * p< 0,05

Le modèle 2 incorpore les variables sociodémographiques et le lag spatial au deuxième niveau, ainsi que le nombre de *tweets*, les six catégories d'humeurs de *tweets* et les heures de la journée au premier niveau.

Pour le modèle prédisant les crimes contre la personne, aucune des variables liées aux *tweets* n'est significative. Ce résultat diffère quelque peu de la logique du premier modèle où la proportion de *tweets* positifs est significative. Les variables du deuxième niveau et la variable heure sont pratiquement identiques au premier modèle.

Dans le modèle des crimes contre la propriété, la proportion de *tweets* de surprise est significative à $p < 0,001$, les proportions de *tweets* de tristesse, joie, peur et colère sont significatives à $p < 0,01$, et la proportion de *tweets* de dégoût ainsi que le nombre de *tweets* sont non-significatifs. On note, comme pour le premier modèle, qu'un plus grand spectre d'humeurs semble lié aux crimes contre la propriété, comparativement aux crimes contre la personne. Les variables du deuxième niveau et la variable heure sont pratiquement identiques au premier modèle.

Un troisième modèle est conçu, afin d'analyser plus en détails la relation entre le nombre de *tweets* et les crimes. Selon les deux modèles présentés ci-haut, la prédiction du nombre de crimes par le nombre de *tweets* est non-significative, autant pour les crimes contre la personne que les crimes contre la propriété. Il a aussi été démontré que de grandes différences existent entre les différentes heures de la journée et le nombre de crimes. Le troisième modèle inclut

l'interaction Nombre de *tweets* * Heure, afin d'analyser la relation entre le nombre de *tweets* et le nombre de crimes selon l'heure de la journée.

Tableau VI. Modèle multiniveau Poisson 3 prédisant les crimes au segment de rue (coefficients beta non standardisés et (intervalles de confiance))

Variable	Crimes contre la personne	Crimes contre la propriété
Population résidente	-0,000** (1,000;1,000)	-0,000*** (1,000;1,000)
Familles monoparentales (%)	0,033*** (1,030;1,037)	0,016*** (1,012;1,021)
Pop sous le seuil pauvreté (%)	0,019*** (1,015;1,024)	0,026*** (1,021;1,032)
Minorité visibles (%)	-0,002* (0,997;1,000)	-0,008*** (0,991;0,994)
Mobilité résidentielle (%)	0,020*** (1,018;1,023)	0,026*** (1,023;1,028)
Lag spatial	0,088*** (1,082;1,102)	0,022*** (1,015;1,030)
Nombre de <i>tweets</i>	-0,019 (0,923;1,043)	0,021*** (1,010;1,033)
Heure 0	1,808*** (5,775;6,440)	1,118*** (2,979;3,141)
Heure 1	1,356*** (3,664;4,109)	0,752*** (2,052;2,194)
Heure 2	1,027*** (2,595;3,007)	0,617*** (1,777;1,935)
Heure 3	1,017*** (2,561;2,985)	0,533*** (1,650;1,762)
Heure 4	0,705*** (1,901;2,157)	0,354*** (1,391;1,461)
Heure 5	0,224*** (1,184;1,322)	0,128*** (1,114;1,160)
Heure 7	0,232*** (1,192;1,335)	0,038** (1,016;1,062)
Heure 8	0,616*** (1,738;1,972)	0,260*** (1,262;1,334)
Heure 9	0,811*** (2,116;2,393)	0,375*** (1,409;1,502)
Heure 10	0,999*** (2,555;2,886)	0,522*** (1,621;1,752)
Heure 11	1,079*** (2,768;3,124)	0,655*** (1,835;2,021)
Heure 12	1,217*** (3,180;3,588)	1,010*** (2,609;2,890)
Heure 13	1,184*** (3,079;3,468)	0,953*** (2,437;2,759)
Heure 14	1,223*** (3,202;3,606)	1,006*** (2,559;2,925)
Heure 15	1,354*** (3,648;4,109)	1,061*** (2,697;3,098)
Heure 16	1,379*** (3,745;4,211)	1,040*** (2,634;3,042)
Heure 17	1,383*** (3,766;4,218)	0,976*** (2,489;2,831)
Heure 18	1,386*** (3,777;4,235)	0,933*** (2,408;2,683)
Heure 19	1,395*** (3,810;4,270)	0,878*** (2,293;2,526)
Heure 20	1,419*** (3,901;4,376)	0,844*** (2,228;2,426)
Heure 21	1,395*** (3,813;4,270)	0,722*** (1,985;2,134)
Heure 22	1,354*** (3,663;4,093)	0,597*** (1,765;1,872)
Heure 23	1,270*** (3,367;3,767)	0,553*** (1,692;1,787)
Interaction Heure 0 * Nombre de <i>tweets</i>	0,038 (0,976;1,105)	0,013** (1,004;1,023)

Interaction Heure 1 * Nombre de <i>tweets</i>	0,060	(0,990;1,137)	0,057**	(1,026;1,093)
Interaction Heure 2 * Nombre de <i>tweets</i>	0,086*	(1,006;1,181)	0,099**	(1,044;1,167)
Interaction Heure 3 * Nombre de <i>tweets</i>	0,119*	(1,016;1,250)	0,103*	(1,001;1,227)
Interaction Heure 4 * Nombre de <i>tweets</i>	0,094*	(1,021;1,182)	0,025	(0,963;1,092)
Interaction Heure 5 * Nombre de <i>tweets</i>	0,034	(0,973;1,100)	0,006*	(1,001;1,012)
Interaction Heure 7 * Nombre de <i>tweets</i>	0,029	(0,969;1,094)	-0,021*	(0,961;0,997)
Interaction Heure 8 * Nombre de <i>tweets</i>	0,025	(0,964;1,090)	-0,005	(0,988;1,002)
Interaction Heure 9 * Nombre de <i>tweets</i>	0,026	(0,965;1,091)	-0,006	(0,984;1,003)
Interaction Heure 10 * Nombre de <i>tweets</i>	0,023	(0,963;1,088)	-0,004	(0,988;1,004)
Interaction Heure 11 * Nombre de <i>tweets</i>	0,020	(0,958;1,087)	-0,003	(0,990;1,004)
Interaction Heure 12 * Nombre de <i>tweets</i>	-0,018	(0,919;1,050)	-0,003	(0,992;1,002)
Interaction Heure 13 * Nombre de <i>tweets</i>	0,023	(0,961;1,089)	0,002	(0,995;1,008)
Interaction Heure 14 * Nombre de <i>tweets</i>	0,021	(0,958;1,087)	-0,002	(0,994;1,002)
Interaction Heure 15 * Nombre de <i>tweets</i>	0,024	(0,963;1,090)	-0,001	(0,993;1,005)
Interaction Heure 16 * Nombre de <i>tweets</i>	0,023	(0,962;1,089)	-0,001	(0,992;1,006)
Interaction Heure 17 * Nombre de <i>tweets</i>	0,002	(0,938;1,070)	0,003	(0,999;1,007)
Interaction Heure 18 * Nombre de <i>tweets</i>	0,003	(0,935;1,075)	-0,001	(0,996;1,003)
Interaction Heure 19 * Nombre de <i>tweets</i>	0,011	(0,946;1,080)	0,005	(1,000;1,011)
Interaction Heure 20 * Nombre de <i>tweets</i>	0,018	(0,956;1,086)	0,003	(0,999;1,007)
Interaction Heure 21 * Nombre de <i>tweets</i>	0,033	(0,972;1,099)	0,005*	(1,000;1,009)
Interaction Heure 22 * Nombre de <i>tweets</i>	0,031	(0,971;1,097)	0,004*	(1,001;1,008)
Interaction Heure 23 * Nombre de <i>tweets</i>	0,034	(0,972;1,101)	0,014**	(1,006;1,023)

*** p<0,001 ** p<0,01 * p<0,05

Pour le modèle des crimes contre la personne, on remarque premièrement que le nombre de *tweets* n'est pas significatif. Par contre, la variable d'interaction nous indique que le nombre de *tweets* est significatif, mais seulement à l'heure 3, 4 et 5.

