

Une intelligence artificielle éthique au service des politiques publiques : Expérimentation dans la restauration scolaire pour maîtriser le gaspillage alimentaire

Retour d'expérience coordonné par Nantes Métropole avec des
contributions de Nantes Métropoles, Maestria Innovation et Verteego

Document de travail – document provisoire

Version du 15/12/2020

Rédacteurs

Nantes Métropole : Claudine Baron, Florent Bedecarrats, Matthieu Clavier, Arnaud Delporte et
Claire Sacheaud ;

Verteego : Clément Guillon, Baptiste Ariaux et Nicolas David ;

Maestria Innovation : Maïeul Lombard, Gilles Cornec et Alan Entem.

Licence du document

CC-SA-BY

Table des matières

| | |
|---|-----------|
| Résumé..... | 3 |
| Contexte et enjeux..... | 5 |
| Défendre une approche innovante et responsable du numérique..... | 7 |
| Une démarche d'innovation ouverte..... | 7 |
| Développer un outil au service de la décision des agents..... | 8 |
| S'abstenir de recueillir ou d'exploiter toute donnée personnelle..... | 9 |
| Réunir les prérequis pour utiliser ces outils de modélisation..... | 10 |
| Acteurs à mobiliser..... | 10 |
| Adapter la solution à son contexte technique et organisationnel..... | 10 |
| Identifier les sources et préparer ses données..... | 11 |
| Développer une modélisation fiable..... | 13 |
| Traitement des données..... | 13 |
| Principaux types de modèles et leurs avantages et inconvénients..... | 15 |
| L'exemple des modèles développés à Nantes..... | 17 |
| Évaluation de la performance des modèles..... | 19 |
| Précautions pour la mise en œuvre..... | 21 |
| Accompagner l'appropriation par le service public..... | 23 |
| S'adapter au processus actuel..... | 23 |
| Éclairer l'interprétation..... | 25 |
| Accompagner l'adoption..... | 25 |
| Cibler d'autres facteurs du gaspillage (grammage, menus)..... | 26 |
| Pour aller plus loin..... | 28 |
| Accéder aux outils mis à disposition..... | 28 |
| Comment participer..... | 28 |
| Références..... | 29 |
| Annexe : résultats des modèles évalués..... | 30 |

Résumé

Objectifs

Ce document présente des outils de modélisation servant à prédire, plusieurs semaines à l'avance, le nombre de convives qui viendront manger dans les restaurants scolaires d'une collectivité territoriale. Cette démarche sert deux objectifs principaux :

1. Aider les agents à améliorer la fiabilité et la robustesse de leurs prévisions, sans déstabiliser l'organisation en place, pour contribuer à la résilience de la collectivité et du système de restauration collective face à certains aléas (départs, absences...);
2. Anticiper les achats de matières premières et fiabiliser les commandes aux fournisseurs.

Prérequis et utilisation

Les modèles prédictifs ont été programmés dans un langage informatique simple (python) et publiés en licence ouverte sur un portail de partage de logiciels (espace Github de Nantes Métropole). Ils peuvent être librement réutilisés par toute collectivité ou opérateur. Ces outils sont configurés pour un système de restauration scolaire proposant un menu unique quotidien (avec une alternative aux plats incluant du porc et des repas individuels adaptés pour motifs médicaux) avec des récurrences hebdomadaires (végétarien le lundi et poisson le vendredi...). Ils devront être adaptés avant d'être appliqués à des configurations différentes (self-services, menus multiples...). Leur utilisation requiert au préalable de consolider des historiques détaillés, sur trois années minimum, pour les données suivantes :

- fréquentation prévue et constatée pour chaque service et chaque établissement ;
- menus pour chaque service ;
- nombre total d'élèves inscrits dans chaque établissement les années concernées ;
- calendrier des vacances scolaires (si autre que zone B) ;
- jours ayant fait l'objet d'un préavis de grève et pouvant concerner les équipes scolaires, périscolaires ou de restauration.

Des historiques supérieurs à 3 ans sont préférables pour améliorer la précision des modèles et réaliser des simulations évaluant la fiabilité des résultats. Ces données sont croisées avec les calendriers des jours fériés et fêtes religieuses déjà enregistrés dans l'outil. D'autres données peuvent être ajoutées afin d'améliorer la fiabilité des modèles : indicateurs quantitatifs du niveau de vie dans la zone où l'établissement se situe (prix du m² à l'achat ou à la vente dans le quartier, revenu moyen à l'IRIS...), ou variables globales susceptibles d'affecter la fréquentation (avis de grèves nationales, indice météo). Seules les variables disponibles pour les dates à prédire au moment du calcul seront prises en compte. Il est possible de ré-exécuter ultérieurement les modèles pour ajuster les prédictions une fois que certaines variables sont disponibles (météo, grèves...).

Résultats

Deux outils prédictifs ont été développés par Verteego et Maestria Innovation. Tous deux génèrent un nombre prévisionnel de convives par établissement et par jour, ainsi que les facteurs qui influencent le plus ces prévisions (frites au menu, événement du calendrier civil ou religieux...). L'outil de Maestria Innovation inclut un modèle de prédiction plus performant au global, que l'on combine aux estimations par établissement pour en améliorer la fiabilité. En entraînant ces modèles sur les années scolaires 2011-2012 à 2017-2018 et en générant des prédictions sur l'année scolaire

2018-2019, on obtient une surproduction moyenne de 6,5 % avec les simulations, par rapport à 9,6 % constatés avec le système existant, soit un différentiel de 430 repas par jour.

Perspectives de déploiement

Les modèles intègrent mieux les facteurs récurrents et mesurables (historiques, effets calendaires...) mais les agents disposent d'informations diffuses (sortie scolaire, vie des écoles...) et d'une connaissance du terrain qui ne sont pas modélisables. Il ne convient donc pas d'utiliser ces outils pour remplacer les estimations réalisées par les agents de restauration, mais plutôt pour les assister dans leurs estimations, à 3 niveaux complémentaires :

1. D'abord, ces outils peuvent servir à anticiper les commandes aux fournisseurs qui doivent être réalisées 4 à 6 semaines avant un service. L'outil développé par Maestria Innovation génère une estimation assez fiable du nombre total de repas consommés un jour donné. Verteego a élaboré une variante de son outil qui permet de prédire le nombre de repas que les agents des établissements prévoient et commanderont pour le jour en question, en plus d'une estimation de la fréquentation réelle par établissement.
2. Les facteurs prépondérants des prédictions peuvent ensuite être indiqués sous forme de messages aux agents de restaurations de chaque établissement lorsqu'ils effectuent leurs commandes 2 à 4 semaines avant le service. Maestria Innovation a développé un prototype d'application s'adaptant à tout support (ordinateur, tablette ou smartphone), qui facilite la transmission de ces messages, le recueil des prévisions de la part des agents et la transmission par les agents à la cuisine centrale d'informations qualitatives pouvant aider à réduire d'autres sources de gaspillages (plats peu appréciés des enfants, suggestions d'ajustement des portions...).
3. Enfin, l'outil peut suppléer aux commandes par les agents de restauration lorsque ceux-ci sont absents ou nouveaux sur leur poste.

Les projets d'accueil individualisés, qui garantissent aux enfants présentant une situation médicale particulière de bénéficier d'une prise en charge adaptée, doivent impérativement continuer à être gérés en dehors de toute modélisation prédictive.

Contexte et enjeux

Au travers de sa [charte métropolitaine de la donnée](#), Nantes s'est engagée à maîtriser et réguler l'usage de ses données, afin notamment de garantir la souveraineté de la collectivité sur les données relevant du service public, de protéger les données des citoyens et de garantir la transparence. L'ambition est aussi de favoriser l'innovation en soutenant l'expérimentation de nouveaux usages au service des citoyens et de l'efficacité de nos services publics.

L'initiative présentée dans ce rapport consiste à mieux anticiper le nombre de convives dans les restaurants scolaires afin de réduire la surproduction responsable d'une partie du gaspillage alimentaire. Ce défi technique répond à des questions importantes sur le plan environnemental, social et économique.

La Ville de Nantes sert tous les jours entre 15 000 à 16 000 repas dans ses restaurants scolaires. Comme dans toutes les collectivités, il existe nécessairement une différence entre le nombre de repas anticipés et le nombre de repas produits et consommés, même si ce différentiel est particulièrement faible. La collectivité pratique une politique de table ouverte, permettant aux enfants de s'inscrire le matin pour le midi. Cette flexibilité favorise l'accès de tous les enfants à une alimentation équilibrée.

L'objectif du projet consiste à utiliser les données produites par le service de restauration (historiques de fréquentation, menus, vacances scolaires, effectifs des écoles...) pour aider à prévoir, plusieurs semaines à l'avance, le nombre d'enfants qui viendront manger à la cantine. Ceci afin d'anticiper les commandes aux fournisseurs (en particulier les producteurs locaux) et adapter la production de la cuisine centrale.

Cette initiative s'inscrit plus globalement dans le cadre de la stratégie en matière de transition énergétique et d'alimentation durable de la collectivité. Elle vient en complément d'autres initiatives en matière d'approvisionnement local et d'ajustement des portions notamment. La collectivité s'engage par exemple à sélectionner des produits locaux, durables et sains pour la restauration collective et met en place la récupération des repas surnuméraires par les associations. Elle structure une filière de recyclage des déchets alimentaires, afin de valoriser les restes non consommés au profit de l'économie circulaire. Enfin, les écoles maternelles et élémentaires de la Ville promeuvent aussi une éducation au "bien manger", avec notamment des potagers écoliers ou des parrainages "Une ferme, une école".

Une meilleure prévision des quantités prévues dans les cantines revêt également un enjeu économique, lié à la maîtrise des dépenses de la collectivité pour l'achat de matières premières. Pendant l'année 2018-2019 à Nantes, sur environ 16 000 repas produits chaque jour, 1350 repas en moyenne étaient préparés en trop, sachant que le coût indicatif des matières premières est de 1,65€ par repas. L'objectif est de maîtriser ce nombre de repas "en trop", tout en évitant au maximum les jours avec des repas manquants.

Une meilleure prévision des quantités estimées peut également avoir une incidence positive sur le développement économique local. La cuisine centrale est, en effet, le principal débouché de nombreux petits producteurs de la région, qui adaptent leurs volumes de production en fonction des commandes et qui gagneraient à mieux anticiper cette demande.

