

JOURNÉE IARD

UTILISATION DE DONNÉES EXTERNES EN MODÉLISATION

29 et 30 mars 2018

Marie-Catherine SARRAUDY
Partner Actuarial Services

Coralie LE PLAT
Manager IARD

Matthieu LAGADEC
Manager IARD

Sommaire

01

Data is everywhere !

02

Mise en pratique de la valorisation des données externes en MRH

03

Quelles utilisations opérationnelles des données externes ?

ANNEXE

La collecte des données externes

Analyse de données externes non structurées





01

Data is everywhere !

Data is everywhere !

Quelques chiffres...



Une tour de DVD de **13 millions de kms de haut**

Réseaux sociaux un des 1^{er} provider de données



De plus en plus de données seront :

- ✓ Collectées
- ✓ Analysées
- ✓ Objectif : partager les données

Créateur de valeur


Dans tous les domaines

Défis pour :

- ✓ Intégrer
- ✓ Analyser
- ✓ Former

Data is everywhere !

Quels types de données nous entourent ?



DONNEES STRUCTUREES

Données contenues dans les champs, identifiables facilement, avec un format prédéfini, une dénomination explicite

Exemples :


- Base de données interne
- Informations externes requêttables



DONNEES INTERNES

Bien souvent non partagées entre services

Notion de DARK DATA : données internes inexploitées




DONNEES NON STRUCTUREES

Données représentées ou stockées sans format prédéfini

Exemples :

- Textuelles : courriels, les présentations PowerPoint, les documents Word,
- Non textuelles : images JPEG, les fichiers audio MP3




DONNEES EXTERNES

- Données publiques (INSEE, data.gouv.fr)
- Données vendues (AAA Data)
- Attention à la réglementation (RGPD, propriété intellectuelle)
- Besoin de moyen technique (SI) et opérationnels (équipes formées) pour les exploiter



Data is everywhere !

Comment les exploiter ? La chaîne de valeur autour de la valorisation de la donnée





Data is everywhere !

Exemples d'applications du couple données externes / machine learning en assurance



GESTION SINISTRE

- Gestion de la fraude
- Amélioration des processus de gestion



MARKETING

- Comportement client
- Reduction du churn
- Géomarketing



ACTUARIAT

- Tarif (sinistres et frais)
- Actifs
- Réassurance
- CAT NAT / Modélisation des risques climatiques
- Indicateurs de pilotage



02

Mise en pratique de la valorisation de
données externes en MRH



Contexte de l'étude - Objectif

Créer, à partir d'arbre de classification, un outil de pilotage de portefeuille permettant de repérer des poches de contrats sous tarifés au sein d'un portefeuille MRH.



MRH



Données externes



CART



Pilotage

Collecte et traitement des données

- Base tarifaire d'un produit MRH
- Ajout de données externes
- Prise en compte d'informations qui ne sont pas incluses dans le tarif

Modélisation

- Application de méthodes de Machine Learning
- Différente mais complémentaire aux GLM

Data visualisation

- Identification des poches de contrats sous-tarifés
- Outil de suivi des résultats


Principe de l'algorithme CART

Principe

1. On part :
 - D'une variable à expliquer : « Etes vous intéressés par cette présentation ? » **Ind. intérêt**
 - De variables explicatives Variable
 - D'un critère / d'une modalité – Exemple avec la durée

2. L'objectif est de **segmenter en regroupant de façon binaire et par étapes** (nœuds) des critères homogènes ensemble (minimisation de la variance inter groupe).
Deux réponses possibles : Oui / Non

3. De nombreuses questions autour de ces arbres :
 - Quand s'arrêter ?
 - Jusqu'à combien de variables explicatives puis-je introduire ?
 - Est-ce robuste ?