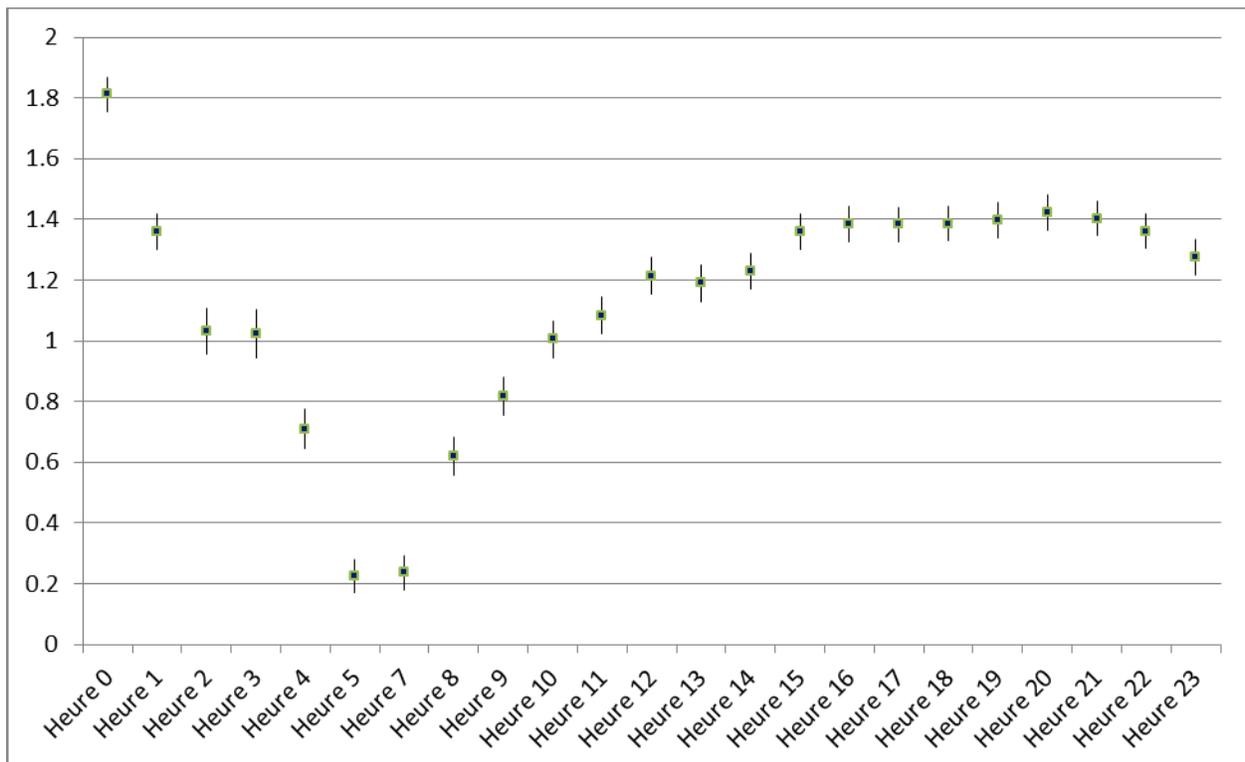
Dans le modèle prédisant les crimes contre la propriété, on remarque que le coefficient de la variable nombre de *tweets* est positif et significatif à p< 0,001. Ainsi, le nombre de *tweets* semble avoir une valeur ajoutée, mais les variables de *tweets* liées à l'humeur (dans les modèles 1 et 2) la rendent non significative. Finalement, on voit que l'interaction est seulement significative à certaines heures de la journée (9/23).

Avec les deux variables dépendantes, on remarque que l'interaction est seulement significative à certaines heures de la journée. Cela renforce l'idée que d'analyser le crime selon des périodes temporelles précises est important. Il serait intéressant de comparer les différentes heures de la journée entre elles, plutôt que seulement par rapport à l'heure de référence (Heure = 6).

5.2.1 La prédiction de la criminalité selon l'heure de la journée

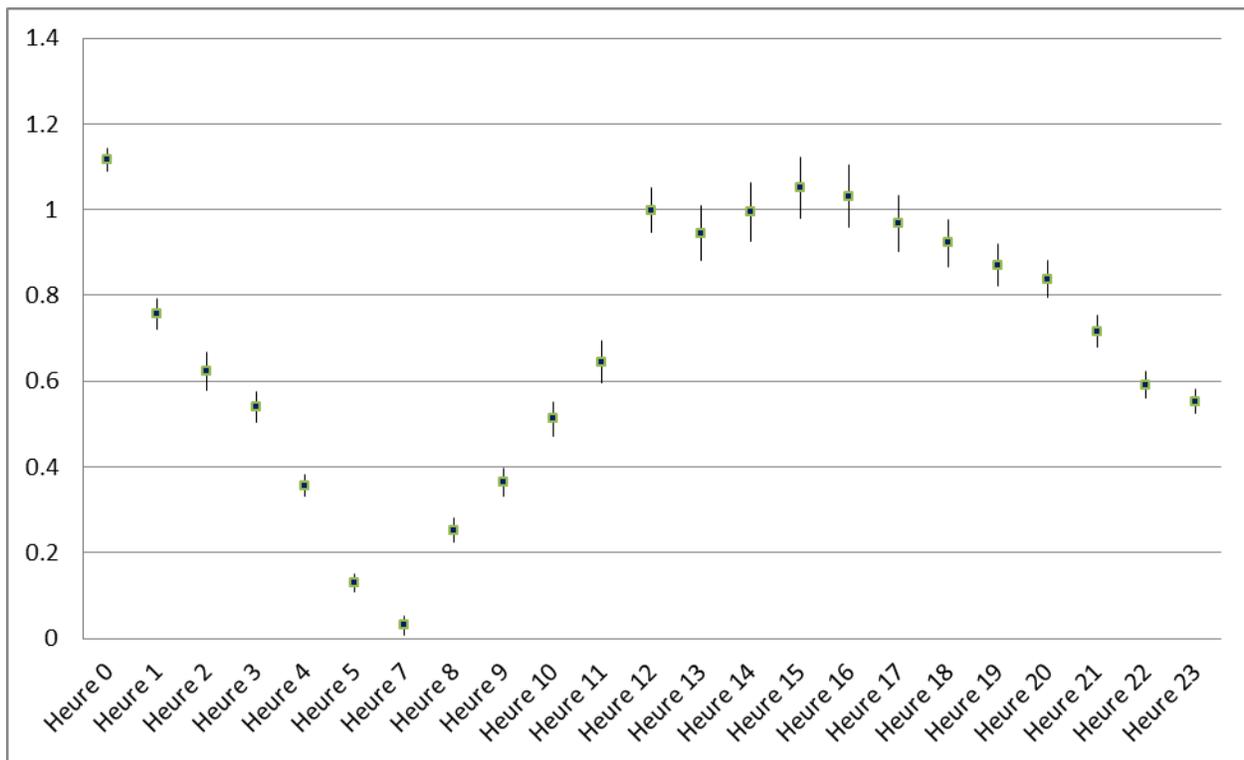
En analysant les effets de l'heure de la journée sur les deux grandes catégories de crimes, il a été conclu que, par rapport à l'heure de référence (Heure = 6), tous les coefficients des heures étaient significativement différents. Pour l'interaction entre le nombre de *tweets* et l'heure de la journée, seules quelques heures étaient significativement différentes de l'heure de référence (Heure = 6). Dans les graphiques suivants, une comparaison des coefficients des heures est faite afin de pouvoir apprécier les différences entre ceux-ci plutôt que seulement par rapport à l'heure de référence.

