Mémoire présenté devant le

Conservatoire National des Arts et Métiers

Pour l'obtention du Master Droit, Economie, Gestion mention Actuariat et l'admission à l'Institut des Actuaires

Le mardi 23 novembre 2021

Par : Frédéric Favre

Titre: Utilisation de réseaux bayésiens pour le provisionnement de sinistres en assurance non vie

Confidentialité : ☑ NON ☐ OUI (Durée : ☐ 1 an ☐ 2 ans)

Les signataires s'engagent à respecter la confidentialité indiquée ci-dessus

Membres présents du jury du Conservatoire National des Arts et Métiers

signatures

SANDRINE LEMERY (président du jury)

NATHANAEL ABECERA

OLIVIER DESMETTRE

DAVID FAURE

FRANCOIS WEISS

Membres présents du jury de l'Institut des Actuaires

PIERRE PETAUTON

HELENE GIBELLO

GEORGES LOUIS GONCALVES

Secrétariat

Bibliothèque :

Entreprise : ALLIANZ PARTNERS

Directeur de mémoire en entreprise :

Nom : NEIL CHRISTIE

Autorisation de publication et de mise en ligne sur un site de diffusion de documents actuariels (après expiration de l'éventuel délai de confidentialité)

Invité :

Nom :

Signature du responsable entreprise

Signature du candidat

Mémoire d'actuariat

Utilisation de réseaux bayésiens pour le provisionnement de sinistres en assurance non vie

Favre, Frederic (Allianz Worldwide Partners)

24/03/2019

Résumé (français) : le groupe Allianz Partners impose un processus de provisionnement impliquant une méthode dite « roll forward » pour laquelle il faut estimer les provisions de sinistres de façon trimestrielle, sur la base des données du trimestre précédent. Des réseaux bayésiens peuvent être utilisés pour prédire dans les triangles de développement des paiements, non seulement le premier terme du développement, mais aussi le premier facteur de développement, qui sont tous deux très structurants pour fiabiliser la charge à l'ultime, et aussi par conséquence la valeur du ratio de sinistres sur primes pour l'année comptable. Un enjeu technique particulier dans le cadre de l'acquisition des deux paramètres est le traitement de la saisonnalité à partir de données catégorielles. Les résultats sont concluants puisqu'il y a une amélioration de la méthode DFM (Chain Ladder), sur le périmètre étudié (assistance automobile et assistance voyage), avec un gain moyen de 1,3% observé sur le ratio sinistre sur prime.

Mots clés : Réseaux Bayésiens, Apprentissage automatique (« machine learning »), provisionnement non-vie, saisonnalité

Abstract (English): Allianz Partners Group is applying a « roll forward » methodology in which quarterly reserves are to be calculated based on information that are collected in the former quarter. Bayesian networks can be used to predict more accurate components of some development triangles (not only initial payment for an incident period, but also a first development factor). Those two factors are key to build a reliable ultimate value, which consequently, ensure a better accuracy of the loss ratios. A particular issue was to derivate accurate parameters from categorical inferenced data, but taking into account seasonality. Results are conclusive as experience indicated that for the defined scope (Car Assistance and Travel Assistance), DFM method (Chain ladder) performance was improved with an average gain of +1,3 % on forecasted loss ratios.

Key words : Bayesian networks, machine learning, non-life reserving, seasonality

SOMMAIRE

INTRODUCTION 8

LA SOCIETE ALLIANZ PARTNERS ET SON CHAMPS D'ACTIVITE 10

ACTIVITES DU GROUPE ALLIANZ PARTNERS 10
VOLUME D'ACTIVITE ET NIVEAU DE PROVISIONNEMENT DU GROUPE 10
ORGANISATION DE LA FONCTION ACTUARIELLE 11
INCERTITUDES ET FACTEURS DE RISQUE ACTUARIELS 11
LE CONTEXTE DU TRAITEMENT COMPTABLE 12
IFRS 4 12
LA PREPARATION DE LA MISE EN PLACE DE LA COMPTABILITE A LA NORME IFRS17 13
REGLEMENT GENERAL SUR LA PROTECTION DES DONNEES (RGPD) 14

LA PROBLEMATIQUE DU PROVISIONNEMENT DE SINISTRES NON-VIE CHEZ ALLIANZ PARTNERS 15

LES PRODUITS ET LES LIGNES D'AFFAIRES (LOB) ET DE SERVICE DU GROUPE ALLIANZ PARTNERS 15
PRESENTATION DU PROCESSUS DE PROVISIONNEMENT DES SINISTRES DU GROUPE ALLIANZ PARTNERS 16
ROLE DE L'ACTUAIRE 16
DEROULEMENT DU PROCESSUS DE PROVISIONNEMENT DE SINISTRES 16
LES GISEMENTS DE DONNEES TECHNIQUES SOURCES 17
LES OUTILS 17
LES METHODOLOGIES DE PROVISIONNEMENT EN VIGUEUR 18
LES INDICATEURS ACTUARIELS D'ALLIANZ PARTNERS 18
LIMITES DE LA METHODE DE PROVISIONNEMENT DES SINISTRES CHEZ ALLIANZ PARTNERS 19
UNE CONTRAINTE METHODOLOGIQUE : LA PROJECTION « ROLL FORWARD » 19
UNE CONTRAINTE ORGANISATIONNELLE 19
UNE CONTRAINTE STRUCTURELLE 19
LES AXES DE COMPENSATION POSSIBLES 20

LES METHODES DE PROVISIONNEMENT EN ASSURANCE NON-VIE 21

LES TRIANGLES DE DEVELOPPEMENT : UN PILIER METHODOLOGIQUE DE L'ASSURANCE NON-VIE 21
CONSTRUCTION DU TRIANGLE DE DEVELOPPEMENT 21
LA METHODE DFM (APPELE « CHAIN-LADDER » DANS LE MONDE ANGLO-SAXON) 23
VALIDATION DE LA METHODE DFM 25

LIMITES DE LA METHODE DFM 25
CONCLUSIONS SUR LA BIBLIOGRAPHIE DES METHODES DE PROVISIONNEMENT EN NON-VIE 26

LES RESEAUX BAYESIENS ET LEUR APPRENTISSAGE 28

DEFINITIONS 28
PROPRIETES 28
INDEPENDANCE CONDITIONNELLE ET D-SEPARATION 28
CAUSALITE 30
INFERENCE DANS UN RESEAU BAYESIEN 31
APPRENTISSAGE DE PARAMETRES DANS UN RESEAU BAYESIEN 31
APPRENTISSAGE DE PARAMETRES A PARTIR D'UN JEU DE DONNEES « COMPLET » 32
CONCLUSION 33

L'ETUDE REALISEE 34

POINTS FORTS SUR LE CHEMIN SUIVI 34
PRESENTATION DU PERIMETRE 35
PRESENTATION DE LA METHODE 36
DEMARCHE A RETENIR DANS UN PROJET D'APPRENTISSAGE DE DONNEES SUR RESEAU BAYESIEN 36
LES VARIABLES MISES EN ŒUVRE DANS LE CADRE DU MODELE 37
LES OUTILS MIS EN ŒUVRE DANS LE CADRE DE L'ETUDE 38
CONSTRUCTION DE LA BASE D'APPRENTISSAGE 38
VALORISATION DES PREDICTIONS EN VUE DE L'ETUDE ACTUARIELLE 41
PLAN D'EXPERIENCE DE L'ETUDE ACTUARIELLE 41

PRESENTATION DES RESULTATS DE L'ETUDE 41

PREAMBULE 41
LES RESEAUX BAYESIENS EXPLOITES 41
RESEAU EXPLOITE POUR LA DETERMINATION DES VALEURS TRIMESTRIELLES DE MONTANT INITIAL DES SINISTRES 42
RESEAU EXPLOITE POUR LA DETERMINATION DES PREMIERS FACTEURS DE DEVELOPPEMENT 43
AXES D'ETUDES 44
BRANCHE D'ACTIVITE « VOYAGES » DE LA BU ESPAGNE 44
BRANCHE D'ACTIVITE « AUTOMOBILES » DE LA BU ESPAGNE 46
SYNTHESE 49
PRESENTATION DES RESULTATS D'INFERENCE 49
PARTICULARITES LIEES AU MECANISME DE DE-CATEGORISATION 50
UTILISATION DES RESULTATS D'INFERENCE 50
ENJEU D'ETUDE 50
PRESENTATION DES RESULTATS 50

INFLUENCE DU CHOIX BAYESIEN SUR LES MONTANTS INITIAUX **51**
RESULTATS POUR L'ASSISTANCE VOYAGE 51
RESULTATS POUR L'ASSISTANCE AUTOMOBILE 52
DISCUSSION DES RESULTATS 53
INFLUENCE DU CHOIX BAYESIEN SUR LES FACTEURS DE DEVELOPPEMENT **54**
RESULTATS POUR L'ASSISTANCE VOYAGE 54
RESULTATS POUR L'ASSISTANCE AUTOMOBILE 55
DISCUSSION DES RESULTATS 56
INFLUENCE DU CHOIX COMBINE **57**
RESULTATS POUR L'ASSISTANCE VOYAGE 57
RESULTATS POUR L'ASSISTANCE AUTOMOBILE 58
DISCUSSION DES RESULTATS 59
PRISE EN COMPTE ET TRAITEMENTS DES LIMITES OBSERVEES 60
PRESENTATION DES RESULTATS FINAUX **61**
RESULTATS POUR L'ASSISTANCE VOYAGE 62
COMMENTAIRES POUR L'ASSISTANCE VOYAGE 62
RESULTATS OBTENUS POUR L'ASSISTANCE AUTOMOBILE 63
COMMENTAIRES POUR L'ASSISTANCE AUTOMOBILE 63
IMPACTS SUR LES RATIOS SINISTRES SUR PRIME **63**
PERTINENCE DES MODELES **65**
CAS DES MODELES POUR LA RECHERCHE DE PAIEMENTS INITIAUX 65
RESULTATS POUR LE RESEAU BAYESIEN DE RECHERCHE DE PAIEMENTS INITIAUX 66
CAS DES MODELES POUR LA RECHERCHE DES FACTEURS DE DEVELOPPEMENT INITIAUX 68
RESULTATS POUR LE RESEAU BAYESIEN DE RECHERCHE DE FACTEURS DE DEVELOPPEMENT INITIAUX 68
DIVERS COMMENTAIRES SUR L'ETUDE **69**
CANTONNEMENT DES PLAGES D'INCERTITUDE 69
INCIDENCE DE LA BASE D'APPRENTISSAGE 69
EFFICACITE DES RESEAUX LIES A LA BRANCHE D'ACTIVITE 70
DEGRE DE PERFORMANCE A ATTENDRE EN UTILISANT UN RESEAU BAYESIEN 70

PERSPECTIVES, LIMITATIONS ET INTERET DES RESEAUX BAYESIENS EN ACTUARIAT **71**

LIMITATIONS POUR LES ACTIVITES DE PROVISIONNEMENT **71**
INTERET ACTUARIEL **71**
ALLER PLUS LOIN **72**

CONCLUSION **73**

ANNEXES **75**

1. CODE DE PROGRAMMATION POUR GENERER UNE BASE D'EXPERTISE **76**

2. PRESENTATION D'UN RESEAU BAYESIEN « FITTE » 79
3. TABLES DE DONNEES CATEGORISEES A DESTINATION DES RESEAUX BAYESIENS 82
4. TABLES DES RESULTATS D'INFERENCE 86
5. TABLE DES RESULTATS ACTUARIELS 91
6. CODE DE PROGRAMMATION DES GRAPHES DE RESULTATS 107
7. TABLE DES « OUTLIERS » 113
8. IMPACT SUR LE PROVISIONNEMENT DU PORTEFEUILLE BUSP (ANNEES 2017 ET 2018) 114
9. MESURE DE LA QUALITE DES MODELES 115
10. SYNTHESE BIBLIOGRAPHIQUE DES METHODES DE PROVISIONNEMENT EN NON VIE 117
11. MISE EN OEUVRE DU PACKAGE BNLEARN 126
12. COMPLEMENT D'INSTRUCTION SUR LES RESEAUX BAYESIENS, LEUR FONCTIONNEMENT ET LEURS POTENTIALITES 129
13. MECANISME DE DE-CATEGORISATION (POUR CONSTITUER DES MONTANTS INITIAUX EXPLOITABLES POUR LES ANALYSES ACTUARIELLES) 141

TABLES DES ACRONYMES : 142

BIBLIOGRAPHIE 143

Introduction

Les activités d'inventaire (dont font partie le calcul des provisions techniques dans le champ actuariel) concernent toutes les entreprises d'assurance. Cependant, les méthodologies mises en œuvre par les sociétés peuvent être différentes. Ainsi, le groupe Allianz SE impose à toutes ses entités (dont le groupe Allianz Partners) un procédé particulier de valorisation dit « en méthode roll-forward » où les provisions de sinistres sont calculées pour un trimestre en s'appuyant sur les données techniques du trimestre précédent.

Bien évidemment, cette méthode a l'avantage de permettre de détecter très en amont des signes avant-coureur d'évolution, mais elle a aussi des faiblesses, dont typiquement la volatilité des informations actuarielles concernant le trimestre qui n'est pas encore écoulé : aucune donnée existante n'est disponible à ce stade pour procéder à l'exercice actuariel.

Dans ce contexte, un enjeu fort pour Allianz Partners est la diminution de cette volatilité, pour donner la prévision la plus juste possible. En effet, ce sont les valorisations actuarielles d'IBNR qui sont inscrites dans les comptes. Elles ont donc un impact direct sur la gestion de l'entreprise (niveau de profitabilité, performance des entités opérationnelles, etc.).

L'explosion des méthodes dites de « machine learning » a mis à portée des actuaires une profusion d'outils statistiques qui pourraient se révéler intéressants dans le cadre de la pratique professionnelle. Les réseaux bayésiens forment une famille moderne d'outils, en plein développement, et qui permettent à la fois d'introduire une composante non linéaire dans les méthodes actuarielles, mais aussi de donner une certaine lisibilité et une certaine intuition à des non utilisateurs (en appréciant les résultats à la lecture du schéma de réseau, par exemple).

C'est la raison pour laquelle une approche innovante est d'essayer de rapprocher cette problématique actuarielle (la valorisation « roll-forward ») et l'usage des réseaux bayésiens.

Ce mémoire traite de ce sujet. Pour ce faire, la démarche s'articule en plusieurs volets. Tout d'abord, une présentation fine du processus actuariel dans l'entreprise, les contraintes et l'organisation posent le cadre de travail. Ensuite, un rappel de la méthode DFM (« Development Factor Method ») et des limites des principales méthodes de provisionnement est fait, appuyé sur une revue bibliographique conservée en annexe. Puis, une présentation générale des réseaux bayésiens est réalisée. Elle permet d'appréhender la philosophie générale qui sous-tend l'usage des réseaux, leur intérêt, les modalités de mises en œuvre et de mesure.

Finalement, des réseaux bayésiens sont mis en œuvre sur un portefeuille représentatif de l'activité d'Allianz Partners : celui de la Business Unit Espagne, qui se trouve avoir une taille moyenne (ordre de grandeur de 100 M€ de primes annuelles), et une répartition caractéristique des activités non vie d'Allianz Partners. C'est l'usage des informations en sortie de ces réseaux (valeur a priori de montants initiaux et de facteurs de développement initiaux)

qui permet d'alimenter les méthodes traditionnelles actuarielles mises en œuvre au sein de l'entreprise.

Les résultats sont discutés et appréciés en comparaison avec les résultats observés *a posteriori*. Ils seront aussi mis en perspective par rapport à l'usage de la traditionnelle méthode de développement des facteurs (DFM) communément appelé « Chain ladder ». Les perspectives et les limitations de ce type de méthode (métissage des méthodes actuarielles traditionnelles avec les méthodes modernes du « machine learning ») sont finalement évoquées.

La société Allianz Partners et son champ d'activité

Activités du groupe Allianz Partners

Les activités d'assurances non-vie du groupe Allianz Partners concernent majoritairement l'assistance et l'assurance voyage. Elles sont produites au sein de vingt-quatre filiales qui opèrent sur des territoires nationaux.

Volume d'activité et niveau de provisionnement du groupe

L'activité est principalement tournée vers l'assistance en Europe du sud, et l'assurance voyage sur le continent américain, même si l'ensemble de l'offre est disponible de façon globale.

AWP T&A Gross Written Premiums (After Premium Refunds) - 31 December 2018

Zone	AWP T&A				
	Assistance	Travel	Automotive	International health	Total
	Euro mn	*Euro mn*	*Euro mn*	*Euro mn*	*Euro mn*
Europe 1	126.8	170.3	29.8	24.6	**351.5**
Europe 2	61.4	225.2	1.3	0.5	**288.5**
Europe 3	675.3	229.3	0.7	0.0	**905.4**
APAC	152.7	231.1	1.9	139.3	**525.0**
America	130.8	793.0	0.0	0.0	**923.7**
FOS	16.6	9.0	0.0	0.0	**25.5**
Automotive	0.0	0.0	11.1	0.0	**11.1**
Thereof Virtual APAC	1.4	51.6	0.0	0.0	**53.0**
Thereof Virtual America	0.0	0.0	0.0	0.0	-
Others	-5.6	-5.1	-0.2	-0.4 -	**11.3**
Total	1,156.6	1,601.0	44.7	164.0	**2,966.4**

Source: Dimension Report A'18 - AWP P&C Finance

Synopsis des primes émises sur le périmètre Assistance (Voyage et Automobile) en 2018

Les provisions techniques se répartissent naturellement entre les provisions de primes et les provisions de sinistres. Elles se concentrent naturellement là où l'activité est la plus florissante.

AWP T&A IFRS Technical Reserves (Net of Reinsurance) - 31 December 2018

Hub	2018 Claims Reserves	2018 Unearned Premium Reserves	2018 Total	2017 Claims Reserves	2017 Unearned Premium Reserves	2017 Total
	Euro mn	*Euro mn*	*Euro mn*	*Euro m's*	*Euro m's*	*Euro m's*
Europe 1	50.97	185.58	**236.55**	49.95	175.80	**225.74**
Europe 2	28.57	81.13	**109.70**	31.03	78.20	**109.23**
Europe 3	117.84	195.15	**312.99**	122.72	204.94	**327.66**
APAC	76.97	392.99	**469.96**	67.34	389.52	**456.86**
Americas	88.84	164.71	**253.55**	68.06	125.47	**193.53**
FOS	1.85	9.19	**11.05**	2.75	9.02	**11.77**
Automotive	4.04	19.92	**23.97**	2.78	10.97	**13.75**
Thereof Virtual APAC	39.95	55.96	**95.91**			
Thereof Virtual Americ	4.78	36.21	**40.99**			
Others*	3.37	- 2.22	**1.15**	- 0.47	- 0.29	- **0.75**
Qualitative Reserves	-	-	-	0.93	-	**0.93**
Total	327.73	954.29	**1,282.01**	345.08	993.63	**1,338.71**

**(incl small BUs, FX effects, eliminations)*

Synopsis des provisions techniques sur le périmètre Assistance (Voyage et Automobile) en 2018

Organisation de la fonction actuarielle

Les activités actuarielles sont menées dans cinq régions (chacune représentant un regroupement de filiales). Une telle pratique régionalisée permet :

- L'harmonisation des méthodes de calcul des provisions IFRS, en cohérence avec les contraintes réglementaires, et les données disponibles localement,
- La mise en œuvre du processus actuariel en concertation avec les équipes financières locales (Contrôle de gestion, comptabilité et souscription).

Les modèles, méthodes et hypothèses retenus sont adaptés en conséquence, pour s'aligner avec le modèle de gouvernance et les bonnes pratiques sur groupe Allianz.

Incertitudes et facteurs de risque actuariels

Les incertitudes dans le processus de provisionnement de sinistres proviennent :

- Des méthodes retenues ou des hypothèses qui ne forment pas une représentation appropriée de la réalité,
- Des données incomplètes, incorrectes ou inappropriées,
- D'erreurs humaines,
- Du caractère contingent et aléatoire des méthodes actuarielles mises en œuvre.

Le risque le plus important pour le provisionnement de sinistres dans le contexte particulier du processus actuariel est de faire des erreurs de calcul : il y aurait en conséquence des écritures comptables conduisant à une valorisation erronée de la profitabilité pour l'exercice (IFRS). Un autre risque tient à une mauvaise compréhension des affaires qui empêche de bien

analyser les chiffres. Des conséquences possibles sont des pertes financières ou une sous-évaluation des bénéfices. Ceci peut aussi concourir par suite, à infléchir le développement d'affaires nouvelles ou d'investissements avec de nouveaux partenaires.

Le contexte du traitement comptable

La pratique actuarielle s'inscrit dans un cadre règlementaire complexe et mouvant. Si certaines règlementations sont maintenant largement inscrites et respectées dans le cadre du travail (comme le respect de la norme IFRS4), d'autres règlementations ont récemment faits leur apparition, et amène à anticiper des changements de pratique (comme l'application de la norme IFRS17 dans le champ de la comptabilité, et RGPD dans le champ de la protection des données).

Les paragraphes suivants rappellent les grandes lignes de ces règlementations.

IFRS 4

L'objectif de la norme IFRS 4 (entrée en vigueur le 1er janvier 2005) est de spécifier l'information financière pour les contrats d'assurance établis par toute entité émettrice, jusqu'à ce que la norme IFRS17 soit achevée et mise en œuvre.

Le contrat d'assurance, le traité de réassurance, la composante dépôt, le passif d'assurance, les actifs au titre des cessions en réassurance sont des notions présumées connus.

Une entité doit appliquer la norme IFRS 4 d'une part aux contrats d'assurance (y compris les traités de réassurance) qu'elle émet et aux traités de réassurance qu'elle détient, et d'autre part aux instruments financiers qu'elle émet avec un élément de participation discrétionnaire. La norme IFRS 4 n'est pas concernée par d'autres aspects de comptabilisation par les assureurs comme la comptabilisation des actifs financiers détenus par les assureurs et les passifs financiers émis par les assureurs.

Dans certains cas, un assureur est tenu de décomposer les composantes assurance et dépôt des contrats.

La norme IFRS 4 exempte un assureur d'appliquer les critères définis aux paragraphes 10 à 12 d'IAS 8 « Méthodes comptables, changements d'estimations comptables et erreurs » aux contrats d'assurance qu'il émet et aux traités de réassurance qu'il détient.

Néanmoins, la norme IFRS 4 n'exempte pas un assureur de certaines implications issues de ces critères. Un assureur :

- Ne doit pas comptabiliser en tant que passif des provisions au titre de demandes d'indemnisation éventuelles futures, si ces demandes sont générées par des contrats d'assurance qui ne sont pas encore souscrits à la date de reporting (telles que les provisions pour risque de catastrophe et les provisions pour égalisation),
- Doit effectuer le test de suffisance du passif décrit ci-dessous,

- Doit sortir un passif d'assurance (ou une partie d'un passif d'assurance) de son bilan, si et seulement s'il est éteint, c'est-à-dire lorsque l'obligation précisée au contrat est acquittée ou annulée ou a expiré,
- Ne doit pas compenser des actifs au titre des cessions en réassurance avec les passifs correspondants ou les produits ou les charges provenant de traités de réassurance avec les charges ou les produits résultant des contrats d'assurance correspondants,
- Doit examiner si ses actifs au titre des cessions en réassurance sont dépréciés.

Un assureur doit évaluer à chaque date de reporting si ses passifs d'assurance comptabilisés sont suffisants, en utilisant les estimations actuelles de flux de trésorerie futurs générés par ses contrats d'assurance. En cas d'insuffisance, celle-ci doit être comptabilisée en résultat.

Un assureur peut changer ses méthodes comptables relatives aux contrats d'assurance si fiabilité et pertinence sont accrues (selon les critères d'IAS 8).

Un assureur doit fournir des informations d'une part qui identifient et expliquent les montants générés par les contrats d'assurance figurant dans ses états financiers, d'autre part qui permettent aux utilisateurs de ses états financiers d'évaluer la nature et l'ampleur des risques découlant des contrats d'assurance.

La préparation de la mise en place de la comptabilité à la norme IFRS17

IFRS 17 est la première véritable norme IFRS destinée aux contrats d'assurance. Elle va remplacer la norme provisoire IFRS 4.

Jusqu'à présent, la comptabilisation des contrats d'assurance différait sensiblement de celle des contrats dans les autres secteurs. C'est pour répondre à ces critiques tout en favorisant la lecture des états financiers pour les non spécialistes que la norme IFRS 17 a été créée. Si les dispositions de la norme IFRS 17 sont différentes de celles d'IFRS 4, elles se rapprochent de la logique de certaines autres normes, telles qu'IAS 32, IFRS 9 et IFRS 15.

IFRS 17 veut rendre la comptabilisation des contrats d'assurance plus cohérente.

Les préconisations de la norme IFRS 17 doivent permettre aux investisseurs d'obtenir des informations à jour sur les obligations, les risques liés et la performance des contrats d'assurance. Il s'agit également d'augmenter la transparence de l'information financière tout en facilitant les comparaisons à l'intérieur du secteur des assurances ou avec des entités d'autres secteurs d'activité.

La norme IFRS 17 concerne toutes les entités qui émettent des contrats d'assurance. Elle affecte donc en priorité le secteur de l'assurance et de la réassurance, même si elle ne vise pas directement les assureurs.

La norme IFRS 17 repose sur trois piliers qui sont la valeur de l'obligation d'assurance, la comptabilisation des produits et la performance de l'assurance.

L'assureur doit ainsi faire apparaître dans ses états financiers, les obligations nées des contrats d'assurance.

Il évalue le contrat d'assurance en utilisant des estimations et des hypothèses actualisées qui reflètent les flux de trésorerie futurs attendus, les échéances des flux de trésorerie et l'incertitude liée aux flux de trésorerie. Ces estimations et hypothèses sont basées uniquement sur les obligations engendrées par le contrat lui-même. La valeur d'un portefeuille de placement que l'assureur pourrait détenir pour anticiper les fluctuations de leurs passifs est évaluée séparément.

La comptabilisation des produits est considérée comme un indicateur important pour toutes les entités et pour tous les types de transaction. Ils sont présentés pour leurs montants réalisés. Les dépôts à vue sont exclus.

La performance de l'assurance se résume essentiellement aux flux de trésorerie et IFRS 17 oblige à réfléchir à la période durant laquelle ces flux de trésorerie sont pris en compte. La norme IFRS 17 rejoint ainsi les préconisations des normes IAS 37 sur les provisions et IFRS 9 sur les instruments financiers. Ces deux normes exigent aussi des évaluations en fonction des flux de trésorerie futurs.

Un contrat d'assurance qui se solderait par une perte doit voir celle-ci immédiatement constatée dans le résultat. La reconnaissance des revenus tirés du contrat d'assurance se rapproche alors des préconisations de la norme IFRS 15.

La norme doit s'appliquer aux exercices ouverts à compter du 1er janvier 2021.

Règlement Général sur la Protection des données (RGPD)

Le règlement n°2016/679, dit règlement général sur la protection des données (RGPD, ou encore GDPR, de l'anglais « General Data Protection Regulation ») est un règlement de l'Union Européenne qui constitue le texte de référence en matière de protection des données à caractère personnel. Il renforce et unifie la protection des données pour les individus au sein de l'Union européenne. Il est en vigueur depuis le 25 mai 2018.

Le RGPD encadre le traitement des données personnelles sur le territoire de l'Union européenne. Le contexte juridique s'adapte pour suivre les évolutions technologiques et sociétales (usages accrus du numérique, développement du commerce en ligne…). Ce nouveau règlement européen s'inscrit dans la continuité de la Loi française Informatique et Libertés de 1978 et renforce le contrôle par les citoyens de l'utilisation qui peut être faite des données les concernant.

L'adhérence entre le respect du RGPD et la mission actuarielle se situe dans les phases d'acquisition et de manipulation des données techniques nécessaires aux calculs actuariels (devoir de vigilance pour bien être sûr d'être en conformité en matière d'exploitation des données).

La problématique du provisionnement de sinistres non-vie chez Allianz Partners

Les produits et les lignes d'affaires (LOB) et de service du groupe Allianz Partners

Les produits et lignes d'affaires du groupe Allianz Partners pour ses activités non-vie sont les suivantes (exhaustivement) :

- Assurance voyage,
- Assistance automobile ("RSA"),
- Extension de garantie automobile,
- Garantie électroménagère (incluant les appareils mobiles et les risques digitaux -MDDR-),
- Assurance évènementielle (billets),
- Assistance et assurance santé,
- Assistance domestique,
- Responsabilité civile (portefeuille d'activité en Italie seulement, en liquidation).

L'offre de produits est homogène sur les dernières années comptables.

Certains des produits présentés dans la liste ci-dessus sont proposés dans un contexte assurantiel (c'est à dire qu'une prime est payée d'abord, pour une période de couverture du risque avec un certain niveau d'incertitude appropriée au niveau d'indemnisation) ou bien dans un contexte de service (c'est-à-dire que le niveau du prix du service est fixé pour l'intervention causée par la réalisation du risque).

La durée des contrats d'assurance est extrêmement disparate. Elle peut s'étendre entre quelques jours (par exemple pour un voyage) et quelques années (assistance automobile).

Présentation du processus de provisionnement des sinistres du groupe Allianz Partners

Rôle de l'actuaire

Les tâches dévolues à l'actuaire dans le cadre du processus de provisionnement non-vie sont les suivantes :

- Mise en œuvre des procédures de provisionnement de sinistres du groupe Allianz,
- Détermination des provisions techniques IFRS,
- Reporting respectant les contraintes du modèle Allianz, et articulant les potentielles pistes d'audit,
- Supervision de la profitabilité et de la souscription,
- Conseil sur l'efficacité du programme de réassurance du groupe Allianz Partners,
- Contribution à la Gestion du Risque (USP, GSP, rapports),
- Responsable de la qualité des données source actuarielles (complétude, précision, pertinence),
- Détermination des courbes d'acquisition des primes,
- Appui aux projets du groupe.

Déroulement du processus de provisionnement de sinistres

L'articulation du processus de provisionnement est le suivant :

- Acquisition des données de sinistres « brut » au format du modèle de données actuarielles deux semaines après la clôture trimestrielle,
- Contrôle des données, sur le plan technique (complétude, précision, pertinence), mais aussi sur le plan comptable : les données techniques doivent se réconcilier avec les informations disponibles dans les documents comptables du groupe. Si ce n'est pas le cas, l'écart doit être compris,
- Transformation des données pour produire des agrégats de données utiles pour les méthodes actuarielles (par exemple regroupement des paiements ou décompte des sinistres par périodes de survenance et période de développement des paiements). Les agrégats sont produits en découpant le portefeuille selon la classe de risque qui permet d'appliquer des méthodes actuarielles de façon efficace,
- Détermination « a priori » de ratios de sinistres pour l'année comptable en vigueur, et des boni-mali de liquidation pour les années antérieures,
- Prise de connaissance du contexte d'activité récent trois semaines avant la clôture comptable trimestrielle (niveau d'activité constaté sur le terrain, survenance de gros sinistres, démarrage de nouveaux contrats, arrêts de contrats existants, changement de rythme dans le processus de gestion des sinistres),
- Prise en compte des retours du terrain pour fiabiliser les ratios de sinistres et les boni-mali de liquidation,
- Fixation du niveau des provisions techniques,

- Présentation des résultats en « réunion de Provisionnement » (« Reserve Meeting ») dans la dernière quinzaine de jours précédant la clôture comptable trimestrielle,
- Contrôle des écritures comptables de nature actuarielle une semaine après la clôture comptable.

Les gisements de données techniques sources

Pour le groupe Allianz Partners, le modèle actuariel utile dans le cadre du processus de provisionnement des sinistres est articulé autour de trois données assurantielles stockées dans des tables (pour le sinistre, la police d'assurance et le contrat) :

La table des sinistres (dénommée CLAIMS) possède toutes les informations élémentaires pour caractériser un sinistre. Les dates de survenance et de paiement sont disponibles, mais aussi la garantie exercée, et la prestation qui a été rendue. De plus, d'autres informations permettent de cerner la classe de risque, et donc de pouvoir isoler les groupes de données qui sont utilisables pour appliquer les méthodes actuarielles sur des ensembles homogènes de données. Le sinistre est aussi associé à sa police dans le cadre de cette table.

La table des polices (dénommée POLICIES) possède toutes les informations élémentaires pour caractériser les Conditions Particulières d'un contrat d'assurance. Y sont consignées les informations permettant de comprendre comment les risques sont couverts au fil du temps (date de démarrage, de fin de contrat, d'annulation, mais aussi date de couverture particulière pour certains risques). Finalement, les garanties et les montants de primes émises, acquises, et les montants de commissions émises et acquises sont aussi disponibles dans la table. La police est aussi associée à son contrat dans le cadre de cette table.

La tables des contrats (dénommée CONTRACTS) possède toutes les informations nécessaires pour caractériser les contrats qui supportent les polices (ou conditions particulières). Y sont aussi consignées les informations permettant de comprendre quand démarre et se termine un contrat, quels sont les signataires, le nom du partenaire commercial et son champ d'activité.

Ces trois tables sont produites à chaque clôture trimestrielle et permettent de caractériser de façon cohérente le sinistre (flux de dépenses, et valorisation du « case estimate ») dans son contexte d'exposition. Le processus de livraison-acceptation inclut une revue de la qualité des données, et en particulier un contrôle de réconciliation avec les comptes du groupe Allianz Partners.