Nantes pratique une politique de table ouverte, permettant aux enfants de s'inscrire à la cantine le matin pour le repas du midi. Cette disposition est particulièrement importante pour les familles, qui ont parfois du mal à s'engager sur des inscriptions des semaines à l'avance. Se doter d'outils fiables de prédiction participe à sécuriser ce dispositif.

Défendre une approche innovante et responsable du numérique

Le défi d'améliorer la prédiction de la fréquentation des restaurants scolaires résulte d'une volonté d'accompagner des innovations éthiques pour développer une Intelligence Artificielle (IA) au service de l'intérêt général. Cela signifie que cette expérimentation est travaillée dans un cadre éthique. Le parti pris est de n'utiliser aucune donnée personnelle, de rendre transparent le fonctionnement de l'IA et de positionner ces modèles prédictifs comme une aide à la décision au service des agents. Ainsi, le but poursuivi avec ces algorithmes est d'aider les agents à améliorer la fiabilité et la robustesse de leurs prévisions, sans déstabiliser l'organisation en place et en contribuant à la résilience de la collectivité et du système de restauration collective face à certains aléas (départs, absences, réorganisations). Enfin, la démarche est conçue pour que les codes sources, les données et les méthodes soient publiés sous une licence libre. L'ambition est de l'ouvrir à d'autres utilisateurs et contributeurs afin de contribuer à construire un outil au service d'une politique publique commune à tous les territoires.

Une démarche d'innovation ouverte

La collectivité a travaillé avec deux entreprises dans le cadre d'un marché multi-attributaire. Ce sont les entreprises Maestria Innovation et Verteego qui ont été retenues. Le fait de retenir deux candidats plutôt qu'un seul permet de jauger les performances respectives des livrables sur les volets communs aux deux propositions (ex. modélisation statistique), mais aussi de valoriser les originalités de chacune des approches (dualité des modèles prédictifs chez Verteego, design du changement chez Maestria Innovation). Les équipes de Verteego et de Maestria Innovation ont travaillé conjointement sur plusieurs phases d'élaboration. Les travaux de contrôle qualité et de nettoyage des données, ainsi que certains entretiens avec les agents de terrain (ATR) ont ainsi été menés en commun.

Favoriser l'utilité sociale des outils produits dans le cadre de cette expérimentation impliquait d'assurer que leur réutilisation par d'autres acteurs (collectivités locales, opérateurs de restauration collective, éditeurs de logiciels professionnels) soit à la fois légalement et techniquement possible. Sur le plan juridique, il fallait que la licence soit libre, c'est-à-dire que les droits accordés par l'auteur du logiciel n'impliquent aucune restriction pour l'utiliser, le diffuser ou le modifier¹. Nantes Métropole a fait le choix d'une licence dite "MIT", qui est qualifiée de "permissive", en ce qu'elle implique très peu de limitations sur la réutilisation du code. Elle est ainsi compatible avec de nombreuses autres licences et permet des réutilisations pour des projets open source, mais aussi commerciaux. Les données utilisées pour la modélisation sont également ouvertes en open data sur le portail dédié de la collectivité : <https://data.nantesmetropole.fr>.

La réutilisation requiert aussi que le code source des outils de prédiction soit techniquement portable. C'est l'une des raisons pour lesquelles les équipes de Maestria Innovation et Verteego ont toutes deux décidé de développer leurs outils en Python, un langage de programmation libre. Python fonctionne sur toutes les plateformes (Windows, Mac, Linux, Android ou iOS) et offre des fonctionnalités particulièrement étendues pour toutes les applications liées à la donnée. Il s'agit

¹ La Loi pour une République numérique de 2016 a instauré l'obligation de publier sous une licence libre tous les codes sources développés par ou pour le compte d'une administration publique (art. L323 du Code des relations entre le Public et l'Administration).

également d'un des langages les plus populaires parmi les développeurs informatiques confirmés ou débutants, et ce choix maximise les chances que d'autres contributeurs s'impliquent dans des évolutions ultérieures.

Enfin, la portabilité technique est garantie par le fait que les codes sources sont ouverts et partagés dans des [dépôts Github ouverts par Nantes Métropole](#). D'autres collectivités locales, opérateurs de restauration collective, éditeurs de logiciel libre et spécialistes de la donnée sont invités à s'associer, à télécharger le code, le tester, rapporter des bugs ou suggérer des évolutions. Les acteurs intéressés à participer au développement de ces outils partagés pourront ainsi le faire en utilisant le processus classique de contribution sur une forge de code (fourches et demandes de modification, cf. [DINUM, 2018](#)).

Développer un outil au service de la décision des agents

La place accordée aux algorithmes et à l'Intelligence Artificielle suscite, à raison, des débats de fond sur la relation que nos sociétés sont en train de construire avec des outils de plus en plus autonomes. Les risques sont de trois ordres, auxquels la démarche entreprise apporte des réponses avec cette expérimentation.

Assister sans remplacer : Ici, il ne s'agit pas de remplacer les personnes, mais de porter à leur connaissance des éléments permettant d'éclairer leur jugement. Les algorithmes sont performants pour tenir compte de facteurs mesurés de manière fiable et sur un temps long, et qui se produisent avec monotonie (vacances, ponts, fêtes religieuses...). Mais seuls des agents présents sur le terrain et entretenant des interactions personnelles avec l'ensemble des parties prenantes (enseignants, élèves, parents, direction...) sont capables de capter des informations plus diffuses (sorties scolaires, événements inattendus...), d'apprécier l'incidence de phénomènes plus complexes (grèves, épidémies...) ou de tenir compte de cas particuliers (allergies, régimes spéciaux...). A fortiori dans des contextes marqués par des crises sanitaires ou des mouvements sociaux, aucun algorithme ne prédira la fréquentation des restaurants scolaires avec plus de fiabilité qu'une équipe expérimentée, bien organisée et entretenant une communication étroite. Mais lorsque les personnes s'absentent, changent, ou que leur organisation est perturbée, l'algorithme sert de guide pour limiter le risque d'erreurs et de dysfonctionnements. Ainsi, le but poursuivi avec cet algorithme est d'améliorer la fiabilité des prévisions réalisées par les agents de terrain et de contribuer à la résilience du système de restauration collective face aux aléas.

Encadrer et maîtriser l'IA : l'intelligence artificielle réalise des calculs complexes pour optimiser une réponse au problème qu'on lui pose, en se bornant aux termes utilisés pour spécifier ce problème. Elle ignore la hiérarchie de valeurs ou les considérations multiples, subtiles et souvent paradoxales qui permettent à une intelligence humaine de raisonner. Sans surveillance humaine, elle pourrait donc reproduire ou accentuer des biais pernicious présents dans les données d'entraînement, ou transgresser des règles que nous aurions omis de spécifier parce qu'elles nous paraissent aller de soi. On ne risque pas, dans le cas présent, de tomber dans le travers de discriminations personnelles par une IA², car il s'agit de prédictions d'effectifs agrégés et pas de décisions individualisées (Nantes s'est d'ailleurs interdit, dans sa [charte de la donnée](#), d'utiliser l'IA pour fonder des décisions individuelles). L'intervention humaine reste cruciale pour éviter les dérives³.

2 Cet aspect a fait l'objet de vifs débats dans la presse et la communauté scientifique, voir notamment [Kasy et Abebe, 2020](#).

3 On parle de « dérive » ou de « divergence » lorsque la fiabilité d'un modèle prédictif se dégrade au cours du temps, par exemple s'il devient de moins en moins précis ou de plus en plus biaisé.

Premièrement, des agents qui connaissent le métier de la restauration et des spécialistes de l'algorithmique doivent échanger pour imaginer des scénarios de dérive, afin de définir les garde-fous à poser au modèle. Par exemple, l'optimisation du modèle pour limiter le gaspillage « en moyenne » doit quand même conserver une marge de sécurité pour réduire l'occurrence et l'ampleur des sous-estimations. Il semble évident que la collectivité doit fournir assez à manger pour tous les enfants qui se présentent à la cantine un jour donné, mais l'algorithme l'ignore si on ne le lui spécifie pas et, sans ce paramètre, sa recherche d'un gaspillage nul le conduirait à ne pas conserver de marge de sécurité.

Deuxièmement, les données qui entrent et qui sortent du modèle doivent être synthétisées et présentées de manière graphique et compréhensible pour être facilement interprétables. Les tableaux de bord doivent notamment permettre de suivre distinctement la manière dont se répartissent les erreurs d'estimation par établissement afin, par exemple, de vérifier si l'algorithme ne sous-estime pas les besoins dans les écoles où la fréquentation est la plus erratique (et qui sont aussi celles situées dans les zones les plus défavorisées).

Garantir la transparence : La plupart des algorithmes d'intelligence artificielle reposent sur des processus d'abstraction et de combinaisons d'opérations tellement complexes qu'il devient presque impossible d'expliquer les résultats auxquels ils parviennent. Pour minimiser cette opacité, on a privilégié ici les algorithmes qui sont les plus aisés à interpréter : outre des résultats, chaque algorithme produit une liste des paramètres qui ont le plus contribué à l'estimation, avec leurs pondérations associées. La séquence des opérations de chacun des outils permet d'assurer une traçabilité entre les résultats et les données sur lesquelles l'algorithme a été entraîné⁴. Enfin, les données utilisées sont accessibles [sur la plateforme open data de la collectivité](#). La transparence est en outre renforcée par la publication du code source et l'ouverture à la discussion avec les pairs, notamment au sein de NaonedIA, le collectif nantais pour une IA éthique, responsable et populaire.

S'abstenir de recueillir ou d'exploiter toute donnée personnelle

Le parti pris de notre démarche a été d'éviter d'utiliser toute donnée personnelle. Techniquement, il aurait pu sembler séduisant de sophistiquer l'analyse en utilisant une méthode d'identification des convives à partir des registres de facturation, afin d'estimer des probabilités de fréquentation au niveau individuel et atteindre ainsi de meilleures performances prédictives. A Nantes, nous avons d'emblée exclu cette éventualité, car les bases de facturation constituent une donnée à caractère personnel. Or, d'une part, la collectivité a adopté une posture particulièrement protectrice à cet égard avec sa charte de la donnée métropolitaine, et d'autre part, les acteurs nantais de l'IA se sont engagés par un manifeste sur huit principes éthiques, qui condamne notamment le traitement de données qui s'effectuent sans le consentement des individus ou sans respecter l'usage pour lequel l'accès aux données a été obtenu ([NaonedIA, 2018](#)). Le pari était donc de parvenir à élaborer un algorithme performant sans voir recours à ces données personnelles.