Figure 3. Les betas non standardisés (± 2 erreurs standards) des catégories de la variable Heure des modèles prédisant les crimes contre la personne (Heure de référence = 6)



Le graphique ci-dessus présente les différents coefficients des catégories de la variable Heure pour les modèles prédisant les crimes contre la personne. L'utilisation de minimums et de maximums correspondant à ± 2 erreurs standards permet d'apprécier des différences « significatives » entre les coefficients. On note un coefficient très élevé à l'heure 0. Des conclusions claires ne peuvent être prises pour les coefficients reliés à Heure = 0, et ce pour l'ensemble des modèles présentés. Ainsi, il a été démontré dans d'autres études montréalaises que certains policiers attribuaient « minuit » à certains crimes dont ils n'étaient pas capables de déterminer l'heure. L'heure 0 est donc biaisée par cette pratique et difficilement interprétable. Si on s'attarde à la distribution des coefficients des autres heures, on note une diminution jusqu'à l'heure de référence (6), suivie d'une augmentation de forme exponentielle jusqu'à 15h, en finissant par une stabilité jusqu'à 23h.

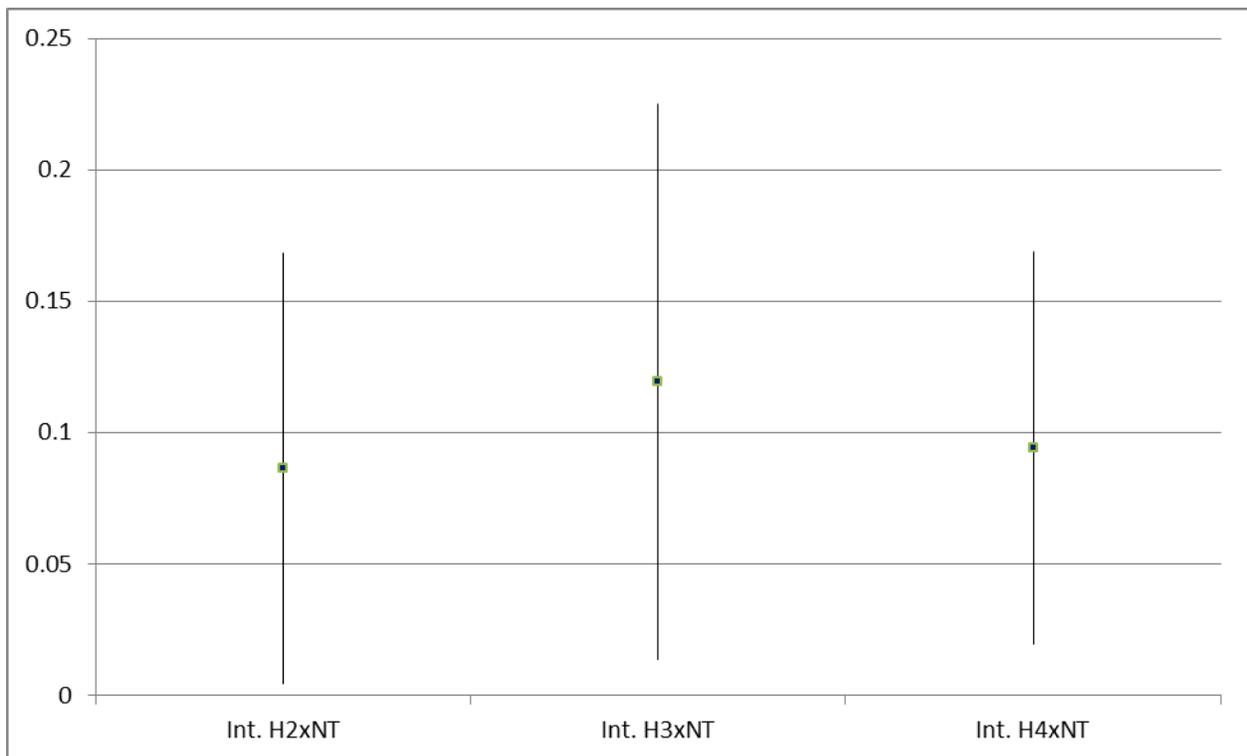
Figure 4. Les betas non standardisés (± 2 erreurs standards) des catégories de la variables Heure des modèles prédisant les crimes contre la propriété (Heure de référence = 6)



L'évolution dans le temps des coefficients pour les modèles des crimes contre la propriété est semblable à celle des crimes contre la personne, mis à part pour la partie de 12h à 23h. Le maximum est atteint plus rapidement pour les crimes contre la propriété (12h plutôt que 15h), et les coefficients sont moins stables. Ainsi, on note une diminution graduelle de 15h à 23h.

En analysant les deux graphiques, on observe qu'en plus d'être différents de l'heure de référence Heure=6, les coefficients des heures de la journée sont différents entre eux. Aussi, quelques différences sont observables entre les patrons des modèles des crimes contre la personne et ceux des crimes contre la propriété. On en conclut qu'il est important de s'attarder à l'évolution des crimes selon le temps de la journée, et que cette évolution semble quelque peu différente entre les crimes contre la personne et ceux contre la propriété.

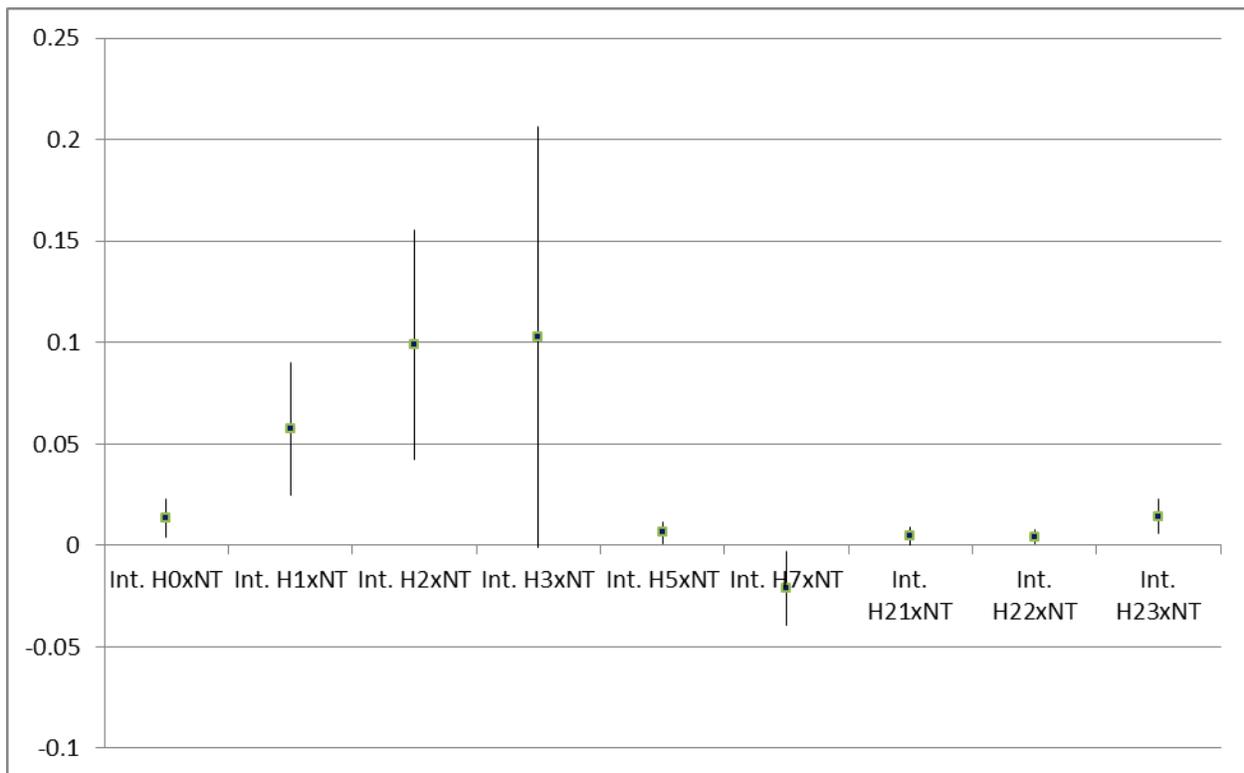
Figure 5. Les betas non standardisés (± 2 erreurs standards) des catégories de la variable Heure * Nombre de tweets du modèle prédisant les crimes contre la personne (Heure de référence = 6)