Les outils

Ces trois tables dont le contenu est partiellement standardisé nourrissent un entrepôt de données actuariel. Pour les besoins de production, l'équipe d'actuaires utilise l'outil SAS et le tableur Excel. Pour les besoins particuliers de la présente étude, les logiciels R et RStudio ont été installés en plus, ce qui permet d'utiliser les programmes de réseaux bayésiens

Les méthodologies de provisionnement en vigueur

Même si l'ensemble des méthodes actuarielles de provisionnement de sinistres est potentiellement utilisable, seules certaines méthodes sont privilégiées en pratique pour les raisons suivantes :

- Auditabilité du processus de provisionnement des sinistres,
- Facilitation de la compréhension et de la lecture des résultats actuariels par les fonctions connexes (équipes de la Direction Financière en local, équipes du Contrôle de Gestion en central),
- Rusticité des méthodes,
- Interopérabilité des actuaires pour reprendre un périmètre, pour procéder à tout type de revue classiquement applicable dans les processus actuariels (« peer-review », « technical-review », « Management Review »).

De ce fait les méthodes les plus utilisées sont les suivantes :

- Les triangles de développement de sinistres payés,
- Les triangles de développement de la charge de sinistre,
- Le modèle de sinistres en fréquence-gravité (avec la fréquence déterminée à partir des triangles de développement de nombre de sinistres survenus),
- La méthode Bornehuetter-Ferguson.

Pour mémoire, ces méthodes de provisionnement sont détaillées dans la partie « les classiques du provisionnement en non-vie » de ce document, ou en annexe.

Les indicateurs actuariels d'Allianz Partners

Les informations et indicateurs actuariels échangés avec les équipes de Contrôle de Gestion et les équipes de la Direction financière de l'entreprise sont :

- Pour ce qui concerne les années précédentes,
    - La charge de sinistres à l'ultime PY (pour « prior year »),
    - Les IBNR PY,
    - Les dépenses de règlements de sinistres PY.
- Pour ce qui concerne l'année en cours, il est déterminé :
    - La charge de sinistres à l'ultime CY (pour « current year »),
    - Les IBNR CY,
    - Un ratio de sinistres sur prime CY,
    - Les dépenses de règlements de sinistres CY.

Par ailleurs, comme les provisions de sinistres dossiers par dossier sont disponibles (fournies par les équipes comptables), la combinaison de toutes ces informations permet de calculer les boni-mali de liquidation. Les ratios combinés ne sont pas strictement calculés par les équipes actuarielles de production.

Limites de la méthode de provisionnement des sinistres chez Allianz Partners

Une contrainte méthodologique : la projection « roll forward »

Disposer des indicateurs actuariels en projection « Roll forward » est un requis des processus d'Allianz. Il s'agit pratiquement d'estimer la charge à l'ultime avec trois mois d'avance. Ceci implique, quel que soit la méthode actuarielle retenue, de faire deux estimations ambitieuses.

Tout d'abord, définir le niveau de sinistralité en première période de survenance n'est pas un exercice facile sans une bonne connaissance des comptes commerciaux et du niveau de l'activité en gestion de sinistres.

Ensuite, cette première valorisation a une incidence forte sur la charge à l'ultime prévue pour cette cohorte : en effet, il faut aussi définir la forme du cycle de développement (par le biais des facteurs) qui va être celle qui sera avérée dans le futur. Une erreur d'appréciation initiale se traduit de façon criante pour le trimestre à venir, puisque rien n'est développé.

Ceci est d'autant plus le cas que le cycle est long (par exemple, dans des contrats impliquant des procédures juridiques, où rien ne se déploie vraiment avant trois à six mois).

Une contrainte organisationnelle

Le processus de l'entreprise est complexe, avec de nombreuses équipes qui procèdent à des calculs dont la vocation est différente. A titre d'exemple, les équipes locales de Contrôle de Gestion suivent les portefeuilles avec un cadencement mensuel tout en cherchant à comprendre le comportement vis-à-vis d'un plan défini au préalable. Ces équipes s'appuient pour ce faire sur les données comptables locales mensuelles et le système de gestion de sinistres. Ils mesurent le comportement du portefeuille en suivant des comptes commerciaux clés.

Il y a donc une asymétrie d'information avec l'équipe d'actuaire du groupe qui doit procéder depuis le siège avec des données bien plus anciennes, et standardisées selon la norme du groupe, et sans connaissance de l'actualité récente sur les comptes. De plus, les techniques de détermination des ratios de sinistres sur primes, ou de calcul de charge à l'ultime ne sont pas identiques, ce qui contribue à entretenir les débats concernant la pertinence de tel ou tel chiffre obtenu.

Une contrainte structurelle

Allianz Partners opère des contrats d'assistance voyage et d'assistance automobile dans une très large mesure. Ces portefeuilles de contrats peuvent réagir de façon très rapide et extrêmement saisonnière. A titre d'exemple, en assistance automobile, si la température est très forte en été ou très froide en hiver, la sinistralité s'en ressentira. De même, en Assurance-Voyage, le tourisme est extrêmement affecté par l'actualité. Un attentat ou une épidémie, ou un épisode météorologique défavorable peuvent suffire à influencer le comportement des assurés, ce qui se traduit indirectement sur la sinistralité *a priori*.

En conclusion, l'horizon de travail même s'il est paradoxalement court, rend difficile une estimation actuarielle du fait de la nature des marchés et des produits. Même sans la méthode « roll-forward », il est difficile de faire le pilotage court terme (c'est-à-dire de façon trimestrielle) du portefeuille.

Cependant, à l'exception des produits pour lesquels le cycle de développement est court (en trois trimestres comme pour l'assistance automobile), la détermination d'un ratio sinistres sur primes en fin d'année comptable est fiable, car les trois quarts de l'activité sont déjà totalement développés, ce qui stabilise les chiffres.

Les axes de compensation possibles

Ces contraintes étant connues, les actuaires d'Allianz Partners doivent faire en sorte de limiter leurs effets négatifs. Des réponses existent et sont à renforcer, d'autres sont vraisemblablement à créer.

Par exemple, accroître les échanges et le courant de communication avec les équipes locales (Contrôle de Gestion et Gestion de Sinistres) peut permettre de digérer le plus en amont possible toutes les innovations détectées. Les méthodes actuarielles peuvent ainsi être adaptées et raffinées.

Une autre approche complémentaire consisterait à renforcer l'arsenal technique de l'actuaire pour qu'il puisse interpréter « avec ce qu'il dispose » (c'est-à-dire sa base d'expérience qui est mise à jour de façon trimestrielle). Typiquement, les réseaux bayésiens, qui sont présentés dans le cadre de ce travail, constituent une famille d'outils complémentaires qui peut rendre plus efficient l'expression des données d'expérience.

Les méthodes de provisionnement en assurance non-vie

Il existe de nombreuses méthodes de provisionnement en assurance non-vie. Elles fournissent des résultats plus ou moins fiables et robustes selon les circonstances (changement des pratiques, changement des méthodes de gestion de sinistres, politique de provisionnement, existence et justesse des informations disponibles, etc.).

La méthode de développement de facteurs DFM (mentionnée dans la littérature anglo-saxonne comme la méthode « Chain Ladder ») est l'une des plus populaires. Elle est présentée ci-après, car elle est sert de point de comparaison pour cette étude.

Pour ce qui concerne les autres méthodes de provisionnement qui ont été évaluées lors de la phase de bibliographie, elles sont résumées et synthétisées dans une des annexes du document. Le développement stochastique (modèle de Mack) de la méthode DFM y est aussi présenté.

Les triangles de développement : un pilier méthodologique de l'assurance non-vie

Construction du triangle de développement

Les méthodes agrégées sont basées sur les triangles de développement (« run-off triangles ») reflétant la dynamique des sinistres. Les données étudiées (notamment dans le cadre du DFM) peuvent être de différentes natures : règlements, charges, nombre de sinistres, ALAE (« Allocated Loss Adjusment Expense » pour règlement des coûts de gestion de sinistre), etc. Dans ce qui suit, la méthode est exposée pour les triangles de règlements. Les données peuvent être rapportées à des périodes différentes : années, semestres, etc. Pour la clarté de l'exposé, il sera considéré des triangles de développement annuels, dans le cadre de l'étude d'un portefeuille prédéfini.

Le triangle de développement est un tableau à double entrée : les lignes correspondent aux années de survenance des sinistres, les colonnes aux années de développement des sinistres.

Les notations suivantes sont introduites :

- L'exercice de rattachement de la sinistralité (c.-à-d. l'année de survenance) désignée par la lettre i, i = 0, ..., n,
- Les années de développement (ou de déroulé de sinistres), désignée par la lettre j, j = 0, ..., n,
- Xi,j désigne le paiement incrémental réglé durant l'année de développement j pour les sinistres survenus durant l'année i,
- Ci,j désigne les règlements cumulés réglés de l'année 0 à l'année de développement j, pour les sinistre survenus durant l'année i :

$$C_{i,j} = \sum_{k=0}^{k=j} X_{i,k}$$

Par hypothèse, n désigne l'année actuelle, c'est-à-dire l'année d'inventaire où l'étude de provisionnement est menée. Pour les sinistres survenus en année i, il est observé le développement jusqu'à l'année j = n-i. Il s'agit de triangle, car au-delà de la dernière diagonale, les montants ne sont pas connus (voir table Triangle des paiements cumulés). Il s'agit de les prévoir pour déterminer les réserves à effectuer.

i\j	0	1	…	J	…	n-1	n
0	$C_{0,0}$	$C_{0,1}$	…	$C_{0,j}$	…	$C_{0,n-1}$	$C_{0,n}$
1	$C_{1,0}$	$C_{1,1}$	…	$C_{1,j}$		$C_{1,n-1}$	
⋮	…	…	…	…	…		
I	$C_{i,0}$	$C_{i,1}$	…	$C_{i,j}$			
⋮	…	…	…				
n-1	$C_{n-1,0}$	$C_{n-1,1}$					
N	$C_{n,0}$						

Triangle des paiements cumulés

Par hypothèse, les sinistres sont ou seront tous clos après n+1 années de développement, quelle que soit la date de survenance. En particulier, pour les sinistres survenus en année i = 0, les sinistres sont tous clos à la date actuelle n. Si ce n'est pas, il faut utiliser des méthodes d'extrapolation pour modéliser les années de développement non connus.

Il est également possible de travailler avec des trapèzes lorsque l'historique des données est plus que suffisant : lorsque le triangle est totalement développé, il peut être logiquement coupé après sa dernière année de développement. Toutes les cohortes dans cette configuration forment alors un rectangle au-dessus du triangle. Les données s'inscrivent dans un trapèze rectangle. A contrario, seul un historique appuyé sur des années comptables peut être disponible. De même, les gestionnaires de risques peuvent également s'intéresser seulement aux dernières diagonales connues du triangle, lorsqu'ils ne se focalisent que sur les évolutions récentes, ou que l'information antérieure n'est pas disponible. La première année d'historique forme alors la partie supérieure d'un trapèze isocèle qui inscrit toutes les données.

En considérant désormais le triangle des règlements cumulés, l'information disponible apportée par une ligne i du triangle est :

$$\mathcal{H}_{i,n} = \{(C_{i,j}) | 0 \leq j \leq n - i\}$$

Toute l'information disponible est notée $\mathcal{H}_n$:

$$\mathcal{H}_n = \{(C_{i,j}) | 0 \leq i + j \leq n\}$$

Les diagonales correspondent aux années calendaires. La lecture des triangles « en diagonale » permet d'appréhender certains changements dans le processus de gestion des sinistres (révision de la réserve de tous les dossiers quelle que soit l'année de survenance), ou les effets de l'inflation.

Après avoir estimé la partie basse du triangle de liquidation par les diverses méthodes qui vont être décrites plus loin,

$$\{(\hat{C}_{i,j})|i+j \geq n, i \leq n, j \leq n\}$$

Il est possible de déterminer :

- la réserve à un an : en faisant la différence entre la somme de la première sous-diagonale et la somme de la diagonale n,
- la réserve à l'ultime, en faisant la différence entre la somme de la dernière colonne et la somme de la diagonale n.

Au lieu de modéliser directement les paiements cumulés futurs, certaines méthodes (dont la méthode DFM) s'intéressent aux facteurs individuels de développement (parfois appelés « link-ratios »). Ces derniers sont définis par :

$$f_{i,j} = \frac{C_{i,j+1}}{C_{i,j}} \text{ pour } 0 \leq i \leq n-1, 0 \leq j \leq n-1$$

Il est notable qu'au lieu de calculer des facteurs de développement, il est possible également de s'intéresser à des cadences de développement sur les règlements cumulés $(\gamma_{i,j})$ ou incrémentaux $(\varphi_{i,j})$:

$$C_{i,j} = \gamma_{i,j} C_{i,n} \; ou \; X_{i,j} = \varphi_{i,j} C_{i,n}$$

Les relations entre γ, ϕ et f sont les suivantes :

$$\gamma_{i,j} = \prod_{k=j}^{k=n-1} \frac{1}{f_{i,k}} \; et \; \varphi_{i,k} = \begin{cases} \gamma_{i,j} \; si \; j=0 \\ \gamma_{i,j} - \gamma_{i,j-1} \; si \; j > 0 \end{cases}$$

La méthode DFM (appelé « Chain-Ladder » dans le monde anglo-saxon)

La méthode DFM est certainement la méthode de provisionnement la plus simple et la plus utilisée par les compagnies d'assurance.

Hypothèses et estimation

La méthode DFM est fondée sur l'hypothèse de proportionnalité entre les années de règlements. Elle s'applique aux triangles des règlements cumulés. Formellement, l'hypothèse H1 est la suivante :

H1 : pour j = 1, ..., n, les facteurs de développement sont indépendants de l'année de survenance du sinistre i.

Sous cette hypothèse, on a : $\frac{C_{0,j+1}}{C_{0,j}} = \frac{C_{1,j+1}}{C_{1,j}} = \cdots = \frac{C_{n-j-1j+1}}{C_{n-j-1,j}}$

Le facteur de développement lié à l'année de développement j est estimé comme le rapport :

$$\widehat{f_J} = \frac{\sum_{i=0}^{i=n-j-1} C_{i,j+1}}{\sum_{i=0}^{i=n-j-1} C_{i,j}} pour\ j = 0, \dots, n-1$$

Ainsi, sous l'hypothèse H1, au lieu de faire une moyenne simple des facteurs de développement individuels, on estime $\hat{f}_j$ par une moyenne pondérée :

$$\hat{f}_j = \sum_{i=0}^{i=n-j-1} \frac{C_{i,j}}{\sum_{i=0}^{i=n-j-1} C_{i,j}} \frac{C_{i,j+1}}{C_{i,j}} \text{ pour } j = 0, \dots, n-1$$

L'exposition au risque est ainsi prise en compte, c'est-à-dire que l'on donne plus d'importance aux années où les paiements cumulés sont les plus importants. La croissance du portefeuille est ainsi implicitement prise en compte.

Une fois que les facteurs sont estimés, l'estimation des paiements cumulés futurs est donné par :

$$\hat{C}_{i,j} = \widehat{f_{j-1}} \times \dots \times \widehat{f_{n-1}} \times C_{i,n-i}$$

Le triangle est ainsi complété (voir table Triangle complété de paiements cumulés).

i\j	0	1	…	j	…	n-1	n	R_i^u
0	$C_{0,0}$	$C_{0,1}$	…	$C_{0,j}$	…	$C_{0,n-1}$	$C_{0,n}$	0
1	$C_{1,0}$	$C_{1,1}$	…	$C_{1,j}$	…	$C_{1,n-1}$	$\hat{C}_{1,n}$	$\hat{C}_{1,n} - C_{1,n-1}$
⋮	…	…	…	…	…	…	…	…
i	$C_{i,0}$	$C_{i,1}$	…	$C_{i,j}$	…	$\hat{C}_{i,n-1}$	$\hat{C}_{i,n}$	$\hat{C}_{i,n} - C_{ij}$
⋮	…	…	…	…	…	…	…	…
n-1	$C_{n-1,0}$	$C_{n-1,1}$	…	$\hat{C}_{n-1,j}$	…	$\hat{C}_{n-1,n-1}$	$\hat{C}_{n-1,n}$	$\hat{C}_{n-1,n} - C_{n-1,1}$
n	$C_{n,0}$	$\hat{C}_{n,1}$	…	$\hat{C}_{n,j}$	…	$\hat{C}_{n,n-1}$	$\hat{C}_{n,n}$	$\hat{C}_{n,n} - C_{n,0}$

Triangle complété des paiements cumulés

Avec le triangle des paiements cumulés, la réserve à un an est formée par tous les paiements incrémentaux qui seront faits à l'horizon d'un an pour les sinistres survenus durant pour l'année i. Elle vaut :

$$\widehat{R_i^1} = \hat{C}_{i,n-i+1} - C_{i,n-i} \text{ pour } i = 1, \dots, n$$

La réserve à un an pour l'ensemble des sinistres vaut :

$$\widehat{R}^1 = \sum_{i=1}^{i=n} \widehat{R}_i^1$$

La réserve à l'ultime pour les sinistres survenus durant l'année i vaut :

$$\hat{R}_i^u = \hat{C}_{i,n} - C_{i,n-i} \quad pour\ i = 1, \dots, n$$

Enfin, la réserve à l'ultime pour l'ensemble des sinistres vaut :

$$\widehat{\mathrm{R}}^{\mathrm{u}} = \sum_{\mathrm{i}=1}^{\mathrm{i}=\mathrm{n}} \widehat{\mathrm{R}}_{\mathrm{i}}^{\mathrm{u}}$$

Validation de la méthode DFM

La validation de la méthode DFM est purement empirique, puisqu'il s'agit d'une méthode déterministe. Plusieurs méthodes de corroborer son utilisation.

Triangle des facteurs de développement (d-triangle)

Il s'agit du triangle constitué des facteurs individuels de développement. Il est calculé la moyenne, l'écart-type, et le coefficient de variation (défini comme le rapport de l'écart-type à la moyenne) de ces facteurs par année de développement. Un faible coefficient de variation permet de valider empiriquement l'hypothèse de la méthode DFM. L'examen de ce triangle permet de repérer les facteurs atypiques.

C-C plots

Il s'agit d'une méthode graphique (*Partrat et al., 2007)*. Sous l'hypothèse de la méthode DFM pour une année de développement donné j = 0, 1, ... les couples (Ci,j ,Ci,j+1)i=0,...,n−j−1 doivent être alignés selon un]e droite passant par l'origine.

Il est également possible d'effectuer une régression linéaire, pour vérifier que l'ordonnée à l'origine estimée n'est pas significative (c'est-à-dire que l'hypothèse qu'elle est statistiquement différente de 0 est rejetée), et que les écarts entre les points et la droite d'ajustement (résidus) sont faibles.

Triangle rétrospectif

Il est également possible d'appliquer de manière rétrospective les facteurs de développement aux triangles, et de comparer les écarts entre les données historiques observées et les données estimées avec les facteurs de développement de la méthode DFM.

Limites de la méthode DFM

Pour que l'hypothèse d'indépendance des facteurs de développement avec les années de survenance soit valide, il faut que les conditions suivantes sur les données soient réunies (*Partrat et al., 2007)*. :

- Le passé doit être régulier. Par exemple, il ne doit pas y avoir de changements dans la politique de gestion des dossiers, notamment une accélération des remboursements au fil des ans. Une évolution dans la composition du portefeuille (changement dans la fréquence et/ou des coûts moyens, changements de souscripteurs ou des modalités

de souscription, etc.) rendra l'estimation des facteurs plus difficile. Dans ce cas-là, une subdivision du triangle peut être envisagée,

- Le présent et le futur doivent être structurellement peu différents. Un changement futur de jurisprudence n'est par exemple pas pris en compte. De même, au niveau de l'inflation, celle qui est passée est implicite dans le calcul des facteurs de développement. Il faut donc supposer que l'inflation moyenne passée (pondérée) sera répétée dans le futur,
- La branche doit être peu volatile. Notamment, si pour une année ou plusieurs années données, des sinistres graves se produisent, ils doivent généralement être traités à part. S'il y a une valeur aberrante (« outlier ») dans la dernière diagonale connue, cette valeur sera projetée jusqu'à la fin,
- Les données doivent être nombreuses et fiables : il faut un portefeuille de taille suffisante.

Un autre désavantage, commun aux méthodes agrégées, est qu'il n'est pas possible d'appliquer de la réassurance non proportionnelle pour calculer les réserves cédées.

Il y a également très peu de données disponibles pour les derniers facteurs de développement f_{n-1}, f_{n-2}, etc. De plus, l'estimation de ces derniers facteurs est basée sur des sinistres survenus dans les années de survenance les plus anciennes, dont le développement peut ne plus être représentatif du développement des sinistres survenus récemment.

Le calcul des réserves estimées par la méthode DFM est fortement sensible aux premières valeurs du triangle. Ainsi, une baisse de 1% de la cadence du premier paiement $\frac{C_{i,0}}{\widehat{C}_{i,n}}$ peut entraîner une baisse de 10% de la charge finale estimée [13].

Conclusions sur la bibliographie des méthodes de provisionnement en non-vie

Les méthodes les plus robustes fournissent des estimations fiables dès lors que le système (le jeu de données) semble avoir un comportement constant, au-delà du bruit.

Dans les environnements constants au cours du temps :

- Les méthodes s'appuyant sur les tendances long-terme donnent de meilleurs résultats que celles s'appuyant sur des historiques courts,
- Les méthodes s'appuyant sur l'exposition (comme celle de Bornehuetter-Ferguson) donnent de meilleurs résultats que les méthodes s'appuyant uniquement sur l'étude des sinistres.

Les changements environnementaux sont importants. Il y a toujours des forces qui vont distendre la structure des triangles, et *de facto,* affaiblir la pertinence des méthodes de provisionnement. L'expérience montre que cette variabilité est toujours présente, et que la « stabilité » des triangles est une utopie.

Lorsque les triangles de données révèlent une période de bouleversement, l'application des méthodes de provisionnement sur des données « brut » ne donne pas de bons résultats. Dans ces circonstances, il est important de prendre en considération les changements avant d'appliquer une méthode.

Dans la circonstance où l'actuaire doit fournir une estimation après une période de bouleversement, les méthodes « sans mémoire », ou « à mémoire courte » fournissent de meilleurs résultats.

L'efficacité d'une méthode de provisionnement tient à un type de changement (par exemple la cadence de paiements) et non pas au changement lui-même (par exemple l'accélération ou le ralentissement de cette cadence). Les effets calendaires (comme l'inflation) influencent la justesse des méthodes car elles distordent les triangles. Les effets uniquement liés à l'année de survenance (par exemple une évolution de la sinistralité) n'ont de l'incidence que si l'innovation déforme la cadence (par exemple avec une évolution de la typologie des sinistres).

Le bruit (fluctuations dans les chiffres) doit impérativement être pris en considération pour fournir une estimation pertinente des provisions de sinistres. Dès lors qu'une méthode est déterministe, elle sur-réagit aux fluctuations, ce qui limite la robustesse des résultats. La justesse de ce type de démarche est donc d'autant moins pertinente que le bruit augmente.

L'usage de méthodes indépendantes qui ont des biais opposés est utile, car il est alors possible d'avoir des estimations bien meilleures en combinant les deux résultats en moyenne.

L'horizon d'analyse des prédictions est souvent mésestimé parce que l'actuaire évalue les résultats sur une plage temporelle trop courte. Il s'en suit que des méthodes de provisionnement puisse être écartés alors qu'elles soient meilleures, mais que ceci n'est pas encore visible parce qu'il aurait fallu disposer des résultats sur un bien plus long terme pour s'en persuader.

Les réseaux bayésiens et leur apprentissage

Les éléments bibliographiques concernant les réseaux bayésiens sont tirés de *(Prestat, 2010)*.

Définitions

Soit un graphe dirigé sans circuit (ou « DAG » pour « directed acyclic graph) $G(X, E)$ où $X = \{X_1, X_2, \dots, X_n\}$ est un ensemble de variables (les noeuds du graphe) et E un ensemble d'arcs. On note $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ l'ensemble des distributions de probabilités tel que :

$$\theta_i = P(X_i | P_a(X_i))$$

où $P_a(X_i)$ est l'ensemble des nœuds reliés à X_i par des arcs d'extrémité X_i (les nœuds parents de X_i). Alors on dit que $B(G, \Theta)$ est un réseau bayésien si et seulement si :

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^{i=n} \theta_i$$

Cette décomposition de la loi conjointe de probabilités en un produit de termes locaux est à l'origine de l'attraction suscitée par les réseaux bayésiens. C'est de la compactification de cette loi conjointe de probabilités qu'est né un nombre d'algorithmes permettant le calcul dans un système complexe probabilisé. Ces algorithmes permettent une utilisation typique des réseaux bayésiens : l'inférence.

Les distributions de probabilités associées à chacune des variables du modèle peuvent être soit continues, soit discrètes. Dans ce dernier cas, le comportement des variables discrètes peut être représenté par des tableaux de probabilités conditionnelles relativement aux combinaisons possibles des états des variables « parent ».

Propriétés

Indépendance conditionnelle et d-séparation

L'indépendance conditionnelle

Cette propriété est essentielle dans la compréhension et l'utilisation d'un réseau bayésien. Elle est le fondement de toutes les stratégies de recherche de structure de réseaux à partir d'un jeu de données. Deux variables X et Y représentées dans un graphe G sont conditionnellement indépendantes, si l'observation d'un ensemble de variables Z rend la variable X indépendante de Y. Cela est noté : $X \perp Y | Z$. Ceci revient à dire en terme de probabilités que : $P(X|Y, Z) = P(X|Z)$.

Les trois graphes présentés ci-dessous exposent les schémas d'indépendance conditionnelle. Le premier sur la gauche (a) représente une conformation en chaîne. Le second au centre (b) illustre une même loi jointe de divergence. Le troisième sur la droite (c) encode une loi jointe différente. Cette dernière structure est communément appelée « V-structure ».

Les trois schémas d'indépendance conditionnelle

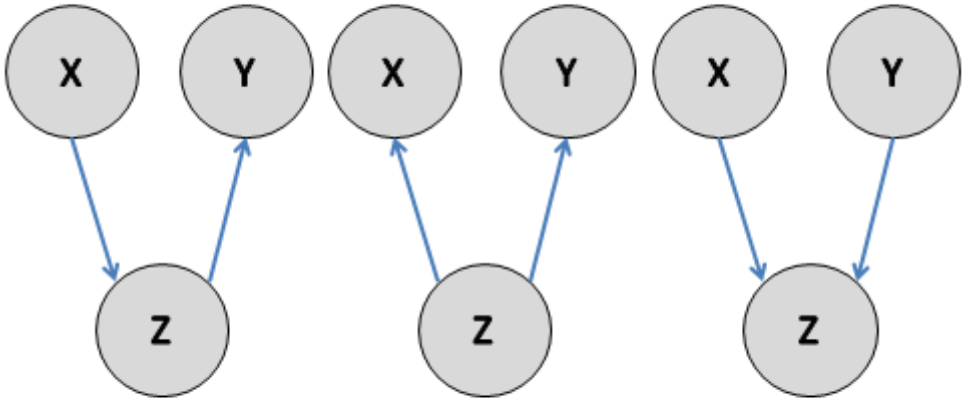

(a) (b) (c)

Dans les exemples illustrés ci-dessus, l'ensemble des variables « intermédiaires » Z a été réduit à une seule variable Z par souci de simplicité. Sur le graphe bayésien représenté en (a), on observe que si X est la seule variable instanciée, cela va mettre à jour la connaissance de Z, ce qui sera répercuté sur Y. X et Y ne sont donc pas indépendantes. Or, lorsque Z est observée, toute modification de X ne changera rien à ce qui est attribué à Y. Ceci permet de comprendre alors la notion d'indépendance conditionnelle.

Toutes ces remarques sont aussi applicables dans le cas (b), qui forme donc un deuxième exemple d'indépendance conditionnelle.

Le cas (c) est quant à lui différent, voire inverse. En effet, si X est seule à être observée, alors la mise à jour de Z ne va pas modifier la « certitude » sur Y. Mais si Z est observée, alors l'observation de X va modifier la connaissance de Y. Si Z représente l'humidité de l'herbe d'une pelouse, que X représente la mise en marche du système d'arrosage, et Y le fait qu'il ait plu. Si Z est dans l'état « très humide », et qu'une information est sortie que les arrosoirs n'ont pas fonctionné depuis deux jours, alors il y a de fortes présomptions sur le fait qu'il ait plu. C'est la dépendance conditionnelle. Il est à noter que cette notion est généralisable à plus de deux enfants dans le cas (b) ou plus de deux parents dans le cas (c).

Si les trois graphes ci-dessus représentent trois réseaux bayésiens, la loi conjointe du cas (a) s'écrit :

$$P(X,Y,Z) = P(X)P(Z|X)P(Y|Z)$$

D'après le théorème des probabilités conditionnelles :

$$P(X)P(Z|X) = P(X \cap Z) = P(Z)P(X|Z)$$

La loi conjointe de (a) peut être écrite ainsi :

$$P(X,Y,Z) = P(Z)P(X|Z)P(Y|Z)$$

La même loi conjointe s'obtient pour le cas (b).

Au contraire, le graphe (c) a une loi conjointe correspondante qui n'est pas identique aux cas (a) et (b) :

$$P(X,Y,Z) = P(X)P(Y)P(Z|X,Y)$$

En pratique, il faut observer des réalisations de la loi conjointe. Pour cette raison, il n'est pas possible de discriminer les cas (a) et (b).

La d-séparation :

Dans un réseau bayésien, deux nœuds X et Y sont d-séparés par un ensemble de variables Z si tous les chemins (sans tenir compte de l'orientation) entre X et Y sont bloqués (en tenant compte de l'orientation). Concrètement, un chemin est bloqué s'il empêche X et Y d'être dépendants, donc si, en se référant à la figure présentant « les trois schémas d'indépendance conditionnelle » :

- dans un chemin de type (a) ou (b), Z est observé,
- dans un chemin de type (c), Z n'est pas observée.

<G,Θ> satisfait la condition de fidélité si les d-séparations en G identifient toutes et exclusivement les indépendances conditionnelles dans Θ, c'est-à-dire

$$X \perp_{\Theta} Y|Z \text{ si et seulement si } X \perp_{G} Y|Z$$

Equivalence de Markov

Les réseaux bayésiens ayant les mêmes lois conjointes de probabilités sont dits équivalents au sens de Markov. Cela signifie qu'ils représentent les mêmes indépendances conditionnelles. Tous les réseaux bayésiens ayant les mêmes nœuds et qui ont la même loi conjointe forment une classe d'équivalence. Tous les graphes d'une classe d'équivalence de réseaux bayésiens ont en commun leur « squelette » (c'est à dire toutes les arêtes non-dirigées) et leurs V-structures.

Causalité

La causalité et sa représentation dans les réseaux bayésiens ne font pas consensus parmi les experts du sujet, car celle-ci n'a pas de fondement ni de définition mathématique. Néanmoins c'est une idée généralement évocatrice, et les notions de graphe causal et de graphe de réseau bayésien peuvent intuitivement être assimilés, c'est pourquoi ils sont nommés par beaucoup « réseaux de causalité ».

Quoiqu'il en soit, il n'est pas ridicule de dire que la causalité a quelque chose à voir avec une action entraînant des changements d'états dans le monde réel. Une manière de mieux cerner

ce qui pourrait correspondre à la notion de causalité est de prendre un exemple avec des variables corrélées A et B. Si le fait de fixer A modifie la croyance en B alors il est possible de dire que A est une cause de B, s'il n'est pas possible de décider de la variable « cause », alors une variable C pouvant être la cause de A et B est recherchée, en se traduisant par une indépendance conditionnelle.

Un autre exemple actuariel est l'irrégularité des cadences de paiement dans un triangle de sinistres. Un ralentissement de paiement à un moment se matérialise par un faible facteur de développement A. Ce faible niveau de paiement sera compensé par une augmentation d'un facteur de développement plus tardif B. B ne peut avoir d'impact sur A qui le précède, par contre une modification de A a une conséquence sur le niveau de B. Cela illustre la notion de « contrôle » inhérente à la causalité. En pratique, un contrôle n'est cependant pas toujours réalisable.

A propos du mot « croyance », les réseaux bayésiens peuvent aussi être nommés « réseaux de croyance » (même s'il ne faut pas y voir pour autant de la métaphysique).

Inférence dans un réseau bayésien

Un réseau bayésien est donc un cadre probabiliste formalisant les indépendances conditionnelles d'un système. La loi des probabilités conditionnelles permet de calculer des probabilités a priori pour toute variable du réseau. Mais ce qui est appelé « l'inférence » dans un réseau bayésien, c'est l'estimation (ou la mise à jour) des distributions de certaines variables lorsque (avec une observation par exemple) des états pour d'autres variables sont fixés.

Certaines variables sont inférées en utilisant la loi des probabilités conditionnelles si la variable instanciée est en amont de la variable à inférer, ou le théorème de Bayes dans le cas inverse. Dans le cas où plusieurs variables sont instanciées, des algorithmes dits de « propagation de messages » existent. Ils mettent en œuvre les théorèmes des probabilités conditionnelles et de Bayes au voisinage des variables instanciées, et propagent à leur tour les résultats de leur mise à jour à leurs voisins et ainsi de suite. Les cas problématiques (réseaux bayésiens de grande dimension) sont traités à l'aide d'heuristiques comme par exemple l'échantillonnage de Gibbs.