Contexte de l'étude – Algorithme CART

Avantages

- ✓ Sélection automatique des variables
- ✓ Identification de phénomènes non identifiés
- ✓ Visualisation simple de l'analyse multivariée
- ✓ Possibilité d'ajuster les métriques (choix parfois complexe)

Inconvénients

- × Un arbre de qualité peut nécessiter de nombreuses branches
- × Interprétation parfois complexe
- × Le modèle peut présenter une certaine instabilité



$\max \left(\left| \frac{S_1}{P_1} - \frac{S_2}{P_2} \right| \right)$: maximisation de l'écart de l'indicateur d'intérêt entre les nœuds fils



Contexte de l'étude – Base de données



BASE MRH



425 000
années polices




**POPULATION DE
RÉSIDENTS**



30
variables
explicatives




1 FORMULE



9 %
avec un sinistre
à charge



3 GARANTIES




100%
S/P indiciel

Sourcing – Données externes

Pour cette étude, la base a été enrichie de données externes :

- Structurées par **Code Postal/Département**
- Créant si possible des **distorsions géographiques**



KelQuartier
Tout sur le quartier d'un bien immobilier





Étapes de travail pour l'élaboration d'un CART



TRAITEMENT DES DONNEES

- Retraitement des variables
- Analyses univariées, corrélations, multivariées

PARAMETRAGE DES MODELES

- Choix des paramètres et méta-paramètres des modèles
- Utilisation de critères d'optimisations applicables



AJOUT DE DONNEES EXTERNES


- Présélection des données à utiliser
- Traitement des données sélectionnées
- Corrélations entre les données internes & externes

ANALYSE DES RESULTATS

- Analyse de l'impact des nouvelles données
- Interprétabilité des résultats



Le pilotage du portefeuille sans données exogènes




Segments déficitaires (5 poches)

- En dehors de la zone 1 et avec antécédents
- Dans la zone 2 et sans antécédent
- En dehors des zones 1, 2 et 3, dans une zone non isolée et avec une prime à fractionnement annuel

Observations

- Un zonier qui apparaît comme le premier élément expliquant la présence de poches sous-tarifées

Le pilotage du portefeuille avec données exogènes




Segments déficitaires (7 poches)

- En dehors de la zone 1
- Avec un nombre de sites SEVESO ≤ 9
- Avec un nombre de logements vacants $\leq 9\%$
- Avec une proportion d'APL $> 74/1000$
- Pour les propriétaires
- Prix moyen $m^2 < 1450 \text{ €}$

Observations

- Un rôle prépondérant des données externes dans l'explication des poches sous-tarifées (5 variables)
- QUID de l'interprétation de la variable SEVESO ? Installations soumises à autorisation ?
- Besoin d'expertise métier !

Le pilotage du portefeuille avec données exogènes & retraitements (expertise métier)



Poches sous tarifées

Variables externes

Variables retirées

- SEVESO
- Installations soumises à autorisation

Même nombres de segments déficitaires (7 poches)

Observations

- Même nouvelles variables externes + 2 nouvelles variables externes (dont une qui ne semble pas expliquer la sous-tarification)



Conclusion de l'étude

1. **Les données externes permettent d'affiner le profil de risque**
2. **L'expertise métier reste indispensable** pour comprendre les interactions de ces nouvelles données dans la modélisation du risque
 - L'algorithme n'est pas auto-suffisant et nécessite une validation des interactions observées entre les variables *a posteriori*
3. **Besoin de temps pour tester la robustesse** de l'approche et aller plus loin (création de nouveaux zoniers ?)
 - Instabilité en termes de classification lors de l'introduction ou de l'exclusion de nouvelles variables
 - Disponibilité des données externes

03

Quelles utilisations opérationnelles des données externes ?

Quelles utilisations opérationnelles ?




Data visualisation & suivi du risque

Visualisation de l'arbre et identification des **poches** dont le S/P est compris entre 2 seuils à fixer

Dynamique et en fonction de :

- La **granularité** souhaitée (garantie / Formule)
- De **données externes** sélectionnées
- Sur une **période** donnée

Permet de fournir un **reporting contrat par contrat** dans les **poches sous tarifées** paramétrées





Quelles utilisations opérationnelles ?




