

Rubrique **MONOGRAPHIE**

LA GESTION DU RISQUE D'INCENDIE PAR LES DONNÉES : DÉFIS ET LEÇONS EN CONTEXTE URBAIN

Christian Boudreau et Justin Lawarée professeurs à l'ENAP

Résumé

L'étude porte notamment sur le déploiement d'un modèle de prédiction du risque d'incendie qui permet au Service de sécurité incendie de Montréal (SIM) de mieux aligner ses activités de prévention, en particulier les inspections de bâtiments, en fonction de ce risque. À partir d'une analyse thématique de ce cas québécois unique et de trois autres cas américains (New York, Atlanta et Pittsburgh), les auteurs mettent en lumière les principaux défis de mise en œuvre de ces modèles prédictifs dans un contexte d'exploitation de données massives. Ils proposent ensuite des leviers d'intervention et des pistes d'amélioration au regard de ces défis, notamment pour le modèle de prédiction du SIM et son déploiement.

Abstract

The study focuses on the deployment of a fire risk prediction model which allows the Montreal Fire Safety Service to better align its prevention activities, specially building inspections, according to this risk. Based on a thematic analysis of this unique Quebec case and three other American cases (New York, Atlanta and Pittsburgh), the authors highlight the main challenges of implementing these predictive models in a context of exploitation of massive data. They then propose levers and avenues for improvement regarding to these challenges, particularly for the SIM prediction model and its deployment.

Mots-clés

Gestion du risque d'incendie, modèle de prédiction, exploitation des données, données massives, études de cas multiples, municipalité

Keywords

Fire risk management, prediction model, data exploitation, big data, multiple case studies, municipality

Pour citer cet article BOUDREAU, C. et LAWARÉE, J. (2023). « La gestion du risque d'incendie par les données : défis et leçons en contexte urbain », *Télescope*, vol. 20, n° 3, https://telescope.enap.ca/Telescope/22/Index_des_numeros.enap#

La gestion du risque est une composante stratégique de la prise de décision dans les organisations contemporaines. Disposant des données toujours plus nombreuses à exploiter, plusieurs organisations publiques se tournent vers des modèles de prédiction pour anticiper et atténuer les risques qui

peuvent affecter leur fonctionnement et l'atteinte de leurs objectifs. Utilisés dans différents secteurs d'activités, ces modèles prédictifs permettent de détecter différents problèmes (ex. : maladies, épidémies, décrochage scolaire, catastrophes naturelles, cyberattaques, fraudes, congestion

routière), à partir d'une analyse systématique de données le souvent automatisée, pour en assurer une meilleure prise en charge.

La gestion des risques d'incendie constitue aussi un important champ d'application pour des modèles de prédiction. Les modèles de prédiction du risque d'incendie visent à détecter les zones ou les habitations susceptibles d'être incendiées afin d'assurer une meilleure coordination des efforts de prévention et de lutte contre les incendies. Les premiers modèles de prédiction des risques d'incendie ont d'abord été expérimentés dans un contexte forestier, au début des années 2000, notamment au Portugal (de Vasconcelos *et al.*, 2001), en Italie (Lapucci *et al.*, 2005) et en Grèce (Iliadis, 2005). Des données relatives à la topographie, aux espèces d'arbres et aux types de sol ont alors été exploitées pour déterminer des probabilités d'incendie dans les forêts et autres milieux naturels (Madaio *et al.*, 2016). Des modèles de prédiction du risque d'incendie ont ensuite été déployés dans des milieux urbains afin de cibler les zones urbaines à risque (Clare *et al.*, 2012). Les modèles de prédiction du risque d'incendie en milieu urbain se sont ensuite raffinés en déterminant un score de prédiction (ou probabilité) d'incendie pour chacun des bâtiments en vue de prioriser les inspections en matière de prévention d'incendie.

La réduction des risques d'incendie est au centre des préoccupations des services municipaux de sécurité incendie. Pour réduire ce risque, les services de sécurité incendie procèdent à des inspections de bâtiments afin de détecter les dangers et les infractions au code de prévention. Comme les services d'incendie n'ont pas les ressources suffisantes pour inspecter l'ensemble des

bâtiments sur leur territoire, les agents de prévention n'en inspectent qu'une faible proportion. Bien que les intervenants en sécurité incendie tendent à s'appuyer sur des facteurs de risque officiellement reconnus et sur leurs expériences, il ne semble pas y avoir d'analyse systématique des données sur les immeubles pour pondérer ces facteurs et pour les opérationnaliser (Madaio *et al.* 2016). Compte tenu du nombre important de bâtiments à inspecter et d'une capacité limitée d'inspection, de grandes villes nord-américaines, comme New York, Atlanta, Pittsburgh et Montréal, ont développé des modèles de prédiction du risque d'incendie qui permettent de prioriser l'inspection des bâtiments en fonction de leur probabilité d'incendie et, ainsi, d'organiser le travail des inspecteurs de manière plus efficace.

La présente étude s'inscrit dans ce nouveau contexte de prévention des incendies caractérisé par une exploitation de données. Elle poursuit un double objectif. Le premier consiste à présenter un cas québécois que nous considérons riche en enseignement, notamment en raison de sa durée et de son ampleur. Ce cas porte sur la conception et le déploiement d'un modèle de prédiction utilisé par le Service de sécurité incendie de Montréal (SIM) afin de planifier ses activités de prévention, en particulier l'inspection de bâtiments sur le territoire de l'agglomération de Montréal, en fonction du risque d'incendie. Contrairement à plusieurs autres projets sur la prédiction du risque d'incendie qui n'ont pas su dépasser la phase d'expérimentation ou de projet pilote, celui du SIM a été déployé à l'ensemble du territoire de la Ville et il est actuellement utilisé par tous les agents de prévention. Mentionnons aussi que Montréal est la première et, pour l'instant, l'unique ville québécoise à recourir à un tel

modèle de prédiction. Le deuxième objectif de l'étude vise à comparer le modèle du SIM avec des modèles de prédiction déployés dans d'autres villes afin de faire ressortir des défis de mise en œuvre communs et de suggérer des leviers d'intervention et des pistes d'amélioration, en particulier pour le SIM et le déploiement de son modèle.

Cette étude de cas multiples comporte six sections. Après avoir présenté notre démarche méthodologique (section 1), nous présentons un cadre de référence présentant les principaux défis informationnels, technologiques et organisationnels de mise en œuvre des modèles de prédiction, accompagnés de certaines bonnes pratiques, en nous appuyant notamment sur des écrits portant sur la gouvernance des données en contexte d'intelligence artificielle (section 2). Nous relatons ensuite l'histoire du premier modèle de prédiction du risque d'incendie au Québec, soit celui du SIM, de sa conception jusqu'à son déploiement, en mettant en exergue certaines retombées (section 3). Par la suite, nous présentons succinctement trois autres modèles de prédiction du risque d'incendie développés par les services de sécurité incendie des villes nord-américaines suivantes : New York, Atlanta et Pittsburgh (section 4). À partir de l'analyse des quatre modèles retenus dans l'étude, nous exposons les principaux défis de mise en œuvre des modèles de prédiction du risque d'incendie (section 5) ainsi que des leviers d'intervention et pistes d'amélioration au regard des défis précédemment soulevés, en portant une attention particulière au cas du SIM (section

6). Enfin, dans la conclusion, nous abordons à la fois des considérations générales et des enseignements pratiques sur la mise en œuvre des modèles de prédiction au sein des organisations publiques.