Apprentissage de paramètres dans un réseau bayésien

Le problème de l'apprentissage de paramètres dans un réseau bayésien consiste à estimer les distributions de probabilités conditionnelles (donc à remplir tous les tableaux de probabilités conditionnelles) à partir d'un échantillonnage. La méthode à mettre en œuvre est différente selon que le jeu de données est complet ou non.

Un jeu de données est complet quand toutes les épreuves ont été mesurées pour chacune des variables (ce qui est le cas pour cette étude où l'intégralité des triangles de développement est connu).

Les types d'apprentissage non mises en œuvre dans le cadre de cette étude sont présentés en annexe pour mémoire.

Apprentissage de paramètres à partir d'un jeu de données « complet »

Dans ce cas, l'apprentissage des paramètres se trouve être assez simple. Les paramètres les plus vraisemblables correspondent aux fréquences observées dans le jeu de données : c'est l'approche « fréquentiste ». Il est aussi possible, si ces probabilités sont anticipées, de pondérer la vraisemblance avec l'a priori : c'est l'approche bayésienne.

Approche bayésienne

L'approche bayésienne considère une distribution a priori des paramètres. D'après le théorème de Bayes, la probabilité a posteriori est proportionnelle au produit de la probabilité a priori et de la vraisemblance :

$$P(\Theta|D) \propto P(\Theta)L(D|\Theta)$$

Il est possible d'estimer le maximum de vraisemblance à l'aide de la méthode du « maximum a posteriori » (MAP) :

$$\hat{\Theta}^{MAP} = argmax[P(\Theta|D)]$$

Partant de l'hypothèse que les paramètres à estimer suivent une loi multinomiale, il est alors commode d'écrire et de calculer en utilisant des distributions a priori conjuguées, en l'occurrence, la loi de Dirichlet de paramètre α (cette loi est la généralisation multivariée de la loi β, qui est donc elle-même conjuguée à la loi binomiale) :

$$P(\Theta) \propto \prod_{i=1}^{i=n} \prod_{j=1}^{j=q_i} \prod_{k=1}^{k=r_i} \Theta_{ijk}^{\alpha_{ijk}-1}$$

$$P(\Theta|D) \propto \prod_{i=1}^{i=n} \prod_{j=1}^{j=q_i} \prod_{k=1}^{k=r_i} \Theta_{ijk}^{N_{ijk}+\alpha_{ijk}-1}$$

Ceci conduit en passant en log-vraisemblance puis en développant à l'estimateur à :

$$\hat{P}_{MAP}(X_i = x_k|pa(X_i) = x_j) = \frac{N_{ijk} + \alpha_{ijk} - 1}{\sum_{k=1}^{k=r_i} N_{ijk} + \alpha_{ijk} - 1}$$

La méthode du MAP n'est pas la seule méthode bayésienne. Il existe aussi une méthode approchante, celle de l'espérance a posteriori (EAP), où comme son nom l'indique l'espérance est calculée, et non pas le maximum de vraisemblance comme précédemment :

$$\hat{\Theta}^{EAP} = E[P(\Theta|D)]$$

Après une reformulation algébrique, ceci s'écrit :

$$\hat{P}_{EAP}(X_i = x_k | pa(X_i) = x_j) = \frac{N_{ijk} + \alpha_{ijk} - 1}{\sum_{k=1}^{k=r_i}(N_{ijk} + \alpha_{ijk})}$$

Conclusion

Les réseaux bayésiens sont un cadre méthodologique qui semble être adapté au problème de la modélisation de l'irrégularité des cadences de paiements dans les triangles de sinistres.

La description fine des indépendances et dépendances conditionnelles est séduisante quant à la recherche de résultats originaux, car elle dépasse les modèles classiques où sont inférés des comportements relationnels (linéarité… ou non !).

Selon les problématiques, les réseaux bayésiens peuvent être employés pour rechercher les effets de nouvelles observations dans le modèle (inférence), estimer des probabilités conditionnelles (apprentissage des paramètres), ou même rechercher une structure dans des données modélisables par de tels réseaux.

Finalement, ces réseaux qui peuvent être bayésiens permettent l'incorporation de probabilités a priori sur les paramètres ou sur la structure. Grâce à cela il est possible de préciser l'apprentissage en couplant par exemple d'autres méthodes en incluant des connaissances extérieures provenant des experts gestionnaires de sinistres ou des souscripteurs.

L'étude réalisée

Points forts sur le chemin suivi

➔ L'objectif final est d'utiliser des réseaux bayésiens en conjonction avec des triangles de développement pour voir dans quelle mesure il est possible d'améliorer la précision des résultats pour un calcul *sur le trimestre à venir* (calcul de charge à l'ultime).

Pratiquement, cette démarche a été utilisée pour résoudre deux problèmes :

1) Comment améliorer la prédiction du facteur de développement initial à retenir ?
2) Comment fixer une valeur de montant initial pour le trimestre à venir ?

➔ Pour chacun des problèmes, un réseau bayésien particulier est mis en œuvre. Les réseaux bayésiens retenus utilisent des données catégorielles. Ceci est cohérent avec l'usage de l'expert dès lors qu'il se retrouve en situation de choix devant un triangle de facteur de développement. La question essentielle est alors : « le facteur de développement à retenir est-il très fort ? Fort ? Faible ? Très faible ? ». De plus, l'exploitation du réseau bayésien avec des paramètres discrets est plus pratique.

➔ L'apprentissage des réseaux se fait en utilisant deux bases de données en conjonction : base d'expertise et base d'expérience.

- La donnée présente dans les triangles de développement alimente *la base d'expérience.* Les données d'expérience (provenant des triangles) ont été normalisées avant d'être discrétisées (pour éviter les distorsions liées aux tendances temporelles et aux saisonnalité).
- *Une base d'expertise* est construite (qui joue le rôle de loi a priori en analogie avec le discours bayésien) indépendamment des données d'expérience dans les triangles de développement.
  - Les facteurs de développement sont distribués symétriquement avec un pic autour de la moyenne (avec 12,5 % des valeurs « très fortes » et 12,5% des valeurs « très faibles »),
  - Les montants initiaux sont répartis de façon uniforme (autant de « très fort » que de « fort » que de « faible » que de « très faible »).
- Les deux bases sont agrégées pour supporter l'apprentissage des réseaux. Cette agrégation est indispensable pour que les réseaux puissent calculer quelle que soit la combinaison proposée en entrée (car la base d'expertise ne couvre pas tous les cas possibles).
  - L'apprentissage du réseau sous la forme qui vient d'être décrite est un apport personnel : la documentation de l'outil logiciel ne stipule ou ne préconise rien. Seul l'usage de l'outil a démontré qu'il fallait nourrir le réseau pour qu'il puisse répondre de façon systématique. Dans le cas

contraire, le réseau renvoie un message d'erreur s'il ne dispose pas des informations sur lesquels baser ses calculs.

➔ Les résultats obtenus sont comparés :

- Pour les facteurs de développement et les montants initiaux : avec les valeurs effectivement constatées dans les triangles de développement pour les facteurs de développement et les montants initiaux
- Pour les charges à l'ultime : avec le montant obtenu selon l'exploitation classique de la méthode DFM pour les charges à l'ultime) en vigueur chez Allianz Partners:
  - Facteur de développement « canonique »
  - Montant initial calculé en considérant d'une part le montant du trimestre précédent et d'autre part la tendance inter-trimestre observée sur les deux années antérieures (sauf indications particulières).
- La représentation graphique des résultats est systématiquement la même : il y est comparé :
  A) Les résultats observés (provenant des triangles et calculés avec la DFM classique après un trimestre de développement supplémentaire). C'est la référence.
  B) Les résultats obtenus avec les réseaux bayésiens. C'est le candidat
  C) Les résultats obtenus avec le DFM classique sans choix bayésien : c'est la mesure de l'erreur avec la référence.
  - Visuellement, la référence se retrouve centrée dans un canal dont la largeur correspond à l'erreur faite en utilisant la méthode FDM classique. L'appréciation directe que le candidat soit inclus ou non dans le canal permet d'évaluer simplement que le réseau bayésien a mieux fait qu'avec la méthode DFM classique.
  - Quand le candidat test est situé en dehors du canal, la plage des valeurs de la catégorie de résultat est indiquée.

Des explications plus détaillées sont fournies tout au long de la présentation de l'étude et de ses résultats.

Présentation du périmètre

L'étude porte sur le portefeuille d'assistance automobile et d'assistance voyage de la BU Espagne du groupe Allianz Partners. Ce choix est guidé par la bonne représentativité de cette BU pour l'ensemble des activités Non Vie du groupe.

La profondeur d'historique est de huit ans. Les données sont structurées de façon systématique, et conforme au modèle de données actuarielles cible. Il n'est retenu dans cette

étude que le travail sur les triangles de sinistres payés, car ceux-ci s'avère être d'une meilleure robustesse que les triangles de sinistres survenus.

Présentation de la méthode

Démarche à retenir dans un projet d'apprentissage de données sur réseau bayésien

Généralités sur la sélection des modèles et leur évaluation

La performance d'un modèle tient à sa capacité à bien prédire avec des jeux de test indépendants et inconnus. L'évaluation de la performance est extrêmement importante en pratique puisqu'elle guide le choix du modèle, et donne la mesure *in fine* de celui qui est retenu.

Le choix du modèle est guidé par :

- La sélection d'un modèle candidat, en comparant les performances concurrentes des candidats, de façon à retenir le meilleur,
- L'évaluation du modèle, une fois qu'il est retenu, afin d'estimer l'erreur de généralisation dès lors qu'il travaillera sur des données inconnues.

Quand les données disponibles sont importantes, la meilleure approche est de diviser l'ensemble des données en trois parties, pour créer un jeu de données d'entraînement, un jeu de données de validation, et un jeu de données de test. Le premier de jeu de données (entraînement) est utilisé pour caler le modèle, le second jeu de données (validation) est utilisé pour évaluer l'erreur de prédiction pour chacun des modèles en compétition, et le troisième jeu de données (test) est utilisé pour évaluer l'erreur de généralisation sur modèle retenu.

Quand un jeu de données est peu fourni, il existe des scores analytiques (comme l'AIC, le BIC, etc.) qui suppléent à la carence d'un ensemble de validation. Des méthodes complémentaires sont aussi disponibles comme les tests de validation croisée, ou le « bootstrap ».

Application dans la mise en place et l'exploitation du modèle bayésien

Dans le cas de réseaux bayésiens, la construction du réseau se fait en déclarant des nœuds de réseau et des arcs qui les relient. Ensuite, une partie des données sert à produire les tables de probabilités conditionnelles, en excluant naturellement les cas de test.

La validation du modèle se fait en exploitant le réseau bayésien par un exercice d'inférence. Une valeur connue (de test) absente de l'ensemble d'apprentissage est comparée à celle qui est obtenue par inférence. L'écart entre ces deux valeurs permet d'apprécier dans quelle mesure le réseau bayésien est pertinent puisque la valeur prédite est relativement conforme à l'expérience.

Dès lors que la certitude est là, le réseau bayésien peut être exploité pour faire de l'inférence sur des données inconnues. Un test *a posteriori* permet de confirmer que le modèle ne dérive pas (ou reste cantonné dans une mesure acceptable).

Les variables mises en œuvre dans le cadre du modèle

Contextualisation des données utiles dans le cadre du provisionnement chez Allianz Partners

Bien qu'il soit possible d'utiliser un réseau bayésien pour prédire les valeurs de tous les éléments d'un triangle de paiements, il n'est en réalité pas nécessaire de prédire l'ensemble des éléments pour deux raisons.

- Tout d'abord, tous les éléments du triangle n'ont pas le même impact sur le calcul de valorisation de la charge ultime (les facteurs de développement à la queue du triangle jouent un rôle mineur ou marginal en terme de valorisation globale de la charge à l'ultime),
- Ensuite, les queues de triangles mettent à disposition moins de données disponibles pour un mécanisme d'apprentissage bayésien,
- Finalement chaque paramètre supplémentaire à prédire implique la sophistication du modèle (extension du réseau ou augmentation de la taille de la collection de réseaux bayésiens à exploiter). Le principe de parcimonie doit s'appliquer.

En conclusion, les variables les plus signifiantes qui permettent de valoriser la charge à l'ultime (pour le « roll forward ») sont au premier ordre le premier facteur de développement et le montant des paiements réalisés lors de la première période de paiement, et au deuxième ordre, le deuxième facteur de développement qui peut jouer dans une mesure plus marginale…

Présentation des variables utilisées

Les variables utilisées sont les suivantes :

- Trimestre : niveau de granularité temporel pour les clôtures comptables,
- Montant initial : cumul des paiements réalisés dans le premier trimestre de survenance des sinistres,
- F1 : le plus récent des premiers facteurs de développement qui correspond au rapport des paiements constatés en deuxième période de paiement sur les paiements constatés en première période de paiement (calculé sur toute la profondeur d'historique des données disponibles,
- F1minQ : le deuxième plus récent premier facteur de développement (pour apprécier la valeur de F1 telle qu'elle était le trimestre précédent),
- F1min4Q : le cinquième plus récent premier facteur de développement (pour apprécier la valeur de F1 telle qu'elle était un an auparavant),

Catégorisation des données disponibles

Le modèle bayésien retenu pour la présente étude est un modèle catégoriel, car plus simple à mettre en œuvre qu'un modèle à données continues (besoin d'un gisement de données pour que la distribution puisse justement représenter le comportement des données).

La démarche s'effectue en quatre phases :

- Acquisition des données,
- Evaluation du comportement des données retenues,
- Choix d'une catégorisation adaptée (c'est-à-dire la construction d'un nombre approprié de catégories, et la manière *ad hoc* de les peupler),
- Consolidation des données catégorielles dans un tableau final.

Les outils mis en œuvre dans le cadre de l'étude

Le package bnlearn (de M.Scutari) disponible sur R

bnlearn est la bibliothèque (« un package ») de fonctions disponible sur la plateforme logicielle R pour réaliser l'étude. Elle a été utilisée dans sa version 4.4.1.

Sa vocation est de :

- Faire l'apprentissage de réseaux bayésiens (différentes approches de mise en place de nœuds structurés sous la forme de réseau),
- Faire l'estimation des paramètres du réseau,
- Faire des calculs d'inférence dans le réseau ainsi défini.

Construction de la base d'apprentissage

Faire de l'inférence avec un réseau bayésien nécessite d'avoir un modèle de réseau (la structure) et l'ensemble des jeux de probabilités conditionnelles qui vont s'appliquer pour chaque nœud (la conjecture). Deux objectifs se présentent :

- Disposer *systématiquement* d'une capacité de calcul de probabilité pour tous les cas d'inférence, c'est-à-dire avoir systématiquement des valeurs pour toutes les combinatoires possibles de valeurs. En effet, un calcul doit être faisable quel que soit les valeurs des variables d'entrée,
- Disposer de probabilités conditionnelles qui soient pertinentes, c'est-à-dire qui maintiennent les résultats obtenus (résultats d'inférence) dans une zone de tolérance (qui cantonnent l'erreur de test dans une zone acceptable).

Ainsi, dès lors qu'un cas d'inférence est manquant (absent de la base de test), il faut donc nourrir le modèle avec des données synthétiques (construction d'une base d'expertise) qui vont donner une bonne représentativité de la réalité : de cette sorte, tous les cas possibles sont disponibles pour peupler les tables de probabilités conditionnelles, avec la seule contrainte exigée que les résultats soient vraisemblables.

Typiquement, dans le cas de l'étude sur les triangles, cette vraisemblance correspond à ce qui pourrait être obtenu par la méthode DFM, avec ses facteurs de développement et sa distribution des montants de paiement initiaux.

C'est donc de cette sorte que se joue la crédibilité du modèle : avec très peu de données, l'*a priori* devra être très important. A contrario dès lors que la base d'expérience devient riche, il ne sera plus nécessaire de s'appuyer sur de l'expertise. La capacité à contrôler cette crédibilité se fait pratiquement en mélangeant dans des proportions plus ou moins importantes les bases respectivement d'expertise et les bases d'expérience.

Le paragraphe suivant explique comment d'une part ces deux bases sont mises à disposition du modèle, et d'autre part comment elles peuvent être dosées pour ajuster le niveau de crédibilité nécessaire.

La base d'expertise

La base d'expertise correspond fonctionnellement à l'information qui n'est pas issue directement de l'expérience. C'est une information de nature agrégée qui est représentative du comportement attendu dans le cadre de l'étude.

Or, l'observation des informations issues de triangles construits avec la méthode DFM montre que :

- Les valeurs des coefficients de développement se distribuent autour d'une moyenne,
- Les paiements effectués lors de la première période ne suivent pas de tendance particulière (distribution uniforme dans la plage à retenir).

Il faut donc créer de l'information synthétique qui simule ce comportement pour alimenter le réseau bayésien, puisque les données d'expériences ne sont pas systématiquement toutes présentes. Cela constitue la base d'expertise.

Très concrètement, la base d'expertise a été élaborée de la façon suivante :

- Tout d'abord, calculer la taille nécessaire de la base d'expertise. Comme on choisit un modèle avec 4 nœuds, et que chaque nœud peut prendre une valeur selon 4 catégories, alors 256 combinaisons sont possibles, et un jeu de donné distribué de façon uniforme devra porter un multiple de ces 256 combinaisons,
- Ensuite, générer toutes les combinaisons possibles. Des commandes simples avec le logiciel R permettent de fabriquer une telle table,
- Finalement, avoir une idée de la distribution des valeurs telles qu'elles soient observables dans le triangle de données. La solution retenue est de créer une distribution où les catégories extrêmes portent 12,5 % des occurrences, et chacune des deux catégories centrales porte 37,5 % des occurrences (en instanciant trois fois la collection initiale de toute la combinatoire, et en supprimant deux fois sur trois les cas de valeurs d'entrée extrêmum).

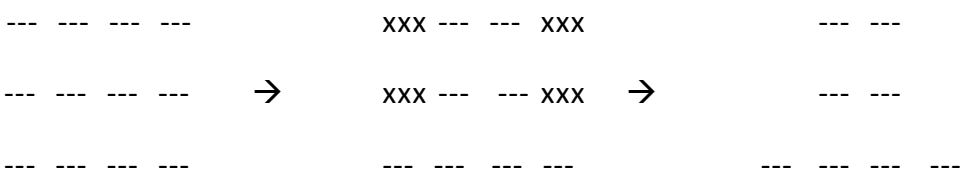

Le code R utilisé pour générer les bases d'expertise est présenté en annexe.

Les bases d'expérience

Acquisition des données

Les données sont originellement disponibles sous la forme de triangles constitués des montants de paiement :

- L'information du trimestre T est aussi facilement dérivable à partir de l'intitulé des périodes de survenance. Dans le cas de l'étude, les triangles sont trimestriels,
- L'information du montant initial est extraite directement des triangles en considérant la première colonne qui correspond aux paiements effectués lors de la première période (ici le trimestre),
- Le premier facteur de développement est naturellement dérivé des triangles cumulatifs de paiements, en considérant, là aussi la première colonne,
- Les autres variables utilisées dans le réseau bayésien sont générées par manipulation des données ci-dessus.

Evaluation du comportement des données

Hormis le trimestre, les autres informations doivent être catégorisées. Les mécanismes de catégorisation sont différents selon que l'on considère le montant de paiement de première période, ou un facteur de développement.

- Pour ce qui concerne les montants de paiement, ils évoluent selon l'activité commerciale au fil des années. Il faut dissocier cette tendance temporelle et les résidus (un modèle linéaire est ici raisonnable, en considérant les données). La catégorisation porte sur ces derniers. *Bien évidemment, une fois que l'exercice d'inférence est fait, il faut réincorporer la tendance à l'instant donné pour disposer de la bonne valorisation du montant initial.* Les résidus ne sont pas uniformément répartis, mais la répartition en quatre catégories est suffisante pour représenter l'ensemble des données
- Pour ce qui concerne le facteur de développement, la découpe de la plage en quatre parties égales est jugée suffisante, car aucune tendance ne se dégage.

Construction des catégories

Tant pour les montants de paiements (ou plutôt leurs résidus) que pour les facteurs de développement, il est retenu la dénomination des quatre catégories suivantes :

- vw : valorisation du premier quartile (très faible),
- w : valorisation du second quartile (faible),

- s : valorisation du troisième quartile (fort),
- vs : valorisation du quatrième quartile (très fort).

Valorisation des prédictions en vue de l'étude actuarielle

Les données disponibles à la source sont catégorisées pour être exploitées dans le réseau. Comme la valeur inférée en sortie est elle aussi catégorielle, il faut donc la retransformer en valeur numérique (avec des hypothèses de valorisation complémentaire) pour qu'elle puisse être exploitable dans le cadre du plan d'étude actuariel (voir ci-dessous).

Plan d'expérience de l'étude actuarielle

Un plan d'expérience est construit. Il vise à évaluer avec la méthode « DFM » l'effet du choix des facteurs F1 et des montants initiaux (avec un modèle bayésien ou par hypothèse classique) sur les indicateurs actuariels classiques (charge ultime, LR, charge ultime B-F, LR-BF).

Les étalons de comparaison sont la méthode « DFM » et les résultats « a posteriori » (observés un trimestre plus tard).

a) Les valorisations suivantes sont donc faites :
   - "DFM" par défaut,
   - Avec un montant initial issue du modèle bayésien et un facteur F1 "classique",
   - Avec un facteur F1 issu du modèle bayésien et un montant initial « classique »,
   - Avec un montant initial et un facteur F1 qui sont tous deux issu de modèle bayésien.

Présentation des résultats de l'étude

Préambule

Les résultats de l'étude sont présentés de la manière suivante :

- Présentation des réseaux bayésiens utilisés,
- Axes d'étude,
- Présentation des résultats d'inférence,
- Utilisation des résultats d'inférence dans le cadre de la méthode DFM,
- Influence du choix bayésien sur les montants initiaux,
- Influence du choix bayésien sur le premier facteur de développement,
- Influence du choix combiné,
- Synthèse.

Les réseaux bayésiens exploités

La méthode étudiée pour calculer les provisions de sinistres est une sophistication de la méthode classique DFM. Les réseaux bayésiens qui sont mis en œuvre ont pour objet :

- D'avoir une valeur du montant de sinistres pour le trimestre à venir (dans le cas de la méthodologie en vigueur "roll-forward",
- D'avoir un facteur de développement initial (qui est le plus important de tous) qui s'avère être pertinent de façon rétrospective.

Deux réseaux sont conçus en respectant chacune de ses raisons. Ils sont présentés ci-dessous :

Réseau exploité pour la détermination des valeurs trimestrielles de montant initial des sinistres

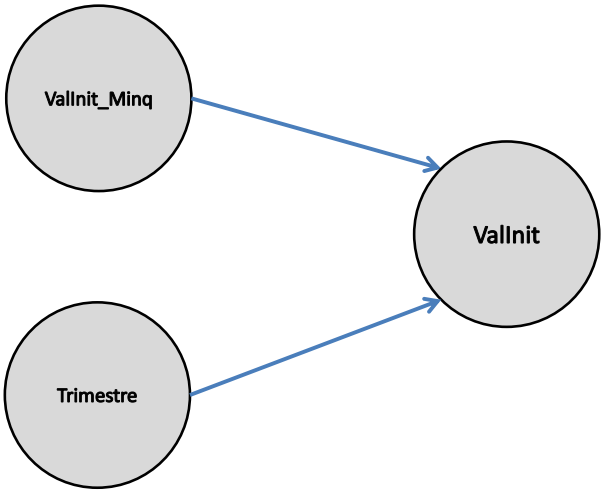

ValInit_Minq : Valorisation Initiale pour le trimestre de survenance précédent
ValInit : Valorisation Initiale pour le trimestre de survenance d'étude
Trimestre : Mention du trimestre pour lequel le montant est constaté

Réseau bayésien pour la détermination des montants initiaux (en première période de paiement)

Les nœuds du réseau sont les suivants :

- ValInit_Minq et ValInit sont les valeurs du montant constaté des sinistres initialement pour deux périodes de survenance successive (cas d'un triangle trimestriel, c'est-à-dire ici pour le trimestre précédent) :
    - ValInit est la première information qui est disponible sur la pointe inférieure gauche d'un triangle de paiement. Elle démarre le développement d'une ligne qui n'est pas encore matérialisée. C'est la ligne sur laquelle l'effort d'investigation est porté, car aucune expérience directe n'y est disponible,
    - ValInit_Minq est la première information disponible sur la deuxième ligne du triangle en partant du bas (la pénultième). C'est la dernière information connue en matière de montants payés pour le démarrage d'un développement de sinistre.

- Trimestre est la mention de la période de l'année pour laquelle a été constaté le montant agrégé ValInit. Ce terme permet d'appréhender les effets de la saisonnalité, et du ralentissement ou de l'accélération de la gestion des sinistres.

Réseau exploité pour la détermination des premiers facteurs de développement

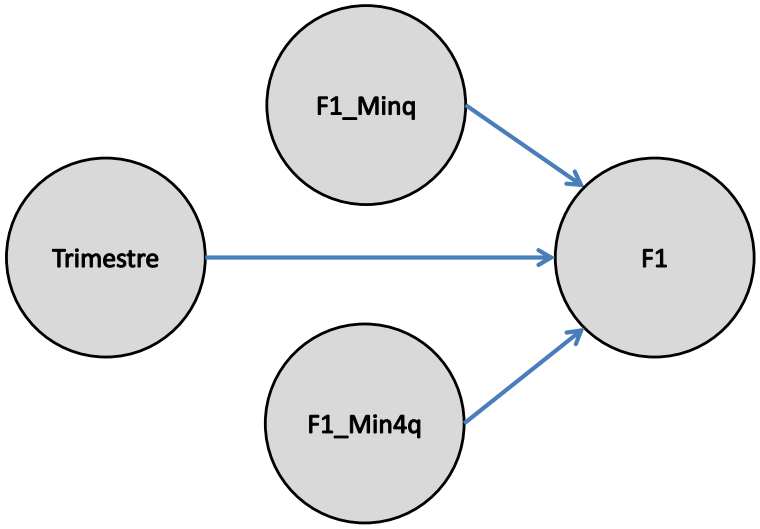

F1_Minq	: Valorisation Initiale pour le trimestre de survenance précédent
F1_4Minq	: Valorisation Initiale pour l'année de survenance précédent
F1	: Valorisation Initiale pour le trimestre de survenance d'étude
Trimestre	: Mention du trimestre pour lequel l'intensité du développement est constaté

Réseau bayésien pour la détermination des premiers facteurs de développement

Les nœuds du réseau sont les suivants :

- F1, F1_Minq et F1_Min4q et sont les valeurs des facteurs de développement initiaux constaté (respectivement pour la dernière période de survenance, la pénultième et celle qui s'est produite un an auparavant) -cas d'un triangle trimestriel-. En considérant un triangle de facteurs de développement :
  - F1 est la première information qui est disponible sur la pointe inférieure gauche d'un triangle de paiement. Elle démarre le développement d'une ligne qui n'est pas encore matérialisée. C'est la ligne sur laquelle l'effort d'investigation est porté, car aucune expérience directe n'y est disponible,
  - F1_Minq est la première information disponible sur la deuxième ligne du triangle en partant du bas (la pénultième). C'est la dernière information connue en matière de montants payés pour le démarrage d'un développement de sinistre. Elle permet d'apprécier l'impact de la conjoncture sur le développement des sinistres,

- F1_Min4q est l'information disponible sur la quatrième ligne du triangle en partant du bas. Elle permet d'apprécier le degré de régularité du développement en regard de la saisonnalité.

- Trimestre est la mention de la période de l'année pour laquelle a été constaté le facteur de développement F1. Ce terme permet d'appréhender l'effet de la saisonnalité sur le facteur de développement.

Axes d'études

Des tables sont créées pour évaluer les données catégorisées qui proviennent des triangles. En effet, le décompte des cas observés (i.e. la base d'expérience) peut indiquer si la distribution obtenue pour les variables mises en œuvre est uniforme ou non. Une manière graphique pour visualiser le comportement des données est l'usage des cartes de chaleur (« heat-map ») qui permettent de voir si les données se concentrent autour des valeurs moyennes. Les coefficients s'apprécient au premier ordre dans le sens de lecture d'une colonne.

Dans le cadre de cette étude, si les zones les plus peuplées sont « w » et « s » quels que soient les trimestres, cela signifie que l'utilisation d'une moyenne (comme dans la classique méthode DFM) est pertinente, et que l'approche des réseaux bayésiens ne donnera pas de gains. A contrario, si les informations ne sont pas systématiquement regroupées autour des valeurs moyennes quels que soient les trimestres, cela veut dire que dans ces cas précis, l'inférence bayésienne devrait apporter des progrès significatifs. Il fait sens de créer ces vues de synthèse qui correspondent aux variables à mettre en œuvre dans les réseaux bayésiens.

Branche d'activité « Voyages » de la BU Espagne

Pour ce qui concerne la branche d'activité « Voyages » de la BU Espagne, les tables de synthèse obtenues sont les suivantes :

Répartition des montants de sinistres initiaux selon les trimestres (impact de la saisonnalité sur les montants initiaux)

Pour la répartition des montants de sinistres initiaux selon les trimestres, il est notable de constater que ceux-ci sont forts lors des deux derniers trimestres de l'année, et plutôt faibles lors des deux premiers trimestres de l'année :

Trimestre\Montant initial	vw	w	s	vs
Q1	7%	4%	7%	7%
Q2	11%	11%	0%	4%
Q3	4%	4%	11%	7%
Q4	7%	0%	11%	7%

Table : répartition par trimestre des intensités de montants initiaux (vw : très faible ; w : faible ; s : fort ; vs : très fort)

Evolution des montants de sinistre vis-à-vis de leur passé récent (impact de la conjoncture sur les montants initiaux)

Pour l'effet de mémoire court terme (ou d'inertie de comportement court terme) en matière de paiement des sinistres initiaux, il est notable de constater que les montants initiaux successifs évoluent *en général* de façon monotone (une valeur très forte ou très faible appelle une valeur de même intensité).

Cependant, une rupture d'intensité peut se produire lorsqu'un montant de paiement initial est très faible. Dans ce cas précis, il y a aussi une probabilité non négligeable de cas pour un scénario où le montant initial devient singulièrement plus important (passage de « vw » à « s »).

Tout ceci indique bien que le comportement des données peut révéler des particularités. De ce fait, l'usage d'un réseau bayésien peut être intéressant.

Montant du trimestre précédent\ Montant du trimestre	vw	w	s	vs
vw	11%	7%	11%	0%
w	7%	0%	4%	7%
s	7%	7%	7%	4%
vs	4%	4%	7%	11%

Table : évolution après un trimestre des intensités de montants initiaux
(première valorisation en ligne, et la suivante en colonne)
(vw : très faible ; w : faible ; s : fort ; vs : très fort)

Répartition des premiers facteurs de développement selon les trimestres (impact de la saisonnalité sur les facteurs de développement)

Pour la répartition des facteurs de développement initiaux selon les trimestres, il est notable de constater que ceux-ci sont forts au quatrième semestre, plutôt faibles lors du premier trimestre, très faibles lors du troisième trimestre. Quelle que soit la période de l'année, ils sont rarement très forts.

Trimestre\F1	vw	w	s	vs
Q1	4%	22%	0%	0%
Q2	0%	15%	7%	4%
Q3	11%	7%	0%	7%
Q4	0%	4%	11%	7%

Table : répartition par trimestre des facteurs de développement initiaux
(vw : très faible ; w : faible ; s : fort ; vs : très fort)

Evolution des premiers facteurs de développement vis-à-vis de leur passé récent (impact de la conjoncture sur les premiers facteurs de développement)

Pour l'impact de la conjoncture en matière d'évolution des premiers facteurs de développement, il est notable de constater que les comportements sont très marqués, car il y a peu de valeur moyenne (indiquées en orange) :

- quand un facteur de développement est plutôt faible, il peut prendre toutes les valeurs possibles, avec plutôt une forte probabilité de reconduire la même intensité,
- quand un facteur de développement est plutôt initialement fort, le suivant sera plus faible,
- quand un facteur de développement est très fort, le suivant sera aussi vraisemblablement très fort.

F1 du trimestre précédent\ F1	vw	w	s	vs
vw	0%	4%	8%	0%
w	12%	23%	12%	4%
s	4%	12%	0%	4%
vs	0%	8%	0%	12%

Table : évolution après un trimestre des facteurs de développement initiaux selon l'intensité initiale (première valorisation en ligne, et la suivante en colonne) (vw : très faible ; w : faible ; s : fort ; vs : très fort)

Evolution des premiers facteurs de développement après une saison (impact de la mémoire de la saisonnalité sur les premiers facteurs de développement)

Pour l'impact de la mémoire de la saisonnalité sur les premiers facteurs de développement (concrètement observer comment le facteur F1 évolue par rapport à sa date anniversaire), deux constats s'imposent :

- l'effet anniversaire joue puisque une intensité donnée a des très fortes probabilités de se reproduire une année plus tard quand l'intensité initiale du facteur de développement n'est pas très forte (c'est-à-dire qu'il ne s'agit pas d'un comportement atypique),
- quand la valeur initiale du facteur de développement est très forte (donc plutôt atypique), elle a tendance à régresser à un niveau radicalement plus faible. C'est une régression qui s'explique aisément puisque cela signifie que l'on revient dans un fonctionnement « moyen ».