Pour le modèle prédisant les crimes contre la personne avec l'interaction Heure*Nombre de tweets, le nombre de tweets par lui-même n'est pas significatif. Pour ce qui est de l'interaction,

seules les heures 2, 3 et 4 sont significativement différentes de l'heure de référence Heure=6. Le graphique ci-dessus permet de comparer ces heures entre elles. On observe qu'elles ne sont pas différentes, et il est ainsi possible de conclure que le nombre de *tweets* ne prédit pas significativement le nombre de crimes contre la personne, mis à part pour la période de 2h à 4h du matin.

Figure 6. Les betas non standardisés (± 2 erreurs standards) des catégories de la variable Heure * Nombre de *tweets* du modèle prédisant les crimes contre la propriété (Heure de référence = 6)



Pour le modèle prédisant les crimes contre la propriété, le nombre de *tweets* est significatif. Pour ce qui est de l'interaction, 9 des 23 heures sont significativement différentes de l'heure de référence Heure = 6. On pourrait regrouper les heures 0, 5, 21, 22 et 23 ensemble, les heures 1 et 2 ensemble, l'heure 3 recoupe les deux premiers groupes et l'heure 7 est par elle-même. Ici, on peut conclure qu'il est important de tenir compte de certaines périodes de la journée lorsqu'on tente de prédire les crimes contre la propriété avec le nombre de *tweets*.

L'analyse de l'interaction apporte des résultats intéressants. Alors qu'on pensait que les crimes contre la personne ne pouvaient être prédits par le nombre de *tweets*, on peut se rendre compte qu'il est possible de les prédire pendant 3 heures de la journée, qui ont le même pouvoir prédictif. Pour les crimes contre la propriété, on note qu'on peut découper la journée en cinq périodes. Au final, de prendre en compte le temps nous permet de trouver des effets qu'on pensait non significatifs car ils étaient non significatifs globalement. Et de voir que pour un prédicteur ayant une capacité dynamique comme les *tweets*, son effet peut être différent selon différentes périodes temporelles.

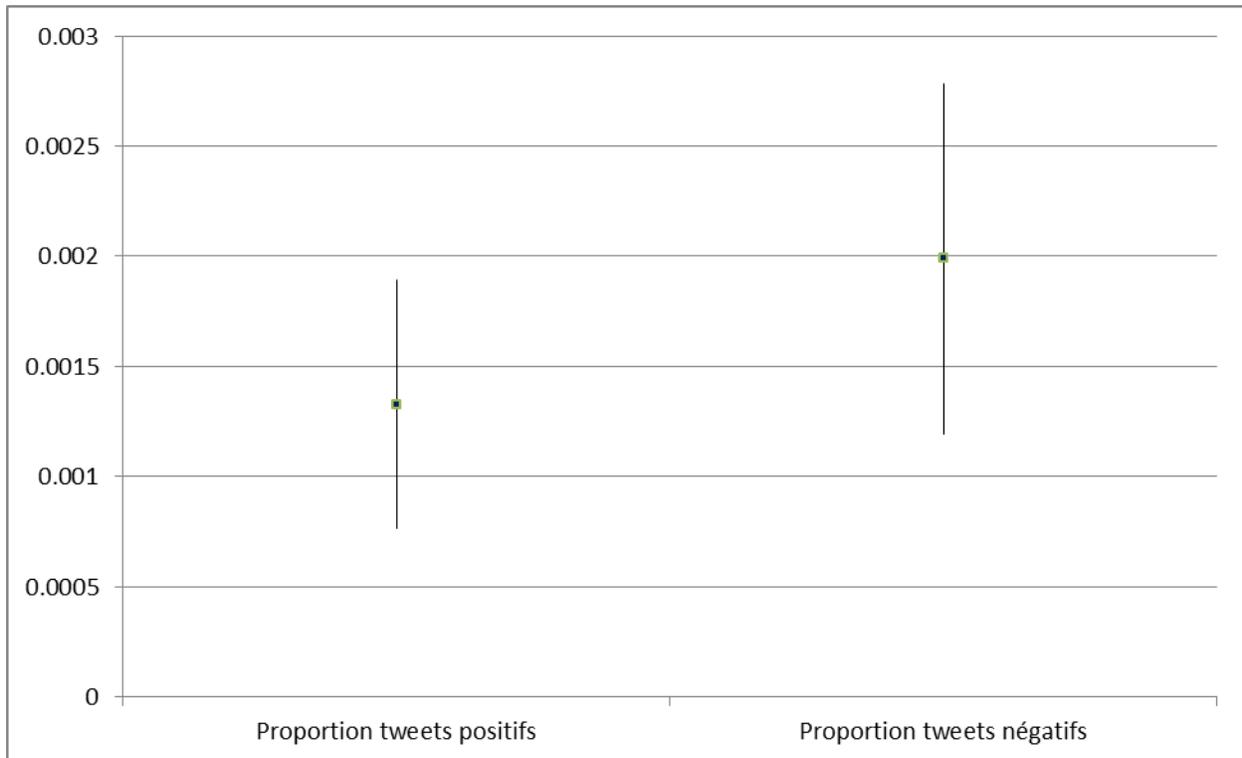
Il est important par contre de se rappeler que le nombre de *tweets* devient non significatif lorsqu'on tient compte de l'humeur de ceux-ci. Il est possible de s'attarder plus longuement sur l'effet de l'humeur afin d'avoir un portrait plus précis de l'effet des *tweets* sur les crimes.

5.2.2 La prédiction de la criminalité selon l'humeur

Pour les crimes contre la personne, il a été vu que le nombre de *tweets* n'est pas significatif, et que seule la proportion des *tweets* de joie est significative. De par sa relation négative, on peut conclure qu'une diminution de la proportion de *tweets* de joie prédit une augmentation du nombre de crimes contre la personne.