1. Démarche méthodologique

La démarche méthodologique se décline en deux phases. La première phase a consisté à documenter et à analyser sous la forme d'une étude de cas la mise en œuvre du modèle de prédiction du risque d'incendie du SIM (Montréal), de sa conception jusqu'à son déploiement. Des entretiens semi-directifs ont été privilégiés comme instrument de collecte durant cette phase. D'une durée variant entre 90 et 160 minutes, ces entretiens ont été menés aux mois de février et mars 2022 auprès de quatre représentants du SIM¹ et d'un représentant du Service des technologies de l'information de la Ville de Montréal². Pour garantir l'anonymat de ces répondants, leurs propos cités dans l'article sont identifiés par un chiffre (de répondant 1 à répondant 5). Durant les entretiens, les répondants devaient raconter l'histoire de la mise en œuvre de ce modèle de prédiction au mieux de leurs connaissances. Ils devaient ensuite identifier les retombées, les limites, les défis et les pistes d'amélioration liés à la conception et utilisation du modèle. Les entretiens enregistrés ont été retranscrits puis codés grâce à l'outil d'analyse qualitative MaxQda. Une première vague de codage a permis d'ordonner chronologiquement les principaux événements qui ont marqué la mise en œuvre du modèle du SIM. Une deuxième vague de codage, basée sur une

¹ Dave Waterhouse (Chef de division, Planification et ressources informationnelles), Karine Séguin (Cheffe de section de la division de la Planification et des ressources informationnelles), Daniel De Vies (Chef de division de la division des Mesures opérationnelles en

prévention) et François Poitevin (Conseiller en planification).

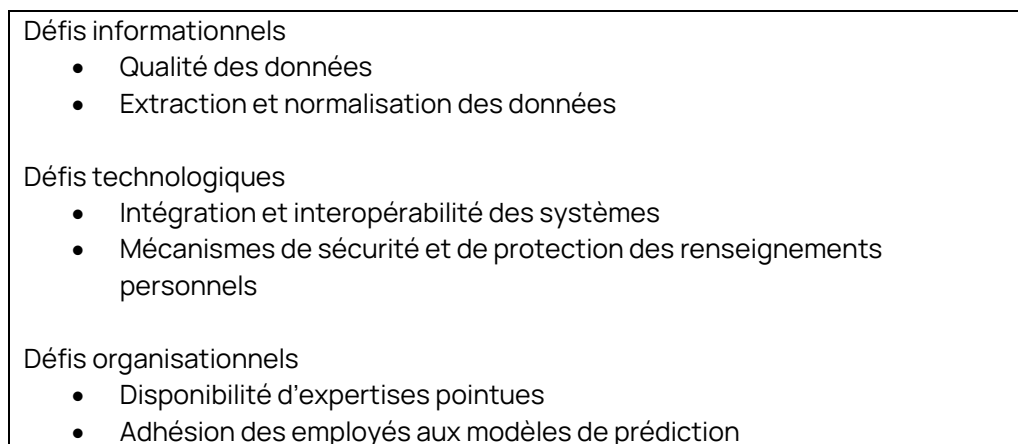
² Patrick Agin, Scientifique de données à la Ville de Montréal.

analyse thématique des matériaux, a permis de dégager *a posteriori* les retombées du modèle, notamment en termes d'optimisation des inspections, ainsi que les principaux défis informationnels, technologiques et organisationnels rencontrés lors de sa mise en œuvre. Ces deux étapes de codage ont conduit à la production d'une version préliminaire de l'étude de cas sur le modèle prédictif du SIM, dont l'essentiel du contenu se retrouve dans la section 2. Cette version préliminaire de l'étude a ensuite été envoyée aux participants pour qu'ils vérifient les faits qui y ont été rapportés.

La deuxième étape a consisté à documenter et analyser la mise en œuvre de modèles de prédiction d'incendie dans trois villes américaines (New York, Atlanta, Pittsburgh) en guise de comparaison. En plus d'être bien documentés, ces trois modèles de prédiction sont parmi les plus souvent cités dans la littérature scientifique ou la littérature grise. Chacun des modèles a d'abord fait

l'objet d'une courte description en mettant en lumière les dimensions informationnelles, technologiques et organisationnelles liées à leur conception et utilisation (section 3). Une analyse thématique transversale des quatre modèles de prédiction à l'étude nous a ensuite permis de mettre en lumière des défis communs de mise en œuvre (section 5) ainsi que des leviers d'intervention et pistes d'amélioration (section 6). À ce propos, un arbre de codage a été créé dans MaxQda, notamment à partir des dimensions informationnelles, technologiques et organisationnelles abordées dans le cadre de référence de la section 2 sur les défis de mise en œuvre des modèles de prédiction. Cet arbre a ensuite été ajusté au contact des matériaux collectés (entretiens et documents) afin de regrouper et de faire ressortir les défis de mise en œuvre issus des cas étudiés et de dégager de bonnes pratiques et des pistes d'amélioration porteuses pour le SIM et le déploiement de son modèle (voir figure 1).

Figure 1 Arbre de codage relatif aux défis de mise en œuvre des modèles de prédiction du risque d'incendie



2. Cadre de référence sur les défis de la mise en œuvre des modèles de prédiction

Les modèles de prédiction du risque transforment les méthodes conventionnelles d'analyse des problèmes et de prise de décision au sein des organisations en s'appuyant sur une exploitation de données relatives à leur environnement et leur fonctionnement. L'intelligence artificielle, conjuguée au phénomène de données massives, contribue au déploiement et au perfectionnement de ces modèles prédictifs, notamment grâce à des algorithmes de plus en plus performants issus d'apprentissage automatique (Athey, 2017). Cependant, cette exploitation systématique, voire algorithmique, des données pose d'importants défis de mise en œuvre pour les organisations qui souhaitent déployer des modèles de prédiction du risque.

Un des principaux défis réside dans la qualité des données qui alimentent ces modèles. La qualité des données renvoie à divers attributs, comme l'exactitude, l'actualité, l'exhaustivité, la pertinence, l'intelligibilité, la cohérence (Strong *et al.*, 1997). Cette qualité peut varier selon le mode de collecte (ex. : saisie manuelle vs captation automatique) et la variété des sources (ex. : données transactionnelles vs médias sociaux) (Janssen *et al.*, 2020). Quant à la performance des modèles de prédiction, elle est intimement liée à la qualité des données exploitées, particulièrement au moment de leur entraînement (Janssen et Kuk, 2016)

Le déploiement des modèles de prédiction peut aussi soulever des enjeux de normalisation des données et d'intégration des systèmes, surtout quand les données proviennent de sources variées et de

systèmes cloisonnés, comme c'est souvent le cas en administration publique (Sun et Medaglia, 2019; Janssen *et al.* 2020). Plus les sources de données et les systèmes qui les gèrent sont nombreux, plus les efforts de normalisation et de nettoyage des données s'avèrent exigeants. Avant d'inclure des données dans un modèle de prédiction, l'organisation doit en évaluer la qualité et le coût d'extraction et de préparation ainsi que les contributions respectives de ces données au modèle de prédiction (Dwivedi *et al.*, 2019), tout en étant consciente que des données parfaites n'existent pas (Janssen *et al.* 2020).