⁴ Sur la notion d'entraînement, voir la section « Erreur : source de la référence non trouvée », p. Erreur : source de la référence non trouvée.

Réunir les prérequis pour utiliser ces outils de modélisation

Acteurs à mobiliser

La mise en place d'outils de modélisation prédictive pour la restauration scolaire doit impliquer différents acteurs :

- **Décideurs** : il s'agit de démarches encore expérimentales qui requièrent que plusieurs agents y consacrent du temps et de l'énergie, pour des résultats incertains. Elles doivent donc être soutenues par les élus et cadres en charge de l'éducation, de la restauration scolaire et du numérique.
- **Equipes en charge de la restauration** : Les responsables de la logistique et de la production ainsi que des agents organisant le service dans les établissements doivent être associés à la définition du besoin, à l'analyse du système existant et à l'évaluation des solutions proposées.
- **Spécialistes du numérique** : l'implication d'agents responsables de l'équipement numérique des établissements scolaires et de l'administration des SI correspondants est indispensable. Il est aussi indispensable de s'adjoindre l'accompagnement d'une personne ressource compétente en « science des données », c'est-à-dire alliant des compétences en informatique, en statistique et en analyse des besoins métiers.

Adapter la solution à son contexte technique et organisationnel

Il est essentiel de bien adapter la modélisation au système de production qui prévaut localement : cuisine centrale ou cuisine sur chaque site, menu unique ou self service, liaison chaude ou froide, système de table ouvert ou non... Les modèles présentés sont aussi susceptibles d'être retravaillés pour produire des résultats par type de convives, mais il faut s'assurer que les données brutes fournies en entrée comportent bien la même typologie de convives que celle qu'on essaye de prévoir.

En France, les écoles proposent systématiquement depuis 2003 un plan d'accueil individualisé pour adapter la prise en charge des enfants atteints de pathologies et maladies chroniques telles que l'allergie alimentaire. Cet aspect requiert impérativement un suivi spécifique hors de toute modélisation prédictive.

La manière de concevoir la composition des menus et leur planification doit être analysée pour s'assurer qu'elle sera bien prise en compte par le modèle. À Nantes, il existe une régularité des types de plats en fonction des jours de la semaine, avec un menu exclusivement végétarien le lundi, du poisson le vendredi et une source alternative de protéine pour tous les autres jours où du porc serait au menu. Cette correspondance entre le jour de la semaine et le menu a conduit Verteego à ne pas prendre en compte le jour de la semaine dans son modèle, car la méthode statistique employée perd en performance si elle utilise des variables très corrélées entre elles. Une collectivité qui n'aurait pas cette régularité hebdomadaire des menus gagnerait en performance en modifiant l'algorithme pour réintroduire le jour de la semaine comme variable d'analyse. Maestria Innovation a, pour sa part, créé des variables ad hoc pour capter ces cas de figure (par exemple une variable "vendredi avec poisson"), mais aussi identifier des exceptions et en tenir compte.

Un autre défi consiste à prendre en compte des situations exceptionnelles. Trois types d'événements induisent des difficultés particulières pour l'analyse :

- **Rentrée de septembre** : Le nombre de repas à préparer pour les premières semaines de septembre est estimé début juillet par les responsables de site, en fonction du nombre d'élèves inscrits pour l'année suivante qui sont enregistrés avant les vacances d'été. Mais de nouvelles inscriptions surviennent souvent en juillet ou en août, qui ne sont généralement validées que quelques jours avant la rentrée. Cette situation est particulièrement prégnante à Nantes, qui est une ville attractive pour les familles.
- **Sorties scolaires** : Les écoles organisent des sorties scolaires à la journée. L'information ne remonte pas toujours et la production n'est alors pas ajustée. À Nantes, la fréquence de ces sorties augmente après les vacances de Pâques.
- **Grèves** : Les grèves sont de nature et d'ampleur hétérogènes et elles affectent autant la distribution que la collecte de données sur les repas effectivement consommés. Les mouvements sociaux de grande ampleur peuvent en outre affecter la complétude de l'information, avec des saisies partielles ou manquantes pour les périodes concernées.

Identifier les sources et préparer ses données

Il importe de bien comprendre trois circuits interdépendants : le processus de production, la chaîne de décisions et les flux de données (voir la Figure 5 p. 23). Certaines données issues de l'organisme en charge de la restauration sont indispensables :

- Des historiques de fréquentation sur une longue période (au moins 3 ans, idéalement plus de 6 ans). Ces effectifs doivent être désagrégés⁵ à la même maille que celle à laquelle on veut faire des prédictions (au global, par école, par type de convive, par type de menus...).
- Des historiques de prévision par les agents en charge de la restauration scolaire. Cette donnée permet d'apprécier la fiabilité des prédictions du modèle à l'aune des erreurs de prévisions par les agents avec le système en place. Elle alimente une variante du modèle développé par Verteego à l'usage de la cuisine centrale et qui prédit, non pas la fréquentation réelle, mais le nombre de repas que les agents des établissements prévoiront et commanderont pour le jour en question.
- Des menus sur l'ensemble de la période. Les algorithmes tiennent compte de la présence de certains termes dans les menus qui indiquent la présence de viande, de poisson, de plats végétariens, de pâtisseries, frites, ou autres caractéristiques.
- Les effectifs d'élèves inscrits dans les écoles dont dépendent les restaurants scolaires. Les effectifs varient en cours d'année, et il convient de ne garder qu'une valeur par année et par école, si possible à une date fixe d'une année sur l'autre.
- Les dates des jours ayant fait l'objet d'un préavis de grève. À ce stade, seules les dates sont prises en compte, sans précision sur la nature ou l'ampleur de ces grèves.

D'autres données requises proviennent de sources externes. Elles ont déjà été consolidées dans les outils de modélisation mis à disposition par Nantes, mais elles peuvent le cas échéant être complétées ou mises à jour :

- Dates des fêtes religieuses ;

⁵ Un dit d'une données qu'elle est désagrégée en fonction de plusieurs paramètres lorsqu'on dispose pour chaque combinaison possible des paramètres. Par exemple, prenons un cas avec deux établissements "A" et "B" et deux jours "1" et "2", le nombre de convives est désagrégé par jour et par école si on dispose de 4 valeurs : nombre de convives pour l'établissement A le jour 1, pour l'établissement A le jour 2, pour l'établissement B le jour 1 et pour l'établissement B le jour 2.

- Calendrier des jours fériés ;
- Calendrier historique des vacances scolaires pour l'ensemble de la période d'apprentissage.

D'autres données peuvent être ajoutées afin d'améliorer la fiabilité du modèle, notamment :

- Indicateurs quantitatifs du niveau de vie dans la zone où l'établissement se situe (prix du m² à l'achat ou à la vente dans le quartier, revenu moyen à l'IRIS...)
- Dates et caractéristiques de mouvements sociaux nationaux ;
- Alertes épidémiques ;
- Prévisions météorologiques.

Sur l'ensemble de ces données, des historiques supérieurs à 3 ans sont préférables pour améliorer l'apprentissage et réaliser des simulations afin de tester la fiabilité des résultats. Seules les variables disponibles pour les dates à prédire au moment de la prédiction seront prises en compte. Il est possible de réexécuter ultérieurement les modèles pour ajuster les prédictions une fois que certaines variables sont disponibles (météo, grèves...).

Pour les données issues de l'organisme chargé de la restauration scolaire, il faut bien analyser le cycle de l'information pour recueillir la donnée à l'endroit le plus adapté. Ainsi à Nantes, les informations proviennent d'une application de gestion de la production⁶ et de registres enrichis manuellement sur des tableurs. Nous avons choisi de mobiliser la donnée issue des tableurs, car, elle a été conservée sur une période plus longue (depuis 2010 dans les tableurs, contre 2016 dans l'application), et elle est de meilleure qualité, car bien qu'elle soit extraite de l'application de production, elle est ensuite contrôlée et manuellement corrigée lorsque c'est approprié.

En revanche, le recours à cette donnée fiabilisée dans des tableurs n'a pas permis de tenir compte de certains paramètres pour l'exercice de modélisation prédictive. À la différence de l'application, les registres tenus dans les tableurs ne précisent pas le type de convive (les élèves de maternelles n'ont pas le même grammage que les élémentaires) ni le type de régime (p. ex. avec ou sans porc, menus allergiques...).

⁶ Il s'agit du logiciel Fusion, de l'éditeur Salamandre. Celui-ci enregistre notamment le détail des menus, leur composition détaillée par ingrédient, les commandes fournisseurs et les repas prévus, produits et consommés.

Développer une modélisation fiable

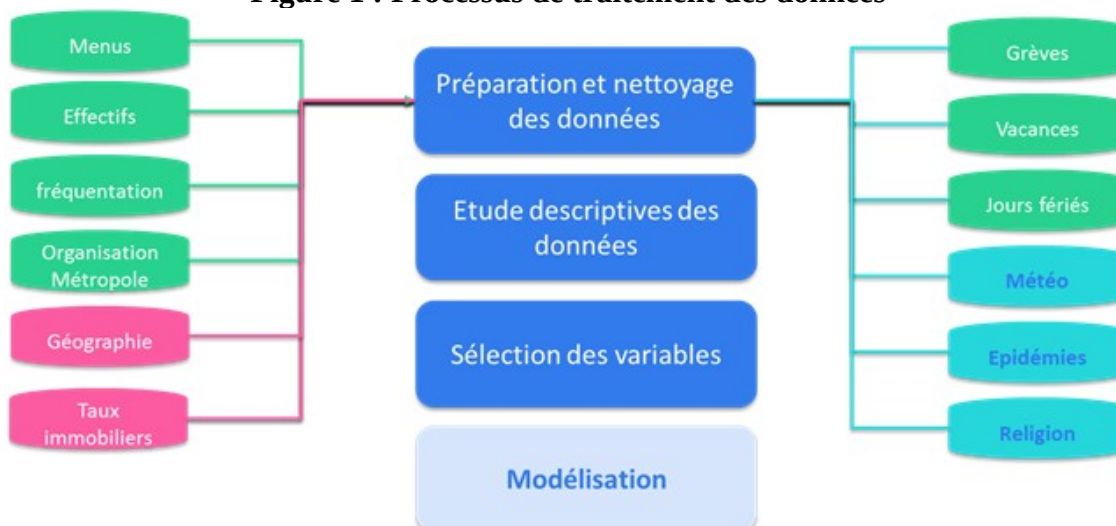
Le principal défi est de parvenir à mettre au point un modèle performant, robuste et interprétable. La performance correspond à la précision des estimations de la fréquentation et le fait qu'elles ne présentent pas de biais. La robustesse du modèle se caractérise par la pérennité de ses performances dans le temps, lorsque de nouvelles données sont acquises. La capacité du modèle à être interprété par les agents est aussi cruciale pour l'adoption de l'outil.