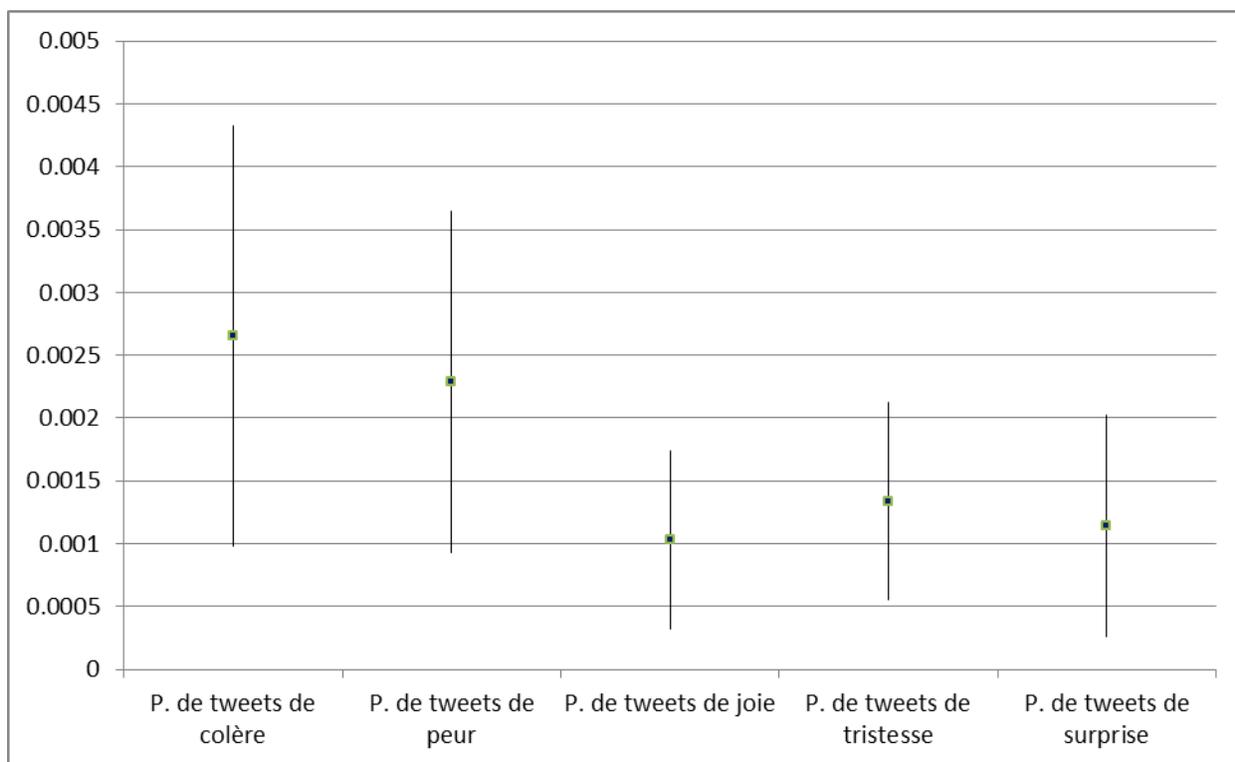
Pour les crimes contre la propriété, le nombre de *tweets* peut être significatif, mais seulement lorsque l'humeur de ceux-ci n'est pas incluse dans le modèle. Les deux polarités et les six catégories d'humeurs rendent le nombre de *tweets* non significatif.

Figure 7. Les betas non standardisés (± 2 erreurs standards) des deux polarités d'humeur du modèle prédisant les crimes contre la propriété



Pour le modèle prédisant les crimes contre la propriété à l'aide des deux polarités d'humeurs, autant les proportions de *tweets* positifs que négatifs étaient significatives et positives. Il y a lieu de se demander s'il existe une différence entre la force de prédiction des coefficients. À l'aide du graphique ci-haut, on observe que bien que le coefficient de la proportion de *tweets* négatifs soit légèrement supérieur, les deux polarités ne sont pas « significativement » différentes. On peut conclure que la présence d'une humeur, qu'elle soit positive ou négative, dans un *tweet* prédit une augmentation du nombre de crimes contre la propriété.

Figure 8. Les betas non standardisés (± 2 erreurs standards) des six catégories d'humeur du modèle prédisant les crimes contre la propriété



En ce qui a trait aux six catégories d'humeurs, elles étaient toutes significatives, mis à part la proportion de *tweets* de dégoût. Avec le graphique ci-haut, il est possible de comparer les coefficients entre les cinq catégories. Bien que les *tweets* de colère et de peurs semblent un peu plus élevés que les autres, il n'y a aucune différence « significative » entre les catégories d'humeurs.

En analysant les tableaux de résultats, il a été possible de constater que peu importe l'humeur, une augmentation de sa proportion prédisait une augmentation du nombre de crimes contre la propriété (à l'exception du dégoût, qui n'était pas significatif). L'étude des deux derniers graphiques nous permet d'aller plus loin et de noter qu'il n'y a aucune différence significative entre les coefficients non standardisés liés à la polarité ou aux catégories d'humeurs. Il est donc possible de conclure qu'une humeur ne prédit pas mieux le nombre de crimes qu'une autre; elles ont la même force de prédiction.

CHAPITRE 6 : DISCUSSION

Cette étude s'inscrit dans une nouvelle lignée de la criminologie, la criminologie des endroits, où l'on tente de comprendre les phénomènes criminels à des niveaux spatiotemporels de plus en plus précis et où l'on analyse l'effet d'endroits plutôt que de personnes spécifiques. On démontre la grande concentration des crimes dans les grandes villes, où une minorité d'endroits contiennent la majorité des crimes. Les forces de l'ordre et autres acteurs de sécurité publique ont donc intérêt à concentrer leurs efforts sur des *hotspots* très précis de crimes pour avoir un retour sur investissement maximal. Deux limites sont apparentes dans les études des dernières années. Premièrement, alors que l'on tente d'être toujours de plus en plus précis au niveau spatial, on ne tient pas compte des fluctuations temporelles précises des crimes urbains. Deuxièmement, il est difficile de trouver des prédictors de la criminalité à un niveau très micro, et cela limite notre capacité à expliquer la variance entre les endroits. Cette étude a donc évalué l'importance des fluctuations intrajournalières des crimes à Montréal, et a utilisé les *tweets* envoyés par la population pour générer deux facteurs explicatifs de la criminalité à des niveaux très précis, soit la population flottante et une caractéristique de celle-ci, l'humeur.

6.1 La dépendance entre les variables

La question de la dépendance spatiale est revenue plusieurs fois dans le rapport. Premièrement, il y a eu introduction d'un lag spatial, qui permettait de contrôler la dépendance entre les segments de rue avoisinants ($d=100m$). Deuxièmement, l'utilisation de modèles hiérarchiques a permis de contrôler la dépendance des unités d'analyse du premier niveau, Segment de rues * Heure de la journée, en introduisant un deuxième niveau, le segment de rue.

La dépendance des variables représente un défi pour les analyses spatiales. Lorsque les unités sont rapprochées dans l'espace, elles s'influencent entre elles. Dans ce rapport, la dépendance des variables dépendantes a été contrôlée. Une étude récente (Boivin et Felson, 2018) a démontré l'importance de tenir aussi compte de la dépendance spatiale des prédictors; l'enjeu n'est pas de la contrôler, mais de produire des résultats plus riches. Ainsi, des prédictors liés à la population étaient dépendants spatialement et des lags spatiaux de ces variables ont été introduits dans le modèle. Cela a permis aux auteurs d'analyser l'effet des populations

avoisinentes sur le nombre de crimes de l'unité d'analyse. On peut penser qu'il serait intéressant d'introduire des lags spatiaux liés aux *tweets* ou tout autre prédicteur spatial dans les prochaines études sur le sujet.

Aussi, cette étude incorpore la temporalité fine dans les analyses spatiales. Il y aurait lieu de tenir compte de la dépendance *temporelle* des prédicteurs et des variables indépendantes. Par exemple, la hausse de crimes à la sortie des bars peut aussi influencer le nombre de crimes par après, car les personnes enivrées ne vont pas nécessairement directement chez elles. Ainsi, un événement peut déborder sur plusieurs unités temporelles, ce qui fait que celles-ci ne sont pas totalement indépendantes. Pour les prédicteurs, il serait possible entre autres de déterminer si le nombre de *tweets* à des périodes temporelles antérieures influent sur une période x .