F1 de l'année précédente\ F1	vw	w	s	vs
vw	4%	0%	0%	4%
w	9%	30%	4%	9%
s	0%	0%	9%	9%
vs	0%	17%	4%	0%

Table : évolution de l'intensité des facteurs de développement initiaux à la date anniversaire (première valorisation en ligne, et celle à la date anniversaire en colonne) (vw : très faible ; w : faible ; s : fort ; vs : très fort)

Branche d'activité « Automobiles » de la BU Espagne

Pour ce qui concerne la branche d'activité « Voyages » de la BU Espagne, les tables de synthèse obtenues sont les suivantes :

Répartition des montants de sinistres initiaux selon les trimestres (impact de la saisonnalité sur les montants initiaux)

Pour la répartition des montants de sinistres initiaux selon les trimestres, il est notable de constater que :

- Hormis pour le troisième trimestre, les valeurs à attendre sont plutôt moyennes (forte occurrence en « s » ou « w » qui sont les catégories moyennes supérieures et inférieures,
- Au troisième trimestre, une probabilité significative d'avoir un montant initial très fort existe.

Trimestre\Montant initial	vw	w	s	vs
Q1	7%	7%	11%	0%
Q2	4%	11%	7%	4%
Q3	0%	4%	11%	11%
Q4	4%	14%	7%	0%

Table : répartition par trimestre des intensités de montants initiaux
(vw : très faible ; w : faible ; s : fort ; vs : très fort)

Evolution des montants de sinistre vis-à-vis de leur passé récent (impact de la conjoncture sur les montants initiaux)

Pour l'effet de mémoire court terme (ou d'inertie de comportement court terme en matière de paiement des sinistres initiaux, le comportement est très singulier :

- Les données moyennes sont plutôt surreprésentées,
- Les données extrêmes, tant très fortes que très faibles sont sous-représentées. Il est raisonnable de penser que les montants initiaux évaluent de façon monotone.

Montant du trimestre précédent\ Montant du trimestre	vw	w	s	vs
vw	7%	4%	4%	0%
w	7%	11%	15%	4%
s	0%	15%	11%	7%
vs	0%	4%	7%	4%

Table : évolution après un trimestre des intensités de montants initiaux
(première valorisation en ligne, et la suivante en colonne)
(vw : très faible ; w : faible ; s : fort ; vs : très fort)

Répartition des premiers facteurs de développement selon les trimestres (impact de la saisonnalité sur les facteurs de développement)

Pour la répartition des facteurs de développement initiaux selon les trimestres, les deux faits notables sont :

- Les premiers facteurs de développement sont en général plutôt très faibles au premier trimestre,
- Les premiers facteurs de développement sont en général plutôt forts au quatrième trimestre,

- Il est difficile de présumer de la valeur du premier facteur de développement lors de la mi- année (pour les deuxième et troisième trimestres).

Trimestre\F1	vw	w	s	vs
Q1	15%	4%	7%	0%
Q2	7%	7%	7%	4%
Q3	7%	7%	4%	7%
Q4	0%	7%	11%	4%

Table : répartition par trimestre des facteurs de développement initiaux
(vw : très faible ; w : faible ; s : fort ; vs : très fort)

Evolution des premiers facteurs de développement vis-à-vis de leur passé récent (impact de la conjoncture sur les premiers facteurs de développement)

Pour l'impact de la conjoncture en matière d'évolution des premiers facteurs de développement, il y a deux points remarquables :

- Un facteur de développement très faible appelle à sa suite un trimestre plus tard un facteur de développement également très faible, ou bien légèrement plus important. Ceci se produit assez fréquemment,
- Un facteur de développement très fort appelle à sa suite un trimestre plus tard un facteur de développement également très fort. Ceci se produit plutôt rarement.

F1 du trimestre précédent\ F1	vw	w	s	vs
vw	12%	12%	8%	8%
w	8%	8%	12%	4%
s	8%	8%	8%	0%
vs	0%	0%	4%	4%

Table : évolution après un trimestre des facteurs de développement initiaux selon l'intensité initiale
(première valorisation en ligne, et la suivante en colonne)
(vw : très faible ; w : faible ; s : fort ; vs : très fort)

Evolution des premiers facteurs de développement après une saison (impact de la mémoire de la saisonnalité sur les premiers facteurs de développement)

Pour l'impact de la mémoire de la saisonnalité sur les premiers facteurs de développement (concrètement observer comment le facteur F1 évolue par rapport à sa date anniversaire), deux constats s'imposent :

- les données moyennes sont plutôt surreprésentées,
- les données extrêmes, tant très fortes que très faibles sont sous-représentées, à l'exception d'un facteur de développement initial très faible
- il est raisonnable de penser qu'en général, les facteurs de développement initiaux évaluent de façon monotone.

F1 de l'année précédente\ F1	vw	w	s	vs
vw	9%	13%	0%	4%
w	4%	4%	13%	4%
s	4%	9%	13%	4%
vs	4%	0%	9%	4%

Table : évolution de l'intensité des facteurs de développement initiaux à la date anniversaire (première valorisation en ligne, et celle à la date anniversaire en colonne) (vw : très faible ; w : faible ; s : fort ; vs : très fort)

Synthèse

L'étude des triangles des branches d'activité « Voyages » et « Automobile » indique que des comportements se dégagent, même si ceux-ci ne sont pas systématiques. Il est à attendre, au vu de ces tables préliminaires, que l'inférence bayésienne pourra, selon les configurations, amener un gain en comparaison de l'exploitation du comportement moyen qui est la référence de la méthode DFM. A ce titre, il fait sens d'utiliser de façon concomitante deux réseaux différents pour faire levier à la fois sur les montants (intensité dans le triangle) et sur le premier facteur de développement (forme plus ou moins accentuée du développement dans le triangle).

Présentation des résultats d'inférence

Comme les tables précédentes indiquent que l'usage de réseaux bayésiens est pertinent, les deux réseaux présentés ont été exploités. Ceci a permis de calculer par inférence des distributions de probabilités sur (1) le premier montant des sinistres payés par période de survenance, et (2) le premier facteur de développement.

Une table est construite pour répertorier tous les calculs faits dans les réseaux. Elle consolide tous les éléments qui vont faire ensuite le lien entre les résultats actuariels et les dimensions d'analyse. La structure de la table des résultats d'inférence est présentée en annexe.

Ces résultats s'inscrivent dans une catégorie, puisque c'est la nature du réseau. Il faut ensuite se livrer à l'exercice inverse de dé-catégorisation pour disposer de nombres qui soient exploitables pour des calculs actuariels. Les quatre types de valorisation sont les suivants :

1. Recalculer l'espérance de la valeur en s'appuyant sur d'une part les probabilités dans chaque catégorie (leur poids), et d'autre part sur la valeur médiane de chaque catégorie (elle sert de pivot et minimise l'erreur à prendre une valeur en moyenne),
2. Considérer uniquement la catégorie pour laquelle la probabilité a été la plus forte, et assigner la valeur médiane de cette catégorie comme résultat,
3. Considérer uniquement la catégorie pour laquelle la probabilité a été la plus forte, et assigner la valeur minimale de cette catégorie comme résultat,
4. Considérer uniquement la catégorie pour laquelle la probabilité a été la plus forte, et assigner la valeur maximale de cette catégorie comme résultat.

Ces quatre possibilités ont été explorées parce que retenir uniquement une valeur médiane présuppose que les données soient distribuées de manière uniforme dans la catégorie, ce qui est vraisemblablement le cas sur les catégories centrales, mais pas sur les catégories marginales où les données devraient naturellement régresser vers le centre. Ceci permettra donc de voir de potentiels impacts.

Particularités liées au mécanisme de dé-catégorisation

Pour mémoire, lors de la catégorisation des montants initiaux, la valorisation est indirecte en prenant en compte les tendances saisonnières et la tendance de moyen terme. Par conséquent, quand il s'agit de revenir à une valorisation à partir d'une catégorie, il faut aussi recourir au mécanisme inverse pour donner une valeur. Le détail du processus de calcul est présenté en annexe.

Utilisation des résultats d'inférence

Les valeurs dé-catégorisées (montant initial par période de survenance ou premier facteur de développement) sont ensuite disponibles directement pour faire une comparaison avec les valeurs obtenues *a posteriori*, ou bien elles peuvent être injectées comme variables dans les méthodes actuarielles pour observer l'effet sur les variables finales d'intérêt (charge à l'ultime associée -selon DFM ou Bornehueter-Ferguson-, et ratio sinistres sur primes associé).

Une table est construite pour répertorier toutes les informations de natures actuarielles (charge à l'ultime, ratio sinistres sur primes), en lien avec les tests bayésiens réalisés (et leurs dimensions d'analyse). Les résultats exhaustifs sont consultables en annexe.

Enjeu d'étude

Il est possible de jouer les méthodes actuarielles DFM ou Bornehueter-Ferguson avec:

- Le montant initial bayésien, et des facteurs de développement du DFM classiques,
- Le facteur F1 bayésien, et de conserver le paiement initial d'hypothèse retenue dans le DFM classique, ainsi que les autres facteurs de développement.
- La combinaison de ces deux variables bayésiennes en entrée (avec deux réseaux bayésiens à niveau de crédibilité identique).

Ceci permet d'apprécier les résultats par :

- Thématique d'étude simple (répondre aux questions « quelle est l'incidence de ce réseau bayésien RB1 pour déterminer la valeur du montant initial ? » ou « quelle est l'incidence de ce réseau bayésien RB2 pour déterminer la valeur du premier facteur de développement? »)
- Par thématique d'étude complexe (répondre à la question « quelle est l'incidence de ces réseaux bayésien RB1 et RB2 pour déterminer la valeur de la charge à l'ultime, ou bien le ratio sinistres sur primes ? »).

Présentation des résultats

Les résultats sont présentés par branche d'activité (assistance voyage, puis assistance automobile) de façon systématique pour apprécier l'incidence de la crédibilité et du parti-pris de valorisation dans les catégories.

Les résultats sont systématiquement présentés en exhibant :

- Un tableau de synthèse qui présente les valorisations pour tous les cas d'étude mentionnés en abscisse.
- Un tableau de synthèse qui montre dans quel cas le réseau est plus précis que l'évaluation classique
- Un graphique illustratif pour la meilleure calibration observée

Influence du choix bayésien sur les montants initiaux

Résultats pour l'assistance voyage

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	2019Q1
Valeurs observées à 2019 Q2	173	254	421	178	211	226	379	176	152
Borne supérieure canal DFM	192	310	465	261	262	230	408	216	170
Borne inférieure canal DFM	154	197	378	95	161	222	349	137	133
Test Crédibilité 1/1 avec valorisation des catégories "1"	208	205	397	193	185	189	410	181	178
Test Crédibilité 1/1 avec valorisation des catégories "2"	221	218	429	139	173	170	417	164	161
Test Crédibilité 1/1 avec valorisation des catégories "3"	239	236	397	158	191	188	385	182	179
Test Crédibilité 1/1 avec valorisation des catégories "4"	203	200	461	121	155	152	449	146	143
Test Crédibilité 1/10 avec valorisation des catégories "1"	204	201	396	193	189	188	394	182	180
Test Crédibilité 1/10 avec valorisation des catégories "2"	221	218	365	212	173	206	417	200	197
Test Crédibilité 1/10 avec valorisation des catégories "3"	239	236	333	230	191	224	385	219	216
Test Crédibilité 1/10 avec valorisation des catégories "4"	203	200	397	194	155	188	449	182	179
Test Crédibilité 10/1 avec valorisation des catégories "1"	217	214	396	193	176	187	415	181	180
Test Crédibilité 10/1 avec valorisation des catégories "2"	221	218	365	139	173	170	417	164	197
Test Crédibilité 10/1 avec valorisation des catégories "3"	239	236	333	158	191	188	385	182	216
Test Crédibilité 10/1 avec valorisation des catégories "4"	203	200	397	121	155	152	449	146	179

Valorisation des montants initiaux en assistance voyage, par trimestre et par test (k€)

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	Efficacité
Test Crédibilité 1/1 avec valorisation des catégories "1"	0	1	1	1	1	0	0	1	63%
Test Crédibilité 1/1 avec valorisation des catégories "2"	0	1	1	1	1	0	0	1	63%
Test Crédibilité 1/1 avec valorisation des catégories "3"	0	1	1	1	1	0	1	1	75%
Test Crédibilité 1/1 avec valorisation des catégories "4"	0	1	1	1	0	0	0	1	50%
Test Crédibilité 1/10 avec valorisation des catégories "1"	0	1	1	1	1	0	1	1	75%
Test Crédibilité 1/10 avec valorisation des catégories "2"	0	1	0	1	1	0	0	1	50%
Test Crédibilité 1/10 avec valorisation des catégories "3"	0	1	0	1	1	1	1	0	63%
Test Crédibilité 1/10 avec valorisation des catégories "4"	0	1	1	1	0	0	0	1	50%
Test Crédibilité 10/1 avec valorisation des catégories "1"	0	1	1	1	1	0	0	1	63%
Test Crédibilité 10/1 avec valorisation des catégories "2"	0	1	0	1	1	0	0	1	50%
Test Crédibilité 10/1 avec valorisation des catégories "3"	0	1	0	1	1	0	1	1	63%
Test Crédibilité 10/1 avec valorisation des catégories "4"	0	1	1	1	0	0	0	1	50%

Synopsis des cas d'amélioration (« 1 signifie 'amélioration' ») dans la prédiction des montants initiaux d'assistance voyage (par trimestre et par test)

Dans le cas de l'assistance voyage, deux calibrations permettent d'avoir une efficacité à 75%. Une de celles-ci est présentée ci-dessous.

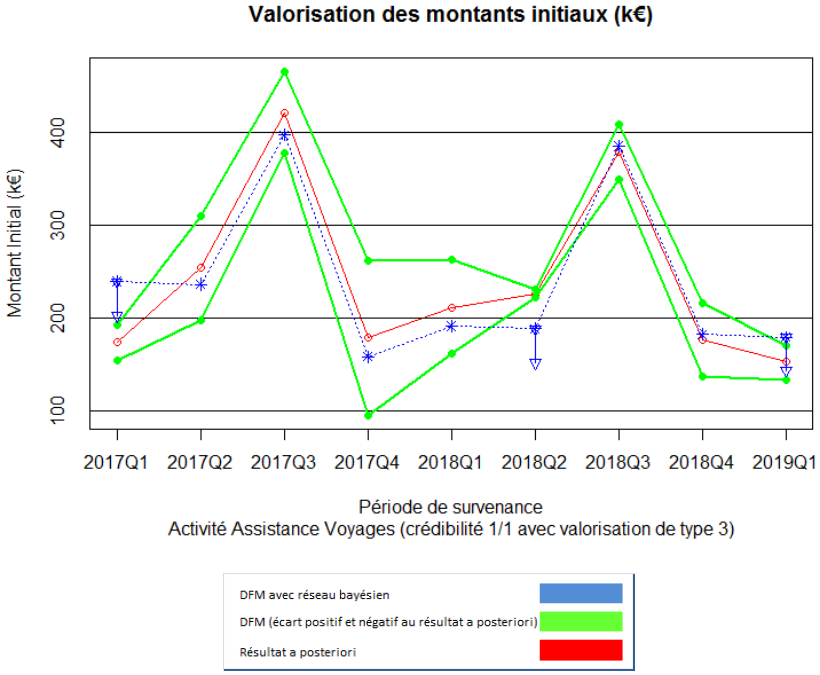

Résultats pour l'assistance automobile

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	2019Q1
Valeurs observées à 2019 Q2	6 247	6 494	8 035	7 561	8 596	9 225	9 539	8 044	8 933
Borne supérieure canal DFM	6 514	6 920	8 540	8 481	9 208	9 701	10 154	8 589	9 318
Borne inférieure canal DFM	5 981	6 068	7 531	6 642	7 984	8 749	8 925	7 499	8 547
Test Crédibilité 1/1 avec valorisation des catégories "1"	7 567	7 390	7 684	7 561	7 638	7 936	8 013	8 070	8 165
Test Crédibilité 1/1 avec valorisation des catégories "2"	7 122	7 184	7 246	7 308	8 275	8 398	9 368	8 460	8 521
Test Crédibilité 1/1 avec valorisation des catégories "3"	6 718	6 779	6 841	6 903	7 774	7 898	8 898	7 959	8 021
Test Crédibilité 1/1 avec valorisation des catégories "4"	7 527	7 589	7 651	7 712	8 775	8 898	9 837	8 960	9 022
Test Crédibilité 1/10 avec valorisation des catégories "1"	7 658	7 620	7 806	7 763	7 792	7 916	7 936	8 077	8 113
Test Crédibilité 1/10 avec valorisation des catégories "2"	8 998	7 184	7 651	7 308	8 275	8 336	8 398	8 460	8 521
Test Crédibilité 1/10 avec valorisation des catégories "3"	8 528	6 779	8 652	6 903	7 774	7 836	7 898	7 959	8 021
Test Crédibilité 1/10 avec valorisation des catégories "4"	9 467	7 589	8 652	7 712	8 775	8 837	8 898	8 960	9 022
Test Crédibilité 10/1 avec valorisation des catégories "1"	7 713	7 218	7 718	7 341	7 411	7 877	7 947	8 015	8 444
Test Crédibilité 10/1 avec valorisation des catégories "2"	8 998	7 184	6 841	7 308	7 369	7 431	6 683	8 460	8 521
Test Crédibilité 10/1 avec valorisation des catégories "3"	8 528	6 779	7 651	6 903	6 964	7 026	6 278	7 959	8 021
Test Crédibilité 10/1 avec valorisation des catégories "4"	9 467	7 589	7 651	7 712	7 774	7 836	7 088	8 960	9 022

Valorisation des montants initiaux en assistance automobile, par trimestre et par test (k€)

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	2019Q1	Efficacité
Test Crédibilité 1/1 avec valorisation des catégories "1"	0	0	1	1	0	0	0	1	0	33%
Test Crédibilité 1/1 avec valorisation des catégories "2"	0	0	0	1	1	0	1	1	0	44%
Test Crédibilité 1/1 avec valorisation des catégories "3"	0	1	0	1	0	0	0	1	0	33%
Test Crédibilité 1/1 avec valorisation des catégories "4"	0	0	1	1	1	1	1	0	1	67%
Test Crédibilité 1/10 avec valorisation des catégories "1"	0	0	1	1	0	0	0	1	0	33%
Test Crédibilité 1/10 avec valorisation des catégories "2"	0	0	1	1	1	0	0	1	0	44%
Test Crédibilité 1/10 avec valorisation des catégories "3"	0	1	0	1	0	0	0	1	0	33%
Test Crédibilité 1/10 avec valorisation des catégories "4"	0	0	0	1	1	1	0	0	1	44%
Test Crédibilité 10/1 avec valorisation des catégories "1"	0	0	1	1	0	0	0	1	0	33%
Test Crédibilité 10/1 avec valorisation des catégories "2"	0	0	0	1	0	0	0	1	0	22%
Test Crédibilité 10/1 avec valorisation des catégories "3"	0	1	1	1	0	0	0	1	0	44%
Test Crédibilité 10/1 avec valorisation des catégories "4"	0	0	1	1	0	0	0	0	1	33%

Synopsis des cas d'amélioration (« 1 signifie 'amélioration' ») dans la prédiction des montants initiaux d'assistance automobile (par trimestre et par test)

Dans le cas précis de l'assistance automobile, une calibration apporte une efficacité de 67%

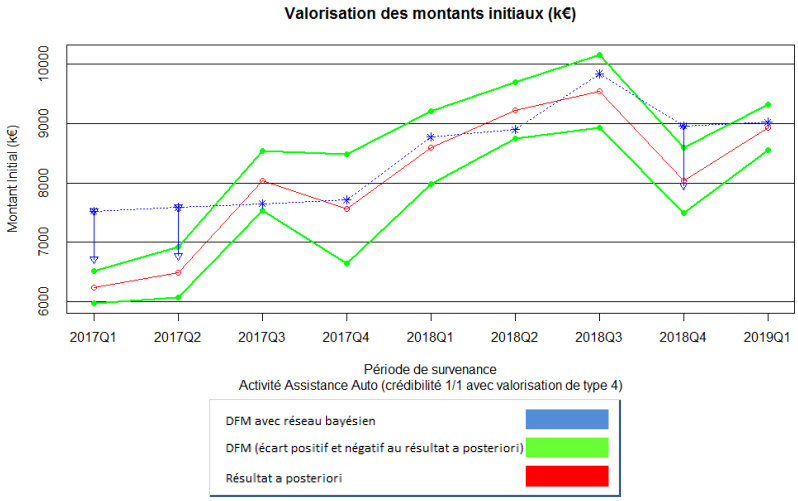

Discussion des résultats

Tout d'abord, il faut constater que le paramétrage du réseau a une forte incidence sur la précision des résultats. Cette calibration est un enjeu fort pour obtenir de façon régulière des résultats plus pertinent qu'une méthode « en espérance » comme la méthode DFM.

En effet, s'appuyer sur un réseau bayésien revient à s'en remettre à des tables conditionnelles de probabilités. Des tirages défavorables peuvent se produire (même s'ils sont improbables) qui vont donner l'impression que le réseau bayésien est moins efficace que la méthode DFM (c'est à dire se situer en dehors du canal symbolisé par l'écart entre les valeurs réellement observées *in fine* et les valeurs obtenues selon la méthode DFM).

La détermination de valeurs de montants initiaux pour l'assistance voyage à partir des réseaux bayésiens est efficace, car elle permet ici de battre au moins une fois sur deux la méthode DFM, quel que soit le paramétrage. Pour les meilleurs paramétrages, le taux de réussite est de 75%. Cependant, il est aussi remarquable que ces résultats ne sont pas identiques pour le cas de l'assistance automobile. Les deux pistes possibles envisageables sont que :

- L'assistance automobile est une activité beaucoup plus régulière par nature (tant du point de vue des coûts de sinistres que du point de vue de la fréquence). Cette régularité donne une espèce de prime à la valeur moyenne. Or même si cette information est aussi confirmée par le réseau, le passage de la catégorie à une donnée chiffrée introduit naturellement un biais qui disqualifie le réseau bayésien modélisé en catégories (le réseau et son paramétrage dans cette étude),
- Le jeu d'essai n'a pas montré en l'état assez de récurrences remarquables sur lequel le réseau pouvait s'appuyer pour construire des probabilités conditionnelles différenciées. Par conséquent le réseau ne peut pas battre une banale méthode en espérance comme la méthode DFM.

Il est naturel que la valeur moyenne puisse être à la fois une valeur candidate, et une valeur qui est effectivement obtenue. C'est ce qui s'est produit typiquement pour 2018Q2 (le

second trimestre de l'année 2018) dans le cas de la branche d'activité Assistance voyage. L'écart entre la valeur obtenue (226 k€) et la valeur obtenue pour la méthode DFM (moyenne mobile pondérée) (222 k€) est de 4k€. Dans cette circonstance, la largeur du canal entre la méthode DFM et la valeur réelle est de 8k€. Il est dans ce cas précis pratiquement impossible de se retrouver à l'intérieur du canal.

Le traitement de l'information « par catégorie » amène à prendre un parti-pris de valorisation « dans la catégorie » pour revenir à des valeurs numériques. Pour apprécier la justesse du réseau bayésien (qui s'exprime dans le langage des catégories), il faut donc indiquer la plage de tolérance qui correspond à la zone des valeurs potentiellement atteignables dans la catégorie, pour chacun des tirages. C'est la raison pour laquelle le graphe indique cette tolérance (segment vertical terminé par des petits triangles) de façon visuelle.

En guise de dernier mot, il est notable de constater que le réseau bayésien donne un résultat meilleur pour l'assistance voyage que pour l'assistance automobile en matière de prédiction des montants initiaux.

Influence du choix bayésien sur les facteurs de développement

Résultats pour l'assistance voyage

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4
Valeurs observées à 2019 Q2	2,443	2,312	2,192	2,586	2,030	2,255	1,753	2,362
Borne supérieure canal DFM	2,556	2,551	2,541	2,599	2,556	2,551	2,541	2,533
Borne inférieure canal DFM	2,329	2,073	1,843	2,573	1,503	1,958	0,965	2,192
Test Crédibilité 1/1 avec valorisation des catégories "1"	2,329	2,357	2,354	2,524	2,274	2,378	2,223	2,712
Test Crédibilité 1/1 avec valorisation des catégories "2"	2,311	2,311	2,311	2,311	2,311	2,311	1,939	2,745
Test Crédibilité 1/1 avec valorisation des catégories "3"	2,125	2,125	2,125	2,125	2,125	2,125	1,753	2,497
Test Crédibilité 1/1 avec valorisation des catégories "4"	2,497	2,497	2,497	2,497	2,497	2,497	2,125	2,993
Test Crédibilité 1/10 avec valorisation des catégories "1"	2,476	2,311	2,495	2,531	2,461	2,502	2,469	2,602
Test Crédibilité 1/10 avec valorisation des catégories "2"	2,311	2,311	2,311	2,311	2,311	2,311	2,745	2,745
Test Crédibilité 1/10 avec valorisation des catégories "3"	2,125	2,125	2,125	2,125	2,125	2,125	2,497	2,497
Test Crédibilité 1/10 avec valorisation des catégories "4"	2,497	2,497	2,497	2,497	2,497	2,497	2,993	2,993
Test Crédibilité 10/1 avec valorisation des catégories "1"	2,315	2,321	2,318	2,540	2,203	2,315	1,983	2,746
Test Crédibilité 10/1 avec valorisation des catégories "2"	2,311	2,311	2,311	2,745	2,311	2,311	1,939	2,745
Test Crédibilité 10/1 avec valorisation des catégories "3"	2,125	2,125	2,125	2,497	2,125	2,125	1,753	2,497
Test Crédibilité 10/1 avec valorisation des catégories "4"	2,497	2,497	2,497	2,993	2,497	2,497	2,125	2,993

Valorisation des premiers facteurs de développement en assistance voyage, par trimestre et par test

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	Efficacité
Test Crédibilité 1/1 avec valorisation des catégories "1"	0	1	1	0	1	1	1	0	63%
Test Crédibilité 1/1 avec valorisation des catégories "2"	0	1	1	0	1	1	1	0	63%
Test Crédibilité 1/1 avec valorisation des catégories "3"	0	1	1	0	1	1	1	1	75%
Test Crédibilité 1/1 avec valorisation des catégories "4"	1	1	1	0	1	1	1	0	75%
Test Crédibilité 1/10 avec valorisation des catégories "1"	1	1	1	0	1	1	1	0	75%
Test Crédibilité 1/10 avec valorisation des catégories "2"	0	1	1	0	1	1	0	0	50%
Test Crédibilité 1/10 avec valorisation des catégories "3"	0	1	1	0	1	1	1	1	75%
Test Crédibilité 1/10 avec valorisation des catégories "4"	1	1	1	0	1	1	0	0	63%
Test Crédibilité 10/1 avec valorisation des catégories "1"	0	1	1	0	1	1	1	0	63%
Test Crédibilité 10/1 avec valorisation des catégories "2"	0	1	1	0	1	1	1	0	63%
Test Crédibilité 10/1 avec valorisation des catégories "3"	0	1	1	0	1	1	1	1	75%
Test Crédibilité 10/1 avec valorisation des catégories "4"	1	1	1	0	1	1	1	0	75%

Synopsis des cas d'amélioration (« 1 signifie 'amélioration' ») dans la prédiction des premiers facteurs de développement, pour l'assistance voyage (par trimestre et par test)

Dans le cas précis de l'assistance voyage, six calibrations apporte nt une efficacité de 75%. Une de celles-ci est présentée ci-dessous.

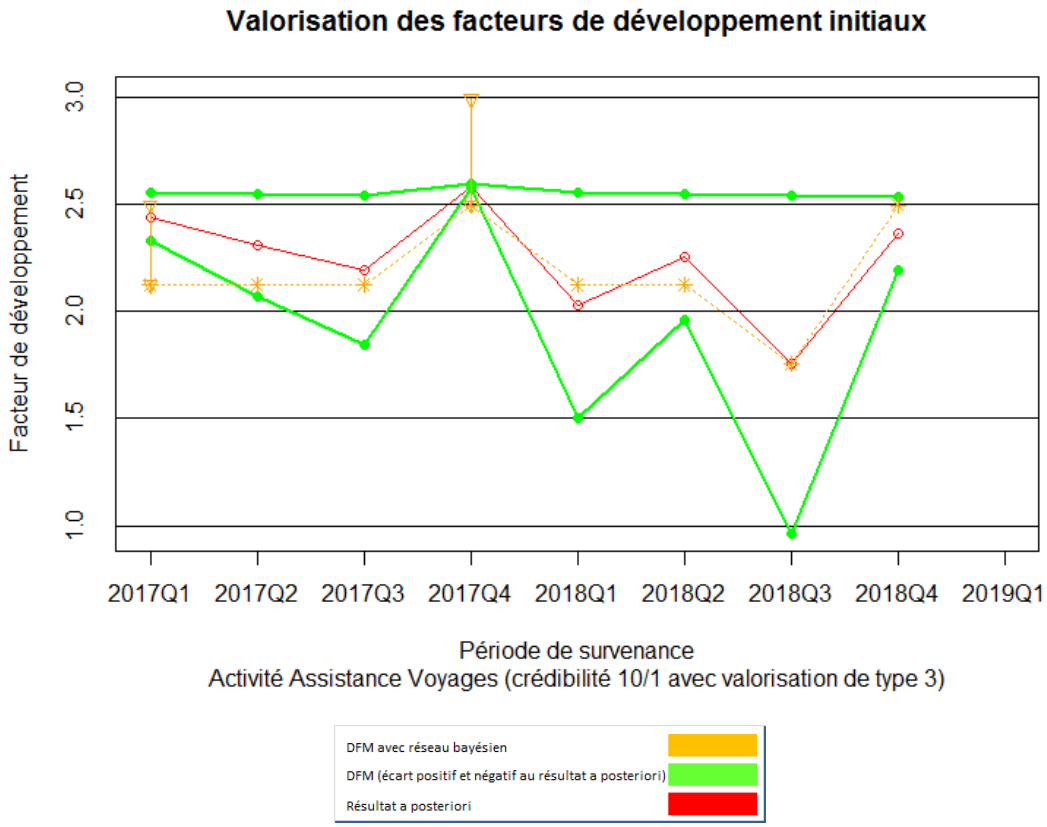

Résultats pour l'assistance automobile

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4
Valeurs observées à 2019 Q2	1,547	1,698	1,594	1,470	1,245	1,256	1,449	
Borne supérieure canal DFM	1,600	1,905	1,714	1,493	1,494	1,491	1,474	
Borne inférieure canal DFM	1,494	1,491	1,474	1,448	0,995	1,022	1,423	
Test Crédibilité 1/1 avec valorisation des catégories "1"	1,507	1,489	1,495	1,505	1,485	1,505	1,500	1,487
Test Crédibilité 1/1 avec valorisation des catégories "2"	1,556	1,556	1,299	1,743	1,408	1,408	1,299	1,556
Test Crédibilité 1/1 avec valorisation des catégories "3"	1,462	1,462	1,245	1,649	1,354	1,354	1,245	1,462
Test Crédibilité 1/1 avec valorisation des catégories "4"	1,649	1,649	1,354	1,837	1,462	1,462	1,354	1,649
Test Crédibilité 1/10 avec valorisation des catégories "1"	1,494	1,485	1,500	1,494	1,482	1,506	1,503	1,492
Test Crédibilité 1/10 avec valorisation des catégories "2"	1,408	1,556	1,556	1,299	1,408	1,743	1,408	1,556
Test Crédibilité 1/10 avec valorisation des catégories "3"	1,354	1,462	1,462	1,245	1,354	1,649	1,354	1,462
Test Crédibilité 1/10 avec valorisation des catégories "4"	1,462	1,649	1,649	1,354	1,462	1,837	1,462	1,649
Test Crédibilité 10/1 avec valorisation des catégories "1"	1,492	1,486	1,499	1,497	1,482	1,502	1,504	1,486
Test Crédibilité 10/1 avec valorisation des catégories "2"	1,408	1,556	1,408	1,299	1,408	1,743	1,743	1,408
Test Crédibilité 10/1 avec valorisation des catégories "3"	1,354	1,462	1,354	1,245	1,354	1,649	1,649	1,354
Test Crédibilité 10/1 avec valorisation des catégories "4"	1,462	1,649	1,462	1,354	1,462	1,837	1,837	1,462

Valorisation des premiers facteurs de développement en assistance automobile, par trimestre et par test

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	Efficacité
Test Crédibilité 1/1 avec valorisation des catégories "1"	1	0	1	0	1	0	0	43%
Test Crédibilité 1/1 avec valorisation des catégories "2"	1	1	0	0	1	1	0	57%
Test Crédibilité 1/1 avec valorisation des catégories "3"	0	0	0	0	1	1	0	29%
Test Crédibilité 1/1 avec valorisation des catégories "4"	0	1	0	0	1	1	0	43%
Test Crédibilité 1/10 avec valorisation des catégories "1"	0	0	1	0	1	0	0	29%
Test Crédibilité 1/10 avec valorisation des catégories "2"	0	1	1	0	1	0	0	43%
Test Crédibilité 1/10 avec valorisation des catégories "3"	0	0	0	0	1	0	0	14%
Test Crédibilité 1/10 avec valorisation des catégories "4"	0	1	1	0	1	0	1	57%
Test Crédibilité 10/1 avec valorisation des catégories "1"	0	0	1	0	1	0	0	29%
Test Crédibilité 10/1 avec valorisation des catégories "2"	0	1	0	0	1	0	0	29%
Test Crédibilité 10/1 avec valorisation des catégories "3"	0	0	0	0	1	0	0	14%
Test Crédibilité 10/1 avec valorisation des catégories "4"	0	1	0	0	1	0	0	29%

Synopsis des cas d'amélioration (« 1 signifie 'amélioration' ») dans la prédiction des premiers facteurs de développement, pour l'assistance automobile (par trimestre et par test)

Dans le cas précis de l'assistance automobile, deux calibrations apportent une efficacité de 57%. Une de celle-ci est présentée ci-dessous.