Un modèle prédictif est un modèle qui estime une grandeur (ici la fréquentation des cantines un jour donnée) en fonction de facteurs en entrée (menus, effectifs, période l'année...). De manière simplifiée, il est possible de se représenter ce modèle comme une fonction qui attribue un poids à chacun de ces facteurs explicatifs : ce sont les paramètres du modèle. Pour trouver le modèle optimal, ou en tout cas un modèle performant, la démarche consiste à définir les paramètres qui minimisent l'erreur entre les prédictions et les données réelles de l'historique. La pratique classique consiste à définir ces paramètres sur une partie seulement des données qui sont à disposition, partie que l'on nomme le jeu d'entraînement. Les données restantes servent alors à tester la capacité de généralisation du modèle sur des données qui n'ont pas servi à l'entraînement du modèle (c'est-à-dire à la définition de ses paramètres). On parle de jeu de test. Si les performances sur le jeu de test sont bonnes, alors le modèle est fiable, du moins sur son domaine de validité (cf. la section « Précautions pour la mise en œuvre », p. 21). Il arrive souvent que des modèles soient très précis sur le jeu d'entraînement, mais non performants sur le jeu de test. C'est ce qu'on appelle le surapprentissage. Dans ce cas, le modèle obtenu avec les paramètres minimisant l'erreur surinterprète les données. Il modélise des phénomènes qui sont liés à d'autres facteurs non disponibles ou du bruit, c'est-à-dire des variations qui sont aléatoires. Il ne sera pas performant sur les données de test. Pour éviter ce surapprentissage, sans rentrer dans des détails techniques, on utilise des hyperparamètres qui vont permettre de limiter cette tendance.

Traitement des données

Pour développer un modèle prédictif, il est nécessaire de préparer les données, sélectionner les bons facteurs influençant la grandeur à estimer et tester plusieurs approches, c'est-à-dire plusieurs types de modèles. La démarche suivie pour la métropole est illustrée ci-dessous.

Figure 1 : Processus de traitement des données



Source : présentation remise par Maestria Innovation

Préparation et nettoyage des données

La préparation des données est la partie la plus chronophage de la démarche. Elle consiste à rassembler les données à disposition, aller chercher d'autres données qui permettraient de détecter un facteur impactant la fréquentation et parvenir à les associer. À Nantes, nous avons cherché à vérifier si la fréquentation dépendait de la météo, des grèves, du contexte épidémiologique (grippe, gastro-entérite, varicelle...), de la localisation de l'établissement. À titre d'exemple, la fréquentation dépend significativement de la localisation de l'établissement. Les établissements dans les quartiers centraux ont une fréquentation moyenne élevée et une variabilité autour de cette moyenne faible. Pour les quartiers plus populaires, la fréquentation est beaucoup plus basse et la variabilité beaucoup plus grande.

Généralement, dans cette phase de préparation des données, on rencontre de nombreux problèmes. Dans l'initiative présentée dans le document, les données de fréquentation prévues et réelles provenaient de sources différentes. Ceci a entraîné des doublons dans les observations et un manque d'homogénéité dans les noms des établissements a rendu particulièrement complexe l'association des données de fréquentation des cantines scolaires et les données d'effectif.

De nombreuses analyses sont nécessaires pour nettoyer et explorer les données. Il n'existe pas réellement de méthode générique pour faire ce travail. Néanmoins voici quelques pistes pour ceux qui souhaitent réaliser une démarche similaire :

- Analyses univariées (un seul facteur) de la fréquentation et des facteurs. Ces analyses visent à comprendre la répartition des valeurs des observations (distribution) et identifier d'éventuelles erreurs ou des valeurs extrêmes. On trace généralement un histogramme des données et on calcule des indicateurs statistiques permettant de synthétiser chaque facteur (moyenne, médiane, écart-type...)
- Analyses multivariées (plusieurs facteurs à la fois) des variables explicatives. Ces analyses visent à identifier des corrélations entre les variables explicatives, c'est-à-dire le fait que certaines variables traduisent la même information. À Nantes, il existe une corrélation entre le jour de la semaine et la présence de viande ou de poisson dans le menu. La variable jour de la semaine (lundi, mardi, jeudi ou vendredi) est donc corrélée avec une variable indiquant la présence de poisson ou de viande dans le menu. Utiliser des variables corrélées dans la modélisation nuit aux performances. Il est donc important de les identifier et de construire des variables explicatives peu corrélées entre elles
- Analyses multivariées entre la valeur à estimer et chaque variable explicative. De manière simplifiée, cela consiste à regarder si la moyenne de la valeur à estimer, c'est-à-dire la fréquentation, est impactée lorsqu'on considère certaines sous-catégories des données, et estimer la probabilité que l'effet observé soit lié au hasard (on utilise le Test T de Student indépendant). Ces analyses visent à identifier les facteurs les plus influents. Dans le cas d'une démarche similaire, il est intéressant de conduire ce type d'analyse sur la fréquentation globale, sur la fréquentation de chaque établissement et sur le taux de surproduction (repas produits par jour / effectif réel). Chacune de ces analyses mettra en avant des disparités intéressantes à exploiter pour améliorer les performances des modèles.

Ces analyses visent à identifier les facteurs à considérer. Parmi ceux-ci, certains, comme l'occurrence de grèves, ne pourront être utilisés dans les estimations, car les informations ne seront pas disponibles lorsqu'on fera ces prédictions en conditions opérationnelles. Les facteurs influents

non considérés vont entraîner des variations dans la fréquentation (“bruit”) qui risquent de pousser le modèle à surapprendre. Dans ce contexte, il est nécessaire de sélectionner méthodiquement les données qui serviront à développer le modèle et définir son domaine de validité.

Sélection des données pour la modélisation

L’objectif principal du modèle est donc d’être performant pour les périodes dites “normales”. Pour définir une période normale de l’historique, il y a 3 méthodes possibles :

- Retirer toutes les dates gênantes (grèves...). C’est une manière peu robuste et qui risque de mener à un surapprentissage du modèle. Ce dernier serait difficilement exploitable dans des conditions réelles.
- Retirer l’effet des grèves et des autres facteurs non exploitables en conditions réelles. L’idée est de rendre normales certaines observations pour avoir un jeu de données le plus complet possible. Les périodes de grèves sont les périodes qui posent le plus de problèmes pour la modélisation. Leur impact est potentiellement très fort. Il serait donc intéressant de retirer de toutes les observations concernées par l’effet des grèves. Cependant, nous ne disposons pas suffisamment d’informations sur les grèves pour faire ce travail. Un indicateur sur le taux de gréviste aurait probablement permis de modéliser l’effet de l’ampleur de la grève sur la fréquentation réelle. Il serait néanmoins intéressant, par la suite, d’enregistrer cette information pour des traitements ultérieurs.
- Utiliser une méthode statistique robuste pour écarter les observations trop « anormales ». Ici, l’idée est d’écarter les observations qui sont le plus éloignées de la moyenne pour chaque année scolaire. À Nantes, nous avons retiré les valeurs extrêmes pour conserver 95% des observations.

Principaux types de modèles et leurs avantages et inconvénients

Un problème central en apprentissage supervisé (modélisation sur la base de données historique) est le surapprentissage. Idéalement, on veut choisir un modèle qui reflète avec précision les régularités dans les données d’apprentissage (celles utilisées pour caler les paramètres du modèle) mais qui se généralise aussi aux données tests (c’est-à-dire les données n’ayant pas servi à la construction du modèle) et également aux nouvelles données (une nouvelle année scolaire dans notre cas). Il est généralement difficile de faire les deux en même temps. Les méthodes d’apprentissage avec une variance élevée (reposant sur un modèle complexe) peuvent assez bien représenter l’échantillon d’apprentissage, mais présentent un risque accru de surapprentissage. En revanche, les algorithmes avec une variance faible produisent généralement des modèles plus simples qui présentent moins de risques de surapprentissage. Ils peuvent cependant être en sous-apprentissage, c’est-à-dire qu’ils omettent des paramètres qui influent sur ce qu’on essaye de prédire. Le défi est donc de trouver le modèle qui réalise le meilleur compromis en testant plusieurs approches. Voici les catégories de modèles testés dans l’initiative avec leurs avantages et inconvénients.

Modèle de séries temporelles

Dans le projet, Verteego a notamment testé des approches autour des séries temporelles. Les séries temporelles sont des suites de valeurs numériques qui représentent une évolution au cours du temps. Dans la génération de prédictions statistiques, elles servent, tout comme les autres types de données, à comprendre une temporalité passée et, ainsi, prévoir une tendance future.

Pour réaliser ces tâches, les spécialistes de la prévision utilisent notamment Prophet, une librairie logicielle open source développée à la base pour analyser l'évolution du nombre de clics sur des pages web, mais qui s'adapte très bien à d'autres usages⁷. L'avantage de ce type de modèles est qu'ils sont faciles à mettre en œuvre à partir de données historiques. Néanmoins ces modèles peuvent être difficiles à interpréter. Dans ce projet, l'approche s'est révélée intéressante. Cependant, il a été compliqué d'ajouter des variables externes non temporelles dans le modèle. En effet, les données rattachées aux différentes cantines ne prennent pas place dans la même série temporelle, les rendant alors plus complexes à utiliser et à maîtriser pour des non-spécialistes. Par ailleurs, l'approche apparaissait plus coûteuse en temps de calcul puisque cette modélisation demandait d'entraîner un modèle par série temporelle, chacune rattachée à une cantine.

Modèle de régression

La deuxième catégorie de modèles de prévision utilisée pour ce projet a été les modèles de régression. En mathématiques, la régression désigne des méthodes d'analyse statistique qui permettent d'estimer une variable à partir de facteurs qui lui sont corrélés.

Dans cette catégorie, il existe de nombreux algorithmes qui peuvent être utilisés et qui sont plus ou moins complexes (régression linéaire, régression non linéaire, forêts d'arbres aléatoires, XGBoost, réseaux de neurones...). Il est à noter que plus le modèle est complexe, plus il sera difficile à interpréter pour les agents (voir la section Éclairer l'interprétation, p. 25). Parmi ces algorithmes, il est possible de différencier 2 approches :

- Celles qui nécessitent de prendre des hypothèses sur la forme du modèle et du type de corrélation (linéaire ou non linéaire) avec les facteurs explicatifs ; et
- celles où ce n'est pas nécessaire, car l'algorithme identifie seul les relations.