Les données servant à l'entraînement des modèles peuvent aussi contenir des biais qui contaminent les résultats des modèles au point de pénaliser injustement certaines clientèles historiquement discriminées (Eubanks, 2017). Pour réduire ces biais discriminatoires, des auteurs proposent diverses stratégies, dont l'adoption d'une approche inclusive au moment de la conception des modèles prédictifs, l'exclusion de données sensibles dans ces modèles (ex. : sexe, race et ethnie) et le recours à des audits externes pour vérifier la qualité et neutralité des données ainsi que la fiabilité et validité des prédictions (Wirtz et Müller, 2019).

Dans la mesure où les organisations publiques souhaitent collecter des données personnelles pour les alimenter leurs modèles de prédiction, elles doivent instaurer des mécanismes pour protéger ces données sensibles, comme l'anonymisation des données, l'authentification des utilisateurs et la journalisation des accès. Afin d'éviter de possibles dérives, les organisations doivent aussi justifier la nécessité de collecter des renseignements personnels au regard de finalités précises, tout comme elles doivent limiter les accès aux seuls utilisateurs dûment

autorisés. (Janssen *et al.*, 2020; Dwivedi *et al.*, 2019).

Les défis liés au déploiement peuvent aussi être de nature organisationnelle. Le manque d'expertise en science des données, en statistiques et autres expertises en analytique avancée est l'un de ces défis (Dwivedi *et al.*, 2019). La mutualisation ou mise en commun d'expertises en forte demande est une façon de pallier cette de pénurie de main-d'œuvre spécialisée (*Ibid.*). Un autre défi organisationnel concerne l'acceptation des modèles de prédiction par leurs utilisateurs, en particulier les employés. Ces outils peuvent en effet être perçus comme une menace au jugement de l'employé et à son autonomie décisionnelle (Sun et Medaglia, 2019). Pour faciliter l'adhésion des utilisateurs, plusieurs organisations les utilisent comme des outils d'aide à la décision. Plus qu'un simple exécutant, l'employé joue un rôle de médiateur qui interprète les prédictions du modèle et les nuance au regard de son expérience et de ses compétences (Janssen *et al.*, 2020). Quant à l'appropriation des modèles prédictifs, des auteurs signalent l'importance de les accompagner d'outils de visualisation simples d'utilisation (Dwivedi *et al.*, 2019).

En somme, il convient de concevoir le déploiement des modèles de prédiction dans les organisations publiques comme le résultat d'un assemblage sociotechnique complexe qui met en relation des données, des systèmes et des humains (Janssen et Kuk, 2016). C'est dans cette perspective aux dimensions multiples (informationnelles, technologiques et organisationnelles) que nous abordons les cas à l'étude exposés dans les prochaines sections.

3. Le modèle de prédiction du SIM

3.1 Les inspections avant le déploiement du modèle de prédiction

Le SIM inspecte annuellement environ 7 500 bâtiments pour évaluer leur conformité à la réglementation en matière de prévention des incendies, sur un total d'environ 335 000 bâtiments. Comme ailleurs, le SIM dispose d'effectifs limités de sorte qu'il n'inspecte qu'un faible pourcentage (environ 2,3 %) des bâtiments sur son territoire. Cependant, le SIM se différencie de plusieurs services d'incendie nord-américains, d'une part, parce que sa responsabilité en matière de prévention couvre l'ensemble des bâtiments (commercial, résidentiel, industriel et para/public) et, d'autre part, parce que cette responsabilité est confiée aux agents de prévention plutôt qu'aux pompiers. Le choix des bâtiments à inspecter était laissé à la discrétion des agents, guidés par leurs connaissances du terrain et leurs habitudes, et ce jusqu'en 2020, au moment du déploiement d'un modèle de prédiction du risque d'incendie.

3.2 La démarche de conception du modèle de prédiction

Grâce, entre autres, à une subvention de la Ville de Montréal, le Centre de recherche informatique de Montréal (CRIM) a mis en oeuvre, en 2016, un projet visant à concevoir un modèle de prédiction du risque d'incendie, en collaboration avec le SIM. Pour concevoir ce modèle, le SIM a dû extraire de son principal système opérationnel, appelé Sous-Système des données opérationnelles, des données sur les interventions et les incidents en matière d'incendie au cours des dix dernières années. Le CRIM a analysé les données extraites afin d'y repérer les variables pouvant être insérées dans le modèle. Une fois ce premier modèle terminé, le CRIM en a cédé les droits de propriété au SIM. Un scientifique de

données de la Ville de Montréal a alors pris en charge le modèle en y apportant d'importantes modifications, de sorte que « le modèle initial proposé est devenu un tout autre modèle... On a donc développé ni plus ni moins notre propre modèle ». (Répondant 1)

Le nombre de variables à considérer dans le modèle est passé d'une vingtaine à quatre, sans pour autant nuire à sa performance : « Certaines variables, présentes au départ, n'étaient pas si utiles... La majorité d'entre elles étaient même superflues... et leur apport marginal ». (Répondant 1) Une variable s'est particulièrement démarquée du lot par son influence déterminante dans le modèle, soit le nombre d'incidents survenus au cours des dix dernières années dans un même bâtiment et qui ont nécessité une intervention du SIM.

Les incidents... c'est plus large que les incendies. On inclut là-dedans une panne d'ascenseur ou un appel pour un petit feu de cuisson ou de la fumée, une alarme d'incendie ou une fuite de gaz. C'est comme des petits signaux qui servent de variables prédictives. (Répondant 5)

S'appuyant sur une régression logistique composée de quatre variables³ et de nombreuses données sur l'historique des interventions, le nouveau modèle de prédiction a permis de générer une liste des 344 000 bâtiments ordonnancés selon leur probabilité d'incendie, les bâtiments les plus à risque apparaissant au haut de cette liste. 41,9 % des incendies survenus en 2018 se seraient retrouvés parmi les 7 500 premiers bâtiments de la liste. Le modèle de prédiction fait bonne impression auprès des responsables du SIM, qui y voient une façon

d'optimiser le travail d'inspection des agents de prévention en « *les dirigeant vers les bâtiments avec le plus haut taux de probabilité d'avoir un incendie* ». (Répondant 2)

3.3 Le déploiement du modèle de prédiction du SIM

Au début de l'année 2019, le modèle de prédiction prenait la forme d'un fichier Excel qui classait les immeubles selon leur probabilité d'incendie dans les douze prochains mois. Ce modèle a été présenté au chef de division du SIM responsable des mesures opérationnelles de la prévention pour la Ville de Montréal. Celui-ci est alors impressionné par la valeur prédictive du modèle : « Le premier bâtiment que le modèle me dit d'aller voir, c'était sur la rue Y... C'était notre premier décès de l'année ». Le chef de division décide de présenter le modèle à ses chefs de section. Une majorité des chefs de section se montre alors réfractaire à son utilisation par crainte de voir l'expérience de leurs agents de prévention substituée par le modèle. Le SIM décide de ne pas rendre obligatoire l'utilisation du modèle en cette première année d'expérimentation. Pour convaincre les chefs de section réfractaires, le chef de division use d'une stratégie de persuasion qui met en lumière l'efficacité du modèle.