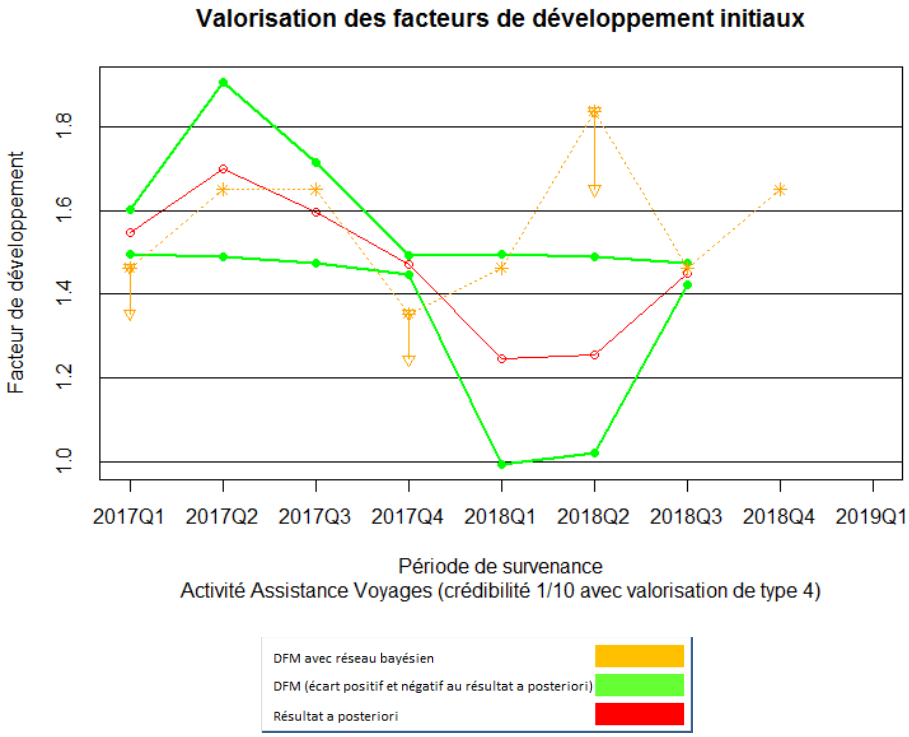

Discussion des résultats

Les résultats obtenus appellent des commentaires analogues à ceux indiqués pour l'utilisation de réseaux bayésiens pour les montants initiaux. A savoir :

- Les résultats obtenus pour l'assistance automobile et pour l'assistance voyage ne sont pas les mêmes. La prédiction est ici meilleure pour l'assistance automobile,
- Il y a une sensibilité à la calibration du réseau bayésien mis en œuvre. Il faut choisir un bon réglage pour obtenir un bon résultat,
- L'efficacité du réseau est vraisemblablement limitée par la base d'expérience. Le réseau bayésien sera d'autant plus être capable de faire de bonnes prédictions que des schémas informationnels émergent des données,
- L'effet de proximité de la valeur réelle avec la valeur moyenne pondérée peut rétrécir le canal et mécaniquement extraire des prédictions qui sont pourtant pertinentes. C'est le cas par exemple au quatrième trimestre de l'année 2017 pour l'assistance voyage, en utilisant une calibration avec crédibilité 1/10 et le quatrième type de valorisation de la catégorie obtenue.

Les résultats obtenus appellent aussi des commentaires différents :

- Dans les deux cas, le réseau bayésien semble donner des informations qui peuvent être très éloignées de la valeur réelle. Ceci pourrait provenir du fait que la portée (écart entre la valeur maximum et la valeur minimum constatées est très large, mais non

représentative de la distribution des valeurs réelles). Il est possible qu'en tronquant (pour rendre plus robuste) la base d'expérience de ces valeurs extrêmes, les données puissent se disposer de façon beaucoup plus conforme aux observations, et redonner du poids à l'inférence faite à partir de réseau bayésien.

En guise de dernier mot, il est notable que le réseau bayésien donne un résultat meilleur pour l'assistance voyage que pour l'assistance automobile en matière de prédiction des premiers facteurs de développement.

Influence du choix combiné

Les résultats sont présentés depuis 2017 jusqu'à la fin 2018. La seule exception est le premier facteur de développement pour le quatrième trimestre de l'année 2018 car elle suppose l'acquisition d'information pour le premier trimestre de l'année 2019, indisponible au moment de l'étude.

Résultats pour l'assistance voyage

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4
Valeurs observées à 2019 Q2	607	891	1 232	604	610	753	839	578
Borne supérieure canal DFM	680	1 081	1 339	940	651	820	1 239	763
Borne inférieure canal DFM	533	701	1 124	268	568	686	439	392
Test Crédibilité 1/1 avec valorisation des catégories "1"	670	668	1 305	673	582	627	1 273	686
Test Crédibilité 1/1 avec valorisation des catégories "2"	705	696	1 383	446	552	548	1 129	629
Test Crédibilité 1/1 avec valorisation des catégories "3"	702	693	1 366	463	455	558	943	635
Test Crédibilité 1/1 avec valorisation des catégories "4"	699	689	1 605	419	534	529	1 332	610
Test Crédibilité 1/10 avec valorisation des catégories "1"	697	689	1 379	677	644	657	1 357	659
Test Crédibilité 1/10 avec valorisation des catégories "2"	705	696	1 177	678	552	665	1 598	767
Test Crédibilité 1/10 avec valorisation des catégories "3"	702	693	988	676	561	665	1 342	761
Test Crédibilité 1/10 avec valorisation des catégories "4"	699	689	1 383	670	534	655	1 875	761
Test Crédibilité 10/1 avec valorisation des catégories "1"	694	686	1 282	680	536	603	1 149	693
Test Crédibilité 10/1 avec valorisation des catégories "2"	705	696	1 177	530	552	548	1 129	629
Test Crédibilité 10/1 avec valorisation des catégories "3"	702	693	988	544	561	558	943	635
Test Crédibilité 10/1 avec valorisation des catégories "4"	699	689	1 383	502	534	529	1 332	610

Valorisation de la charge à l'ultime en assistance voyage, par trimestre et par test (en k€)

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	Efficacité
Test Crédibilité 1/1 avec valorisation des catégories "1"	1	0	1	1	1	0	0	1	63%
Test Crédibilité 1/1 avec valorisation des catégories "2"	0	0	0	1	0	0	1	1	38%
Test Crédibilité 1/1 avec valorisation des catégories "3"	0	0	0	1	0	0	1	1	38%
Test Crédibilité 1/1 avec valorisation des catégories "4"	0	0	0	1	0	0	0	1	25%
Test Crédibilité 1/10 avec valorisation des catégories "1"	0	0	0	1	1	0	0	1	38%
Test Crédibilité 1/10 avec valorisation des catégories "2"	0	0	1	1	0	0	0	0	25%
Test Crédibilité 1/10 avec valorisation des catégories "3"	0	0	0	1	0	0	0	1	25%
Test Crédibilité 1/10 avec valorisation des catégories "4"	0	0	0	1	0	0	0	1	25%
Test Crédibilité 10/1 avec valorisation des catégories "1"	0	0	1	1	0	0	1	1	50%
Test Crédibilité 10/1 avec valorisation des catégories "2"	0	0	1	1	0	0	1	1	50%
Test Crédibilité 10/1 avec valorisation des catégories "3"	0	0	0	1	0	0	1	1	38%
Test Crédibilité 10/1 avec valorisation des catégories "4"	0	0	0	1	0	0	0	1	25%

Synopsis des cas d'amélioration (« 1 signifie 'amélioration' ») dans la prédiction de la charge à l'ultime, pour l'assistance voyage (par trimestre et par test) (en k€)

Dans le cas précis de l'assistance voyage, une calibration apporte une efficacité de 63%.

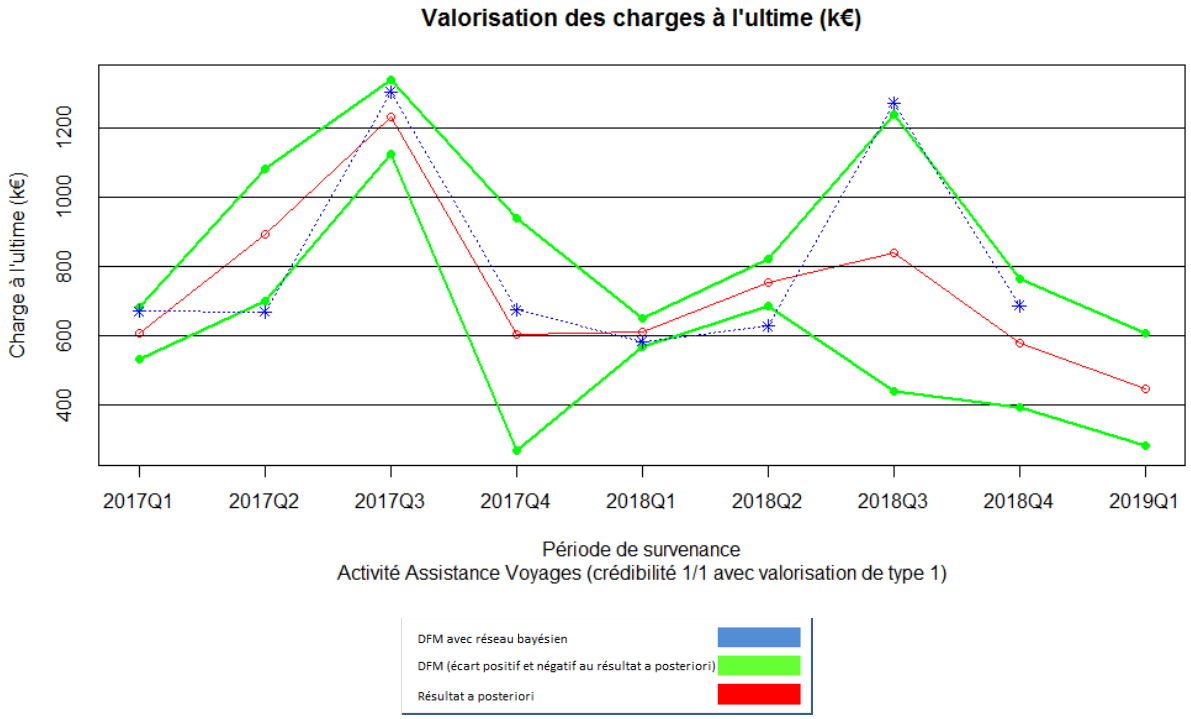

Résultats pour l'assistance automobile

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4
Valeurs observées à 2019 Q2	10 110	11 586	13 358	11 547	10 981	12 090	14 524	10 562
Borne supérieure canal DFM	10 891	13 721	15 139	12 738	12 453	13 626	15 610	13 103
Borne inférieure canal DFM	9 329	9 450	11 577	10 356	9 510	10 554	13 438	8 021
Test Crédibilité 1/1 avec valorisation des catégories "1"	11 902	11 497	12 006	11 889	11 852	12 481	12 538	12 515
Test Crédibilité 1/1 avec valorisation des catégories "2"	11 567	11 679	9 836	13 308	12 173	12 354	10 858	13 725
Test Crédibilité 1/1 avec valorisation des catégories "3"	10 253	10 358	8 898	11 896	10 995	11 170	11 553	12 137
Test Crédibilité 1/1 avec valorisation des catégories "4"	12 960	13 079	10 821	14 799	13 407	13 596	13 887	15 411
Test Crédibilité 1/10 avec valorisation des catégories "1"	11 943	11 822	12 235	12 117	12 066	12 452	12 439	12 563
Test Crédibilité 1/10 avec valorisation des catégories "2"	13 223	11 679	13 251	9 920	12 173	15 181	12 331	13 725
Test Crédibilité 1/10 avec valorisation des catégories "3"	12 049	10 358	11 690	8 978	10 995	13 504	11 149	12 137
Test Crédibilité 1/10 avec valorisation des catégories "4"	14 451	13 079	14 910	10 908	13 407	16 956	13 571	15 411
Test Crédibilité 10/1 avec valorisation des catégories "1"	12 008	11 203	12 090	11 480	11 474	12 365	12 465	12 419
Test Crédibilité 10/1 avec valorisation des catégories "2"	13 223	11 679	10 659	9 920	10 841	13 533	12 147	12 420
Test Crédibilité 10/1 avec valorisation des catégories "3"	12 049	10 358	9 675	8 978	9 850	12 108	10 799	11 234
Test Crédibilité 10/1 avec valorisation des catégories "4"	14 451	13 079	11 690	10 908	11 878	15 036	13 575	13 663

Valorisation de la charge à l'ultime en assistance automobile, par trimestre et par test (en k€)

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	Efficacité
Test Crédibilité 1/1 avec valorisation des catégories "1"	0	1	1	1	1	1	0	1	75%
Test Crédibilité 1/1 avec valorisation des catégories "2"	0	1	0	0	1	1	0	0	38%
Test Crédibilité 1/1 avec valorisation des catégories "3"	1	1	0	1	1	1	0	1	75%
Test Crédibilité 1/1 avec valorisation des catégories "4"	0	1	0	0	0	1	1	0	38%
Test Crédibilité 1/10 avec valorisation des catégories "1"	0	1	1	1	1	1	0	1	75%
Test Crédibilité 1/10 avec valorisation des catégories "2"	0	1	1	0	1	0	0	0	38%
Test Crédibilité 1/10 avec valorisation des catégories "3"	0	1	1	0	1	1	0	1	63%
Test Crédibilité 1/10 avec valorisation des catégories "4"	0	1	1	1	0	0	1	0	50%
Test Crédibilité 10/1 avec valorisation des catégories "1"	0	1	1	1	1	1	0	1	75%
Test Crédibilité 10/1 avec valorisation des catégories "2"	0	1	0	0	1	1	0	1	50%
Test Crédibilité 10/1 avec valorisation des catégories "3"	0	1	0	0	1	1	0	1	50%
Test Crédibilité 10/1 avec valorisation des catégories "4"	0	1	1	1	1	0	1	0	63%

Synopsis des cas d'amélioration (« 1 signifie 'amélioration' ») dans la prédiction de la charge à l'ultime, pour l'assistance automobile (par trimestre et par test) (en k€)

Dans le cas précis de l'assistance automobile, quatre calibrations apportent une efficacité de 75%. Un des quatre cas sont présentés ci-dessous.

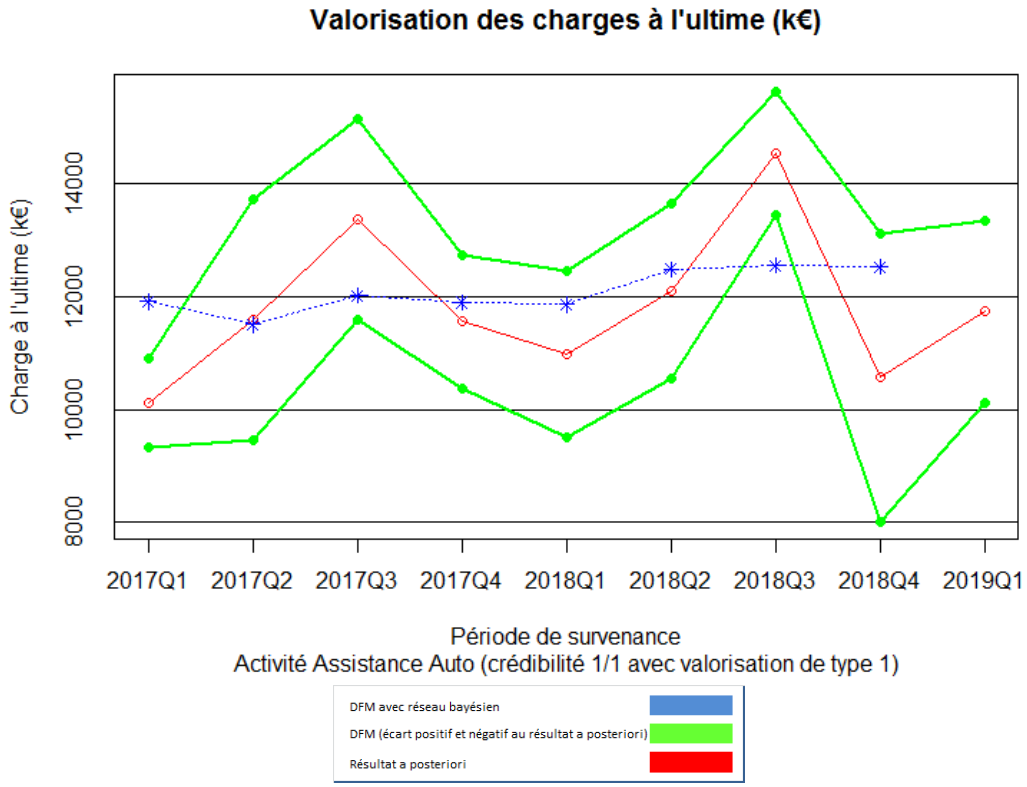

Discussion des résultats

La valorisation de la charge à l'ultime pour l'assistance automobile à partir des réseaux bayésiens est efficace car elle permet de battre dans 75 % au moins une fois sur deux la méthode DFM, quel que soit le paramétrage. Dans un tiers des cas de paramétrage, le taux de réussite est de 75%.

Les résultats obtenus appellent des commentaires analogues à ceux indiqués pour l'utilisation de réseaux bayésiens pour les montants initiaux et pour les facteurs de développement. A savoir :

- Les résultats obtenus pour l'assistance automobile et pour l'assistance voyage ne sont pas les mêmes. La prédiction est ici meilleure pour l'assistance automobile,
- Il y a une sensibilité à la calibration du réseau bayésien mis en œuvre. Il faut choisir un bon réglage pour obtenir un bon résultat. Cette calibration n'est pas nécessairement identique à celles qui avaient été établies lors des prédictions sur les bases de la méthode (à savoir de façon indépendante, la détermination d'un montant initial et d'un premier facteur de développement),
- L'effet de proximité de la valeur réelle avec la valeur moyenne pondérée peut rétrécir le canal et mécaniquement disqualifier des prédictions qui sont pourtant pertinentes. C'est le cas par exemple au deuxième trimestre pour l'assistance voyage, en utilisant une calibration avec crédibilité 1/1 et premier type de valorisation de la catégorie obtenue.

Les résultats obtenus appellent aussi des commentaires différents :

- Il y a un effet de mitigation de la performance quand deux réseaux bayésiens sont conjointement utilisés. En effet, la comparaison entre tests ne peut se faire qu'à base d'apprentissage et valorisation des catégories identique. En conséquence, ce ne sont pas systématiquement les meilleurs modèles qui sont assemblés pour former la meilleure prédiction de la charge ultime. *En utilisant de façon indépendante la meilleure prédiction pour le montant initial et la meilleure prédiction pour le premier facteur de développement, la valeur obtenue pour la charge à l'ultime et pour le ratio sinistres sur primes serait encore plus précise,*
- Il ne fait pas sens d'indiquer les plages de tolérance dans le cas des valorisations mixtes, car cette valorisation s'appuie sur deux paramètres différents qui ont eux-mêmes une plage de tolérance. Les plages obtenues (dont les extrema sont formés par la somme des deux minima ou des deux maxima) seraient alors très larges et n'apporteraient donc aucun intérêt : une plage ferait intersection avec le canal, mais comme l'épaisseur du canal serait faible devant la largeur de la plage, aucune conclusion pertinente ne pourrait en être tirée.

Prise en compte et traitements des limites observées

Suite aux résultats obtenus lors la première passe de tests présentée ci-avant, les observations sont prises en compte et les opérations suivantes sont mises en œuvre :

1) Comme le canal DFM peut se resserrer si la circonstance détermine une valeur qui se trouve par hasard proche (voire très proche) de la valeur observée *in fine*, l'épaisseur du canal est re-calibrée « en moyenne ». Concrètement, ceci consiste à :
    a. Déterminer mois après mois l'écart entre la valeur finalement observée et la valeur obtenue avec le modèle DFM,
    b. Prendre sa valeur absolue (en effet, la valeur obtenue avec le modèle DFM peut être supérieure ou inférieure à la valeur finalement observée),
    c. Faire la somme de tous ces valeurs absolues,
    d. Diviser par le nombre de mois pour lesquels le modèle est joué (ceci peut-être 7 fois pour les facteurs de développement, ou 8 mois pour les valeurs initiales de paiement) pour obtenir l'écart moyen,
    e. Ajouter ou retrancher cet écart moyen de la valeur observée, mois après mois, pour tracer la borne supérieure et la borne inférieure du canal DFM.

    Ceci permet de voir en moyenne si les inférences faites avec le réseau bayésien « battent » ou non la valeur obtenue avec la méthode DFM.

2) Comme le mécanisme de dé-catégorisation est grossier (pour mémoire, il consiste à prendre l'espérance des valeurs moyennes par catégories, ou bien les valeurs maximales ou minimales dans les tranches définies (« very weak », « weak », « strong », « very strong »), il est très sensible aux valeurs extrêmes c'est-à-dire à la

valeur maximale de la catégorie « very strong » et à la valeur minimale de la catégorie « very weak ». Une manière simple de juguler cet effet est de rendre plus robuste ces deux catégories en supprimant leurs valeurs les plus extrêmes avant de construire les catégories « very weak » et « very strong ». Ces deux catégories sont alors plus ramassées et recentrées vers les valeurs médianes « weak » et « strong ». Concrètement trois valeurs sont retranchées (en tout) pour l'activité d'assistance voyage, et quatre pour l'assistance automobile. Pour mémoire, la base d'expérience couvre les années 2012 à 2018, soit 27 à 28 valeurs initiales. La base d'expérience est donc robustifiée en ne gardant que 86% des valeurs ((7*4-4)/28),

Ceci permet d'avoir des valeurs moins extrêmes (et donc moins « limites ») dans le cas où l'inférence amène à retenir une valeur « very weak » ou « very strong », car le retraitement numérique est toujours réalisé préalablement aux calculs actuariels avec des valeurs utilisées moins dispersées.

3) Comme il a été vu d'une part que les réseaux bayésiens utilisés pour la détermination du montant initial et du facteur de développement sont différents et indépendants, et d'autre part que la finalité est l'établissement d'une charge à l'ultime ou d'un ratio sinistres sur primes, les deux réseaux doivent être utilisées de façon concomitante. Les valeurs d'inférence dépendent d'une part de la base d'apprentissage et d'autre part du choix de la base de calcul lors de la dé-catégorisation. Tous ses paramètres correspondent à des « réglages » du modèle, et peuvent être mis en œuvre de façon indépendante. Pour garder une certaine rusticité, il est décidé de considérer les résultats combinés (facteurs de développement et montants de sinistres initiaux) à paramètres d'inférence égal : par exemple, il est calculé une charge à l'ultime pour un niveau de crédibilité et pour un protocole de dé-catégorisation donnés.

Ceci permet de ne pas multiplier la combinatoire de manière outrancière, et donc en production de simplifier le paramétrage initial du modèle (même si ces raffinements amèneraient un gain supplémentaire de précision).

Présentation des résultats finaux

En suivant la même logique de présentation, et après traitement des limites, l'étude de la charge à l'ultime est conduite.

Pour éviter le biais de confirmation :

- Uniquement la base d'apprentissage de référence est exploitée : celle qui permet par défaut aux réseaux bayésiens de calculer (superposition de la base d'expertise et de la base d'expérience).
- Les résultats obtenus en exploitant les quatre mécanismes de conversion en valeur numérique des données catégorielles sont tous considérés.
- Les gains finaux sont calculés en moyenne sur chacun des cas, pour chaque trimestre.

Résultats pour l'assistance voyage

	2017	2017	2017	2017	2018	2018	2018	2018
	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4
Valeurs observées à 2019Q2	607	891	1232	604	610	753	839	578
Borne supérieure canal DFM	762	1 047	1 387	760	765	908	994	733
Borne inférieure canal DFM	451	736	1 076	448	454	597	683	422
Usage de réseau bayésien	668	765	1 401	600	517	633	1 470	771

Valorisation des charges à l'ultime en assistance voyage (pour 2017 et 2018, en k€)

Ci-dessous, chaque « 1 » code pour une situation où le test est concluant (le réseau bayésien bat la méthode DFM).

Valeurs observées à :	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	Efficacité
Performance des réseaux bayésiens	1	1	0	1	1	1	0	0	63%

Surperformance du réseau bayésien en assistance voyage contre la méthode DFM seule (valorisation à « 1 »)

Commentaires pour l'assistance voyage

Les résultats sont corrects puisque dans 63% des cas, le réseau bayésien dûment paramétré permet *en moyenne* de faire mieux que la méthode DFM.

Il reste juste à expliquer pourquoi les valeurs en 2017Q3, 2018Q3 et 2018Q4 sont en dehors du canal DFM, en particulier pour 2018Q3. La visualisation des valeurs obtenues par la méthode DFM sont éclairantes :

Période d'analyse	2017Q3	2018Q3	2018Q4
Valeur observée (k€)	1232	839	578
Valeur haute du canal DFM (k€)	1387	994	733
Valeur obtenue (DFM) (k€)	1339	1239	763
Valeur obtenue (réseau bayésien) (k€)	1401	1470	771

Diverses valorisations de la charge à l'ultime pour 2017Q3, 2018Q3 et 2018Q4 (assistance voyage)

La situation observée pour l'assistance voyage en particulier au troisième trimestre de l'année 2018 est improbable. Il est espéré avec la méthode DFM une charge à l'ultime de 1239 k€ alors que la valeur finalement observée est de 839 k€. Comme la situation à Q3 2018 est improbable et que la base d'apprentissage n'avait pas assez fréquemment vu cette situation, les tables conditionnelles du réseau bayésien ne fournissaient pas d'indications qui permettrait de « doper » la catégorie « very weak ». Comme conséquence, le réseau bayésien a fonctionné de la même manière que la méthode DFM (c'est-à-dire en prenant en compte la partie base d'expertise de la base d'apprentissage : *in fine,* les résultats obtenus avec le réseau bayésien et avec la méthode DFM sont cohérents (1470 k€ pour le premier et 1239 k€ pour la seconde), qui est imputable au mécanisme de décatégorisation.

Pour les résultats obtenus à 2017Q3 et 2018Q4, les valeurs obtenues avec la méthode DFM classique ou avec le réseau bayésien sont similaires. La loi a priori (base d'expertise) a joué, et de faibles écarts sont imputables au mécanisme de décatégorisation.

Résultats obtenus pour l'assistance automobile

	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4
Valeurs observées à 2019Q2	10110	11586	13358	11547	10981	12090	14524	10562
Borne supérieure canal DFM	11 676	13 151	14 923	13 113	12 547	13 656	16 089	12 128
Borne inférieure canal DFM	8 544	10 020	11 792	9 981	9 416	10 525	12 958	8 997
Usage de réseau bayésien	11 252	10 829	12 536	11 503	11 655	12 164	12 367	11 438

Valorisation de la charge à l'ultime en assistance automobile pour 2017 et 2018

Ci-dessous, chaque « 1 » code pour une situation où le test est concluant (le réseau bayésien bat la méthode DFM).

Valeurs observées à :	2017Q1	2017Q2	2017Q3	2017Q4	2018Q1	2018Q2	2018Q3	2018Q4	Efficacité
Performance des réseaux bayésiens	1	1	1	1	1	1	0	1	88%

Surperformance du réseau bayésien en assistance automobile contre la méthode DFM seule (valorisation à « 1 »)

Commentaires pour l'assistance automobile

Les résultats sont concluants puisque dans 88 % des cas, le réseau bayésien dûment paramétré permet *en moyenne* de faire mieux que la méthode DFM.

Impacts sur les ratios sinistres sur prime

En matière de présentation des résultats actuariels, il est d'usage chez Allianz Partners de fournir des ratios sinistres sur primes. En effet, cette information est compréhensible facilement par les autres fonctions de la Direction Financière (en particulier le service de Contrôle de Gestion). De plus, comme il s'agit d'une grandeur intensive, il est facile de faire des calculs auxiliaires avec cette information.

C'est la raison pour laquelle, il est présenté ici ci-dessous l'impact de cette nouvelle méthode (usage de réseau bayésien), sur les ratios sinistres sur primes pour le périmètre de l'étude (la BU Espagne du groupe Allianz Partners).

Les ratios sinistres sur primes sont présentés par trimestre de survenance entre 2017 et 2018, par LOB et au global. Comme les volumes d'affaires pour les LOB « Home » (assistance domestique) et « Legal » (Assistance juridique et responsabilité civile) sont très en deçà des volumes d'affaires pour les branches d'activité assistance automobile et assistance voyage, les ratios sinistres sur primes sont calculés en considérant que l'apport de la nouvelle méthode est négligeable pour les deux branches minoritaires, et donc que la méthode DFM uniquement appliquée donnerait une contribution quantitative qui peut être jugée identique.

Le gain de précision sur le ratio est construit comme la différence en valeur absolue qui est constatée entre :

- L'écart de la prévision faite avec le réseau bayésien comparativement à la valeur observée finalement,
- L'écart de la prévision faite la méthode DFM comparativement à la valeur observée finalement.

De cette manière, les valeurs absolues permettent de comparer le plus petit écart par rapport à la réelle valeur du ratio « sinistres sur primes » quand le développement de sinistres est accompli.

La convention retenue est de considérer la valeur obtenue par le réseau bayésien comme la référence. Ainsi, si le gain de précision est positif, cela signifie que l'usage du réseau bayésien donne un meilleur résultat.

Les résultats pour les branches d'activité « assistance automobile » et « assistance voyage » sont les suivants :

Période de survenance	LOB	Prime acquise (GEP - K€)	Ratio sinistres sur prime observé a posteriori	Ecart DFM/observé a posteriori	Ecart Réseau bayésien/observé a posteriori	Gain de précision sur le ratio	Gain de précision sur le ratio (valeur)
2017Q1	AUTO	16343	61,86%	-4,8%	8,2%	NON	-3,38%
2017Q2	AUTO	16830	68,84%	-12,7%	-4,7%	OUI	8,03%
2017Q3	AUTO	17270	77,35%	-10,3%	-6,0%	OUI	4,29%
2017Q4	AUTO	18669	61,85%	-6,4%	2,7%	OUI	3,65%
2018Q1	AUTO	17645	62,23%	8,3%	5,1%	OUI	3,23%
2018Q2	AUTO	17821	67,84%	8,6%	4,6%	OUI	4,06%
2018Q3	AUTO	18544	78,32%	5,9%	-9,2%	NON	-3,38%
2018Q4	AUTO	18730	56,39%	13,6%	5,1%	OUI	8,51%
2017Q1	TRAVEL	3627	16,72%	2,0%	1,7%	OUI	0,31%
2017Q2	TRAVEL	4408	20,21%	-4,3%	-2,9%	OUI	1,45%
2017Q3	TRAVEL	5333	23,10%	2,0%	3,5%	NON	-1,45%
2017Q4	TRAVEL	2796	21,60%	12,0%	-1,5%	OUI	10,50%
2018Q1	TRAVEL	3148	19,38%	-1,3%	-3,0%	NON	-1,68%
2018Q2	TRAVEL	3850	19,56%	1,8%	-3,1%	NON	-1,36%
2018Q3	TRAVEL	3896	21,53%	10,3%	16,2%	NON	-5,93%
2018Q4	TRAVEL	2544	22,71%	7,3%	7,6%	NON	-0,28%

Evaluation des ratios sinistre sur primes selon les méthodes (par trimestre et par LOB)

Pour l'assistance automobile, les gains sont majoritaires, et permettent d'apporter une correction de bonne intensité (plus que 3% en moyenne).

Pour l'assistance voyage, la situation est plus nuancée, car les prédictions faites avec les deux méthodes sont très proches (souvent inférieures à 1,5%). La correction est minime puisqu'elle se monte seulement en moyenne à 0,20%. Les deux méthodes se valent donc, à l'exception d'un cas où l'utilisation d'un réseau bayésien a permis de faire un gain de précision de plus de 10%.

Les résultats pour le portefeuille global de la BU Espagne sont les suivants :

Période de survenance	LOB	Prime acquise (GEP - K€)	Ratio sinistres sur prime observé a posteriori	Ecart DFM/observé a posteriori	Ecart Réseau bayésien/observé a posteriori	Gain de précision sur le ratio	Gain de précision sur le ratio (valeur)
2017Q1	GLOBAL	25542	49,09%	-2,8%	9,0%	NON	-6,27%
2017Q2	GLOBAL	27813	51,74%	-8,4%	2,7%	OUI	5,69%
2017Q3	GLOBAL	29446	56,84%	-5,7%	6,3%	NON	-0,60%
2017Q4	GLOBAL	27885	51,65%	-3,1%	4,4%	NON	-1,28%
2018Q1	GLOBAL	22245	54,93%	6,4%	4,4%	OUI	2,04%
2018Q2	GLOBAL	23076	59,20%	7,0%	3,5%	OUI	3,42%
2018Q3	GLOBAL	23939	66,47%	6,2%	-4,1%	OUI	2,09%
2018Q4	GLOBAL	22879	50,71%	11,9%	6,3%	OUI	5,60%

Evaluation des ratios sinistre sur primes selon les méthodes (par trimestre, pour tout le portefeuille de la BU Espagne)

Au niveau globalisé du portefeuille de la BU Espagne, il apparaît un gain moyen de 1,3% à utiliser les réseaux bayésiens par opposition à la méthode DFM simple. Lorsqu'il n'y a pas de gain, la perte de précision est faible (sauf dans un unique cas), mais au contraire, s'il y a un gain, il est matériel (plus que 4% moyenne).