En somme, cette étude a démontré l'importance d'intégrer un lag spatial de la variable dépendante lors d'analyses du crime urbain. Pour les prochaines études et analyses de la sorte, l'introduction d'un lag spatial pour les prédicteurs et de lags temporels pour toute variable dynamique permettrait d'aller encore plus loin dans notre compréhension des fluctuations spatiotemporelles de la criminalité dans les grandes villes.

6.2 Les grandes catégories de crimes et les *tweets*

Cette étude s'est penchée sur les deux grandes catégories de crimes, soit les crimes contre la personne et les crimes contre la propriété. L'influence des *tweets* sur ces catégories était assez différente; le nombre de *tweets* et l'humeur prédisaient significativement et positivement le nombre de crimes contre la propriété, alors que c'était un peu moins clair pour les crimes contre la personne.

Ces derniers ne pouvaient être prédits ni par le nombre de crimes, ni par les catégories d'humeurs. Du côté de la polarité, la proportion de *tweets* positifs influencent négativement le nombre de crimes. On peut penser que plus les gens ont du plaisir et partagent des expériences positives, moins ils sont portés à faire preuve de violence et donc de commettre des crimes contre la personne. Il se peut que la raison pour laquelle aucune des catégories d'humeur était significative, pas même la proportion de *tweets* de joie, se trouve dans le nombre de *tweets* répertoriés pour l'étude. Ainsi, en divisant les *tweets* en seulement deux catégories, chaque

catégorie contient plus de *tweets* que s'ils étaient divisés en six catégories, et un plus grand échantillon a plus de chances d'être significatif.

Pour ce qui est du nombre de *tweets*, il n'était pas significatif de façon globale, ce qui corrobore les résultats d'autres études montréalaises (Boivin et D'Elia, 2017), mais pas d'autres études canadiennes (Andresen, 2011). Il est à noter que la population flottante prédisait significativement le nombre de voies de fait entre étrangers dans une étude montréalaise (Boivin, 2013). Deux hypothèses peuvent être mises de l'avant. Premièrement, le rôle des gardiens, issus de la théorie des activités routinières, pourrait expliquer pourquoi les crimes contre la personne ne semblent pas être influencés par le nombre de personnes présentes. Alors que le nombre de personnes à un endroit augmente, le nombre de victimes et d'auteurs de crimes potentiels augmente et il ne faut pas oublier que le nombre de gardiens, formels ou informels, augmente également. Il est possible qu'à Montréal, les personnes présentes aient un plus grand effet dissuasif sur le crime, qui supplanterait l'influence de l'augmentation des auteurs et victimes potentiels. Et cet effet des gardiens ne serait pas aussi notable pour les crimes contre la propriété, car ceux-ci n'attirent pas autant l'attention des personnes autour que les crimes contre la personne. Ce serait une hypothèse à confirmer dans de prochaines études. Deuxièmement, et ce point va être abordé plus en détails dans une section suivante, les grandes catégories de crimes renferment plusieurs types de crimes qui peuvent avoir des « comportements » assez différents. Ce qui fait qu'alors que la grande catégorie des crimes contre la personne n'a pas de lien significatif avec la population flottante, les voies de faits entre étrangers, un type de crime compris dans la grande catégorie, ont un lien significatif. On peut penser que d'analyser des types de crimes plutôt que des grandes catégories pourrait être plus intéressant et plus précis, surtout d'un point de vue pratique.

Les résultats liés aux *tweets* étaient plus probants pour les crimes contre la propriété. Ainsi, il a été constaté qu'une augmentation du nombre de *tweets* – ou de la population flottante – prédisait une augmentation du nombre de crimes. Par contre, lorsque que l'on tenait compte des humeurs, l'effet du nombre de personnes perdait sa significativité. On peut conclure, en se basant sur ces résultats, que le nombre de personnes présentes sur un segment de rue perd son importance lorsqu'on tient compte de ses caractéristiques, ici l'humeur. Des études ont tenté de caractériser les visiteurs de par l'intention de leur visite (Felson et Boivin, 2015; Boivin et

D'Elia, 2017), soit pour le travail, pour magasiner, pour un loisir ou pour l'école et ont obtenu des résultats intéressants. L'avantage de cette étude est d'avoir utilisé une proportion plutôt qu'un nombre brut pour les prédicteurs qui caractérisaient la population flottante. Cela a permis d'introduire le nombre brut total (nombre de *tweets*) dans le même modèle sans créer de multicolinéarité entre les prédicteurs et d'ainsi comparer l'apport du nombre brut total comparativement aux prédicteurs de caractérisation (proportion de *tweets* d'humeurs). Selon les résultats présentés dans ce rapport, il y aurait intérêt à concentrer les efforts des prochaines études à caractériser la population flottante plutôt qu'à la compter.

6.3 L'importance de la temporalité intrajournalière

Plusieurs démarches et résultats de l'étude ont permis d'évaluer l'importance des fluctuations intrajournalières des crimes et force est de constater qu'elles sont indispensables à la compréhension du phénomène criminel urbain.

Le modèle des composantes de la variance a mis en compétition la variance explicable au niveau spatial des segments de rue à celle au niveau temporel des heures de la journée. Bien que la variance soit légèrement plus élevée au niveau des segments, elle est également élevée au niveau des heures de la journée. Il est donc primordial de tenir compte de la temporalité intrajournalière pour avoir un portrait complet de la criminalité aux endroits.

En introduisant les heures de la journée comme prédicteurs dans les modèles multivariés, il a été possible de comparer l'apport de chacune sur le nombre de crimes et de constater qu'il y avait des différences significatives entre elles, ainsi qu'entre les deux catégories de crimes. On conclut qu'il serait important pour les recherches futures d'inclure des périodes intrajournalières dans leurs analyses de la criminalité urbaine, et de tenter de comprendre pourquoi certains facteurs prédisent plus ou moins bien à certaines périodes et, au final, comprendre pourquoi les crimes fluctuent autant dans une journée.

Il y a également eu l'introduction d'une interaction dans le troisième modèle multivarié présenté, soit entre le nombre de *tweets* et les heures de la journée. Pour les crimes contre la propriété, il a été constaté que la force de prédiction du nombre de *tweets* différait selon les heures de la journée. Pour les crimes contre la personne, alors que l'effet global était non

significatif, l'effet d'interaction était significatif pour trois heures de la journée. Cela suggère que la force des prédicteurs qui ont une dimension temporelle peut changer dans le temps, et donc que les chercheurs qui s'intéressent à ceux-ci dans le cadre de leur étude devraient tester leur variabilité temporelle et tenter de comprendre les facteurs expliquant celle-ci. Cette trouvaille alimente aussi la littérature sur la population flottante. Ainsi, la variabilité temporelle du nombre de *tweets* suggère que la composition, et donc les caractéristiques de la population flottante changent au cours de la journée. Les prochaines études devraient tenter d'identifier les facteurs explicatifs de ces fluctuations, et surtout utiliser une donnée de population flottante très précise.

6.4 La désorganisation sociale

Les éléments de la théorie de la désorganisation sociale étaient un peu en arrière-plan dans cette étude, mais servaient à illustrer l'importance des variables spatiales moins précises pour avoir un portrait intégral de la criminalité urbaine. Les résultats étaient semblables pour les crimes contre la personne et les crimes contre les biens. Ainsi, tous les éléments étaient significatifs, et tous étaient positifs, mis à part pour le pourcentage de minorités visibles. Ces résultats défendent la pertinence de la désorganisation sociale pour expliquer la criminalité urbaine. Cependant, les minorités ethniques ne semblent pas défendre la direction de la désorganisation sociale. Cela est typique des études canadiennes, qui démontrent majoritairement un lien négatif ou non significatif entre le pourcentage de minorité ethniques et le nombre de crimes (Andresen, 2006; Boivin et Ouellet, 2011; Boivin et D'Elia, 2017). Andresen (2006) l'explique par la réalité différente des communautés ethniques au Canada, comparativement à celle aux États-Unis, où la théorie de la désorganisation sociale a pris forme. Ainsi, l'auteur avance que les minorités ethniques peuvent aussi former des communautés dans les quartiers urbains et ainsi développer une cohésion sociale, plutôt qu'une désorganisation sociale. Cet élément de la théorie ne serait donc pas applicable en contexte canadien.