La première approche, qui est utilisée notamment en économétrie⁸, nécessite de conduire de nombreuses analyses pour déterminer les bonnes hypothèses. Elle présente l'avantage d'être parfaitement interprétable, mais elle peut ne pas être suffisamment performante pour certains cas d'usage. La seconde est plus simple à tester, fonctionnera dans une grande majorité des cas, mais elle peut avoir tendance au sur apprentissage et à être moins interprétable.

Dans le cadre du projet, Maestia Innovation s'est concentré sur la première approche. L'équipe a utilisé des régressions linéaires en s'appuyant sur une démarche économétrique pour analyser le phénomène. Le parti pris a été de s'appuyer sur les observations des agents de restauration pour déterminer les hypothèses initiales et construire un modèle directement interprétable par les futurs utilisateurs.

L'équipe de Verteego, quant à elle, a investigué la deuxième approche en s'appuyant notamment sur l'algorithme XGBoost, une référence dans les modèles de régression. Il s'agit d'une implémentation des techniques d'optimisation de gradient afin d'aider l'algorithme à capitaliser par rapport aux exécutions précédentes en travaillant de manière séquentielle.

L'implémentation choisie de ce modèle est facilement interprétable, car ce dernier se base sur des arbres de décision. XGBoost permet de réaliser une prédiction de la valeur étudiée. Par ailleurs, une

⁷ Nantes Métropole l'utilise notamment pour détecter des anomalies sur des compteurs vélos : https://data.nantesmetropole.fr/api/datasets/1.0/244400404_comptages-velo-nantes-metropole-historique-jour/attachments/comptages_velo_anomalies_et_donnees_ajustees_rapport_pdf/

⁸ L'économétrie est une discipline au croisement de la science économique et des statistiques appliquées qui se concentre sur le développement de méthodes statistiques visant à établir des méthodes d'analyse statistiques pour estimer des relations causales, tester des théories économiques et évaluer ou aider à la mise en œuvre de politiques publiques. Définition librement adaptée de Wooldridge Jeffrey (2012) : *Introductory Econometrics*, Cengage, p. 1.

déclinaison est également proposée dans cet outil afin d'assurer une prédiction d'intervalle de confiance⁹.

En utilisant ce type de modèle dans ce projet, les équipes techniques de Verteego ont utilisé leur expérience et mis en place des stratégies d'ajustement d'hyperparamètres plus poussées. Dans le domaine de l'apprentissage automatique, les hyperparamètres sont des paramètres fixes, déterminés en amont du projet et qui vont définir la manière dont le processus d'apprentissage sera organisé. Il a donc été choisi, pour ce projet, un groupe de paramètres optimaux pour faire fonctionner le modèle XGBoost s'appuyant sur des arbres de décisions. Ces paramètres sont les suivants : le nombre d'arbres, la profondeur des arbres, mais également le nombre d'individus par feuilles ou d'autres paramètres plus spécifiques.

Afin d'éviter le phénomène de sur apprentissage des modèles, c'est-à-dire d'entraîner des arbres trop spécifiques aux données utilisées et n'arrivant plus à se généraliser aux données d'évaluation, une stratégie classique d'interruption précoce a été mise en place. Cette technique permet d'arrêter l'entraînement de nouveaux arbres lorsque l'algorithme constate que l'amélioration que ceux-ci permettent sur un jeu de données de test n'est pas suffisante. Par ailleurs, des courbes tracées permettront, lors de l'entraînement, à des personnes familières de ce type de problème, de contrôler plus facilement le phénomène. De plus, les équipes techniques ont mis en place l'interprétation des modèles entraînés. En d'autres mots, le modèle construit rend possible l'identification des degrés d'importance des variables dans les données utilisées.

L'utilisation de XGBoost, dans la génération de prédictions des repas des cantines de Nantes Métropole, a donc permis de trouver un compromis intéressant entre la rapidité d'entraînement, les performances attendues et l'interprétabilité des résultats.

L'exemple des modèles développés à Nantes

Maestria a développé deux modèles, tous deux fondés sur des régressions. Le premier ne prédit la fréquentation qu'au niveau global, c'est-à-dire la fréquentation totale pour l'ensemble des établissements un jour donné. Le second prédit la fréquentation établissement pour chaque établissement un jour donné. Verteego a développé deux modèles : un modèle d'optimisation de gradient (XGBoost) et un modèle de séries temporelles (Prophet). Ces deux modèles sont appliqués pour prédire la fréquentation réelle des établissements, mais une variante consiste à les utiliser pour prédire la fréquentation prévue des établissements, c'est-à-dire le nombre de repas que les agents des établissements prévoient et commanderont pour le jour en question.

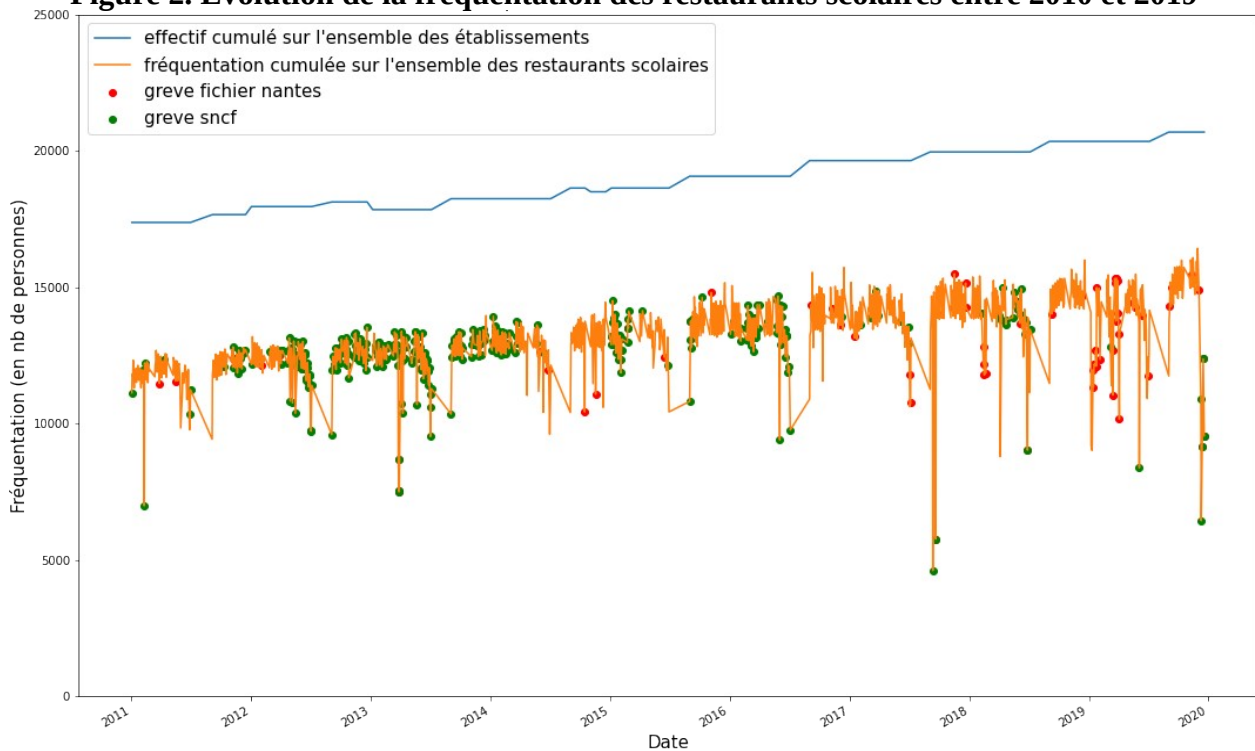
Modèle de fréquentation global élaboré par Maestria

Comme il est possible de le voir sur la Figure 2 à la page suivante, la fréquentation suit l'évolution de l'effectif global. Il y a donc un effet d'échelle. Pour modéliser la fréquentation, l'équipe de Maestria Innovation a opté pour un modèle économétrique où chaque effet indépendant est cumulé pour obtenir l'estimation. Chaque effet est exprimé en pourcentage de l'effectif. Après plusieurs tests, l'équipe s'est arrêtée sur le modèle suivant qui donne de bons résultats.

$$\text{Réal} = a_{\text{eff}} * \text{effectif} + a_{\text{repas-noel}} * \text{effectif} + a_{\text{derniers_jours}} * \text{effectif} + a_{\text{lundi_sans_poisson}} * \text{effectif} + a_{\text{lundi_avec_poisson}} * \text{effectif} + a_{\text{mardi_sans_poisson}} * \text{effectif} + a_{\text{jeudi_avec_poisson}} * \text{effectif} + a_{\text{jeudi_sans_poisson}} * \text{effectif} + a_{\text{mois_1}} * \text{effectif} + \dots + a_{\text{mois_12}} * \text{effectif}$$

⁹ Pour plus d'information sur l'utilisation des intervalles de confiance avec XGBoost, voir [Saupin 2020](#).

Figure 2. Evolution de la fréquentation des restaurants scolaires entre 2010 et 2019



Source : rapport d'analyse de Maestria Innovation

Le jour de référence est un vendredi, jour du poisson, du mois de juin. Tous les autres effets s'ajoutent par rapport à cette référence. Les facteurs sont construits pour être indépendants entre-eux et ainsi éviter les co-corrélations. C'est pourquoi il est distingué les jours avec ou sans poisson. De plus, un effet pour chaque mois est considéré.

Modèle de fréquentation par établissement élaboré par Maestria

Afin de modéliser la fréquentation par établissement, l'équipe a choisi dans un premier temps de conserver les mêmes variables que pour le modèle global, mais d'entraîner un modèle par établissement afin de capter au mieux les spécificités de chaque établissement. En l'état cette approche permettrait d'améliorer le gaspillage sur une vingtaine d'établissements. Par manque de temps, l'équipe n'a pas pu affiner les modèles. Cependant ce travail très prometteur pourra se poursuivre notamment :

- En utilisant des facteurs spécifiques par quartier. Certains effets sont plus ou moins significatifs selon le quartier.
- En construisant un modèle permettant d'évaluer la contribution de chaque établissement à la prédiction du modèle global.