Actions opérationnelles

Détermination des **variables les plus importantes** dans la **segmentation** du portefeuille et celles qui peuvent **expliquer les pertes**


- Revue des règles de souscription
- Revalorisation tarifaire
 - Règles d'action tarifaire si le S/P atteint un certain niveau
- Ajustements des algorithmes tarifaires
 - Intégration dans un GLM ou machine learning

Pilotage



Validation des interactions observées

Ajustements



Actions tarifaires



Règles de souscription



Les ajustements ne doivent être réalisés qu'après la validation des interactions observées sur une période donnée



Quelques *bonnes pratiques* ...pour intégrer au mieux les nouvelles données externes



Fiabiliser l'existant

- Inventorier les **données disponibles** (internes/externes, structurées/non structurées) et traiter les aspects fonctionnels en étroite collaboration avec les métiers.
- **Fiabiliser les données** internes avant d'intégrer des données externes.



Investir dans des infrastructures et notamment des serveurs

- Prévoir un **stockage adapté** (pour des volumes de données en croissance exponentielle, les bases de données...).
- Anticiper les besoins en **performance** (pour le traitement en temps réel et l'accès aux données).



Tester sur un périmètre restreint

- Délimiter un périmètre (marketing, production...) pour réaliser rapidement un ou plusieurs **projets pilotes** ou « **proof of concept** ».



Echanger et challenger

- **Echanger avec les autres métiers** : gestion sinistre, la souscription

ANNEXE

Pour aller plus loin...

Collecte des données externes et
analyse de données non structurées

Collecte de la données externes

Mise en place d'une collecte automatisée : Le Web Scraping

Le **Scraping** est un ensemble de techniques pour extraire le contenu d'un site Web




L'**objectif** est de **transformer les données récupérées** afin de les utiliser en base pour qu'elles soient **analysées**.



Collecte de la données externes

Les étapes pour la mise en place de web scraping





Collecte de la données externes

Attention à la réglementation



Qu'est-il possible de faire aujourd'hui ?

- Scraper en vue de récupérer les données pour les « transformer »

Exemple

- Indice ou intervalle de score de marché pour un benchmark
- Transformation de données de plusieurs assureurs de place pour obtenir un zonier ou un algorithme de tarification marché




Les bonnes pratiques

- Lire les conditions générales d'utilisation
- Ne pas surcharger le site web scrapé
- Ne pas forcer l'accès à certaines données



Analyse de données externes non structurées

La technique du text mining





Analyse de données externes non structurées


Application dans l'analyse des actualités

News	Sentiment
La plus belle pluie d'étoiles filantes de l'année aura lieu cette nuit	1,00
Jean-Michel Blanquer à Millas on va être très attentifs à ce qui se passe pour les enfants ici	1,00
L'écharpe plus indispensable qu'il n'y paraît pour prévenir les crises d'asthme	0,98
Serge Haroche Nobel de physique très surpris et très heureux	0,93
VIDEO SOCIÉTÉ Serge Haroche Nobel de physique très surpris et très heureux	0,93
...	
Une centaine d'œuvres du Caravage auraient été retrouvées	0,00
L'usine PSA d'Aulnay-sous-Bois bloquée par les intérimaires	0,00
Italie une centaine de dessins de jeunesse du Caravage trouvés à Milan	0,00
Les pilotes de Canadair cessent leur grève	0,00
Exclu TV rencontre avec le père d'Amy Winehouse	0,00
...	
Prostitution le PS qualifie le texte adopté au Sénat de régression scandaleuse	-0,80
Le Chilesaurus un dinosaure herbivore vraiment très bizarre	-0,80
Philippot juge scandaleuse une fermeture de ligne de trains	-0,80
VIDEO SOCIÉTÉ Les soldes d'hiver commencent très mal	-1,00
Lyon discours très agressif de Nicolas Sarkozy à l'égard du PS	-1,00




— Analyse de données externes non structurées

Application dans l'assurance



Surveillance

- ✓ Détection de fraude
- ✓ Détection des cyber attaques



**Gestion /
Relation client**

- ✓ Gestion de recouvrement
- ✓ Gestion des sinistres
- ✓ Satisfaction client



Compliance

- ✓ Analyse de la jurisprudence

optimind.

manage risk, build your future



strategy. finance. risk. compliance. market.
human resources. digital transformation. data. bpo.