6.5 Les types et les catégories de crimes

Il a été soulevé à de nombreuses reprises que les résultats de l'étude pouvaient être assez différents entre les deux grandes catégories de crimes. Cela nous indique qu'il existe des différences non-négligeables entre les crimes contre la personne et les crimes contre la propriété, et donc que les facteurs explicatifs et, ultimement, les interventions par des acteurs de la sécurité publique, peuvent être différents selon la problématique criminelle étudiée. De plus, une étude récente (Haberman, 2017) a démontré que les *hotspots* de différents types de crimes se chevauchaient très peu, et donc que leurs facteurs explicatifs se devaient d'être différents. Plus tôt dans ce rapport, il a été soulevé que la population flottante ne prédisait pas significativement le nombre de crimes contre la personne, mais qu'une étude montréalaise (Boivin, 2013) avait démontré qu'elle prédisait les voies de fait entre étrangers. On en vient au constat qu'en plus d'être différentes entre elles, les deux grandes catégories de crimes contiennent des types de crimes qui ne s'expliquent pas de la même façon. Il est donc impossible de généraliser les résultats obtenus pour ces catégories de crimes à des types de crimes plus précis.

CONCLUSION ET RETOMBÉES PRATIQUES

L'étude présentée a permis de faire avancer les connaissances sur l'analyse de la criminalité en milieu urbain, surtout en ce qui a trait à l'importance de la temporalité fine, et les effets de la population flottante.

Comme expliqué à la section précédente, l'importance de la temporalité intrajournalière a été démontrée à de nombreuses reprises lors du rapport. Il est important que tout chercheur ou analyste qui s'intéresse à l'analyse de la criminalité aux micro-endroits tiennent compte des fluctuations temporelles fines, autant des crimes que de leurs prédicteurs.

Pour ce qui est de la population flottante, l'importance de sa caractérisation a été démontrée. Selon l'étude, elle effacerait la pertinence du nombre brut de personnes présentes. Aussi, il a été démontré que sa force de prédiction changeait au cours de la journée, et donc que ses caractéristiques changeaient aussi.

D'un point de vue plus pratique, l'étude permet d'avoir une réflexion sur les enjeux de l'analyse spatiotemporelle du crime, et démontre un exemple de méthodologie robuste qui peut guider les acteurs de sécurité publique qui sont amenés à analyser le crime urbain. De plus, cette étude fait la preuve de concept de l'utilisation de *tweets* pour prédire les crimes dans une grande ville.

Les *tweets* d'un point de vue pratique

L'utilité des *tweets* pour définir une population flottante précise autant au niveau spatial que temporel a été démontrée grâce à l'étude. Aussi, l'analyse de l'humeur a ouvert la porte à l'analyse du contenu des *tweets* pour caractériser la population flottante. Il y a lieu de se demander si l'analyse de *tweets* pourrait être utilisée par les milieux pratiques, notamment les forces de l'ordre.

Une première réflexion sur les limites de l'utilisation des *tweets* est primordiale avant d'aller plus loin. On peut se demander si les utilisateurs de Twitter à Montréal représentent la population réelle de la ville. Plusieurs études étrangères se sont penchées sur la question (Sui et Goodchild, 2011; Steiger et al., 2015; Mellon et Prosser, 2017) et toutes s'accordent pour

affirmer que les utilisateurs de la plateforme ne représentent pas parfaitement la population générale. Une étude britannique (Mellon et Prosser, 2017) a démontré que les utilisateurs de Twitter sont notamment plus jeunes, plus éduqués et les hommes sont surreprésentés. Il existe des différences importantes entre les utilisateurs de différents pays (Poblete et al., 2011) et donc des études de représentativité devraient être faites au Canada et même au Québec afin de mieux baliser et définir la population qui *tweet*.

Suite à ce balisage, le plaisir peut commencer. Comme avec l'humeur dans cette étude, l'analyse du contenu des *tweets* peut être facilement mise sur pied avec le logiciel R. L'utilisation de lexiques ou autres techniques de traitement de texte peuvent permettre de caractériser une population et ainsi tester des hypothèses. Et les possibilités ne sont pas limitées à la population flottante. Par exemple, un analyste travaillant pour la police pourrait vouloir déterminer le sentiment de sécurité des citoyens, et vérifier si celui-ci est lié à la sécurité réelle d'un quartier. Alors qu'il doit habituellement défrayer temps et argent pour faire passer un sondage, il pourrait analyser les *tweets* envoyés par la population et tenter de déterminer beaucoup plus facilement leur sentiment de sécurité. Les possibilités sont infinies, et au cours des prochaines années, les *tweets* devraient faire partie de la boîte à outil de plus en plus de chercheurs et d'acteurs en sécurité publique.

BIBLIOGRAPHIE

- Andresen, M. A. (2011). The ambient population and crime analysis. *The Professional Geographer*, 63(2), 193-212.
- Andresen, M. A., et Malleson, N. (2011). Testing the stability of crime patterns: implications for theory and policy. *Journal of Research in Crime and Delinquency*, 48(1), 58-82.
- Anselin, L. (1988). *Spatial Econometrics: methods and models*. Kluwer, Boston.
- Ashby, M. P., et Bowers, K. J. (2013). A comparison of methods for temporal analysis of aoristic crime. *Crime Science*, 2(1), 1-16.
- Bermingham, A., et Smeaton, A. (2011). On using Twitter to monitor political sentiment and predict election results. In *Proceedings of the Workshop on Sentiment Analysis where AI meets Psychology (SAAIP 2011)* (p. 2-10).
- Biderman, A. D., et Reiss Jr, A. J. (1967). On exploring the "dark figure" of crime. *The Annals of the American Academy of Political and Social Science*, 374(1), 1-15.
- Boivin, R. (2013). On the Use of Crime Rates. *Canadian Journal of Criminology and Criminal Justice*, 55(2), 263-277.
- Boivin, R., et D'Elia, M. (2017). A network of neighborhoods: predicting crime trips in a large Canadian city. *Journal of research in crime and delinquency*, 54(6), 824-846.
- Boivin, R., et Felson, M. (2018). Crimes by visitors versus crimes by residents: The influence of visitor inflows. *Journal of Quantitative Criminology*, 34(2), 465-480.
- Boivin, R., et Ouellet, F. (2011). La dynamique de la criminalité à Montréal: l'écologie criminelle revisitée. *Canadian Journal of Criminology and Criminal Justice*, 53(2), 189-216.
- Bollen, J., Mao, H., et Zeng, X. (2011). Twitter mood predicts the stock market. *Journal of computational science*, 2(1), 1-8.