Au mois de mars 2020, je rencontre un premier chef qui a eu un décès dans son secteur... Il regarde [le modèle] et me dit : « Dans mon secteur de caserne, ce serait le premier bâtiment à inspecter durant mon année... Je comprends vraiment que le modèle est bon et je vais le vendre à mes agents. » Celui-là l'a vendu à ses agents... Un

³ Dont le type de bâtiment (par exemple, résidentiel, condo ou autre), la catégorie et la sous-catégorie du bâtiment et le nombre d'incidents passés.

mois après, il y a eu un autre décès dans une autre division qui n'avait pas utilisé le modèle prédictif, et j'ai fait la même chose avec le chef.

Une majorité de chefs de section adhère au modèle au terme de ces approches. Après avoir permis l'utilisation du modèle sur une base volontaire de 2019 à 2020, les autorités du SIM rendent son utilisation obligatoire pour l'ensemble des agents de prévention à partir de 2021. Le SIM cible les immeubles qui affichent une probabilité d'incendie égale ou supérieure à 3 %, pour un total d'environ 7 500 bâtiments à inspecter. Depuis 2021, les probabilités d'incendie du modèle sont intégrées à une interface de visualisation de données, Qlik Sense, qui permet aux utilisateurs d'afficher sur une carte tous les bâtiments selon différents niveaux de risque d'incendie. Depuis 2022, le modèle est aussi utilisé par les pompiers qui doivent visiter des bâtiments résidentiels pour vérifier la présence d'avertisseurs de fumée.

3.4 Des retombées organisationnelles

Avec l'utilisation du modèle, le travail d'inspection des agents de prévention et celui des pompiers se trouvent davantage alignés sur les immeubles les plus à risque d'incendie. L'utilisation du modèle a aussi conduit à une réorganisation territoriale du travail des agents de prévention selon le risque d'incendie des bâtiments. Avant le déploiement du modèle, « les inspections étaient gérées selon la structure du territoire ». (Répondant 5) Il faut savoir que le territoire montréalais a été découpé en six grandes divisions, à la suite d'une révision de la structure opérationnelle du SIM, en

2017-2018 : « cinq de ces divisions ont 12 casernes et une en avait six, le centre-ville ». (Répondant 4) Le modèle de prédiction a montré que les bâtiments à risque d'incendie étaient inégalement répartis d'un territoire à l'autre de sorte que certaines divisions contiennent plus de bâtiments à haut taux de probabilités d'incendie que d'autres. Pour que le SIM puisse inspecter annuellement l'ensemble des 7 500 bâtiments qui affichent une probabilité de 3 % et plus d'incendies, le déplacement d'agents de prévention d'une division à l'autre est devenu nécessaire et effectif en 2021. Par exemple...

dans la division Y, les besoins opérationnels, quand on utilise le modèle prédictif, sont de deux agents. Mais, dans le bureau de cette division, on retrouve six agents plus un chef... On rencontre alors les six personnes et leur chef, et on leur dit que deux vont travailler dans cette division et les quatre autres vont aider dans une autre division où j'ai plus de bâtiments à risque d'incendie... Avant le modèle, les six personnes de la division Y restaient sur leur territoire. (Répondant 4)

Ce décloisonnement territorial du travail des agents de prévention est certainement l'une des retombées les plus importantes de l'utilisation du modèle.

4. Les trois principaux modèles de prédiction du risque d'incendie en milieu urbain aux États-Unis

4.1 Le modèle de prédiction du Service d'incendie de la Ville de New York (FireCast)

Le Service d'incendie de la Ville de New York (Fire Department of the City of New York ou FDNY) doit inspecter annuellement au moins 10 pour cent des 330 000 bâtiments dont il a la responsabilité en matière de prévention d'incendie. Tous les bâtiments sont sujets à inspection, à l'exception des maisons unifamiliales ou bi-familiales. Auparavant, les incidents, les inspections et autres interventions de la FDNY étaient consignés dans un système de fiches en format papier. Chaque immeuble disposait de sa propre fiche contenant des renseignements de base, comme l'année de sa construction, sa superficie, le type d'occupation, les matériaux ayant servi à sa construction et l'historique des inspections et des infractions au code de prévention. Pour accéder aux fiches, les inspecteurs en sécurité d'incendie devaient se rendre dans les casernes. Comme plusieurs éléments d'information étaient manquants ou incomplets dans ces fiches, celles-ci ne constituaient pas un guide fiable pour allouer les ressources en prévention d'incendie ou pour guider les interventions des pompiers (Roman, 2014).

En raison notamment de ce manque d'information sur les immeubles, deux pompiers auraient péri alors qu'ils combattaient un incendie à la Deutsche Bank Building, en 2007. Pour éviter que de tels incidents ne se répètent et pour faciliter l'échange d'information entre différents services municipaux, la Ville de New York a créé un entrepôt de données, nommé DataBridge, qui réunit d'innombrables renseignements provenant du FDNY ainsi que d'une trentaine d'autres services municipaux. La Ville a aussi créé une application pour exploiter les

données de cet entrepôt, appelé Risk Based Inspection System (RBIS), afin de prioriser de façon plus éclairée les bâtiments à inspecter. Développé par le New York Mayor's Office of Data Analytics (MODA)⁴, en étroite collaboration avec le FDNY, le RBIS a été déployé à l'ensemble du territoire de la ville, en mars 2013. Le RBIS donne accès à un dossier étayé et à jour sur chaque immeuble (caractéristiques, incidents, inspections, infractions, altérations, etc.), dont le FDNY a la responsabilité, afin de guider les inspections et autres interventions. Ce système est aussi doté d'une interface de visualisation qui permet de situer sur une carte interactive plusieurs de ces données.

Le RBIS est aussi équipé d'un modèle de prédiction du risque d'incendie, appelé Firecast, qui permet de prioriser les immeubles à inspecter à partir de l'analyse des données de l'entrepôt. Pièce maîtresse du RBIS, FireCast dresse une liste d'immeubles à inspecter en fonction de leur probabilité de violation et d'incendie. Concrètement, les équipes d'inspecteurs en sécurité incendie reçoivent chaque jour une liste des 15 bâtiments les plus à risque dans leur secteur. La production de cette liste s'appuie sur une régression logistique composée d'une soixantaine de variables ou facteurs de risques. La probabilité d'incendie de chacun des immeubles est recalculée quotidiennement par le modèle FireCast pour tenir compte des mises à jour du système, les inspecteurs devant saisir de nouvelles données dans le RBIS une fois les inspections ou autres interventions de la journée terminées. Bien que les inspecteurs se gardent une certaine discrétion dans la

⁴ Le MODA est un bureau de la Ville de New York dédié à l'intégration et à l'analyse des données de l'ensemble des services municipaux afin d'assurer une meilleure gestion

des problèmes de criminalité, de sécurité publique et de qualité de vie.

planification de leur calendrier d'inspections, l'utilisation du modèle a contribué à l'amélioration de la détection des infractions.

Avant l'application du modèle, les 25 premières inspections du FDNY entraînaient la découverte de 21 % des violations les plus graves. En utilisant le modèle de prédiction, les premiers 25 % des inspections entraînent désormais la découverte de plus de 70 % des violations les plus graves. (NYC, 2013, p. 13 ; ma traduction)

Depuis 2015, le FDNY et le MODA travaillent conjointement sur une nouvelle version du FireCast qui permet de traiter un plus large éventail de données en provenance d'une vingtaine de services municipaux, dont des plaintes recueillies au service 311, comme des bruits excessifs, des poubelles renversées ou la présence de rongeurs. Sur les 2,6 millions de plaintes traitées annuellement par le service 311, 1,4 million est lié au bâtiment (Roman, 2014, p. 46). Ainsi, FireCast continue de se raffiner avec l'ajout de données sur les bâtiments, sur les comportements humains et sur les milieux de vie. Le nombre de variables dans le modèle serait passé de 60 à 7 500. La nouvelle version de l'outil permet aussi de moduler la pondération de certains facteurs de risque d'incendie en fonction de la localisation de l'immeuble.