Les modèles de Verteego et leurs variantes

Les deux modèles développés par Verteego (XGBoost et Prophet) peuvent être appliqués selon deux variantes. En effet, suite aux échanges avec les différentes équipes métiers, Verteego a constaté que les quantités de repas renseignées par les responsables de cantines correspondent aux quantités à honorer par la cuisine centrale. Or, les responsables de cantines prévoient souvent plus de repas que nécessaire pour ne pas être en rupture. En effet, il est indispensable que chaque élève inscrit à la

cantine puisse avoir un repas. Ainsi, la quantité réelle de repas consommés est souvent inférieure au nombre de repas préparés par la cuisine centrale.

Pour que sa modélisation soit utilisable par les équipes, Verteego a proposé deux variantes complémentaires, permettant la cohabitation des deux estimations : une prédiction des repas prévus par les responsables de cantine, et une prédiction des quantités de repas réellement consommés.

Variante 1 : Prédiction des nombre de repas prévus par les responsables de cantine

Cette première variante est entraînée grâce aux données représentant le nombre de repas prévus par les responsables de cantine. Les résultats de ce modèle servent donc directement le responsable logistique de la cuisine centrale, qui a une estimation du nombre de repas à prévoir deux à trois semaines avant de recevoir les commandes issues des établissements. La précision de ce modèle peut être directement mesurée en comparant les résultats obtenus avec les prévisions globales du responsable logistique (hors jours particuliers).

Variante 2 : Prédiction des nombre de repas réellement consommés

Une seconde variante consiste à entraîner le modèle grâce aux données représentant le nombre réel d'élèves ayant déjeuné à la cantine. Les résultats de ce modèle ne pourront pas, dans un premier temps, être utilisés, car ils viendraient perturber et rendre incohérents les résultats issus de la première variante. Toutefois, il est intéressant d'utiliser cette variante car elle peut, à court terme, aider les responsables de cantine à mieux anticiper les événements particuliers grâce à l'importance des variables du modèle (prise en compte des jours particuliers). À long terme, cette seconde variante pourrait se substituer à la première.

Évaluation de la performance des modèles


Pour jauger la fiabilité de chaque modèle, on prend comme base d'apprentissage les données réelles des années scolaires 2011-2012 à 2017-2018, puis on réalise des prédictions pour l'année scolaire 2018-2019. Les prédictions sont réalisées par itérations successives : on prédit la fréquentation pour la période entre les vacances d'été et les vacances de la Toussaint, qu'on compare aux données réelles. Puis on ajoute les données réelles été-Toussaint à la base d'apprentissage et on prédit la fréquentation pour la période entre les vacances de la Toussaint et Noël, et ainsi de suite. Une fois les prédictions générées, on calcule les écarts avec les données réelles. Ces écarts correspondent aux erreurs de prédiction issues du modèle. Ils sont comparés aux erreurs de prédiction qu'avaient faites les agents en réalisant leurs prévisions sur cette même période.

Les écarts ont une signification différente selon qu'ils se produisent au niveau d'un établissement ou au niveau global (somme des écarts pour tous les établissements sur un même jour). Si l'écart est négatif au niveau global, alors suivre le modèle induit une sous-production au niveau de la cuisine centrale, c'est-à-dire qu'il s manque des repas pour les convives. Il faut alors pallier au manque en utilisant les repas de secours (plats longue conservation disponibles au niveau des établissements ou à la cuisine centrale) ou en partageant les repas produits. Si l'écart est positif au niveau global, alors le modèle induit une surproduction (des repas sont gaspillés s'ils ne sont pas donnés à des associations). Au niveau global, on doit minimiser le risque de sous-production (l'engagement prioritaire du service public est d'avoir assez à manger pour tous les convives), tout en limitant la surproduction. Au niveau des établissements, une erreur négative signifie qu'un nombre insuffisant de repas sera livré et que les équipes de livraisons risquent d'avoir à réaliser des trajets supplémentaires pour rapatrier des repas dans des établissements où des repas en trop ont été remis.

On cherche donc à limiter les sous-estimations au niveau des établissements, mais ce souci est moins impérieux qu’au niveau global.

Lors de l’évaluation des modèles, il faut bien tenir compte qu’un même modèle peut faire l’objet de réglages différents. Un paramètre crucial est l’intervalle de confiance, c’est-à-dire la probabilité que l’on admet pour qu’un résultat négatif survienne : sans spécifier d’intervalle de confiance, on aura la même probabilité de sous-estimations que de sur-estimation. Avec un intervalle de confiance de 90 %, la probabilité de sous-estimation passe à 10 %. Le graphique suivant illustre l’influence de ce paramètre sur les résultats produits par le modèle XGBoost de Verteego.

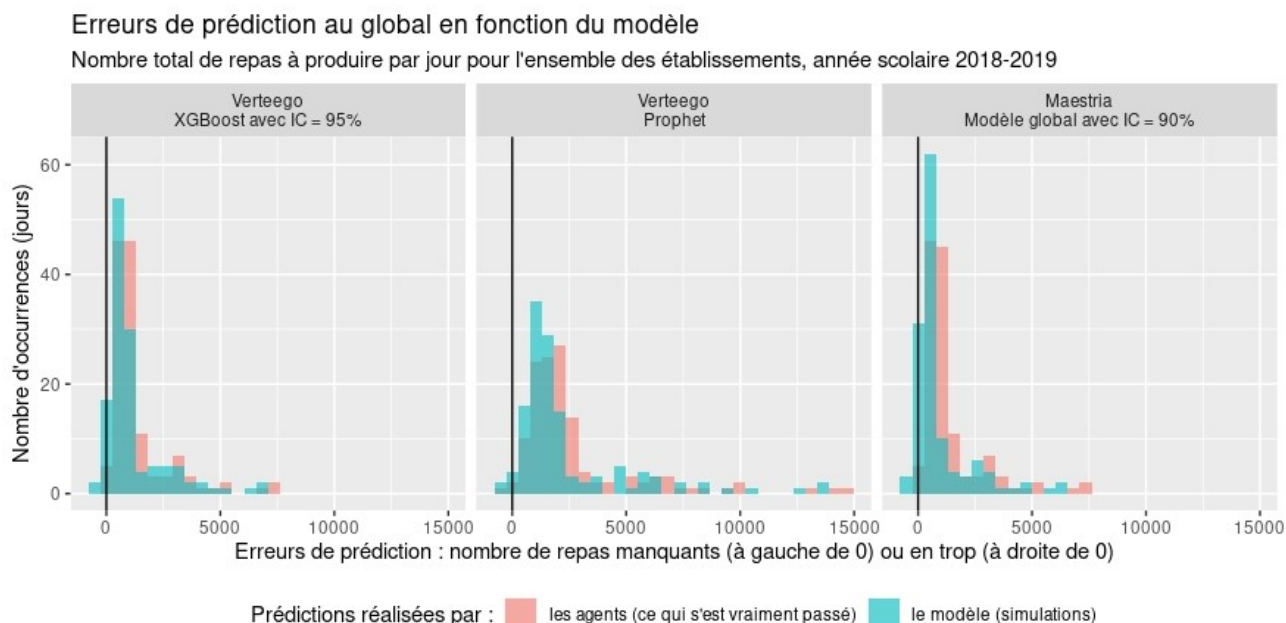
Figure 3. Influence de l’intervalle de confiance sur les résultats



La Figure 3 représente les erreurs d’estimation au global induite par un même modèle (XGBoost), avec des intervalles de confiance différents. Le modèle sans intervalle de confiance produit des résultats apparemment excellents en moyenne (1,7 % de surproduction), mais en le suivant, on aurait manqué de nourriture pour les enfants 89 jours sur les 131 jours de services dans l’année, dont 47 jours pour lesquels il manque plus de 300 repas. Cette option n’est donc pas acceptable. On doit spécifier un intervalle de confiance pour réduire le risque de sous-évaluation, mais un intervalle de confiance trop élevé amène à faire des choix plus conservateurs que les agents et à augmenter le gaspillage. Avec un intervalle de confiance de 99 %, le risque de sous-production est presque nul, mais au prix d’une surproduction de 13,3 %, contre 9,6 % avec les prédictions effectivement réalisées par les agents pour la même année.

Sur cette base, on retient un indice de confiance de 90 % pour le modèle de XGBoost. On compare dans le graphique suivant la performance des principaux modèles pour prédire la fréquentation réelle.

Figure 4. Précision des modèles pour prédire la fréquentation réelle



On constate sur la Figure 4 que le modèle Prophet est peu performant et rencontre sans doute des anomalies de fonctionnement (surévaluations très importantes). Le modèle XGBoost associé à un intervalle de confiance de 90 % induit une surproduction moyenne de 6,6 %. On relève encore 17 jours de sous-production avec ce modèle, dont 5 jours avec plus de 300 repas manquants. Toutefois, après analyse, les sous-productions substantielles sont toutes dues à des anomalies dans le prétraitement des données : certains menus étaient classés par erreur comme "avec viande", alors qu'ils étaient "végétarien" ou avec "poisson". Dans ces cas, bien identifiés, le modèle n'anticipe pas la hausse de fréquentation induite par l'offre d'un menu végétarien (environ 400 convives additionnels) ou d'un menu incluant du poisson (environ 800 convives additionnels). Ces erreurs de prétraitement seront rectifiées par l'application d'un correctif dans le code source. Le modèle global élaboré par Maestria Innovation associé à un intervalle de confiance de 90 % réduit la surproduction moyenne à 6,5 %, avec 8 jours de sousproduction, dont 3 avec plus de 300 repas manquants. Là encore, il s'agit de jours où des repas végétariens ont été offerts et pour lesquels le prétraitement des données n'a pas identifié cette particularité. Cette lacune dans le prétraitement fera aussi l'objet d'un correctif qui améliorera la fiabilité et évitera ces « accidents » de prédiction.

Précautions pour la mise en œuvre

Domaine de validité des modèles

Un modèle performant parvient à intégrer les informations contenues dans les données de l'historique. Néanmoins, il ne peut pas intégrer des informations qui n'y sont pas. C'est le cas dans notre contexte où on ne peut pas considérer certains facteurs influents (jour de grève, sortie scolaire, météo...). Il ne sera pertinent que sur les périodes dites "normales" évoquées plus haut. De manière équivalente, si pour un des facteurs utilisés dans le modèle, une nouvelle observation est significativement différente de celles observées dans l'historique, le modèle ne sera plus dans son domaine de validité. D'où la nécessité de garder du recul par rapport au modèle et de se réinterroger sur sa validité à chaque changement significatif (voir « Supervision » ci-dessous).