Pertinence des modèles

Les nœuds du réseau bayésien peuvent s'organiser de multiples façons. Dans chaque cas, ceci constituerait un modèle : il faut en choisir un parmi cette multitude qui soit efficient. Pour évaluer les deux modèles qui ont été retenus, trois des critères les plus classiques ont été calculés pour chacun de nos deux modèles utilisés dans cette étude :

- Maximum de vraisemblance,
- Critère d'information d'Akaike,
- Critère d'information bayésien.

Il suffit alors de comparer la performance du modèle parmi ses concurrents : plusieurs modèles alternatifs ont été créés dans chacun des deux cas (recherche du paiement initial et recherche du facteur de développement initial). Ceci a été fait pour les bases *« df_apprentissage_8 »* -inférence sur les montants initiaux- et *« df_apprentissage_21 »* -inférence sur les facteurs de développement initiaux- utiles dans l'étude.

Cas des modèles pour la recherche de paiements initiaux

Les réseaux concurrents pour la recherche de paiements initiaux sont les suivants :

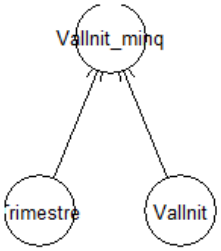

Réseau bayésien alternatif numéro 1

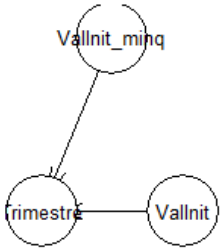

Réseau bayésien alternatif numéro 2

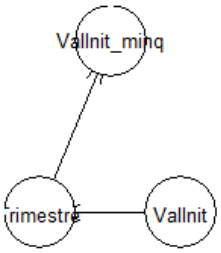

Réseau bayésien alternatif numéro 3

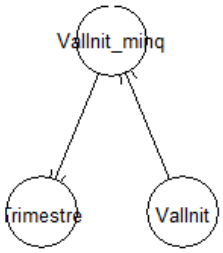

Réseau bayésien alternatif numéro 4

Il n'y a évidemment pas lieu de chercher de logique dans l'agencement et le sens des relations entre les nœuds. Il s'agit juste de disposition de réseaux qui pourraient ou non se révéler efficace pour faire de l'inférence.

Résultats pour le réseau bayésien de recherche de paiements initiaux

Le graphique obtenu présente les résultats pour la log-vraisemblance (les autres résultats AIC et BIC sont présentés en annexe pour ne pas alourdir le corps du texte) :

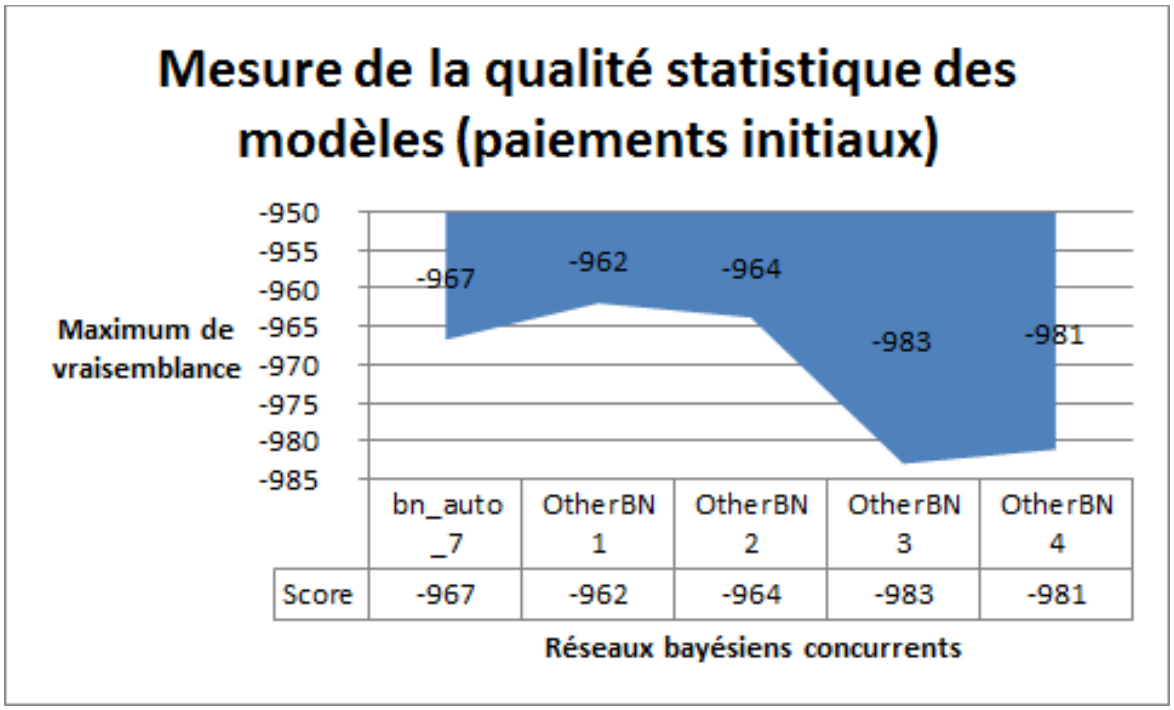

Il y a globalement deux plateaux : le premier dans la zone de -960 pour trois des modèles concurrents, et un deuxième dans la zone de -980 pour deux autres modèles.

Le maximum est atteint sur le premier plateau, et le modèle qui a été exploité dans le cadre de cette étude est bien situé. Il est donc légitime de le retenir comme un bon modèle, d'autant plus que l'organisation du réseau rend compte d'une certaine intelligibilité pour les lecteurs (pour mémoire « le prochain montant initial est dépendant de la saisonnalité et de la tendance très court terme »).

Le réseau bayésien retenu pour l'étude des paiements initiaux est pertinent au vu du critère de vraisemblance.

Cas des modèles pour la recherche des facteurs de développement initiaux

Les réseaux concurrents pour la recherche des facteurs de développement initiaux sont les suivants :

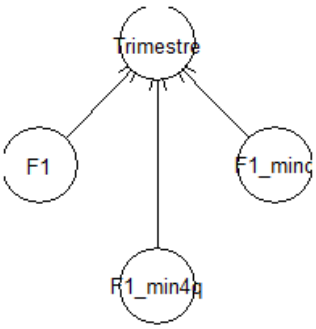

Réseau bayésien alternatif numéro 5

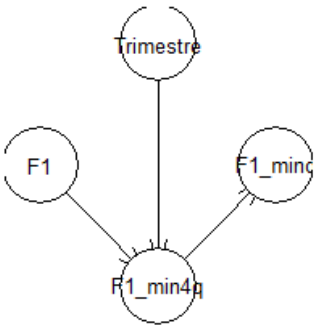

Réseau bayésien alternatif numéro 8

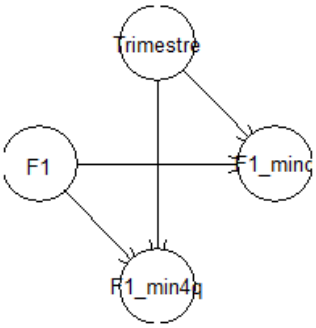

Réseau bayésien alternatif numéro 12

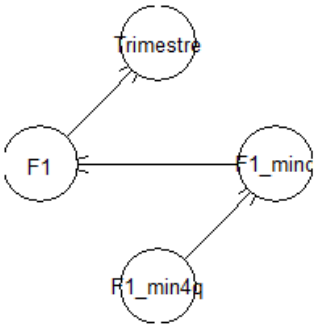

Réseau bayésien alternatif numéro 14

Bien évidemment, il n'y a pas ici non plus lieu de chercher de logique dans l'agencement et le sens des relations entre les nœuds. Il s'agit juste de disposition de réseaux qui pourraient ou non se révéler efficace pour faire de l'inférence.

Résultats pour le réseau bayésien de recherche de facteurs de développement initiaux

Le graphique obtenu présente les résultats pour la log-vraisemblance (les autres résultats AIC et BIC sont présentés en annexe pour ne pas alourdir le corps du texte) :

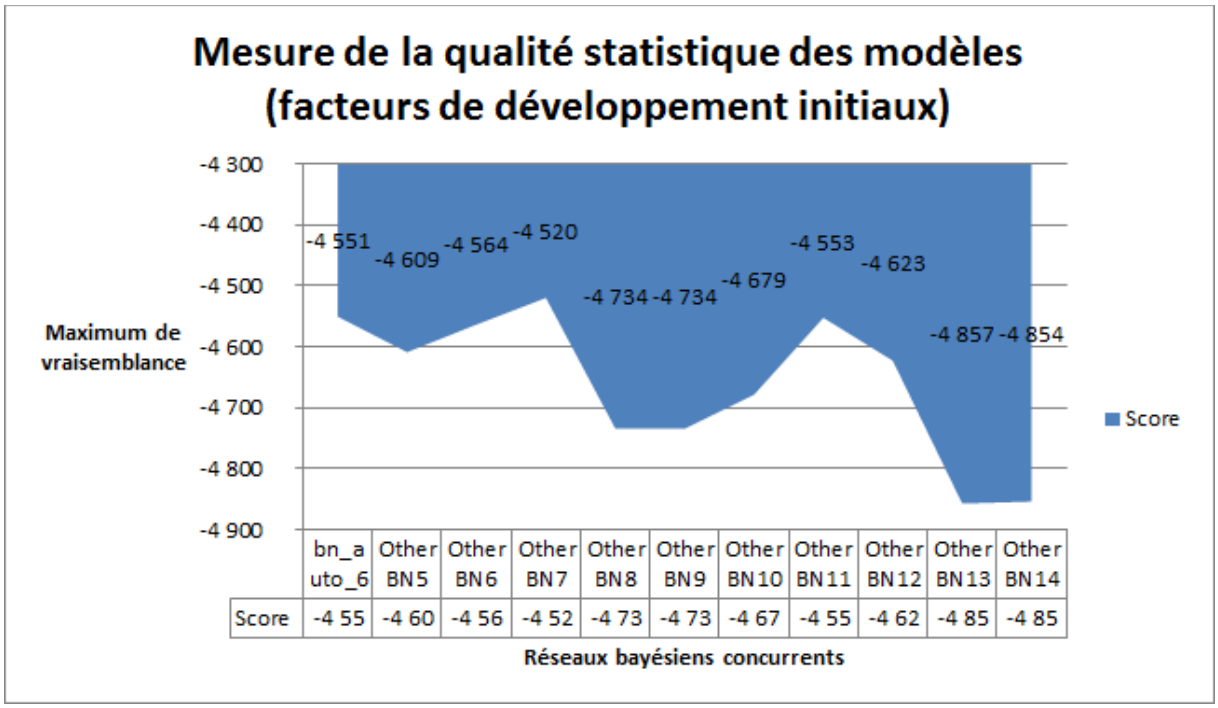

Il y a globalement trois plateaux : le premier dans la zone de -4 550 pour six des modèles concurrents, un second dans la zone de -4 700 pour trois autres modèles, et un troisième plateau dans la zone de -4 850.

Le maximum est atteint sur le premier plateau, et le modèle qui a été exploité dans le cadre de cette étude est bien situé. Il est donc légitime de le retenir comme un bon modèle, d'autant plus que l'organisation du réseau rend compte d'une certaine intelligibilité pour les lecteurs (pour mémoire « le prochain facteur de développement est dépendant de la saisonnalité et de la tendance très court terme »).

Le réseau bayésien retenu pour l'étude des facteurs de développement initiaux est pertinent au vu du critère de vraisemblance.

Divers commentaires sur l'étude

Cantonnement des plages d'incertitude

Dès lors que le résultat est consolidé au niveau de la BU (et non pas au niveau de la branche d'activité), il y a lieu de combiner plusieurs réseaux bayésiens qui sont différents. La plage d'incertitude générale doit être construite en cumulant les largeurs de plage d'incertitude obtenues sur chacun des réseaux bayésiens dé-catégorisés (pour qu'elles touchent deux fois le maximum et deux fois le minimum). La plage générale serait alors tellement large… qu'elle n'aurait plus d'intérêt parce qu'elle serait alors bien au-delà du canal DFM : les plages d'incertitude ne sont pas pertinentes dès lors que les résultats sont consolidés.

Incidence de la base d'apprentissage

En théorie des graphes, en théorie de la complexité des algorithmes et en intelligence artificielle, une heuristique est une méthode de calcul qui fournit rapidement une solution

réalisable, pas nécessairement optimale pour un problème d'optimisation. La construction de la base d'apprentissage crédible (au sens de la crédibilité bayésienne) est opérée de cette façon dans le cadre du paramétrage des réseaux bayésiens : les bases d'apprentissage exploitées ne sont pas optimales, mais suffisantes pour arrêter un choix de réseau suffisamment efficace.

Efficacité des réseaux liés à la branche d'activité

Les bases d'expériences consignent des cas qui sont plus ou moins répétitifs et fréquents, et les base d'expertise sont elles aussi extrêmement tributaires de la connaissance empirique sur les branches d'activités (qui peuvent avoir des spécificités intrinsèques… Par exemple il ne peut y avoir de « large claims » -sinistres très lourds- en assistance automobile alors que c'est le cas en assistance voyage). Dans ce cadre, un réseau bayésien, même s'il est appuyé sur une unique structure de réseau, peut donner des prédictions plus ou moins précises : les spécificités des activités économiques s'expriment dans les prédictions des réseaux bayésiens.

Degré de performance à attendre en utilisant un réseau bayésien

Les résultats de cette étude ont montré que les réseaux bayésiens sont capables de donner des résultats plus précis qu'une méthode basique comme la méthode DFM. Mais comment apprécier cette surperformance ? La définition de la performance s'inscrit dans la capacité à battre la méthode DFM. La battre une fois sur deux serait passable, puisque cela signifierait que l'on fait moins bien en moyenne qu'une méthode dite rustique. Apprécier au-delà dans quelle mesure les réseaux bayésiens sont sur-performants est un autre sujet de réflexion : les réseaux bayésiens surperforment la méthode DFM dans cette étude, mais le degré de surperformance possible ou acceptable pour basculer d'une méthode à une autre est ouvert. Les réseaux bayésiens sont dans tous les cas une bonne méthode auxiliaire.

Perspectives, limitations et intérêt des réseaux bayésiens en actuariat

Limitations pour les activités de provisionnement

Le processus de provisionnement est originellement issu de l'agrégation des données techniques historiques dont dispose la société d'assurances. Une fois agrégées, ces données permettent de constituer des triangles d'information dont la profondeur est liée à l'historique des données disponibles. Dans le cadre d'Allianz Partners, les données disponibles oscillent entre trois à quatre années dans les cas les moins favorables, jusqu'à la dizaine d'année dans les meilleurs cas. La raison en est que les informations ne sont plus archivées, ou bien difficilement extractibles de façon homogène parce que le système d'information évolue. Au final, le triangle disponible permet :

- D'avoir au maximum une collection d'une quarantaine de paiements trimestriels initiaux,
- D'avoir au maximum une collection d'une quarantaine de facteurs de développement initiaux.

Il s'agit donc d'ensemble de données plutôt parcimonieux pour faire des statistiques *directement à partir de ce substrat.* La complémentation de ces bases d'expériences avec des bases d'expertise est donc indispensable.

Les portefeuilles des BUs sont représentatifs de leur activité commerciale. Si la majorité des affaires concerne l'assistance automobile et l'assistance voyage, il y a aussi des petits portefeuilles d'assistance domestique (ou électrodomestique) et d'assistance/assurance juridique. Ici aussi, la taille des portefeuilles introduit aussi de la volatilité dans ces sous-triangles, ce qui rend d'autant plus difficile l'utilisation d'outil complémentaire comme les réseaux bayésiens (en tout cas, directement sur la base des triangles de données)

Intérêt actuariel

En matière de provisionnement, l'actuaire sait que la multiplication des méthodes lui permet d'avoir des éclairages différents sur la provision à l'ultime, qui peut s'interpréter avec intérêt en considérant les principes sous-jacentes aux différentes méthodes. La méthode DFM nécessite des cadences régulières, la méthode BF implique l'utilisation d'un ratio sinistres sur primes pour avoir un *a priori* d'évolution différent, etc. Dans ce cadre, les réseaux bayésiens permettent aussi d'outrepasser ces limites en apportant une nouvelle compréhension des écarts (en regard des probabilités conditionnelles qui édifient le réseau).

Les signaux obtenus peuvent être exploités de deux façons différentes.

Tout d'abord, il y a une exploitation « positive » du réseau bayésien : il confirme ou infirme les hypothèses constatées en utilisant d'autres méthodes (par exemple la régularité de cadence)

Ensuite, il y a une exploitation « négative » du réseau bayésien : dès lors qu'un évènement peu probable se produise, celui-ci sera automatiquement traduit dans l'inférence sous-tendue par les tables de probabilités conditionnelles. En effet, l'évènement sera jugé peu probable sur un des nœuds du réseau. Ceci est un signal qui indique qu'il faut creuser plus avant la compréhension de la situation : y a-t-il un changement de cadence lié à un problème technique ? Y a-t-il une « large loss » (gros sinistre) ? Les dernières données disponibles pour compléter les triangles ont elles un comportement normal ?

Aller plus loin

La présente étude a exploité des réseaux bayésiens pour lesquels les tables de probabilités conditionnelles ont été réparties en catégorie. Ceci permet de travail avec une famille de réseau simple à exploiter, et aussi de ne pas faire d'hypothèse hasardeuse sur la distribution de probabilités conditionnelles. Mais cette voie alternative pourrait se révéler une piste prometteuse.

L'utilisation de lois de distributions (par exemple gaussienne en première approche) en remplacement des tables de probabilités conditionnelles est une perspective intéressante et permettrait aussi de diminuer l'erreur liée à la dé-catégorisation des prédictions inférés avec les réseaux bayésiens.

Par ailleurs, comme il a été indiqué, les bases d'apprentissage sont le produit d'une heuristique. Un travail complémentaire intéressant pourrait être de mettre en place une méthode plus systématique qui permettrait de réaliser un paramétrage optimisé des modèles.

Ensuite, les modèles jugés les plus simples (avec uniquement trois ou quatre nœuds) ont été exploités dans le cadre de cette étude. Une extension naturelle du sujet serait de faire produire les réseaux bayésiens en auto-apprentissage, sans se donner une contrainte *a priori* de parcimonie, ou de sens commun à donner au réseau. De même, à réseau constant, divers algorithmes peuvent être exploités pour juger de leur pertinence dans le cadre particulier de cet exercice de provisionnement actuariel.

Finalement, cette étude s'est concentrée sur l'utilisation de réseaux qui constitue une famille d'outil de « machine learning » parmi d'autres. Il serait aussi intéressant de conserver la base d'apprentissage constante et d'observer dans quelle mesure les réseaux bayésiens constituent une technique complémentaire plus ou moins précise et plus ou moins facile à mettre en œuvre que d'autres méthodes innovantes.

Sans perspective académique, une analyse complémentaire devrait être menée pour voir dans quelle mesure cette famille d'outils pourrait être utilisée dans le cadre productif des entreprises d'assurance. En effet, cette étude met aussi en évidence qu'en l'état, la conception des réseaux, leur apprentissage et leur exploitation (mécanisme de catégorisation-dé-catégorisation) restent des freins à l'usage, sans même considérer leur acceptation dans la trousse à outil de l'actuaire.

Conclusion

Dans la société Allianz Partners, le provisionnement se fait en « roll forward », c'est-à-dire qu'il faut s'appuyer sur les données des trimestres existants pour évaluer les charges à l'ultime du trimestre à venir.

Pour améliorer la précision des résultats dans ce cadre, les réseaux bayésiens présentent un intérêt puisque certaines données triangulées (montants ou coefficient de développement) pourraient être évaluées de façon plus nuancée. Ces résultats sont alors utilisables avec les méthodes classiques telles que les méthodes DFM ou Bornehuetter-Ferguson. La présente étude est menée en ce sens :

Les données observées dans les triangles ont été discrétisées, catégorisées pour les besoins d'inférence. Ensuite, les prédictions (elles aussi catégorisées) ont été retraduites dans le champ initial continu pour avoir des prédictions sur les montants initiaux et facteurs de développement à retenir pour le trimestre à venir. Les prédictions s'appuient sur une base d'apprentissage s'appuyant sur les données du triangle mais aussi sur l'expertise (comportement à attendre a priori concernant les valeurs). La méthode DFM sert de jauge pour évaluer la pertinence des résultats obtenus : un résultat est jugé satisfaisant s'il permet d'avoir une prédiction meilleure avec le réseau bayésien que sans.

Des travaux ont été menés, sur le périmètre de la filiale espagnole du groupe Allianz Partners, sur ses deux branches d'activités majoritaires que sont l'assistance automobile et l'assistance voyage. Des ratios sinistres sur primes ont été calculés selon le protocole de l'étude : 1,3% de précision est gagné en moyenne sur la valeur du ratio sinistre sur prime, en comparaison d'une application classique de la méthode DFM.

Le gain est positif dès lors que plusieurs inférences sont faites, car la tendance est globalement favorable. C'est donc de cette façon qu'il faut utiliser les réseaux bayésiens en conjonction avec la méthode classique DFM. Par exemple, cette méthode est intéressante pour faire un calcul sur toutes les BUs d'une ligne d'activité, car la méthode sera jouée une trentaine de fois et apportera un gain de précision dès lors que l'on consolidera le résultat pour le pilotage de la ligne d'activité.

En terme stricte d'applicabilité, cette étude a démontré que le travail de paramétrage reste en l'état plutôt complexe, et peu compatible avec les exigences de production dans les services d'inventaire ou de pilotage financier de l'entreprise. Donc il ne serait pas forcément pragmatique de demander à chaque collaborateur d'utiliser ainsi cette technique.

Cependant, les réseaux bayésiens auraient toute leur place s'ils étaient encapsulés comme des programmes d'aide à la décision dans des outils de provisionnement de type ResQ (qui est utilisé chez Allianz). Ainsi, l'actuaire pourrait bénéficier de façon plus transparente des calculs d'inférence pour bien décider du facteur de développement à retenir pour ses calculs.

Mais il n'aurait pas à souffrir de complexes exercices de paramétrage. Qui plus est, l'acceptation de cette technique serait plus facile de cette sorte puisqu'elle est adossée à un outil connu.

Dans cette même veine de raisonnement, il serait sans doute suffisant de s'arrêter aux résultats discrets d'inférence, sans faire de traitement complémentaire de valorisation des facteurs de développement. L'appréciation fournie par le réseau bayésien (« fort », « très fort », « faible », « très faible ») est déjà une information pratique que l'actuaire peut utiliser pour retenir un facteur de développement, en cohérence avec les options et l'ergonomie des outils de provisionnement.

Annexes

1. Code de programmation pour générer une base d'expertise
2. Présentation d'un réseau bayésien « fitté » avec le package BnLearn sous R
3. Tables de données catégorisées à destination des réseaux bayésiens
4. Table des résultats d'inférence
5. Table des résultats actuariels
6. Code de programmation des graphes de résultats
7. Table des « outliers »
8. Mesure de la qualité des modèles (vraisemblance, AIC, BIC)

1. Code de programmation pour générer une base d'expertise

```
#Construction d'une nouvelle base d'expertise utile pour la prédiction des valeurs initiales, et à utiliser en particulier avec le réseau bn_auto_5

#dimension de la base
4*4*4  #cardinal de chacune des listes de catégories pour les variables Trimestre, Val_init et Val_Init_minq

#cr?ation d'un vecteur caractère vide
c("")->apriori7

#cr?ation d'un vecteur de la taille de la base d'apprentissage
apriori7<-rep(apriori7, each=64*3)
dim(apriori7)<-c(64,3)

#cr?ation d'un vecteur pour chaque variable de la base d'apprentissage
rep(c("s","vs","vw","w"),times=16)->apriori7[,3] #troisième vecteur
rep(rep(c("s","vs","vw","w"),each=4),times=4)->apriori7[,2] #deuxième vecteur
rep(rep(c("Q1","Q2","Q3","Q4"),each=16))->apriori7[,1] #premier vecteur
View(apriori7)
df_expertise5=data.frame(Trimestre=apriori7[,1],ValInit=apriori7[,2],ValInit_minq=apriori7[,3])
View(df_expertise5)

#-----------------------------
#cr?ation d'une nouvelle base d'apprentissage en renforçant le degr? d'occurence des valeurs m?dianes (pour la bas d'expertise des valeurs initiales)
4*4*4  #cardinal de chacune des listes de catégories pour les variables Trimestre, Val_init et Val_Init_minq

#cr?ation d'un vecteur caractère vide
c("")->apriori8

#cr?ation d'un vecteur de la taille de la base d'apprentissage
apriori8<-rep(apriori8, each=64*3)
dim(apriori8)<-c(64,3)

#cr?ation d'un vecteur pour chaque variable de la base d'apprentissage
rep(c("s","s","w","w"),times=16)->apriori8[,3] #troisième vecteur
rep(rep(c("s","s","w","w"),each=4),times=4)->apriori8[,2] #deuxième vecteur
rep(rep(c("Q1","Q2","Q3","Q4"),each=16))->apriori8[,1] #premier vecteur
View(apriori8)

#création de apriori9 pour accueillir la concaténatation des deux tables (en vue de la création de la vraie base d'expertise)
c("")->apriori9
```

```
#cr?ation d'un vecteur de la taille de la base d'apprentissage
apriori9<-rep(apriori9, each=64*2*3)
dim(apriori9)<-c(64*2,3)
factor(apriori9)->apriori9
#fusion des tables apriori7 dans apriori8 pour augmenter les occurences médianes
factor(c(as.vector(apriori7[,1]),as.vector(apriori8[,1])))->tuti1
factor(c(as.vector(apriori7[,2]),as.vector(apriori8[,2])))->tuti2
factor(c(as.vector(apriori7[,3]),as.vector(apriori8[,3])))->tuti3
#construction du nouveau dataframe d'expertise
df_expertise6=data.frame(Trimestre=tuti1,ValInit=tuti2,ValInit_minq=tuti3)
View(df_expertise6)

#-----------------------------------------------------------#

#Construction d'une deuxième nouvelle base d'expertise utile pour la prédiction des facteurs F1, et à utiliser en particulier avec le réseau bn_auto_6

#dimension de la base
4*4*4*4  #cardinal de chacune des listes de catégories pour les variables Trimestre, Val_init et Val_Init_minq et Val_Init_min4q

#cr?ation d'un vecteur caractère vide
c("")->apriori10

#cr?ation d'un vecteur de la taille de la base d'apprentissage
apriori10<-rep(apriori10, each=4*64*4)
dim(apriori10)<-c(4*64,4)

#cr?ation d'un vecteur pour chaque variable de la base d'apprentissage
rep(c("s","vs","vw","w"),times=16*4)->apriori10[,4] #quatrième vecteur
rep(rep(c("s","vs","vw","w"),each=4),times=4*4)->apriori10[,3] #troisième vecteur
rep(rep(c("s","vs","vw","w"),each=16),times=4)->apriori10[,2] #deuxième vecteur
rep(rep(c("Q1","Q2","Q3","Q4"),each=16*4))->apriori10[,1]  #premier vecteur
View(apriori10)
df_expertise7=data.frame(Trimestre=apriori10[,1],ValInit=apriori10[,2],ValInit_minq=apriori
10[,3],ValInit_min4q=apriori10[,4])
View(df_expertise7)

#-----------------------------
#cr?ation d'une nouvelle base d'apprentissage en renforçant le degr? d'occurence des valeurs m?dianes (pour la bas d'expertise des facteurs F1)

#dimension de la base
4*4*4*4  #cardinal de chacune des listes de catégories pour les variables Trimestre, Val_init et Val_Init_minq et Val_Init_min4q
```

```
#cr?ation d'un vecteur caractère vide
c("")->apriori11

#cr?ation d'un vecteur de la taille de la base d'apprentissage
apriori11<-rep(apriori11, each=4*64*4)
dim(apriori11)<-c(4*64,4)

#cr?ation d'un vecteur pour chaque variable de la base d'apprentissage
rep(c("s","s","w","w"),times=16*4)->apriori11[,4] #quatrième vecteur
rep(rep(c("s","s","w","w"),each=4),times=4*4)->apriori11[,3] #troisième vecteur
rep(rep(c("s","s","w","w"),each=4*4),times=4)->apriori11[,2] #deuxième vecteur
rep(rep(c("Q1","Q2","Q3","Q4"),each=16*4))->apriori11[,1]  #premier vecteur
View(apriori11)

#création de apriori12 pour accueillir la concaténatation des deux tables (en vue de la création de la vraie base d'expertise)
c("")->apriori12

#cr?ation d'un vecteur de la taille de la base d'apprentissage
apriori12<-rep(apriori12, each=256*2*4)
dim(apriori12)<-c(256*2,4)
factor(apriori12)->apriori12
#fusion des tables apriori10 et apriori11 pour augmenter les occurences médianes
factor(c(as.vector(apriori10[,1]),as.vector(apriori11[,1])))->tati1
factor(c(as.vector(apriori10[,2]),as.vector(apriori11[,2])))->tati2
factor(c(as.vector(apriori10[,3]),as.vector(apriori11[,3])))->tati3
factor(c(as.vector(apriori10[,4]),as.vector(apriori11[,4])))->tati4

#construction du nouveau dataframe d'expertise
df_expertise8=data.frame(Trimestre=tati1,ValInit=tati2,ValInit_minq=tati3,ValInit_min4q=tati4)
View(df_expertise8)
```

2. Présentation d'un réseau bayésien « fitté »

Cette annexe présente à titre d'illustration le réseau bayésien « fitté » utile pour :