New York est la première grande ville nord-américaine à avoir déployé à grande échelle un modèle de prévention du risque d'incendie basé sur l'exploitation des données massives pour planifier ses inspections. Jusqu'ici, aucune autre ville nord-américaine ne s'est dotée d'un système de prévention du risque d'incendie aussi perfectionné, du moins sur le plan technologique. Après New York, deux autres grandes villes américaines, Atlanta et Pittsburgh, ont décidé de recourir à des

modèles de prédiction pour améliorer la planification de leurs inspections. Ces deux modèles sont présentés ici de façon succincte.

4.2 Le modèle de prédiction du Service d'incendie d'Atlanta (Firecast)

À l'instar du FDNY, le service de sécurité incendie de la ville d'Atlanta (Atlanta Fire Rescue Department ou AFRD) dressait traditionnellement une liste de bâtiments commerciaux à inspecter, le plus souvent en format papier, qui était reportée d'une année à l'autre. En l'absence d'une démarche de priorisation des inspections basées sur l'analyse de données, l'ajout de nouveaux bâtiments dans cette liste était laissé, ici aussi, à la discrétion des inspecteurs.

Les inspecteurs en incendie de l'AFRD recevaient chaque mois une liste de propriétés à inspecter, qui avaient été inspectées au cours du même mois de l'année précédente... Il incombait en grande partie aux inspecteurs de repérer les nouveaux bâtiments à inspecter. (Madaio *et al.* 2015; notre traduction)

Pour les autorités de l'AFRD, les 2 600 inspections réalisées annuellement par leurs inspecteurs ne ciblaient pas nécessairement les bâtiments ayant les plus fortes probabilités d'incendie. Avec la collaboration d'une équipe de chercheurs de la Georgia Institute of Technology, l'AFRD a décidé de développer, à l'été 2015, un modèle de prédiction, appelé Firebird, qui permet d'attribuer aux immeubles commerciaux une probabilité d'incendie. Pour détecter les propriétés commerciales affichant un risque élevé d'incendie et pour les prioriser lors d'inspections, Firebird, comme FireCast, exploite divers ensembles de

données⁵ gérés par différents services municipaux⁶. S'appuyant sur une soixantaine de variables, ce modèle de prédiction pouvait prédire jusqu'à 71 % des incendies survenus dans les quelque 5 000 immeubles commerciaux évalués par l'outil. Pour faciliter l'utilisation de Firebird, un outil de visualisation a aussi été développé permettant d'afficher sur une carte interactive les probabilités d'incendie des propriétés commerciales ainsi que d'autres renseignements sur ces commerces (nom, adresse, type d'occupation, date du dernier incident ou de la dernière inspection).

En 2016, l'utilisation de Firebird a contribué à mettre fin à certaines routines d'inspection, dont le recours à une liste relativement stable de bâtiments à inspecter d'une année à l'autre. Plusieurs nouveaux commerces ont été ajoutés à cette liste. L'utilisation de Firebird a aussi amené l'AFRD à revoir l'affectation géographique des inspecteurs en tenant compte de la proportion de bâtiments à risque d'incendie dans une région plutôt qu'en fonction de l'emplacement des casernes de pompiers. Contrairement au FDNY, l'AFRD n'évalue pas le risque d'incendie dans les propriétés résidentielles, là où la majorité des incendies surviennent à Atlanta. Depuis sa création en 2015, le modèle Firebird et ses données d'entraînement ne semblent pas avoir été mis à jour (Metro 21 : Smart Cities Initiative, 2018).

⁵ Dont l'historique des incendies et autres incidents, les inspections, les permis d'alcool, les crimes, les données socioéconomiques et démographiques ainsi que divers renseignements sur les propriétés (ex. : âge, matériaux de construction, prix de vente, nombre d'étages et d'unités).

⁶ Dont l'AFRD, l'Atlanta Police Department, l'Atlanta Regional Commission et le U.S. Census Bureau.

4.3 Le modèle de prédiction du Service d'incendie de Pittsburg

Le Bureau des incendies de la Ville de Pittsburgh (Pittsburgh Bureau of Fire ou PBF), comme bien d'autres services de sécurité incendie nord-américains, effectue des inspections de bâtiments autres que résidentiels pour s'assurer de leur conformité aux normes de sécurité en matière d'incendie. N'ayant pas les ressources pour inspecter l'ensemble des quelque 20 000 bâtiments non résidentiels dont ils ont la responsabilité, le PBF décide, lui aussi, de recourir à un modèle de prédiction pour optimiser ses inspections ainsi qu'à des chercheurs universitaires pour concevoir ce modèle. S'appuyant sur une diversité de données relatives aux bâtiments⁷ ainsi que sur un modèle d'apprentissage automatique, ces chercheurs et le PBF ont développé un modèle prédictif qui calcule la probabilité qu'un bâtiment subisse un incendie dans les six prochains mois. Depuis 2017,

Le modèle de prévision des risques d'incendie est déployé sur le serveur du Pittsburgh Bureau of Fire, où il s'exécute chaque semaine, générant de nouveaux scores de risque basés sur les données les plus récentes sur les incendies et les propriétés (Metro21 et Madaio, 2018, p. 7 ; notre traduction).

Ainsi, les probabilités d'incendie sont mises à jour sur une base régulière. Avec ce modèle, le PBF est en mesure de détecter plus de la moitié (55 %) des incendies qui se sont

⁷ En particulier l'historique des incidents et des inspections en matière d'incendie de 2009 à 2017, les infractions ou violations de tout genre (ex. : bruit et insalubrité), les permis, les licences et divers renseignements sur les immeubles (ex. : adresse, no de lot, valeur).

produits. Pour faciliter son utilisation, le modèle a été intégré à une interface de visualisation cartographique développée par la Ville ainsi qu'à des tableaux de bord qui permettent de suivre et de comparer les scores de prédiction du modèle et autres données dans le temps et dans l'espace. À l'image du modèle FireCast, on envisage d'y inclure des données de sources externes au PBF, dont des requêtes du 311, des données de recensement ou des taxes impayées. Enfin, le modèle est présenté comme un outil qui complète, et non remplace, l'évaluation des risques et la planification des inspections par le PBF et ses inspecteurs. Cette autonomie permet aux inspecteurs de tenir compte de facteurs de risque jugés pertinents et qui sont absents du modèle.

5. Les principaux défis de la mise en œuvre des modèles de prédiction du risque d'incendie

L'analyse comparative des cas montre que la conception et le déploiement d'un modèle de prédiction du risque d'incendie soulèvent d'importants défis informationnels, technologiques et humains ou organisationnels auxquels les services de sécurité incendie sont confrontés. Examinons les défis communs de mise en œuvre qui ressortent de cette analyse, en portant une attention particulière au cas du SIM et à son modèle de prédiction.

5.1 L'intégration des données et des systèmes

Les fusions municipales de 2002 ont contribué à l'intégration de bases de données à l'ensemble du territoire montréalais. « Au début des fusions, il y a eu 22 systèmes d'incendie à combiner... La fusion a aussi permis l'accumulation des données depuis l'an 2002 dans un gros cube d'informations ».