Par ailleurs, certains effets ont tendance à évoluer dans le temps. Ce sont les usages des familles qui évoluent. Par exemple, la fréquentation et l'impact du poisson dans le menu ont tendance à augmenter avec le temps. Pour bien capter ces évolutions, il est nécessaire d'entraîner un modèle sur un historique peu profond. En conditions réelles, il sera donc nécessaire de le faire sur une fenêtre temporelle glissante afin que le modèle suive les évolutions des usages. En revanche, pour certains effets, nous avons très peu d'observations. C'est le cas pour les repas de Noël et les derniers jours de l'année qui sont des facteurs rares, mais influents sur la fréquentation. Si l'historique servant à l'entraînement considéré n'est pas assez profond, il sera difficile de bien décrire ces effets. Empiriquement, on observe qu'une fenêtre glissante de 3 ans d'historique semble être un bon compromis.

Une autre illustration de ce point correspond aux jours de production qui se trouvent entre un jour férié et un week-end. Sur ces jours la fréquentation chute de 20%. Cependant, nous n'avons que deux observations sur les dix ans d'historique. Il n'est pas pertinent d'en faire une variable de notre modèle, mais cela peut faire l'objet de corrections humaines et devenir une "règle métier".

Supervision

Les périodes de forts changements dans l'organisation, comme le confinement lié à la crise sanitaire de la COVID 19, sont à prendre en compte. Elles peuvent être source de modification ou d'adaptation des paramètres des modèles. Au cours de ce projet, il n'a pas été possible d'entraîner les modèles sur la période du premier confinement, à partir de mars 2020. En effet, cette période, spécifique par le bouleversement qu'elle a engendré dans la distribution des repas et la fréquentation des écoles, a pour l'instant été mise à l'écart de cette étude. La supervision pourra également faire l'objet d'une réflexion, sur les prochaines phases d'utilisation du modèle selon l'évolution des performances, suite aux réentraînements. Le suivi des performances du modèle doit être corrélé avec la configuration de ce dernier. Il est recommandé d'utiliser un outil permettant une visualisation précise et globale des prédictions et de leurs écarts avec la réalité.

Phase de test

Lors de tout projet d'apprentissage automatique, une phase de test en situation réelle est primordiale. Celle-ci permet de confronter les résultats du modèle aux nouvelles données créées et de mesurer la performance du modèle construit. En complément, cette phase permet d'identifier des pistes d'améliorations sur les cas de figure où le modèle est moins performant. Par exemple, dans notre cas, nous pourrions faire un travail d'approfondissement sur des situations spéciales et isolées (jours particuliers, événements impromptus ...) et étudier le comportement du modèle afin de corriger les possibles erreurs.

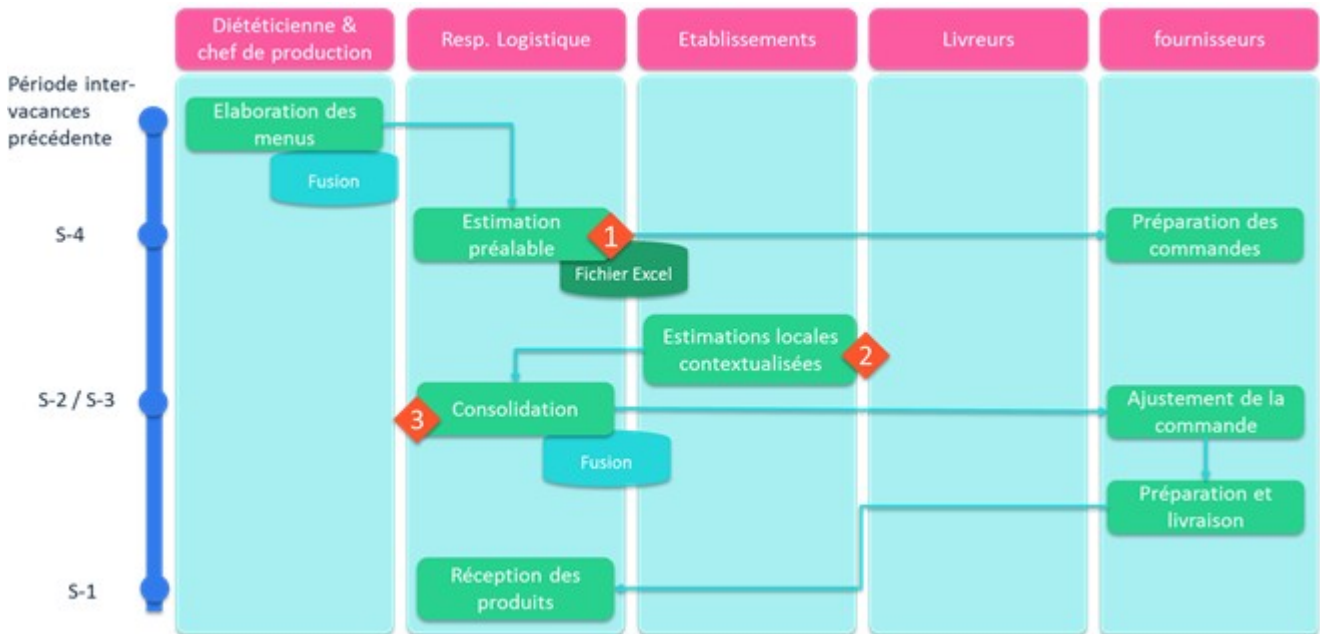
Accompagner l'appropriation par le service public

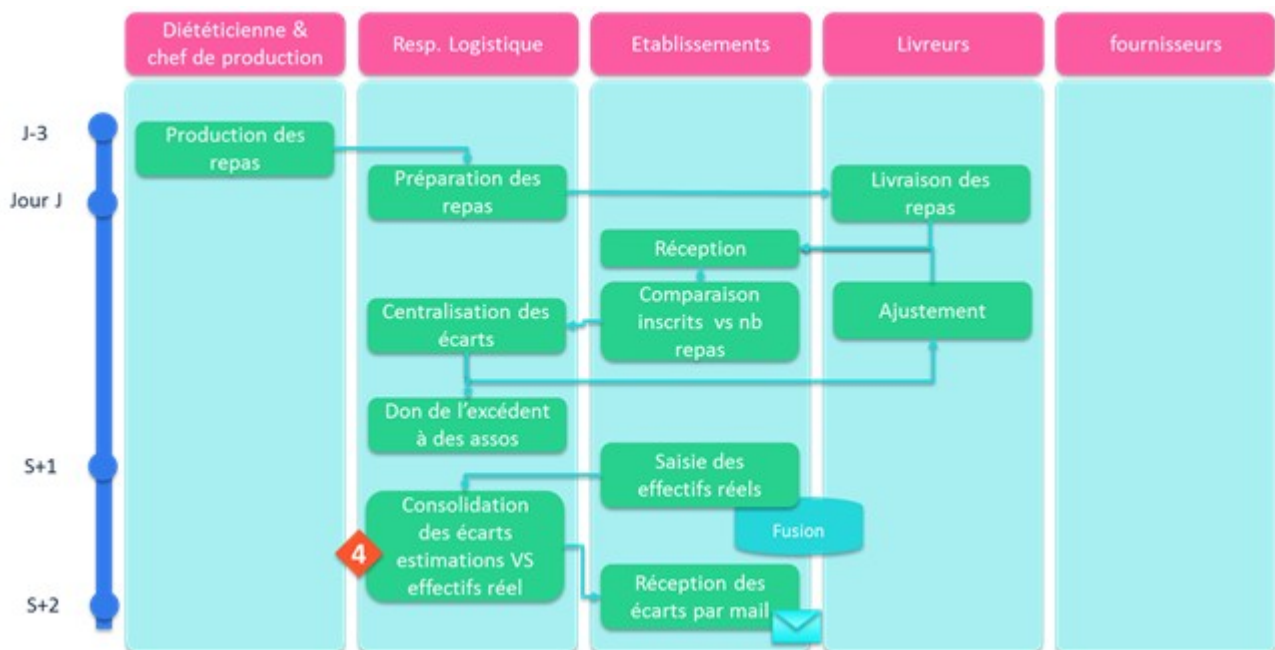
L'enquête terrain réalisée, notamment les entretiens avec les ATR, indique que l'enjeu majeur, pour que le projet passe le stade de l'expérimentation, est l'adoption de l'outil par les futurs utilisateurs. Il est d'ailleurs souvent observé dans les projets d'IA que des algorithmes, dont la valeur ajoutée a pourtant été démontrée, ne soient finalement pas utilisés par manque de compréhension ou de confiance de la part des utilisateurs. Pour favoriser la confiance, il est nécessaire de travailler sur les axes décrits ci-après.

S'adapter au processus actuel

Le travail technique de modélisation statistique n'est utile que s'il peut être exploité dans le processus actuel. Dans la démarche, il est donc important en amont du travail de modélisation de comprendre de manière détaillée le fonctionnement en place et d'identifier les moments clés où un outil statistique peut apporter une aide. Ce travail permet de comprendre, en conditions réelles, les données qui seront disponibles pour faire les estimations. En effet, plusieurs facteurs déterminants (météo, grèves...) ne sont connus que très peu de temps avant le repas et, par conséquent, ils ne peuvent être utilisés dans les estimations réalisées pour les commandes de matières premières. Pour que le modèle statistique soit exploitable, il doit se trouver dans les mêmes conditions que les estimations du processus actuel. À Nantes, le processus de planification et de suivi de la production des repas peut être représenté de la manière suivante.

Figure 5 : processus de planification et suivi de la production des repas





Source : présentation de restitution par Maestria Innovation. Les entêtes de colonnes indiquent les acteurs mobilisés ; l'axe vertical à gauche du graphique indique la position de chaque étape par rapport au jour de consommation (S = semaine et J = jour) ; les blocs verts indiquent les étapes du processus de planification, réalisation et suivi de la production ; les blocs bleus indiquent les outils numériques utilisés ; les losanges orange indiquent les étapes auxquelles les outils de modélisation peuvent être utilisés.