- Déterminer les probabilités d'usage pour la détermination de facteurs de développement
- Avec une base d'apprentissage où le poids de l'expérience et de l'expertise sont à parité (crédibilité 1/1)
- Dans son instanciation (base « Leave One Out ») pour faire de l'inférence pour le quatrième trimestre de l'année 2018

```
> fitted_bn_auto_6_app32

 Bayesian network parameters

 Parameters of node F1 (multinomial distribution)

Conditional probability table:

, , F1_minq = s, Trimestre = Q1

   F1_min4q
F1       s      vs      vw      w
 s  0.45000000 0.25000000 0.25000000 0.11688312
 vs 0.05000000 0.25000000 0.25000000 0.01298701
 vw 0.05000000 0.25000000 0.25000000 0.25974026
 w  0.45000000 0.25000000 0.25000000 0.61038961

, , F1_minq = vs, Trimestre = Q1

   F1_min4q
F1       s      vs      vw      w
 s  0.25000000 0.25000000 0.25000000 0.02380952
 vs 0.25000000 0.25000000 0.25000000 0.02380952
 vw 0.25000000 0.25000000 0.25000000 0.02380952
 w  0.25000000 0.25000000 0.25000000 0.92857143

, , F1_minq = vw, Trimestre = Q1

   F1_min4q
F1       s      vs      vw      w
 s  0.25000000 0.25000000 0.25000000 0.25000000
 vs 0.25000000 0.25000000 0.25000000 0.25000000
 vw 0.25000000 0.25000000 0.25000000 0.25000000
 w  0.25000000 0.25000000 0.25000000 0.25000000

, , F1_minq = w, Trimestre = Q1

   F1_min4q
F1       s      vs      vw      w
 s  0.45000000 0.25000000 0.25000000 0.23076923
 vs 0.05000000 0.25000000 0.25000000 0.02564103
 vw 0.05000000 0.25000000 0.25000000 0.02564103
 w  0.45000000 0.25000000 0.25000000 0.71794872

, , F1_minq = s, Trimestre = Q2
```

```
  F1_min4q
F1       s      vs      vw      w
 s 0.45000000 0.25000000 0.25000000 0.45000000
 vs 0.05000000 0.25000000 0.25000000 0.05000000
 vw 0.05000000 0.25000000 0.25000000 0.05000000
 w 0.45000000 0.25000000 0.25000000 0.45000000

, , F1_minq = vs, Trimestre = Q2

  F1_min4q
F1       s      vs      vw      w
 s 0.25000000 0.25000000 0.25000000 0.25000000
 vs 0.25000000 0.25000000 0.25000000 0.25000000
 vw 0.25000000 0.25000000 0.25000000 0.25000000
 w 0.25000000 0.25000000 0.25000000 0.25000000

, , F1_minq = vw, Trimestre = Q2

  F1_min4q
F1       s      vs      vw      w
 s 0.25000000 0.25000000 0.25000000 0.04347826
 vs 0.25000000 0.25000000 0.25000000 0.04347826
 vw 0.25000000 0.25000000 0.25000000 0.04347826
 w 0.25000000 0.25000000 0.25000000 0.86956522

, , F1_minq = w, Trimestre = Q2

  F1_min4q
F1       s      vs      vw      w
 s 0.48275862 0.04347826 0.25000000 0.48275862
 vs 0.34482759 0.04347826 0.25000000 0.01724138
 vw 0.01724138 0.04347826 0.25000000 0.01724138
 w 0.15517241 0.86956522 0.25000000 0.48275862

, , F1_minq = s, Trimestre = Q3

  F1_min4q
F1       s      vs      vw      w
 s 0.45000000 0.04347826 0.04347826 0.45000000
 vs 0.05000000 0.04347826 0.86956522 0.05000000
 vw 0.05000000 0.04347826 0.04347826 0.05000000
 w 0.45000000 0.86956522 0.04347826 0.45000000

, , F1_minq = vs, Trimestre = Q3

  F1_min4q
F1       s      vs      vw      w
 s 0.25000000 0.25000000 0.25000000 0.04347826
 vs 0.25000000 0.25000000 0.25000000 0.86956522
 vw 0.25000000 0.25000000 0.25000000 0.04347826
 w 0.25000000 0.25000000 0.25000000 0.04347826

, , F1_minq = vw, Trimestre = Q3

  F1_min4q
F1       s      vs      vw      w
 s 0.25000000 0.25000000 0.25000000 0.25000000
 vs 0.25000000 0.25000000 0.25000000 0.25000000
 vw 0.25000000 0.25000000 0.25000000 0.25000000
 w 0.25000000 0.25000000 0.25000000 0.25000000
```

```
, , F1_minq = w, Trimestre = Q3

  F1_min4q
F1       s     vs     vw     w
 s 0.45000000 0.04347826 0.04347826 0.23076923
 vs 0.05000000 0.04347826 0.04347826 0.02564103
 vw 0.05000000 0.04347826 0.86956522 0.51282051
 w 0.45000000 0.86956522 0.04347826 0.23076923

, , F1_minq = s, Trimestre = Q4

  F1_min4q
F1       s     vs     vw     w
 s 0.45000000 0.25000000 0.25000000 0.45000000
 vs 0.05000000 0.25000000 0.25000000 0.05000000
 vw 0.05000000 0.25000000 0.25000000 0.05000000
 w 0.45000000 0.25000000 0.25000000 0.45000000

, , F1_minq = vs, Trimestre = Q4

  F1_min4q
F1       s     vs     vw     w
 s 0.04347826 0.25000000 0.25000000 0.04347826
 vs 0.86956522 0.25000000 0.25000000 0.86956522
 vw 0.04347826 0.25000000 0.25000000 0.04347826
 w 0.04347826 0.25000000 0.25000000 0.04347826

, , F1_minq = vw, Trimestre = Q4

  F1_min4q
F1       s     vs     vw     w
 s 0.86956522 0.25000000 0.25000000 0.25000000
 vs 0.04347826 0.25000000 0.25000000 0.25000000
 vw 0.04347826 0.25000000 0.25000000 0.25000000
 w 0.04347826 0.25000000 0.25000000 0.25000000

, , F1_minq = w, Trimestre = Q4

  F1_min4q
F1       s     vs     vw     w
 s 0.45000000 0.47619048 0.25000000 0.45000000
 vs 0.05000000 0.02380952 0.25000000 0.05000000
 vw 0.05000000 0.02380952 0.25000000 0.05000000
 w 0.45000000 0.47619048 0.25000000 0.45000000

Parameters of node F1_min4q (multinomial distribution)

Conditional probability table:
      s     vs     vw      w
0.2824025 0.1675448 0.1074816 0.4425711

 Parameters of node F1_minq (multinomial distribution)

Conditional probability table:
      s     vs     vw      w
0.2852883 0.1580517 0.1202783 0.4363817

 Parameters of node Trimestre (multinomial distribution)

Conditional probability table:
     Q1     Q2     Q3     Q4
0.2546341 0.2546341 0.2546341 0.2360976
```

3. Tables de données catégorisées à destination des réseaux bayésiens

Première campagne (avant optimisation) : cas de la BU Espagne, pour la branche d'activité automobile, entre 2012 et 2018 :

Trimestre	F1	F2	F1_minq	F1_min4q	F2_minq	F2_min4q	Vallnit	Vallnit_minq	Vallnit_min4q
Q1	VW	VW					W		
Q2	VW	VW	VW		VW		W	W	
Q3	VW	W	VW		VW		S	W	
Q4	W	VW	VW		W		W	S	
Q1	VW	VW	W	VW	VW	VW	W	W	W
Q2	W	W	VW	VW	VW	VW	S	W	W
Q3	W	W	W	VW	W	W	VS	S	S
Q4	W	VW	W	W	W	VW	S	VS	W
Q1	VW	VW	W	VW	VW	VW	S	S	W
Q2	S	VW	VW	W	VW	W	W	S	S
Q3	VW	S	S	W	VW	W	VS	W	VS
Q4	S	W	VW	W	S	VW	W	VS	S
Q1	W	W	S	VW	W	VW	S	W	S
Q2	S	S	W	S	W	VW	S	S	W
Q3	VS	S	S	VW	S	S	S	S	VS
Q4	S	W	VS	S	S	W	W	S	W
Q1	S	VW	S	W	W	W	VW	W	S
Q2	W	VS	S	S	VW	S	W	VW	S
Q3	VS	S	W	VS	VS	S	W	W	S
Q4	VS	S	VS	S	S	W	VW	W	W
Q1	S	S	VS	S	S	VW	VW	VW	VW
Q2	VS	S	S	W	S	VS	VW	VW	W
Q3	S	S	VS	VS	S	S	S	VW	W
Q4	S	VW	S	VS	S	S	W	S	VW
Q1	VW	VW	S	S	VW	S	S	W	VW
Q2	VW	VW	VW	VS	VW	S	VS	S	VW
Q3	W		VW	S	VW	S	VS	VS	S
Q4			W	S		VW	S	VS	W
Q1				VW		VW		S	S
Q2				VW		VW			VS
Q3				W					VS
Q4									S

Première campagne (avant optimisation) : cas de la BU Espagne, pour la branche d'activité voyages, entre 2012 et 2018 :

Trimestre	F1	F2	F1_minq	F1_min4	F2_minq	F2_min4	Vallnit	Vallnit_minq	Vallnit_min4q
Q1	w	s					vs		
Q2	w	s	w		s		w	vs	
Q3	vw	vw	w		s		vs	w	
Q4	s	w	vw		vw		vs	vs	
Q1	w	w	w		w		vs	vs	vs
Q2	w	s	w		vw		vs	vs	w
Q3	w	vw	s		w		s	vs	vs
Q4	s	w	vw		vw		w	vs	vs
Q1	w	w	s		vw		s	vs	vs
Q2	s	w	w		w		s	s	vs
Q3	vs	vw	s		w		vs	w	s
Q4	w	s	w		vw		w	vw	vw
Q1	w	s	w		vw		s	vw	vw
Q2	w	s	w		vw		vw	s	w
Q3	w	s	w		w		vw	vw	vw
Q4	s	w	w		w		s	vw	vw
Q1	vw	s	s		w		w	vw	vw
Q2	w	vs	vw		s		vw	w	vw
Q3	vw		w		vs		w	vw	s
Q4			vw		w		s	w	s
Q1				vw	s			s	w
Q2				w		vs			vw
Q3				vw					w
Q4									s

Deuxième campagne (après optimisation) : cas de la BU Espagne, pour la branche d'activité automobile, entre 2012 et 2018 :

Trimestre	F1	F2	F1_minq	F1_min4q	F2_minq	F2_min4q	Vallnit	Vallnit_minq	Vallnit_min4q
Q1	vw	vw					w		
Q2	vw	vw	vw		vw		w	w	
Q3	vw	w	vw		vw		vs	w	
Q4	w	vw	vw		w		w	vs	
Q1	vw	w	w		vw		w	w	w
Q2	w	w	vw		vw		s	w	w
Q3	w	vw	vw		w		vs	s	vs
Q4	w	vw	w		vw		s	vs	w
Q1	vw	vw	vw		vw		w	w	w
Q2	vw	vw	vw		vw		s	w	w
Q3	vw	vw	vw		vw		vs	w	vs
Q4	vs	vw	vw		vw		s	vs	w
Q1	s	vw	vw		vw		s	vs	w
Q2	s	vw	w		vw		s	vs	w
Q3	vs	vw	vs		vw		s	vs	vs
Q4	vs	vw	vs		vw		s	vs	w
Q1	s	vw	vs		vw		s	vs	w
Q2	w	vw	s		vw		s	vs	w
Q3	vs	vw	vs		vw		s	vs	s
Q4	vs	s	vs		vw		s	vs	s
Q1	s	s	vs		vw		s	vs	s
Q2	vs	s	s		w		s	vs	s
Q3	vs	s	vs		vw		s	vs	vs
Q4	s	vw	vs		vw		w	s	vw
Q1	vw	vw	s		vw		vs	w	vw
Q2	vw	vw	vs		vw		vs	vs	vw
Q3	w	vw	vw		vw		vs	vs	s
Q4			w		vw		s	vs	w
Q1				vw	vw	vw		s	vs
Q2				vw	vw				vs
Q3				w					vs
Q4									s

Deuxième campagne (après optimisation) : cas de la BU Espagne, pour la branche d'activité assistance voyage, entre 2012 et 2018 :

Trimestre	F1	F2	F1_minq	F1_min4q	F2_minq	F2_min4q	ValInit	ValInit_minq	ValInit_min4q
Q1	W	VS					VS		
Q2	VW	VS	W		VS		S	VS	
Q3	VW	VW	VW		VS		VS	S	
Q4	S	W	VW		VW		VS	VS	
Q1	W	VW	S	W	W	VS	VS	VS	VS
Q2	W	S	W	VW	VW	VS	VS	VS	S
Q3	VW	VW	W	VW	S	VW	S	VS	VS
Q4	S	W	VW	S	VW	W	VS	S	VS
Q1	W	W	S	W	W	VW	S	VS	VS
Q2	VS	W	W	W	W	S	W	S	VS
Q3	VS	VW	VS	VW	W	VW	VS	W	S
Q4	VS	VS	VS	S	VW	W	VW	VS	VS
Q1	VW	VS	VS	W	VS	W	VW	VW	S
Q2	VS	VW	VW	VS	VS	W	VW	VW	W
Q3	VW	S	VS	VS	VW	VW	VS	VW	VS
Q4	VW	VS	VW	VS	S	VS	VW	VS	VW
Q1	W	W	VW	VW	VS	VS	VW	VW	VW
Q2	VS	VS	W	VS	W	VW	S	VW	VW
Q3	VS	W	VS	VW	VS	S	VW	S	VS
Q4	VS	S	VS	VW	W	VS	S	VW	VW
Q1	W	W	VS	W	S	W	VS	S	VW
Q2	W	S	W	VS	W	VS	VW	VS	S
Q3	VW	VS	W	VS	S	W	S	VW	VW
Q4	S	W	VW	VS	VS	S	VS	S	S
Q1	VW	S	S	W	W	W	W	VS	VS
Q2	VW	VS	VW	W	S	S	W	W	VW
Q3	VW		VW	VW	VS	VS	S	W	S
Q4			VW	S		W	S	S	VS
Q1				VW		S		S	W
Q2				VW		VS			W
Q3				VW					S
Q4									S

4. Tables des résultats d'inférence

Structure de la table des résultats d'inférence

- Numéro_de_test (référence),
- Business_Unit,
- LOB,
- Cas (libellé du test),
- Réseau bayésien utilisé,
- Base d'apprentissage utilisée,
- Evidence (variables d'entrée du réseau)
- Crédibilité (degré de crédibilité Expérience/Expertise dans la base d'apprentissage),
- S : probabilité inférée dans la catégorie "S" (« Strong") -pour la variable de sortie-,
- VS : probabilité inférée dans la catégorie "VS" ("Very Strong") -pour la variable de sortie-,
- VW : probabilité inférée dans la catégorie "VW" ("Very Weak") -pour la variable de sortie-,
- W : probabilité inférée dans la catégorie "W" ("Weak") - pour la variable de sortie-.

Première campagne de test (avant optimisation)

intermédiaire technique	Numéro_de_test	Business Unit	LOB	Cas	réseau	apprentissage	evidence	Crédibilité (Experience/ Expertise)	S	VS	VW	W	Valorisation Variable bayesienne (F1 ou Montant initial) selon (1)	Valorisation Variable bayesienne (F1 ou Montant initial) selon (2)	Valorisation Variable bayesienne (F1 ou Montant initial) selon (3)	Valorisation Variable bayesienne (F1 ou Montant initial) selon (4)
autorechercheP AID_2019_Q11 pour 1	7 BUSP	auto	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage6	evidence7	1 pour 1	0,592	0,038	0,072	0,298	8 164 863	8 521 309	8 020 908	9 021 709
autorechercheP AID_2019_Q110 pour1	8 BUSP	auto	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage6_C1	evidence7	10 pour 1	0,898	0,014	0,014	0,074	8 443 876	8 521 309	8 020 908	9 021 709
autorechercheP AID_2019_Q11 pour 10	9 BUSP	auto	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage6_C2	evidence7	1 pour 10	0,434	0,092	0,084	0,39	8 113 363	8 521 309	8 020 908	9 021 709
autorechercheP AID_2018_Q41 pour 1	10 BUSP	auto	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage7	evidence8	1 pour 1	0,454	0,088	0,074	0,384	8 070 386	8 459 627	7 959 227	8 960 027
autorechercheP AID_2018_Q410 pour1	11 BUSP	auto	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage7_C1	evidence8	10 pour 1	0,506	0,004	0,006	0,484	8 015 014	8 459 627	7 959 227	8 960 027
autorechercheP AID_2018_Q41 pour 10	12 BUSP	auto	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage7_C2	evidence8	1 pour 10	0,328	0,2	0,184	0,288	8 077 253	8 459 627	7 959 227	8 960 027
autorechercheP AID_2018_Q31 pour 1	13 BUSP	auto	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage8	evidence9	1 pour 1	0,24	0,268	0,246	0,246	8 013 204	9 367 910	8 898 345	9 837 475
autorechercheP AID_2018_Q310 pour1	14 BUSP	auto	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage8_C1	evidence9	10 pour 1	0,252	0,24	0,276	0,232	7 947 261	6 682 623	6 277 649	7 087 597
autorechercheP AID_2018_Q31 pour 10	15 BUSP	auto	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage8_C2	evidence9	1 pour 10	0,284	0,222	0,284	0,21	7 935 997	8 397 945	7 897 545	8 898 345
autorechercheP AID_2018_Q21 pour 1	15 BUSP	auto	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage9	evidence10	1 pour 1	0,48	0,034	0,044	0,442	7 893 592	8 336 263	7 835 863	8 836 664
autorechercheP AID_2018_Q210 pour1	16 BUSP	auto	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage9_C1	evidence10	10 pour 1	0,476	0,014	0,014	0,496	7 876 763	7 430 889	7 025 915	7 835 863
autorechercheP AID_2018_Q21 pour 10	17 BUSP	auto	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage9_C2	evidence10	1 pour 10	0,428	0,084	0,074	0,414	7 915 981	8 336 263	7 835 863	8 836 664
autorechercheP AID_2018_Q11 pour 1	18 BUSP	auto	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage10	evidence11	1 pour 1	0,374	0,052	0,206	0,368	7 638 485	8 274 581	7 774 181	8 774 982
autorechercheP AID_2018_Q110 pour1	19 BUSP	auto	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage10_C1	evidence11	10 pour 1	0,322	0,01	0,332	0,336	7 410 588	7 369 207	6 964 233	7 774 181
autorechercheP AID_2018_Q11 pour 10	20 BUSP	auto	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage10_C2	evidence11	1 pour 10	0,416	0,074	0,114	0,396	7 792 284	8 274 581	7 774 181	8 774 982
autorechercheP AID_2017_Q41 pour 1	21 BUSP	auto	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage11	evidence12	1 pour 1	0,216	0,048	0,04	0,696	7 560 704	7 307 525	6 902 551	7 712 499
autorechercheP AID_2017_Q410 pour1	22 BUSP	auto	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage11_C1	evidence12	10 pour 1	0,038	0,004	0,01	0,948	7 341 331	7 307 525	6 902 551	7 712 499
autorechercheP AID_2017_Q41 pour 10	23 BUSP	auto	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage11_C2	evidence12	1 pour 10	0,4	0,08	0,07	0,45	7 763 006	7 307 525	6 902 551	7 712 499
autorechercheP AID_2017_Q31 pour 1	24 BUSP	auto	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage12	evidence13	1 pour 1	0,224	0,232	0,246	0,298	7 684 479	7 245 843	6 840 869	7 650 817
autorechercheP AID_2017_Q310 pour1	25 BUSP	auto	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage12_C1	evidence13	10 pour 1	0,248	0,24	0,25	0,262	7 717 971	7 245 843	6 840 869	7 650 817
autorechercheP AID_2017_Q31 pour 10	27 BUSP	auto	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage12_C2	evidence13	1 pour 10	0,272	0,264	0,224	0,24	7 805 766	8 151 218	7 650 817	8 651 618
autorechercheP AID_2017_Q21 pour 1	28 BUSP	auto	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage13	evidence14	1 pour 1	0,102	0,116	0,128	0,654	7 390 376	7 184 161	6 779 187	7 589 135
autorechercheP AID_2017_Q210 pour1	29 BUSP	auto	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage13_C1	evidence14	10 pour 1	0,026	0,014	0,02	0,94	7 217 757	7 184 161	6 779 187	7 589 135
autorechercheP AID_2017_Q21 pour 10	30 BUSP	auto	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage13_C2	evidence14	1 pour 10	0,214	0,218	0,206	0,362	7 619 886	7 184 161	6 779 187	7 589 135
autorechercheP AID_2017_Q11 pour 1	31 BUSP	auto	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage14	evidence15	1 pour 1	0,234	0,234	0,254	0,278	7 567 440	7 122 480	6 717 506	7 527 453
autorechercheP AID_2017_Q110 pour1	32 BUSP	auto	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage14_C1	evidence15	10 pour 1	0,232	0,292	0,206	0,27	7 713 276	8 997 819	8 528 254	9 467 384
autorechercheP AID_2017_Q11 pour 10	33 BUSP	auto	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage14_C2	evidence15	1 pour 10	0,25	0,27	0,244	0,236	7 657 537	8 997 819	8 528 254	9 467 384
autorechercheP AID_2017_Q1 pour 1	34 BUSP	auto	rechercheP1_2018_Q4	bn_auto_6	df_apprentissage15	evidence16	1 pour 1	0,456	0,054	0,058	0,432	1,487	1,556	1,462	1,649
autorechercheP1_2018_Q410 pour1	35 BUSP	auto	rechercheP1_2018_Q4	bn_auto_6	df_apprentissage15_C1	evidence16	10 pour 1	0,044	0,058	0,06	0,442	1,486	1,408	1,354	1,462
autorechercheP1_2018_Q41 pour 10	36 BUSP	auto	rechercheP1_2018_Q4	bn_auto_6	df_apprentissage15_C2	evidence16	1 pour 10	0,504	0,04	0,04	0,416	1,492	1,556	1,462	1,649
autorechercheP1_2018_Q31 pour 1	37 BUSP	auto	rechercheP1_2018_Q3	bn_auto_6	df_apprentissage16	evidence17	1 pour 1	0,262	0,25	0,278	0,21	1,500	1,299	1,245	1,354
autorechercheP1_2018_Q310 pour 1	38 BUSP	auto	rechercheP1_2018_Q3	bn_auto_6	df_apprentissage16_C1	evidence17	10 pour 1	0,25	0,256	0,246	0,248	1,504	1,743	1,649	1,837
autorechercheP1_2018_Q31 pour 10	39 BUSP	auto	rechercheP1_2018_Q3	bn_auto_6	df_apprentissage16_C2	evidence17	1 pour 10	0,242	0,256	0,244	0,258	1,503	1,408	1,354	1,462
autorechercheP1_2018_Q21 pour 1	40 BUSP	auto	rechercheP1_2018_Q2	bn_auto_6	df_apprentissage17	evidence18	1 pour 1	0,25	0,256	0,234	0,26	1,505	1,408	1,354	1,462
autorechercheP1_2018_Q210 pour 1	41 BUSP	auto	rechercheP1_2018_Q2	bn_auto_6	df_apprentissage17_C1	evidence18	10 pour 1	0,25	0,252	0,248	0,25	1,502	1,743	1,649	1,837
autorechercheP1_2018_Q21 pour 10	42 BUSP	auto	rechercheP1_2018_Q2	bn_auto_6	df_apprentissage17_C2	evidence18	1 pour 10	0,256	0,258	0,246	0,24	1,506	1,743	1,649	1,837
autorechercheP1_2018_Q11 pour 1	43 BUSP	auto	rechercheP1_2018_Q1	bn_auto_6	df_apprentissage18	evidence19	1 pour 1	0,414	0,064	0,052	0,47	1,485	1,408	1,354	1,462
autorechercheP1_2018_Q110 pour 1	44 BUSP	auto	rechercheP1_2018_Q1	bn_auto_6	df_apprentissage18_C1	evidence19	10 pour 1	0,432	0,048	0,056	0,464	1,482	1,408	1,354	1,462
autorechercheP1_2018_Q11 pour 10	45 BUSP	auto	rechercheP1_2018_Q1	bn_auto_6	df_apprentissage18_C2	evidence19	1 pour 10	0,418	0,054	0,054	0,474	1,482	1,408	1,354	1,462
autorechercheP1_2017_Q41 pour 1	46 BUSP	auto	rechercheP1_2017_Q4	bn_auto_6	df_apprentissage19	evidence20	1 pour 1	0,252	0,262	0,258	0,228	1,505	1,743	1,649	1,837
autorechercheP1_2017_Q410 pour 1	47 BUSP	auto	rechercheP1_2017_Q4	bn_auto_6	df_apprentissage19_C1	evidence20	10 pour 1	0,256	0,238	0,266	0,24	1,497	1,299	1,245	1,354
autorechercheP1_2017_Q41 pour 10	48 BUSP	auto	rechercheP1_2017_Q4	bn_auto_6	df_apprentissage19_C2	evidence20	1 pour 10	0,236	0,24	0,27	0,254	1,494	1,299	1,245	1,354
autorechercheP1_2017_Q31 pour 1	49 BUSP	auto	rechercheP1_2017_Q3	bn_auto_6	df_apprentissage20	evidence21	1 pour 1	0,232	0,248	0,276	0,244	1,495	1,299	1,245	1,354
autorechercheP1_2017_Q310 pour 1	50 BUSP	auto	rechercheP1_2017_Q3	bn_auto_6	df_apprentissage20_C1	evidence21	10 pour 1	0,242	0,246	0,248	0,264	1,499	1,408	1,354	1,462
autorechercheP1_2017_Q31 pour 10	51 BUSP	auto	rechercheP1_2017_Q3	bn_auto_6	df_apprentissage20_C2	evidence21	1 pour 10	0,262	0,244	0,26	0,234	1,500	1,556	1,462	1,649
autorechercheP1_2017_Q21 pour 1	52 BUSP	auto	rechercheP1_2017_Q2	bn_auto_6	df_apprentissage21	evidence22	1 pour 1	0,456	0,058	0,054	0,432	1,489	1,556	1,462	1,649
autorechercheP1_2017_Q210 pour 1	53 BUSP	auto	rechercheP1_2017_Q2	bn_auto_6	df_apprentissage21_C1	evidence22	10 pour 1	0,452	0,048	0,05	0,45	1,486	1,556	1,462	1,649
autorechercheP1_2017_Q21 pour 10	54 BUSP	auto	rechercheP1_2017_Q2	bn_auto_6	df_apprentissage21_C2	evidence22	1 pour 10	0,46	0,044	0,054	0,442	1,485	1,556	1,462	1,649
autorechercheP1_2017_Q11 pour 1	55 BUSP	auto	rechercheP1_2017_Q1	bn_auto_6	df_apprentissage22	evidence23	1 pour 1	0,26	0,246	0,234	0,274	1,507	1,556	1,462	1,649
autorechercheP1_2017_Q110 pour 1	56 BUSP	auto	rechercheP1_2017_Q1	bn_auto_6	df_apprentissage22_C1	evidence23	10 pour 1	0,238	0,23	0,264	0,268	1,492	1,408	1,354	1,462
autorechercheP1_2017_Q11 pour 10	57 BUSP	auto	rechercheP1_2017_Q1	bn_auto_6	df_apprentissage22_C2	evidence23	1 pour 10	0,232	0,238	0,256	0,274	1,494	1,408	1,354	1,462

intermédiaire technique	Numéro_de_test	Business Unit	LOB	Cas	réseau	apprentissage	evidence	Crédibilité (Experience/ Expertise)	S	VS	VW	W	Valorisation Variable bayesienne (F1 ou Montant initial) selon (1)	Valorisation Variable bayesienne (F1 ou Montant initial) selon (2)	Valorisation Variable bayesienne (F1 ou Montant initial) selon (3)	Valorisation Variable bayesienne (F1 ou Montant initial) selon (4)
travelrecherche PAID_2019_Q11 pour 1	58	BUSP	travel	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage23	evidence24	1 pour 1	0,468	0,048	0,024	0,46	177 908	161 238	179 371	143 106
travelrecherche PAID_2019_Q110 pour 1	59	BUSP	travel	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage23_C1	evidence24	10 pour 1	0,49	0,004	0,008	0,498	179 725	197 491	215 611	179 371
travelrecherche PAID_2019_Q11 pour 10	60	BUSP	travel	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage23_C2	evidence24	1 pour 10	0,41	0,072	0,078	0,44	180 215	197 491	215 611	179 371
travelrecherche PAID_2018_Q41 pour 1	61	BUSP	travel	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage24	evidence25	1 pour 1	0,448	0,08	0,082	0,39	181 300	164 136	182 269	146 004
travelrecherche PAID_2018_Q410 pour 1	62	BUSP	travel	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage24_C1	evidence25	10 pour 1	0,43	0,088	0,07	0,412	180 940	164 136	182 269	146 004
travelrecherche PAID_2018_Q41 pour 10	63	BUSP	travel	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage24_C2	evidence25	1 pour 10	0,416	0,086	0,07	0,428	181 593	200 389	218 509	182 269
travelrecherche PAID_2018_Q31 pour 1	64	BUSP	travel	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage25	evidence26	1 pour 1	0,806	0,07	0,052	0,072	410 496	417 272	385 357	449 187
travelrecherche PAID_2018_Q310 pour 1	65	BUSP	travel	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage25_C1	evidence26	10 pour 1	0,962	0,01	0,012	0,016	415 355	417 272	385 357	449 187
travelrecherche PAID_2018_Q31 pour 10	66	BUSP	travel	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage25_C2	evidence26	1 pour 10	0,39	0,228	0,212	0,17	393 865	417 272	385 357	449 187
travelrecherche PAID_2018_Q21 pour 1	67	BUSP	travel	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage26	evidence27	1 pour 1	0,44	0,074	0,112	0,374	188 901	169 932	188 065	151 800
travelrecherche PAID_2018_Q210 pour 1	68	BUSP	travel	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage26_C1	evidence27	10 pour 1	0,462	0,072	0,068	0,398	186 664	169 932	188 065	151 800
travelrecherche PAID_2018_Q21 pour 10	69	BUSP	travel	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage26_C2	evidence27	1 pour 10	0,4	0,086	0,076	0,438	188 185	206 185	224 305	188 065
travelrecherche PAID_2018_Q11 pour 1	70	BUSP	travel	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage27	evidence28	1 pour 1	0,614	0,06	0,07	0,256	184 994	172 830	190 963	154 698
travelrecherche PAID_2018_Q110 pour 1	71	BUSP	travel	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage27_C1	evidence28	10 pour 1	0,874	0,026	0,014	0,086	176 017	172 830	190 963	154 698
travelrecherche PAID_2018_Q11 pour 10	72	BUSP	travel	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage27_C2	evidence28	1 pour 10	0,444	0,082	0,058	0,416	189 129	172 830	190 963	154 698
travelrecherche PAID_2017_Q41 pour 1	73	BUSP	travel	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage28	evidence29	1 pour 1	0,218	0,286	0,26	0,236	192 702	139 464	157 596	121 332
travelrecherche PAID_2017_Q410 pour 1	74	BUSP	travel	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage28_C1	evidence29	10 pour 1	0,048	0,45	0,44	0,062	193 455	139 464	157 596	121 332
travelrecherche PAID_2017_Q41 pour 10	75	BUSP	travel	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage28_C2	evidence29	1 pour 10	0,376	0,128	0,116	0,38	193 246	211 981	230 101	193 861
travelrecherche PAID_2017_Q31 pour 1	76	BUSP	travel	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage29	evidence30	1 pour 1	0,436	0,074	0,078	0,412	397 323	428 864	396 949	460 779
travelrecherche PAID_2017_Q310 pour 1	77	BUSP	travel	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage29_C1	evidence30	10 pour 1	0,49	0,006	0,01	0,494	396 446	365 055	333 161	396 949
travelrecherche PAID_2017_Q31 pour 10	78	BUSP	travel	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage29_C2	evidence30	1 pour 10	0,26	0,22	0,21	0,31	396 269	365 055	333 161	396 949
travelrecherche PAID_2017_Q21 pour 1	79	BUSP	travel	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage30	evidence31	1 pour 1	0,288	0,06	0,054	0,598	204 930	217 777	235 897	199 657
travelrecherche PAID_2017_Q210 pour 1	80	BUSP	travel	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage30_C1	evidence31	10 pour 1	0,104	0,014	0,018	0,864	213 640	217 777	235 897	199 657
travelrecherche PAID_2017_Q21 pour 10	81	BUSP	travel	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage30_C2	evidence31	1 pour 10	0,362	0,098	0,104	0,436	201 293	217 777	235 897	199 657
travelrecherche PAID_2017_Q11 pour 1	82	BUSP	travel	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage31	evidence32	1 pour 1	0,286	0,058	0,054	0,602	208 046	220 675	238 795	202 555
travelrecherche PAID_2017_Q110 pour 1	83	BUSP	travel	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage31_C1	evidence32	10 pour 1	0,088	0,014	0,012	0,886	216 902	220 675	238 795	202 555
travelrecherche PAID_2017_Q11 pour 10	84	BUSP	travel	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage31_C2	evidence32	1 pour 10	0,386	0,086	0,086	0,442	203 542	220 675	238 795	202 555
travelrechercheF1_2018_Q41 pour 1	85	BUSP	travel	rechercheF1_2018_Q4	bn_auto_6	df_apprentissage32	evidence33	1 pour 1	0,842	0,06	0,054	0,044	2,712	2,745	2,497	2,993
travelrechercheF1_2018_Q410 pour 1	86	BUSP	travel	rechercheF1_2018_Q4	bn_auto_6	df_apprentissage32_C1	evidence33	10 pour 1	0,982	0,01	0,002	0,006	2,746	2,745	2,497	2,993
travelrechercheF1_2018_Q41 pour 10	87	BUSP	travel	rechercheF1_2018_Q4	bn_auto_6	df_apprentissage32_C2	evidence33	1 pour 10	0,484	0,154	0,166	0,196	2,602	2,745	2,497	2,993
travelrechercheF1_2018_Q31 pour 1	88	BUSP	travel	rechercheF1_2018_Q3	bn_auto_6	df_apprentissage33	evidence34	1 pour 1	0,208	0,022	0,534	0,236	2,223	1,939	1,753	2,125
travelrechercheF1_2018_Q310 pour 1	89	BUSP	travel	rechercheF1_2018_Q3	bn_auto_6	df_apprentissage33_C1	evidence34	10 pour 1	0,034	0,002	0,926	0,038	1,983	1,939	1,753	2,125
travelrechercheF1_2018_Q31 pour 10	90	BUSP	travel	rechercheF1_2018_Q3	bn_auto_6	df_apprentissage33_C2	evidence34	1 pour 10	0,43	0,032	0,156	0,382	2,469	2,745	2,497	2,993
travelrechercheF1_2018_Q21 pour 1	91	BUSP	travel	rechercheF1_2018_Q2	bn_auto_6	df_apprentissage34	evidence35	1 pour 1	0,04	0,062	0,022	0,876	2,378	2,311	2,125	2,497
travelrechercheF1_2018_Q210 pour 1	92	BUSP	travel	rechercheF1_2018_Q2	bn_auto_6	df_apprentissage34_C1	evidence35	10 pour 1	0,002	0,004	0,002	0,992	2,315	2,311	2,125	2,497
travelrechercheF1_2018_Q21 pour 10	93	BUSP	travel	rechercheF1_2018_Q2	bn_auto_6	df_apprentissage34_C2	evidence35	1 pour 10	0,15	0,206	0,176	0,468	2,502	2,311	2,125	2,497
travelrechercheF1_2018_Q11 pour 1	94	BUSP	travel	rechercheF1_2018_Q1	bn_auto_6	df_apprentissage35	evidence36	1 pour 1	0,112	0,008	0,25	0,63	2,274	2,311	2,125	2,497
travelrechercheF1_2018_Q110 pour 1	95	BUSP	travel	rechercheF1_2018_Q1	bn_auto_6	df_apprentissage35_C1	evidence36	10 pour 1	0,024	0,002	0,324	0,65	2,203	2,311	2,125	2,497
travelrechercheF1_2018_Q11 pour 10	96	BUSP	travel	rechercheF1_2018_Q1	bn_auto_6	df_apprentissage35_C2	evidence36	1 pour 10	0,344	0,046	0,114	0,496	2,461	2,311	2,125	2,497
travelrechercheF1_2017_Q41 pour 1	97	BUSP	travel	rechercheF1_2017_Q4	bn_auto_6	df_apprentissage36	evidence37	1 pour 1	0,446	0,034	0,032	0,488	2,524	2,311	2,125	2,497
travelrechercheF1_2017_Q410 pour 1	98	BUSP	travel	rechercheF1_2017_Q4	bn_auto_6	df_apprentissage36_C1	evidence37	10 pour 1	0,527	0,001	0,001	0,471	2,540	2,745	2,497	2,993
travelrechercheF1_2017_Q41 pour 10	99	BUSP	travel	rechercheF1_2017_Q4	bn_auto_6	df_apprentissage36_C2	evidence37	1 pour 10	0,336	0,128	0,12	0,416	2,531	2,311	2,125	2,497
travelrechercheF1_2017_Q31 pour 1	100	BUSP	travel	rechercheF1_2017_Q3	bn_auto_6	df_apprentissage37	evidence38	1 pour 1	0,036	0,054	0,062	0,848	2,354	2,311	2,125	2,497
travelrechercheF1_2017_Q310 pour 1	101	BUSP	travel	rechercheF1_2017_Q3	bn_auto_6	df_apprentissage37_C1	evidence38	10 pour 1	0,002	0,008	0,004	0,986	2,318	2,311	2,125	2,497
travelrechercheF1_2017_Q31 pour 10	102	BUSP	travel	rechercheF1_2017_Q3	bn_auto_6	df_apprentissage37_C2	evidence38	1 pour 10	0,182	0,182	0,174	0,462	2,495	2,311	2,125	2,497
travelrechercheF1_2017_Q21 pour 1	103	BUSP	travel	rechercheF1_2017_Q2	bn_auto_6	df_apprentissage38	evidence39	1 pour 1	0,05	0,044	0,046	0,86	2,357	2,311	2,125	2,497
travelrechercheF1_2017_Q210 pour 1	104	BUSP	travel	rechercheF1_2017_Q2	bn_auto_6	df_apprentissage38_C1	evidence39	10 pour 1	0,002	0,01	0,002	0,986	2,321	2,311	2,125	2,497
travelrechercheF1_2017_Q21 pour 10	105	BUSP	travel	rechercheF1_2017_Q2	bn_auto_6	df_apprentissage38_C2	evidence39	1 pour 10	0,16	0,186	0,208	0,446	2,476	2,311	2,125	2,497
travelrechercheF1_2017_Q11 pour 1	106	BUSP	travel	rechercheF1_2017_Q1	bn_auto_6	df_apprentissage39	evidence40	1 pour 1	0,02	0,02	0,026	0,934	2,329	2,311	2,125	2,497
travelrechercheF1_2017_Q110 pour 1	107	BUSP	travel	rechercheF1_2017_Q1	bn_auto_6	df_apprentissage39_C1	evidence40	10 pour 1	0,002	0,004	0,002	0,992	2,315	2,311	2,125	2,497
travelrechercheF1_2017_Q11 pour 10	108	BUSP	travel	rechercheF1_2017_Q1	bn_auto_6	df_apprentissage39_C2	evidence40	1 pour 10	0,16	0,186	0,208	0,446	2,476	2,311	2,125	2,497