(Répondant 5) Cet accès à de nombreuses données opérationnelles a rendu possible le développement du modèle de prédiction. Toutefois, certaines données du modèle posent des défis d'extraction, de normalisation et de synchronisation qui limitent pour l'instant les possibilités d'intégration, particulièrement quand il s'agit de croiser des bases de données gérées par différents systèmes et services municipaux. C'est le cas des adresses physiques et autres données sur les bâtiments. « Non seulement les adresses entrées ne sont pas toujours normalisées, mais les bases de données ne sont pas synchronisées. ». (Répondant 1) D'importants défis d'extraction et d'intégration des données apparaissent aussi quand on désire inclure de nouvelles données au modèle, comme l'historique des inspections.

Probablement le plus gros du travail, ce serait celui de collecter les données de cette variable [historique des inspections] qui résident dans d'autres systèmes, puis de croiser les données pour constituer un jeu de données sur lequel on peut ensuite estimer la valeur de telle ou telle variable. (Répondant 1)

Les trois autres villes de l'étude ont, elles aussi, rencontré d'importants défis de normalisation des données et d'intégration des systèmes au moment de concevoir leur modèle de prédiction. L'absence d'uniformité des données sur les bâtiments (ex. : adresses) ainsi que la diversité des supports (ex. : dossiers papiers ou numériques), des formats (ex. : données structurées ou non structurées) et des plateformes (ex. : infonuagique ou solution locale) utilisés ont en effet rendu complexes l'extraction et le traitement des données au moment de l'entraînement des modèles.

5.2 La disponibilité de l'expertise et l'évolution du modèle

Le SIM est autonome dans son utilisation du modèle. « On y a automatisé les traitements pour que tout ça roule en continu... sans que personne n'intervienne. Le tableau de bord se met à jour tout seul ». (Répondant 5) Par contre, il ne dispose pas à l'interne de l'expertise pour faire évoluer le modèle. Depuis sa conception, en 2019, le modèle n'a pas évolué par manque de disponibilité du scientifique de données qui a été sollicité dans le démarrage d'autres projets à la Ville. « En ce moment, je suis à peu près tout seul à pouvoir faire ce que je fais, à la Ville, ce qui est clairement insuffisant... On a perdu beaucoup de monde, notamment en raison de l'attrait du privé », affirme le scientifique de données. Plusieurs répondants soutiennent qu'il serait temps de bonifier le modèle par l'ajout d'autres variables, comme l'impact potentiel d'un incendie.

Jusqu'ici, il n'y a pas d'analyse d'impact qui est faite sur les bâtiments. Deux bâtiments de même risque vont être traités également dans la liste... Pourtant, l'impact d'un incendie serait beaucoup plus grand sur une école ou sur un hôpital que sur une maison... L'analyse d'impacts viendrait un peu replacer dans un nouvel ordre les bâtiments, en considérant l'impact possible en termes de vies humaines, en termes de coûts économiques, de coûts environnementaux ou de coûts réputationnels. (Répondant 1)

Certains répondants suggèrent aussi d'inclure l'historique des inspections dans le modèle, comme c'est le cas des trois autres modèles étudiés, ou la météo et son impact sur les interventions. Enfin, il peut être opportun d'évaluer l'ajout de variables associées aux

immeubles (ex. : permis de rénovation et taxes impayées) et aux comportements (ex. : plaintes aux 311 et crimes) présentes dans les autres modèles étudiés.

5.3 L'adhésion à un outil de prédiction dans un contexte de réorganisation du travail

Rappelons que le déploiement du modèle du SIM a rencontré, au départ, de la résistance de plusieurs chefs de section et de leurs agents de prévention qui voyaient d'un mauvais œil l'arrivée d'un outil qui encadre la planification des immeubles à inspecter et qui, de surcroît, décloisonne territorialement leur travail. Pour favoriser l'adhésion des chefs de section à l'utilisation de l'outil, le chef de division a utilisé d'une stratégie de persuasion efficace qui misait sur la performance du modèle, notamment en leur présentant les probabilités d'incendie des immeubles sur leur territoire où un incendie est survenu. Le SIM a aussi équipé les chefs de section d'un outil de visualisation et de géolocalisation simple d'utilisation.

Pour favoriser l'adhésion des agents de prévention, le SIM a assoupli certaines règles de fonctionnement dans la planification des inspections, notamment en reconnaissant à ces agents une marge d'autonomie dans le processus d'inspection. En effet, les agents de prévention peuvent, depuis 2022, choisir les bâtiments à inspecter jusqu'à concurrence de 20 % des inspections totales qu'ils souhaitent mener. Cependant, ils doivent justifier leurs choix s'ils dérogent aux indications du modèle. Cette marge d'autonomie constitue un complément utile au modèle de prédiction et à ses limites, notamment quand il permet de tenir compte de l'impact de l'incendie dans leurs choix d'inspection, ce que le modèle ne permet pas de faire pour le moment.

6. Des leviers d'intervention et pistes d'amélioration

6.1 Une uniformisation des données et une intégration des infrastructures

Plus le modèle est alimenté par des données nombreuses, variées et valides, plus sa prédiction est susceptible d'être précise et fiable. Cependant, plusieurs données peuvent être difficiles à extraire et à exploiter lorsqu'elles se trouvent proviennent de diverses sources, consignées dans différents systèmes d'information, *a fortiori* gérés par des entités distinctes.

L'intégration des données a été l'un des principaux enjeux rencontrés par les autorités municipales dans la mise en œuvre des modèles de prédiction étudiés. Ces autorités et leurs équipes d'experts ont dû uniformiser le format et la nomenclature des variables (ex. : date, adresses, incidents) servant à l'entraînement des modèles puis créer des identifiants pour que les données puissent être regroupées, analysées et visualisées. Des infrastructures ont aussi été déployées pour faciliter l'exploitation des données une fois normalisées.

À ce propos, la Ville de New York a mis en place l'une des infrastructures technologiques les plus sophistiquées en matière de gestion des risques d'incendie qui, par un réseau d'échange automatisé de données normalisées (DEEP), permet de connecter une multitude de partenaires municipaux en temps réel à un entrepôt de données mis à jour quotidiennement (DataBridge). Cette infrastructure est aussi équipée d'une interface intégrée permettant d'afficher sur une même carte les données des partenaires. Ainsi, plus d'une trentaine de services municipaux et autres partenaires peuvent mettre en commun leurs données, les

exploiter et les visualiser. Pour utiliser cette infrastructure, les partenaires doivent s'engager à verser des données dans l'entrepôt pour les rendre disponibles aux autres partenaires.

Montréal pourrait s'inspirer de New York en mettant en place un environnement informationnel interconnecté et normalisé qui faciliterait la collecte, l'échange et l'exploitation des données en matière de prévention du risque d'incendie ou autres risques, que ce soit à des fins d'intelligence d'affaires (ex. : tableaux de bord) ou d'intelligence artificielle (ex. : modèles de prédiction). Cet environnement pourrait notamment s'interconnecter à Qlik Sense, le tableau de bord corporatif de la Ville de Montréal, afin de faciliter l'analyse et la visualisation des nombreuses données par les utilisateurs eux-mêmes.