Les quatre losanges mis en évidence en orange sur le schéma représentent les étapes auxquelles des interactions peuvent être développées entre l'outil de modélisation prédictive et le processus de préparation des repas de la cuisine centrale à Nantes. Une fois les menus pour une période intervacances validés par la commission de restauration, ils sont transmis au responsable logistique. Celui-ci réalise des estimations globales de la fréquentation attendue et passe ses commandes auprès des fournisseurs locaux environ un mois à l'avance. Deux à trois semaines avant le jour du repas, les établissements transmettent leur commande de repas à partir de leur propre estimation. La consolidation des commandes permet de déterminer si un ajustement des commandes fournisseurs est nécessaire. Sur ces deux types d'estimation (au niveau global et par établissement), l'outil de modélisation prédictive pourrait permettre de fiabiliser le processus et réduire la surproduction (losanges « 1 », « 2 » et « 3 »). Par ailleurs, après le jour J, lors de la saisie de la fréquentation réelle, l'outil permettrait de récupérer de nouvelles données, d'analyser les écarts et d'actualiser la calibration des modèles statistiques (losange « 4 »). Une collectivité qui souhaiterait adopter des outils de modélisation prédictive devrait réaliser une analyse similaire.

Cette phase d'analyse du processus existant pourrait en outre être une opportunité pour revoir le processus en place et s'interroger sur les optimisations possibles. Par exemple, à Nantes, faire en sorte que les établissements passent leur commande plus en amont, au niveau des estimations préalables du responsable logistique, permettrait d'éviter d'avoir à ajuster les commandes. Cependant, cette anticipation peut dégrader la qualité des estimations des établissements. En revanche, si ces estimations sont aidées d'un outil statistique qui intègre bien les effets de saisonnalité, cette anticipation serait tout à fait pertinente.

Éclairer l'interprétation

On est confronté à un dilemme : les modèles les plus complexes tendent à être plus fiables, mais leurs résultats sont très difficilement interprétables : l'utilisateur est rarement certain de comprendre les paramètres qui ont déterminé le résultat prédit (phénomène de « boîte noire »). De plus, plus un modèle est complexe, plus il est difficile pour les utilisateurs de contrôler les phénomènes de dérive qui pourraient apparaître. En effet si l'utilisateur éprouve des difficultés à comprendre les paramètres qui influencent les prédictions, il ne sera pas capable de détecter les cas où le modèle dérive ou sort de son domaine de validité. Un modèle difficilement interprétable qui se mettrait à diverger lors d'une utilisation en conditions réelles entraînerait un rejet immédiat des utilisateurs. De plus, en conditions réelles, lors des estimations des fréquentations qui ont lieu plusieurs semaines avant le jour du repas, il y a plusieurs facteurs déterminants qui ne sont pas connus (jour de grève, météo, sorties scolaires non anticipées...). Il est donc préférable de modéliser des effets indépendants qui ont été observés sur le terrain. De ce fait, les utilisateurs n'auront pas de mal à se les approprier et le modèle sera plus robuste.

Si cette approche de modélisation ne se révèle néanmoins pas suffisamment performante et que le développement d'une IA « boîte-noire » s'avère indispensable, il sera alors nécessaire d'y adosser des modèles plus simples qui permettront de la rendre interprétable¹⁰.

Accompagner l'adoption

Les principaux leviers pour faciliter l'adoption et conduire le changement sont l'implication des utilisateurs, la communication tout au long du projet, la formation et le support à l'utilisation. L'approche idéale pour obtenir l'implication des utilisateurs consiste à les associer à la conception de l'outil, afin que l'outil tienne compte des besoins des utilisateurs et que les utilisateurs s'approprient l'outil. Cette co-construction facilite et accélère la mise en service de l'outil.

Pour animer ces ateliers, une bonne pratique consiste à rendre concrets les échanges avec des maquettes ou une première version d'application. Cela aide les utilisateurs à se projeter. L'application développée dans l'initiative nantaise pourrait d'ailleurs être utilisée comme base de discussion dans une autre démarche. Une co-construction en plusieurs itérations permet de développer des fonctionnalités qui répondront à des besoins réels et un outil qui sera adapté au contexte. Plus l'outil apportera de solutions concrètes aux problématiques terrain, plus l'adoption sera facile. Il ne faut donc pas hésiter à étendre le périmètre fonctionnel de l'outil, si cela peut aider l'adoption.

Dans le contexte nantais, nous avons par exemple identifié qu'une fonctionnalité permettant de récolter des informations du terrain sur les restes d'assiettes était particulièrement souhaitée.

Il a été choisi de développer une application de type « Progressive Web Application » qui s'adapte à tout type de support (PC, tablette, smartphone...). Ce type d'application a l'avantage de faciliter le déploiement à partir d'une simple URL. Les agents équipés pourraient ainsi utiliser simplement l'application sur tout type d'appareil connecté. Pour les établissements non équipés ou sans WIFI, l'utilisation du smartphone du cadre de proximité pourrait être envisagée. De plus, ce déploiement

¹⁰ Pour plus de détail sur les méthodes qui permettent favoriser l'interprétabilité, voir : Poissonnier Thibault, L'introduction de modèles d'apprentissage automatique complexes, Tribune expert, Avisia, www.avisia.fr/news/tribune-expert/interprete-modes-machine-learning/

pourrait s'envisager sous la forme d'une expérimentation dans quelques établissements en premier lieu.

Cibler d'autres facteurs du gaspillage (grammage, menus)

Un besoin prégnant remonté en interne concerne les restes d'assiettes. Dans son étude sur les pertes et gaspillages alimentaires (Vernier, 2016), l'ADEME évalue qu'en restauration collective plus de la moitié du gaspillage alimentaire est généré par les restes d'assiettes.

Table 1 : Pertes et gaspillages alimentaires dans la restauration collective en France

| | Estimation d'acteur* | Mesure réalisée** |
|--------------------------------------|----------------------|-------------------|
| Produits périmés ou abîmés | 2% | 3% |
| Produits préparés mais non consommés | 2% | 5% |
| Restes d'assiettes | 5% | 12% |
| Total pertes et gaspillages | 9% | 20% |

Source : Vernier, 2016, p. 136 ; Données collectées dans 21 établissements de restauration collective dont 8 dans l'enseignement.* : moyenne des estimations rapportées par une personne ressource dans chaque établissements ; ** mesures réalisées sur 4 jours.

Il y a donc un enjeu important à concevoir des menus générant le moins de restes possible tout en respectant les pratiques diététiques. Ces restes peuvent être engendrés par des grammages non adaptés ou par le rejet de certains aliments par les enfants. Actuellement des enquêtes sur les menus sont réalisées ponctuellement. Cependant, cela ne permet pas d'obtenir suffisamment d'informations détaillées. La consolidation progressive d'une base de données sur tous les repas serait donc un levier important pour réduire le gaspillage alimentaire. En exploitant cette base, la cuisine centrale pourrait adapter ces menus. La maquette ci-dessous illustre la fonctionnalité que pourraient utiliser les agents de restauration lors de la saisie de la fréquentation réelle. Comme évoqué plus haut, cette fonctionnalité attendue par les utilisateurs serait un atout à exploiter pour faciliter l'adoption du projet.

Une fois la base de données constituée, des algorithmes d'IA pourraient être développés pour aider la cuisine centrale à comprendre les facteurs engendrant le gaspillage et même à le prédire pour chaque menu. Cette évolution permettrait donc de rendre l'initiative encore plus efficace.

Figure 6 : Onglet de recueil des retours terrain de l'application de suivi développée à Nantes

Source : application développée à Nantes, disponible sur <https://github.com/nantesmetropole>

Pour aller plus loin

Accéder aux outils mis à disposition

Les codes sources des outils mentionnés dans ce document, ainsi que les guides d'installation et d'utilisation sont disponibles sur le portail Github de la collectivité :

<https://github.com/nantesmetropole>

- Outil de modélisation prédictive développé par Verteego :
https://github.com/nantesmetropole/school_meal_forecast_xgboost
- Outil de modélisation prédictive développé par Maestria :
https://github.com/nantesmetropole/school_meal_forecast_regressions
- Prototype d'application utilisateur pour les agents de la restauration développée par Maestria : <https://github.com/nantesmetropole/school-catering-feedback-app>

Les données brutes utilisées pour réaliser les modélisations à Nantes sur les années 2010 à 2019 sont disponibles sur le portail open data de Nantes Métropole : <https://data.nantesmetropole.fr>

De futures versions actualisées du présent rapport peut être téléchargé à l'adresse suivante :

https://data.nantesmetropole.fr/explore/dataset/244400404_nombre-convives-jour-cantine-nantes-2011/information/

Comment participer

Les acteurs intéressés pour utiliser ces outils ou contribuer à leur développement sont invités à se signaler en ouvrant une "issue" sur le dépôt Github correspondant ou en écrivant à l'équipe data de Nantes Métropole via le formulaire de contact sur la page

<https://data.nantesmetropole.fr/pages/contact/>.

Références

DINUM, 2018 : “Bonnes pratiques”, dans : Politique de contribution aux logiciels libres de l’État, disponible en ligne : <https://www.numerique.gouv.fr/publications/politique-logiciel-libre/pratique/>

Kasy M., Abebe R., 2020 : “Fairness, equality, and power in algorithmic decision making”. *Preprint*, disponible en ligne : https://www.cs.cornell.edu/~red/fairness_equality_power.pdf

NaonedIA, 2018 : “Pour une IA éthique, responsable et populaire”, *Collectif Nantais de l’Intelligence Artificielle pour tous*, disponible en ligne : <http://naonedia.fr/>

Nantes Métropole, 2018 : “Vers un nouveau modèle alimentaire de la Métropole Nantaise”, *Projet Alimentaire Territorial*, disponible en ligne : <https://metropole.nantes.fr/alimentation>

Nantes Métropole, 2019 : “Charte métropolitaine de la donnée”, *Un cadre éthique pour protéger les citoyens et réguler l’utilisation des données sur le territoire*, disponible en ligne : <https://metropole.nantes.fr/charte-donnee>

OECP, 2019: “Guide pratique de l’achat innovant”, *Ministère des Finances*, disponible en ligne : <https://www.economie.gouv.fr/daj/conseil-acheteurs-guides#innov>

Saupin Guillaume (2020) : “Confidence intervals for XGBoost : Building a regularized Quantile Regression objective”, *towards data science*, disponible en ligne : <https://towardsdatascience.com/confidence-intervals-for-xgboost-cac2955a8fde>

Vernier Antoine (coord.), 2016 : “Etat des lieux des masses de gaspillages alimentaires et de sa gestion aux différentes étapes de la chaîne alimentaire”, *Expertises*, ADEME, disponible en ligne : <https://www.ademe.fr/etat-lieux-masses-gaspillages-alimentaires-gestion-differentes-etapes-chaine-alimentaire>

Annexe : résultats des modèles évalués

[Tableau final à inclure]