- Braga, A. A., Papachristos, A. V., et Hureau, D. M. (2010). The concentration and stability of gun violence at micro places in Boston, 1980–2008. *Journal of Quantitative Criminology*, 26(1), 33-53.
- Braga, A., Papachristos, A., et Hureau, D. (2012). Hot spots policing effects on crime. *Campbell Systematic Reviews*, 8(8), 1-96.
- Brantingham, P. L., et Brantingham, P. J. (1993). Nodes, paths and edges: Considerations on the complexity of crime and the physical environment. *Journal of Environmental Psychology*, 13(1), 3-28.
- Budd, T. (2001). *Burglary: Practice messages from the British crime survey*. Great Britain, Home Office, Policing and Reducing Crime Unit.
- Chen, X., Cho, Y., et Jang, S. Y. (2015). Crime prediction using Twitter sentiment and weather. In *Systems and Information Engineering Design Symposium (SIEDS), 2015*(p. 63-68). IEEE.
- Clarke, R. V., et Cornish, D. B. (1985). Modeling offenders' decisions: A framework for research and policy. *Crime and justice*, 6, 147-185.
- Clarke, R. V. et Eck, J. (2005). *Crime analysis for problem solvers in 60 small steps*. Washington, D.C.: Office of Community Oriented Policing Services, United States Department of Justice.
- Cohen, L. E., et Felson, M. (1979). Social change and crime rate trends: A routine activity approach. *American sociological review*, 588-608.
- Curman, A. S., Andresen, M. A., et Brantingham, P. J. (2015). Crime and place: a longitudinal examination of street segment patterns in Vancouver, BC. *Journal of Quantitative Criminology*, 31(1), 127-147.
- Eck, J. E., et Spelman, W. (1987). Problem-solving: Problem-oriented policing in Newport News.

- Felson, M., et Boivin, R. (2015). Daily crime flows within a city. *Crime Science*, 4(1), 31.
- Gibbs, J.P. et Erickson. M.L. (1976). Crime rates of American cities in an ecological context. *American Journal of Sociology* 82(3), 605–20.
- Graham, M. H. (2003). Confronting multicollinearity in ecological multiple regression. *Ecology*, 84(11), 2809-2815.
- Guthrie, J. (2010). Qui est la population du centre-ville? Repéré à <http://journalmetro.com/actualites/montreal/33125/qui-est-la-population-du-centre-ville/>
- Haberman, C. P. (2017). Overlapping Hot Spots? *Criminology & Public Policy*, 16(2), 633-660.
- Haberman, C. P., et Ratcliffe, J. H. (2015). Testing for temporally differentiated relationships among potentially criminogenic places and census block street robbery counts. *Criminology*, 53(3), 457-483.
- Haberman, C. P., Sorg, E. T., et Ratcliffe, J. H. (2017). Assessing the validity of the law of crime concentration across different temporal scales. *Journal of quantitative criminology*, 33(3), 547-567.
- Manning, P. K. (2001). Technology's ways: Information technology, crime analysis and the rationalizing of policing. *Criminal Justice*, 1(1), 83-103.
- Malleson, N., & Andresen, M. A. (2015). Spatio-temporal crime hotspots and the ambient population. *Crime science*, 4(1), 10-17.
- Malleson, N., et Andresen, M. A. (2016). Exploring the impact of ambient population measures on London crime hotspots. *Journal of Criminal Justice*, 46, 52-63.
- Mellon, J., et Prosser, C. (2017). Twitter and Facebook are not representative of the general population: Political attitudes and demographics of British social media users. *Research & Politics*, 4(3), 2053168017720008.

- Mohammad, S.M., Turney, P.D. (2013). Crowdsourcing a Word-Emotion Association Lexicon. *Computational Intelligence*, 29, 436–465.
- Gerber, M. S. (2014). Predicting crime using Twitter and kernel density estimation. *Decision Support Systems*, 61, 115-125.
- Greene, W. (2012). *Econometric Analysis*. New York: Pearson.
- Groff, E., Weisburd, D., et Morris, N. A. (2009). Where the action is at places: examining spatio-temporal patterns of juvenile crime at places using trajectory analysis and GIS. Dans *Putting crime in its place* (p. 61-86). Springer New York.
- Koper, C. S. (1995). Just enough police presence: Reducing crime and disorderly behavior by optimizing patrol time in crime hot spots. *Justice Quarterly*, 12(4), 649-672.
- Lesage-Mann, E. (2016). *Géographie des seringues à la traîne : analyse du quartier montréalais Centre-Sud* Mémoire. Québec, Université du Québec, Institut national de la recherche scientifique, Maîtrise en études urbaines, 88 p.
- National Research Council. (2004). *Fairness and effectiveness in policing: The evidence*. National Academies Press.
- Osgood, D. W. (2000). Poisson-based regression analysis of aggregate crime rates. *Journal of quantitative criminology*, 16(1), 21-43.
- Poblete, B., Garcia, R., Mendoza, M., et Jaimes, A. (2011,). Do all birds *tweet* the same?: characterizing twitter around the world. *Proceedings of the 20th ACM international conference on Information and knowledge management*, 1025-1030. ACM.
- Ratcliffe, J. H. (2000). Aoristic analysis: the spatial interpretation of unspecific temporal events. *International journal of geographical information science*, 14(7), 669-679.
- Ratcliffe, J. H. (2002). Aoristic signatures and the spatio-temporal analysis of high volume crime patterns. *Journal of Quantitative Criminology*, 18(1), 23-43.

- Ratcliffe, J. H. (2004). The *hotspot* matrix: A framework for the spatio-temporal targeting of crime reduction. *Police practice and research*, 5(1), 5-23.
- Ratcliffe, J., Groff, E., Haberman, C., et Sorg, E. (2012). Smart policing initiative final report. *Philadelphia, PA: Temple University Center for Security and Crime Science*.
- Rosser, G., Davies, T., Bowers, K. J., Johnson, S. D., et Cheng, T. (2017). Predictive crime mapping: arbitrary grids or street networks? *Journal of quantitative criminology*, 33(3), 569-594.
- Sherman, L. W., Gartin, P. R., et Buerger, M. E. (1989). Hot spots of predatory crime: Routine activities and the criminology of place. *Criminology*, 27(1), 27-56.
- Sherman, L. W., et Weisburd, D. (1995). General deterrent effects of police patrol in crime “hot spots”: A randomized, controlled trial. *Justice quarterly*, 12(4), 625-648.
- Steenbeek, W., & Weisburd, D. (2016). Where the action is in crime? An examination of variability of crime across different spatial units in The Hague, 2001–2009. *Journal of quantitative criminology*, 32(3), 449-469.
- Steiger, E., Westerholt, R., Resch, B., et Zipf, A. (2015). Twitter as an indicator for whereabouts of people? Correlating Twitter with UK census data. *Computers, Environment and Urban Systems*, 54, 255-265.
- Statistiques Canada. (2018). Secteur de recensement : Définition en langage simple. Repéré à <https://www150.statcan.gc.ca/n1/pub/92-195-x/2011001/geo/ct-sr/ct-sr-fra.htm>
- Sui, D., et M. Goodchild. (2011). The convergence of GIS and social media: Challenges for GIScience. *International Journal of Geographical Information Science* 25(11), 1737-1748.

- Wang, X., Gerber, M. S., et Brown, D. E. (2012). Automatic crime prediction using events extracted from twitter posts. In *International conference on social computing, behavioral-cultural modeling, and prediction* (p. 231-238). Springer, Berlin, Heidelberg.
- Weisburd, D., Groff, E. R., et Yang, S. M. (2012). *The criminology of place: Street segments and our understanding of the crime problem*. Oxford University Press.
- Weisburd, D., et Telep, C. W. (2014). Hot spots policing: What we know and what we need to know. *Journal of Contemporary Criminal Justice*, 30(2), 200-220.
- Weisburd, D. (2015). The law of crime concentration and the criminology of place. *Criminology*, 53(2), 133-157.
- Wheeler, A., & Haberman, C. (2018). Modeling the Spatial Patterns of Intra-Day Crime Trends. *Available at SSRN 3136030*.
- Wortley, R., & Townsley, M. (Eds.). (2016). *Environmental criminology and crime analysis* (Vol. 18). Taylor & Francis.