6.2 Une gouvernance des données responsable

La gestion prédictive du risque soulève aussi des enjeux de gouvernance de données. Un premier enjeu de gouvernance informationnelle a trait au repérage des sources d'information disponible et à la sélection des données à inclure dans le modèle. Il faut d'abord s'assurer que les données à inclure dans le modèle sont non seulement accessibles et de qualité, mais aussi réutilisables. Plus les sources sont nombreuses et diversifiées, plus le travail de nettoyage et de normalisation s'avère majeur. Il importe aussi d'évaluer le pouvoir de prédiction des données avant de les inclure dans le modèle : « On ne peut pas se permettre de mettre une variable comme ça à la va vite » (Répondant 5). Encore faut-il que cet ajout améliore le rendement du modèle.

La gestion des accès constitue un autre enjeu de gouvernance informationnelle. Dans un contexte d'exploitation de données massives, il devient en effet primordial de préciser clairement les règles d'accès aux données (par ex., qui a accès à quelles données et pour quel usage?), surtout quand l'information est sensible et que les utilisateurs sont nombreux. À la lumière des cas américains, les modèles de prédiction du risque d'incendie ne se limitent plus aux données sur les immeubles et sur l'historique des incidents et des inspections ou autres interventions. Ils s'appuient aussi sur des données sociodémographiques (ex. : âge, revenu, scolarité) et comportementales (ex. : poubelles renversées, bruit excessif et crimes). L'ajout de données plus sensibles ne doit pas porter préjudice aux individus, aux groupes ou aux territoires. D'où l'importance de limiter l'accès aux données aux seuls intervenants dûment autorisés et de justifier la nécessité des usages et de finalités de manière à éviter certaines dérives, comme la constitution de dossiers sur les individus et leurs conduites pouvant conduire à du profilage.

Enfin, la prudence semble de mise quant à l'utilisation d'un modèle de prédiction par la population. Bien que séduisante sur le plan de la transparence municipale, cette utilisation peut entraîner des inconvénients supérieurs aux bénéfices escomptés. Par exemple, « on pourrait assister à une dégentrification de certains secteurs... Si le secteur est à risque, on n'ira pas acheter là. Puis, ça peut jouer sur les prix et la valeur foncière ». (Répondant 2) C'est pourquoi le SIM souhaite garder à l'interne l'usage du modèle et des outils de visualisation qui l'accompagnent. Aucun des services de sécurité incendie étudiés n'a d'ailleurs rendu publiques les probabilités

d'incendie des immeubles dont ils ont la responsabilité. Cependant, il en est autrement du code source des modèles prédictifs d'Atlanta et de Pittsburgh qui, lui, est ouvert (open source), ce qui favorise la réutilisation de ces modèles par d'autres administrations municipales.

6.3 Une mutualisation d'expertises en demande

Bien que nécessaire, la mise en place d'une infrastructure technologique performante et d'une gouvernance de l'information responsable n'est pas suffisante pour actualiser et bonifier le modèle de prédiction du SIM et autres modèles. Encore faut-il disposer d'expertises capables de faire évoluer les modèles, dont des compétences en sciences des données et en analytique avancée. Or, de telles expertises semblent rares et très sollicitées à la Ville de Montréal, comme ailleurs.

Le cas de New York peut se révéler une fois de plus inspirant pour Montréal et d'autres villes. À la demande du maire de l'époque, Michael Bloomberg, la ville de New York a créé, en 2013, le Mayor's Office of Data Analytics (MODA). Constitué d'une petite équipe d'experts en exploitation de données, ce bureau accompagne et soutient le FDYN et les autres services de la Ville dans la préparation, l'analyse et la valorisation de leurs données en fonction des services qu'ils offrent. Le MODA a aussi la responsabilité de l'entretien et de l'évolution des systèmes (ex. : DEEP, DataBridge et RBIS) qui permettent l'exploitation et la valorisation des données.

À l'image du MODA, la Ville de Montréal aurait intérêt à créer une escouade d'experts en exploitation des données qui collaborerait avec les différents services municipaux. Cette équipe serait utile non seulement pour le SIM

qui souhaite bonifier son modèle de prédiction, mais aussi pour les autres services municipaux qui désiraient être accompagnés dans l'exploitation et la valorisation des données afin d'éclairer leurs décisions quant à l'allocation des ressources et la qualité des services.

Conclusion

Les données constituent un intrant essentiel à l'entraînement et au déploiement des modèles de prédiction, notamment dans la gestion des risques d'incendie. Plus ces données sont nombreuses et variées, plus les modèles de prédiction gagnent en efficacité, pour autant que les données exploitées soient de qualité et qu'elles contribuent au pouvoir prédictif de ces modèles (Dwivedi, 2019). Avec la numérisation et l'interconnexion des systèmes d'information dans les administrations municipales et autres administrations, il faut s'attendre à une exploitation de plus en plus massive et systématique, voire algorithmique, de ces données (Athey, 2017). De nombreuses données opérationnelles peuvent donc avoir une deuxième vie. Le cas de New York et de son modèle de prédiction du risque d'incendie est éloquent à cet égard, avec l'exploitation de 7 500 variables en provenance d'une vingtaine de services municipaux.

Notre étude montre que les modèles de prédiction du risque d'incendie s'avèrent plus performants que les méthodes traditionnelles, fondées essentiellement sur l'expérience et les habitudes des inspecteurs. Nul doute que les modèles de prédiction du risque peuvent contribuer à optimiser l'utilisation des ressources, notamment pour détecter ou atténuer les risques d'incendie par des activités de prévention mieux ciblées. L'étude révèle aussi que le recours au modèle de

prédiction ne suffit pas et que le jugement d'un agent expérimenté demeure utile, que ce soit pour interpréter le modèle au regard de son expérience ou pour prendre en considération des facteurs de risques absents du modèle, comme l'impact des incendies ou de la météo dans le cas du SIM. Le rôle de l'utilisateur s'apparente plus à celui d'un médiateur qu'à un exécutant, au sens où Janssen et ses collaborateurs l'entendent (2020).

Cependant, d'importants défis de mise en œuvre guettent les organisations publiques dans le déploiement de ces modèles, tel que le propose la présente étude ainsi que bon nombre d'auteurs (voir la section 2). Ces défis peuvent être de nature informationnelle ou technologique. À ce propos, la multiplication des données provenant des systèmes opérationnels cloisonnés rend l'extraction et la réutilisation des données complexes, voire périlleuses (Sun et Medaglia, 2019; Janssen *et al.* 2020). D'où l'importance de sélectionner des données en fonction de leur contribution au modèle ainsi que des coûts d'extraction et d'exploitation des données (Dwivedi *et al.*, 2019).

Les résultats de l'étude montrent que les défis à relever peuvent aussi être de nature organisationnelle, à l'instar de la littérature que nous avons consultée. Sans surprise, l'un de ces défis réside dans l'accès à des expertises en exploitation des données. L'accès à ces expertises pointues demeure en effet un enjeu de premier plan pour les administrations publiques en général (Dwivedi *et al.*, 2019). Un autre important défi organisationnel a trait à la résistance des employés et autres utilisateurs qui, le plus souvent, perçoivent l'utilisation des modèles de prédiction et autres outils intelligents automatisés comme une perte d'autonomie décisionnelle et comme un désaveu à l'égard

de leurs compétences (Sun et Medaglia, 2019). Il n'est donc pas surprenant que les autorités aient tendance à présenter ces outils intelligents comme des aides à la décision qui complètent le jugement des utilisateurs, et non le remplacent (Jacob et Souissi, 2021). Cette préoccupation face à l'adhésion des utilisateurs a d'ailleurs amené le SIM à revoir les règles d'utilisation de son modèle de prédiction du risque afin de préserver une marge d'autonomie chez les agents de prévention dans la planification de leurs inspections. Reste à savoir combien de temps cette marge d'autonomie sera préservée, compte tenu d'une exploitation toujours plus massive des données et, conséquemment, d'une performance croissante des modèles de prédiction qui les exploitent. D'autres mesures d'adhésion et d'intéressement seront à prévoir au fur et à mesure que les modèles de prédiction se perfectionneront et encadreront de façon plus serrée le travail des agents de prévention et autres employés de l'État.

Différents facteurs de succès peuvent expliquer le déploiement du modèle du SIM à l'ensemble de son territoire. Le fait d'avoir expérimenté le modèle sur base volontaire, de 2019 à 2020, a permis d'évaluer la performance du modèle et d'en faire la promotion auprès des chefs de section, dont plusieurs s'étaient montrés réfractaires au départ. Le recours à des outils de visualisation simple d'utilisation (ex. cartes interactives) a aussi facilité l'appropriation du modèle ainsi que l'exploitation d'autres données probantes par les chefs de section et autres utilisateurs. La préservation d'une marge d'autonomie chez les agents de prévention dans la planification de leurs inspections a facilité, quant à elle, leur adhésion au modèle. Enfin, la collaboration étroite d'un scientifique de données de la Ville

de Montréal a permis le développement d'un modèle de prédiction à la fois simple et performant.

Comme nous l'avons vu, le SIM peut s'inspirer des autres modèles de prédiction du risque d'incendie que nous avons examinés pour améliorer la performance de son modèle. Pour augmenter le pouvoir prédictif de son modèle, le SIM peut, à l'instar des modèles américains, inclure de nouveaux ensembles de données dans l'entraînement de son modèle, comme l'historique des inspections et l'impact sur les interventions ainsi que des données associées aux immeubles (ex. : permis de rénovation et taxes impayées) et aux comportements (ex. : plaintes aux 311 et crimes). Cependant, pour faciliter l'ajout et l'exploitation de nouvelles données dans le modèle, il convient de mettre en place une infrastructure intégrée (ex. réseau d'échange automatisé de données, entrepôt et outils d'analyse et de visualisation) qui permet à une multitude de partenaires municipaux de mettre en commun leurs données et de les valoriser. Ici, le cas de New York peut être un exemple à suivre. Pour perfectionner son modèle, le SIM doit aussi disposer d'expertises en sciences des données et autres compétences en analytique avancée. Afin de pallier le manque d'expertises en exploitation des données, la Ville de Montréal aurait intérêt à regrouper ces expertises au sein d'une même entité qui appuierait les différents services municipaux dans la valorisation de leurs données, à l'image du MODA de la Ville de New York.

En somme, les municipalités qui désirent se démarquer dans la gestion des risques d'incendie et autres risques en contexte de données massives devront miser sur le développement de leurs capacités technologiques, informationnelles et organisation-

nelles à mutualiser leurs données et à les exploiter de manière performante et acceptable pour les utilisateurs.

Biographies

Détenteur d'un doctorat en management de l'Université Laval (2002), **Christian Boudreau** est professeur à l'École nationale d'administration publique (Québec, Canada) depuis 2002. Ses travaux de recherche portent sur la gouvernance collaborative, la participation citoyenne, le gouvernement ouvert et la surveillance. Dans ses plus récentes recherches, il étudie les défis liés au déploiement de l'intelligence artificielle dans le secteur public. Il est aussi un spécialiste des méthodes de recherche qualitatives, particulièrement les études de cas et la théorisation ancrée.

Justin Lawarée a un doctorat en sciences politiques de l'UCLouvain (Belgique). Défendue en 2017, sa thèse a étudié l'intégration des innovations dans l'administration publique. Après un postdoctorat au sein du CAPP (Université Laval), il a contribué à l'élaboration de la stratégie d'intégration de l'intelligence artificielle dans l'administration québécoise et à alimenter les réflexions pour la Recommandation sur l'éthique de l'IA (UNESCO). De 2021 à 2022, Justin a été conseiller aux affaires publiques au sein de l'OBVIA et du numérique (OBVIA). Depuis 2022, il est professeur adjoint à l'École nationale d'administration publique.

Bibliographie

ATHEY, S. (2017). "Beyond prediction: Using big data for policy problems", *Science*, no 355, pp. 483-485.

CLARE, J. *et al.* (2012). "Reduced frequency and severity of residential fires following delivery of fire

prevention education by on-duty fire fighters: Cluster randomized controlled study", *Journal of safety research*, vol.43, no. 2, p.123-128.

DE VASCONCELOS, M. J. P., Silva, S., Tomé, M., Alvim, M. et Pereira, J.-M. (2001). « Spatial prediction of fire ignition probabilities: comparing logistic regression and neural networks ». *Photogrammetric engineering and remote sensing*, vol. 67, no.1, p. 73-81.

DWIVEDI, Y. K. *et al.* (2019). "Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy". *International Journal of Information*, vol 67.

EUBANKS, V. (2017). "Automating Inequality: How High-Tech Tools Profile, Police, and Punish the Poor", St. Martin's Press, New York.

LIADIS, L. (2005). « A decision support system applying an integrated fuzzy model for long-term forest fire risk estimation », *Environmental Modelling & Software*, vol. 20, no 5, p. 613-621.

JANSSEN, M et KUK, G. (2016). "The challenges and limits of big data algorithms in technocratic governance", *Government Information Quarterly*, vol. 33, no 3, p. 371-377.

JANSSEN, M. *et al.* (2020). « Data governance: Organizing data for trustworthy Artificial Intelligence », *Government Information Quarterly*, vol. 37, no 3.

LAPUCCI, A. *et al.* (2005). A KDD based multicriteria decision making model for fire risk evaluation, *Conference on GIS-cience (AGILE)*.

METRO21 et MADAIO, M. (2018). Predictive Modeling of Building Fire Risk Designing and evaluating predictive models of fire risk to prioritize property fire inspections, *Metro21 Research Publication*.

MADAIO, M. *et al.* (2016). Firebird: Predicting Fire Risk and Prioritizing Fire Inspections in Atlanta, *ACM Knowledge Discovery and Data Mining 2016 conference*.

NEW YORK CITY – MAYOR'S OFFICE OF DATA ANALYTICS (2013). *Annual Report 2013*.

ROMAN, J. (2014). Data Driven 2013. Information and the brave new world of smart firefighting, *NFPA Journal*, novembre/décembre 2014.

ROTH, J. (2014). The Analytics of Fire, Profiles in Public Service, *Urban Omnibus*, 25 juin 2014.

STRONG, D. M., LEE, Y. W. et WANG, R.Y. (1997). "Data quality in context". *Communications of the ACM*, vol 40, no 5, p. 103-110.

SUN, T.Q. et MEDAGLIA, R. (2019). « Mapping the challenges of Artificial Intelligence in the public sector: Evidence from public healthcare », *Government Information Quarterly*, vol. 36, no 2.

WIRTZ, B.W. et MÜLLER, W.M. (2019). "An integrated artificial intelligence framework for public management", *Public Management Review*, vol. 21, no 7, p. 1076-1100.