Deuxième campagne de test (après optimisation) :

intermédiaire technique	Numéro_de_test	Business Unit	LOB	Cas	réseau	apprentissage	evidence	Crédibilité (Experience/ Expertise)	S	VS	VW	W	Valorisation Variable bayesienne (F1 ou Montant Initial) selon (…	Valorisation Variable bayesienne (F1 ou Montant Initial) selon (…	Valorisation Variable bayesienne (F1 ou Montant Initial) selon (…	Valorisation Variable bayesienne (F1 ou Montant Initial) selon (…
NEWautorechercheP AID_2019_Q11 pour 1	109	BUSP	auto	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage6	evidence7	1 pour 1	0,606	0,058	0,058	0,278	8 148 325	8 346 850	7 992 509	8 701 191
NEWautorechercheP AID_2019_Q110 pour 1	110	BUSP	auto	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage6_C1	evidence7	10 pour 1	0,89	0,026	0,016	0,068	8 304 568	8 346 850	7 992 509	8 701 191
NEWautorechercheP AID_2019_Q11 pour 10	111	BUSP	auto	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage6_C2	evidence7	1 pour 10	0,418	0,07	0,118	0,394	8 015 507	8 346 850	7 992 509	8 701 191
NEWautorechercheP AID_2018_Q41 pour 1	112	BUSP	auto	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage7	evidence8	1 pour 1	0,34	0,056	0,344	0,26	7 766 193	7 130 580	6 863 831	7 397 329
NEWautorechercheP AID_2018_Q410 pour 1	113	BUSP	auto	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage7_C1	evidence8	10 pour 1	0,302	0,006	0,372	0,32	7 661 165	7 130 580	6 863 831	7 397 329
NEWautorechercheP AID_2018_Q41 pour 10	114	BUSP	auto	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage7_C2	evidence8	1 pour 10	0,264	0,182	0,278	0,276	7 921 752	7 130 580	6 863 831	7 397 329
NEWautorechercheP AID_2018_Q31 pour 1	115	BUSP	auto	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage8	evidence9	1 pour 1	0,214	0,24	0,268	0,278	7 911 477	7 602 396	7 335 647	7 869 145
NEWautorechercheP AID_2018_Q310 pour 1	116	BUSP	auto	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage8_C1	evidence9	10 pour 1	0,268	0,238	0,246	0,248	7 954 094	8 223 486	7 869 145	8 577 827
NEWautorechercheP AID_2018_Q310 pour 10	117	BUSP	auto	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage8_C2	evidence9	1 pour 10	0,25	0,24	0,264	0,246	7 935 971	7 068 898	6 802 149	7 335 647
NEWautorechercheP AID_2018_Q21 pour 1	118	BUSP	auto	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage9	evidence10	1 pour 1	0,46	0,036	0,296	0,208	7 716 372	8 161 805	7 807 464	8 516 145
NEWautorechercheP AID_2018_Q210 pour 1	119	BUSP	auto	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage9_C1	evidence10	10 pour 1	0,462	0,014	0,486	0,038	7 586 995	7 007 216	6 740 467	7 273 965
NEWautorechercheP AID_2018_Q21 pour 10	120	BUSP	auto	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage9_C2	evidence10	1 pour 10	0,442	0,056	0,09	0,412	7 841 689	8 161 805	7 807 464	8 516 145
NEWautorechercheP AID_2018_Q11 pour 1	121	BUSP	auto	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage10	evidence11	1 pour 1	0,284	0,082	0,05	0,584	7 737 789	7 479 033	7 212 283	7 745 782
NEWautorechercheP AID_2018_Q110 pour 1	122	BUSP	auto	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage10_C1	evidence11	10 pour 1	0,1	0,022	0,014	0,864	7 562 928	7 479 033	7 212 283	7 745 782
NEWautorechercheP AID_2018_Q11 pour 10	123	BUSP	auto	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage10_C2	evidence11	1 pour 10	0,398	0,054	0,078	0,47	7 756 421	7 479 033	7 212 283	7 745 782
NEWautorechercheP AID_2017_Q41 pour 1	124	BUSP	auto	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage11	evidence12	1 pour 1	0,278	0,04	0,346	0,336	7 458 614	6 883 852	6 617 103	7 150 602
NEWautorechercheP AID_2017_Q410 pour 1	125	BUSP	auto	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage11_C1	evidence12	10 pour 1	0,102	0,01	0,812	0,076	7 060 799	6 883 852	6 617 103	7 150 602
NEWautorechercheP AID_2017_Q41 pour 10	126	BUSP	auto	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage11_C2	evidence12	1 pour 10	0,416	0,088	0,108	0,388	7 735 126	8 038 441	7 684 100	8 392 782
NEWautorechercheP AID_2017_Q31 pour 1	127	BUSP	auto	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage12	evidence13	1 pour 1	0,078	0,424	0,418	0,08	7 744 935	8 085 441	8 331 100	9 039 782
NEWautorechercheP AID_2017_Q310 pour 1	128	BUSP	auto	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage12_C1	evidence13	10 pour 1	0,012	0,472	0,504	0,012	7 721 891	6 822 171	6 555 421	7 088 920
NEWautorechercheP AID_2017_Q310 pour 10	129	BUSP	auto	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage12_C2	evidence13	1 pour 10	0,172	0,328	0,3	0,2	7 738 612	8 685 441	8 331 100	9 039 782
NEWautorechercheP AID_2017_Q21 pour 1	130	BUSP	auto	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage13	evidence14	1 pour 1	0,102	0,134	0,65	0,114	7 188 754	6 760 489	6 493 740	7 027 238
NEWautorechercheP AID_2017_Q210 pour 1	131	BUSP	auto	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage13_C1	evidence14	10 pour 1	0,018	0,02	0,94	0,022	6 830 274	6 760 489	6 493 740	7 027 238
NEWautorechercheP AID_2017_Q21 pour 10	132	BUSP	auto	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage13_C2	evidence14	1 pour 10	0,234	0,24	0,258	0,268	7 620 825	7 593 987	7 027 238	7 560 736
NEWautorechercheP AID_2017_Q11 pour 1	133	BUSP	auto	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage14	evidence15	1 pour 1	0,418	0,074	0,438	0,07	7 356 652	6 698 807	6 432 058	6 965 556
NEWautorechercheP AID_2017_Q110 pour 1	134	BUSP	auto	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage14_C1	evidence15	10 pour 1	0,464	0,014	0,516	0,006	7 263 823	6 698 807	6 432 058	6 965 556
NEWautorechercheP AID_2017_Q11 pour 10	135	BUSP	auto	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage14_C2	evidence15	1 pour 10	0,284	0,206	0,324	0,186	7 509 774	6 698 807	6 432 058	6 965 556
NEWautorechercheP AID_2018_Q41 pour 1	136	BUSP	auto	recherche PAID_2018_Q4	bn_auto_6	df_apprentissage15	evidence16	1 pour 1	0,46	0,048	0,048	0,444	1,46760167	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2018_Q410 pour 1	137	BUSP	auto	recherche PAID_2018_Q4	bn_auto_6	df_apprentissage15_C1	evidence16	10 pour 1	0,472	0,042	0,052	0,434	1,46714764	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2018_Q41 pour 10	138	BUSP	auto	recherche PAID_2018_Q4	bn_auto_6	df_apprentissage15_C2	evidence16	1 pour 10	0,428	0,05	0,056	0,466	1,46370298	1,410841039	1,359300639	1,462381439
NEWautorechercheP AID_2018_Q31 pour 1	139	BUSP	auto	recherche PAID_2018_Q3	bn_auto_6	df_apprentissage16	evidence17	1 pour 1	0,244	0,306	0,242	0,208	1,48259193 6	1,638842447	1,580022111	1,697662784
NEWautorechercheP AID_2018_Q310 pour 1	140	BUSP	auto	recherche PAID_2018_Q3	bn_auto_6	df_apprentissage16_C1	evidence17	10 pour 1	0,296	0,244	0,224	0,236	1,47605006 1	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2018_Q31 pour 10	141	BUSP	auto	recherche PAID_2018_Q3	bn_auto_6	df_apprentissage16_C2	evidence17	1 pour 10	0,232	0,258	0,248	0,262	1,46970505	1,410841039	1,359300639	1,462381439
NEWautorechercheP AID_2018_Q21 pour 1	142	BUSP	auto	recherche PAID_2018_Q2	bn_auto_6	df_apprentissage17	evidence18	1 pour 1	0,284	0,242	0,274	0,2	1,46911569	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2018_Q210 pour 1	143	BUSP	auto	recherche PAID_2018_Q2	bn_auto_6	df_apprentissage17_C1	evidence18	10 pour 1	0,262	0,254	0,246	0,238	1,47231003 3	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2018_Q21 pour 10	144	BUSP	auto	recherche PAID_2018_Q2	bn_auto_6	df_apprentissage17_C2	evidence18	1 pour 10	0,246	0,254	0,294	0,206	1,46559638 3	1,307760239	1,25621984	1,359300639
NEWautorechercheP AID_2018_Q11 pour 1	145	BUSP	auto	recherche PAID_2018_Q1	bn_auto_6	df_apprentissage18	evidence19	1 pour 1	0,446	0,088	0,046	0,42	1,47538343 3	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2018_Q110 pour 1	146	BUSP	auto	recherche PAID_2018_Q1	bn_auto_6	df_apprentissage18_C1	evidence19	10 pour 1	0,442	0,038	0,054	0,466	1,46278175	1,410841039	1,359300639	1,462381439
NEWautorechercheP AID_2018_Q11 pour 10	147	BUSP	auto	recherche PAID_2018_Q1	bn_auto_6	df_apprentissage18_C2	evidence19	1 pour 10	0,448	0,046	0,05	0,456	1,46561667 4	1,410841039	1,359300639	1,462381439
NEWautorechercheP AID_2017_Q41 pour 1	148	BUSP	auto	recherche PAID_2017_Q4	bn_auto_6	df_apprentissage19	evidence20	1 pour 1	0,238	0,274	0,228	0,26	1,47607685 8	1,638842447	1,580022111	1,697662784
NEWautorechercheP AID_2017_Q410 pour 1	149	BUSP	auto	recherche PAID_2017_Q4	bn_auto_6	df_apprentissage19_C1	evidence20	10 pour 1	0,264	0,246	0,25	0,24	1,47029442	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q41 pour 10	150	BUSP	auto	recherche PAID_2017_Q4	bn_auto_6	df_apprentissage19_C2	evidence20	1 pour 10	0,276	0,242	0,244	0,238	1,47132528	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q31 pour 1	151	BUSP	auto	recherche PAID_2017_Q3	bn_auto_6	df_apprentissage20	evidence21	1 pour 1	0,27	0,21	0,254	0,266	1,46233621	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q310 pour 1	152	BUSP	auto	recherche PAID_2017_Q3	bn_auto_6	df_apprentissage20_C1	evidence21	10 pour 1	0,282	0,252	0,242	0,224	1,47447568	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q31 pour 10	153	BUSP	auto	recherche PAID_2017_Q3	bn_auto_6	df_apprentissage20_C2	evidence21	1 pour 10	0,248	0,256	0,268	0,228	1,46895328	1,307760239	1,25621984	1,359300639
NEWautorechercheP AID_2017_Q21 pour 1	154	BUSP	auto	recherche PAID_2017_Q2	bn_auto_6	df_apprentissage21	evidence22	1 pour 1	0,474	0,044	0,054	0,428	1,46761727	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q210 pour 1	155	BUSP	auto	recherche PAID_2017_Q2	bn_auto_6	df_apprentissage21_C1	evidence22	10 pour 1	0,474	0,046	0,042	0,438	1,46931069	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q21 pour 10	156	BUSP	auto	recherche PAID_2017_Q2	bn_auto_6	df_apprentissage21_C2	evidence22	1 pour 10	0,492	0,046	0,044	0,418	1,47109103 1	1,521201775	1,462381439	1,580022111
NEWautorechercheP AID_2017_Q11 pour 1	157	BUSP	auto	recherche PAID_2017_Q1	bn_auto_6	df_apprentissage22	evidence23	1 pour 1	0,26	0,294	0,202	0,244	1,48574923	1,638842447	1,580022111	1,697662784
NEWautorechercheP AID_2017_Q110 pour 1	158	BUSP	auto	recherche P AID_2017_Q1	bn_auto_6	df_apprentissage22_C1	evidence23	10 pour 1	0,22	0,284	0,202	0,294	1,47900509	1,410841039	1,359300639	1,462381439
NEWautorechercheP AID_2017_Q11 pour 10	159	BUSP	auto	recherche P AID_2017_Q1	bn_auto_6	df_apprentissage22_C2	evidence23	1 pour 10	0,248	0,282	0,248	0,222	1,47694286	1,638842447	1,580022111	1,697662784

intermédiaire technique	Numéro_de_test	Business Un	LOB	Cas	réseau	apprentissage	evidence	Crédibilité (Experience/ Expertise	S	VS	VW	W	Valorisation Variable bayesienne (F1 ou Montant initial) selon (	Valorisation Variable bayesienne (F1 ou Montant initial) selon (	Valorisation Variable bayesienne (F1 ou Montant initial) selon (	Valorisation Variable bayesienne (F1 ou Montant initial) selon (
NEWtravelrecherche PAID_2019_Q11 pour 1	160	BUSP	travel	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage23	evodence24	1 pour 1	0,296	0,322	0,046	0,336	175 998	205 440	219 908	190 971
NEWtravelrecherche PAID_2019_Q110 pour 1	161	BUSP	travel	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage23_C1	evodence24	10 pour 1	0,076	0,814	0,012	0,098	146 666	135 402	163 963	106 842
NEWtravelrecherche PAID_2019_Q11 pour 10	162	BUSP	travel	recherche PAID_2019_Q1	bn_auto_7	df_apprentissage23_C2	evodence24	1 pour 10	0,4	0,09	0,09	0,42	190 667	205 440	219 908	190 971
NEWtravelrecherche PAID_2018_Q41 pour 1	163	BUSP	travel	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage24	evodence25	1 pour 1	0,422	0,054	0,086	0,438	195 350	208 338	222 806	193 869
NEWtravelrecherche PAID_2018_Q410 pour 1	164	BUSP	travel	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage24_C1	evodence25	10 pour 1	0,436	0,086	0,084	0,394	192 657	180 365	193 869	166 861
NEWtravelrecherche PAID_2018_Q41 pour 10	165	BUSP	travel	recherche PAID_2018_Q4	bn_auto_7	df_apprentissage24_C2	evodence25	1 pour 10	0,412	0,082	0,078	0,428	193 427	208 338	222 806	193 869
NEWtravelrecherche PAID_2018_Q31 pour 1	166	BUSP	travel	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage25	evodence26	1 pour 1	0,44	0,384	0,082	0,094	404 056	388 707	364 938	412 476
NEWtravelrecherche PAID_2018_Q310 pour 1	167	BUSP	travel	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage25_C1	evodence26	10 pour 1	0,496	0,492	0,008	0,004	424 113	388 707	364 938	412 476
NEWtravelrecherche PAID_2018_Q31 pour 10	168	BUSP	travel	recherche PAID_2018_Q3	bn_auto_7	df_apprentissage25_C2	evodence26	1 pour 10	0,31	0,3	0,204	0,186	380 728	388 707	364 938	412 476
NEWtravelrecherche PAID_2018_Q21 pour 1	169	BUSP	travel	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage26	evodence27	1 pour 1	0,41	0,09	0,066	0,434	198 356	214 134	228 602	199 665
NEWtravelrecherche PAID_2018_Q210 pour 1	170	BUSP	travel	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage26_C1	evodence27	10 pour 1	0,43	0,07	0,062	0,438	199 076	214 134	228 602	199 665
NEWtravelrecherche PAID_2018_Q21 pour 10	171	BUSP	travel	recherche PAID_2018_Q2	bn_auto_7	df_apprentissage26_C2	evodence27	1 pour 10	0,424	0,07	0,082	0,424	199 848	186 161	199 665	172 657
NEWtravelrecherche PAID_2018_Q11 pour 1	172	BUSP	travel	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage27	evodence28	1 pour 1	0,288	0,372	0,064	0,276	184 856	146 994	175 555	118 434
NEWtravelrecherche PAID_2018_Q110 pour 1	173	BUSP	travel	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage27_C1	evodence28	10 pour 1	0,088	0,78	0,024	0,108	160 666	146 994	175 555	118 434
NEWtravelrecherche PAID_2018_Q11 pour 10	174	BUSP	travel	recherche PAID_2018_Q1	bn_auto_7	df_apprentissage27_C2	evodence28	1 pour 10	0,416	0,146	0,084	0,354	197 708	189 059	202 563	175 555
NEWtravelrecherche PAID_2017_Q41 pour 1	175	BUSP	travel	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage28	evodence29	1 pour 1	0,422	0,304	0,04	0,234	188 043	191 957	205 461	178 453
NEWtravelrecherche PAID_2017_Q410 pour 1	176	BUSP	travel	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage28_C1	evodence29	10 pour 1	0,458	0,484	0,02	0,038	173 825	149 892	178 453	121 332
NEWtravelrecherche PAID_2017_Q41 pour 10	177	BUSP	travel	recherche PAID_2017_Q4	bn_auto_7	df_apprentissage28_C2	evodence29	1 pour 10	0,476	0,124	0,04	0,36	199 139	191 957	205 461	178 453
NEWtravelrecherche PAID_2017_Q31 pour 1	178	BUSP	travel	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage29	evodence30	1 pour 1	0,144	0,616	0,126	0,114	427 303	474 339	424 068	524 610
NEWtravelrecherche PAID_2017_Q310 pour 1	179	BUSP	travel	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage29_C1	evodence30	10 pour 1	0,014	0,946	0,024	0,016	467 078	474 339	424 068	524 610
NEWtravelrecherche PAID_2017_Q31 pour 10	180	BUSP	travel	recherche PAID_2017_Q3	bn_auto_7	df_apprentissage29_C2	evodence30	1 pour 10	0,214	0,34	0,212	0,234	392 093	474 339	424 068	524 610
NEWtravelrecherche PAID_2017_Q21 pour 1	181	BUSP	travel	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage30	evodence31	1 pour 1	0,318	0,072	0,044	0,566	213 117	225 726	240 194	211 257
NEWtravelrecherche PAID_2017_Q210 pour 1	182	BUSP	travel	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage30_C1	evodence31	10 pour 1	0,08	0,016	0,018	0,888	222 818	225 726	240 194	211 257
NEWtravelrecherche PAID_2017_Q21 pour 10	183	BUSP	travel	recherche PAID_2017_Q2	bn_auto_7	df_apprentissage30_C2	evodence31	1 pour 10	0,402	0,066	0,096	0,436	212 759	225 726	240 194	211 257
NEWtravelrecherche PAID_2017_Q11 pour 1	184	BUSP	travel	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage31	evodence32	1 pour 1	0,426	0,102	0,064	0,408	211 497	200 651	214 155	187 147
NEWtravelrecherche PAID_2017_Q110 pour 1	185	BUSP	travel	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage31_C1	evodence32	10 pour 1	0,424	0,096	0,088	0,392	212 699	200 651	214 155	187 147
NEWtravelrecherche PAID_2017_Q11 pour 10	186	BUSP	travel	recherche PAID_2017_Q1	bn_auto_7	df_apprentissage31_C2	evodence32	1 pour 10	0,396	0,104	0,086	0,414	212 861	228 624	243 092	214 155
NEWtravelrecherche F1_2018_Q41 pour 1	187	BUSP	travel	recherche F1_2018_Q4	bn_auto_6	df_apprentissage32	evodence33	1 pour 1	0,858	0,052	0,056	0,034	2,692493316	2,713062503	2,497042326	2,92908268
NEWtravelrecherche F1_2018_Q410 pour 1	188	BUSP	travel	recherche F1_2018_Q4	bn_auto_6	df_apprentissage32_C1	evodence33	10 pour 1	0,988	0,006	0,002	0,004	2,71319063	2,713062503	2,497042326	2,92908268
NEWtravelrecherche F1_2018_Q41 pour 10	189	BUSP	travel	recherche F1_2018_Q4	bn_auto_6	df_apprentissage32_C2	evodence33	1 pour 10	0,496	0,148	0,16	0,196	2,621144931	2,713062503	2,497042326	2,92908268
NEWtravelrecherche F1_2018_Q31 pour 1	190	BUSP	travel	recherche F1_2018_Q3	bn_auto_6	df_apprentissage33	evodence34	1 pour 1	0,48	0,058	0,042	0,42	2,574547076	2,713062503	2,497042326	2,92908268
NEWtravelrecherche F1_2018_Q310 pour 1	191	BUSP	travel	recherche F1_2018_Q3	bn_auto_6	df_apprentissage33_C1	evodence34	10 pour 1	0,462	0,052	0,056	0,43	2,560696784	2,713062503	2,497042326	2,92908268
NEWtravelrecherche F1_2018_Q31 pour 10	192	BUSP	travel	recherche F1_2018_Q3	bn_auto_6	df_apprentissage33_C2	evodence34	1 pour 10	0,448	0,066	0,06	0,426	2,565810954	2,713062503	2,497042326	2,92908268
NEWtravelrecherche F1_2018_Q21 pour 1	193	BUSP	travel	recherche F1_2018_Q2	bn_auto_6	df_apprentissage34	evodence35	1 pour 1	0,034	0,04	0,874	0,052	2,21798797	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2018_Q210 pour 1	194	BUSP	travel	recherche F1_2018_Q2	bn_auto_6	df_apprentissage34_C1	evodence35	10 pour 1	0,006	0,004	0,984	0,006	2,15543821	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2018_Q21 pour 10	195	BUSP	travel	recherche F1_2018_Q2	bn_auto_6	df_apprentissage34_C2	evodence35	1 pour 10	0,152	0,152	0,502	0,194	2,429823697	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2018_Q11 pour 1	196	BUSP	travel	recherche F1_2018_Q1	bn_auto_6	df_apprentissage35	evodence36	1 pour 1	0,126	0,014	0,234	0,626	2,378224178	2,380242975	2,263443625	2,497042326
NEWtravelrecherche F1_2018_Q110 pour 1	197	BUSP	travel	recherche F1_2018_Q1	bn_auto_6	df_apprentissage35_C1	evodence36	10 pour 1	0,01	0	0,354	0,636	2,30087723	2,380242975	2,263443625	2,497042326
NEWtravelrecherche F1_2018_Q11 pour 10	198	BUSP	travel	recherche F1_2018_Q1	bn_auto_6	df_apprentissage35_C2	evodence36	1 pour 10	0,394	0,044	0,104	0,458	2,520733439	2,380242975	2,263443625	2,497042326
NEWtravelrecherche F1_2017_Q41 pour 1	199	BUSP	travel	recherche F1_2017_Q4	bn_auto_6	df_apprentissage36	evodence37	1 pour 1	0,24	0,252	0,26	0,248	2,59212869	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q410 pour 1	200	BUSP	travel	recherche F1_2017_Q4	bn_auto_6	df_apprentissage36_C1	evodence37	10 pour 1	0,258	0,214	0,28	0,248	2,564382792	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q41 pour 10	201	BUSP	travel	recherche F1_2017_Q4	bn_auto_6	df_apprentissage36_C2	evodence37	1 pour 10	0,232	0,238	0,288	0,242	2,572217332	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q31 pour 1	202	BUSP	travel	recherche F1_2017_Q3	bn_auto_6	df_apprentissage37	evodence38	1 pour 1	0,04	0,044	0,868	0,048	2,224445919	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q310 pour 1	203	BUSP	travel	recherche F1_2017_Q3	bn_auto_6	df_apprentissage37_C1	evodence38	10 pour 1	0,006	0,014	0,98	0	2,164021204	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q31 pour 10	204	BUSP	travel	recherche F1_2017_Q3	bn_auto_6	df_apprentissage37_C2	evodence38	1 pour 10	0,166	0,186	0,52	0,128	2,45628363	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q21 pour 1	205	BUSP	travel	recherche F1_2017_Q2	bn_auto_6	df_apprentissage38	evodence39	1 pour 1	0,026	0,468	0,018	0,488	2,742645931	2,380242975	2,263443625	2,497042326
NEWtravelrecherche F1_2017_Q210 pour 1	206	BUSP	travel	recherche F1_2017_Q2	bn_auto_6	df_apprentissage38_C1	evodence39	10 pour 1	0,004	0,512	0,002	0,482	2,772715315	3,145102856	2,92908268	3,361123033
NEWtravelrecherche F1_2017_Q21 pour 10	207	BUSP	travel	recherche F1_2017_Q2	bn_auto_6	df_apprentissage38_C2	evodence39	1 pour 10	0,12	0,404	0,128	0,348	2,699284077	3,145102856	2,92908268	3,361123033
NEWtravelrecherche F1_2017_Q11 pour 1	208	BUSP	travel	recherche F1_2017_Q1	bn_auto_6	df_apprentissage39	evodence40	1 pour 1	0,024	0,028	0,466	0,482	2,300789726	2,380242975	2,263443625	2,497042326
NEWtravelrecherche F1_2017_Q110 pour 1	209	BUSP	travel	recherche F1_2017_Q1	bn_auto_6	df_apprentissage39_C1	evodence40	10 pour 1	0,002	0,004	0,518	0,476	2,262963927	2,146644274	2,029844924	2,263443625
NEWtravelrecherche F1_2017_Q11 pour 10	210	BUSP	travel	recherche F1_2017_Q1	bn_auto_6	df_apprentissage39_C2	evodence40	1 pour 10	0,12	0,404	0,128	0,348	2,699284077	3,145102856	2,92908268	3,361123033

5. Table des résultats actuariels

Structure de la table des résultats

La structure de la table des résultats est la suivante :

- Technical Test ID (identifiant de test)
- Model\information (modèle appliqué),
- Numéro_de_test,
- Niveau_de_crédibilité,
- Valorisation de la catégorie (1), (2), (3), (4),
- Business Unit,
- LOB,
- Cohorte,
- Paid1 (k€),
- F1,
- ULT (k€),
- GEP (k€),
- LR,
- LR-BF,
- ULT-BF (k€)

Première campagne de test (avant optimisation)

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
1	Chain-ladder classical		sans objet		BUSP	auto	2017Q1	5 981	1,494398	9 329	16 343	57,1%	58,0%	9 487
2	Actual		sans objet		BUSP	auto	2017Q1	6 247	1,547295	10 110	16 343	61,9%	62,0%	10 135
3	Bayesian for Paid1	31	1/1	1	BUSP	auto	2017Q1	7 567	1,494398	11 804	16 343	72,2%	72,2%	11 804
4	Bayesian for Paid1	32	10/1	1	BUSP	auto	2017Q1	7 713	1,494398	12 031	16 343	73,6%	73,6%	12 031
5	Bayesian for Paid1	33	1/10	1	BUSP	auto	2017Q1	7 658	1,494398	11 944	16 343	73,1%	73,1%	11 944
6	Bayesian Network for F1	55	1/1	1	BUSP	auto	2017Q1	5 981	1,506833	9 406	16 343	57,6%	58,4%	9 546
7	Bayesian Network for F1	56	10/1	1	BUSP	auto	2017Q1	5 981	1,491571	9 311	16 343	57,0%	58,0%	9 474
8	Bayesian Network for F1	57	1/10	1	BUSP	auto	2017Q1	5 981	1,494234	9 328	16 343	57,1%	58,0%	9 486
9	Bayesian Network for mix (Paid1+F1)	55-31	1/1	1	BUSP	auto	2017Q1	7 567	1,506833	11 902	16 343	72,8%	72,8%	11 902
10	Bayesian Network for mix (Paid1+F1)	56-32	10/1	1	BUSP	auto	2017Q1	7 713	1,491571	12 008	16 343	73,5%	73,5%	12 008
11	Bayesian Network for mix (Paid1+F1)	57-33	1/10	1	BUSP	auto	2017Q1	7 658	1,494234	11 943	16 343	73,1%	73,1%	11 943
12	Chain-ladder classical		sans objet		BUSP	auto	2017Q2	6 068	1,49068	9 450	16 830	56,2%	59,3%	9 974
13	Actual		sans objet		BUSP	auto	2017Q2	6 494	1,697663	11 586	16 830	68,8%	68,9%	11 597
14	Bayesian for Paid1	28	1/1	1	BUSP	auto	2017Q2	7 390	1,49068	11 510	16 830	68,4%	68,5%	11 527
15	Bayesian for Paid1	29	10/1	1	BUSP	auto	2017Q2	7 218	1,49068	11 241	16 830	66,8%	67,0%	11 284
16	Bayesian for Paid1	30	1/10	1	BUSP	auto	2017Q2	7 620	1,49068	11 868	16 830	70,5%	70,5%	11 868
17	Bayesian Network for F1	52	1/1	1	BUSP	auto	2017Q2	6 068	1,489027	9 440	16 830	56,1%	59,2%	9 968
18	Bayesian Network for F1	53	10/1	1	BUSP	auto	2017Q2	6 068	1,48552	9 418	16 830	56,0%	59,2%	9 955
19	Bayesian Network for F1	54	1/10	1	BUSP	auto	2017Q2	6 068	1,484928	9 414	16 830	55,9%	59,1%	9 953
20	Bayesian Network for mix (Paid1+F1)	52-28	1/1	1	BUSP	auto	2017Q2	7 390	1,489027	11 497	16 830	68,3%	68,4%	11 515
21	Bayesian Network for mix (Paid1+F1)	53-29	10/1	1	BUSP	auto	2017Q2	7 218	1,48552	11 203	16 830	66,6%	66,8%	11 250
22	Bayesian Network for mix (Paid1+F1)	54-30	1/10	1	BUSP	auto	2017Q2	7 620	1,484928	11 822	16 830	70,2%	70,3%	11 823
23	Chain-ladder classical		sans objet		BUSP	auto	2017Q3	7 531	1,474136	11 577	17 270	67,0%	69,1%	11 934
24	Actual		sans objet		BUSP	auto	2017Q3	8 035	1,594313	13 358	17 270	77,3%	77,4%	13 372
25	Bayesian for Paid1	24	1/1	1	BUSP	auto	2017Q3	7 684	1,474136	11 814	17 270	68,4%	70,1%	12 099
26	Bayesian for Paid1	25	10/1	1	BUSP	auto	2017Q3	7 718	1,474136	11 865	17 270	68,7%	70,3%	12 136
27	Bayesian for Paid1	27	1/10	1	BUSP	auto	2017Q3	7 806	1,474136	12 000	17 270	69,5%	70,8%	12 234
28	Bayesian Network for F1	49	1/1	1	BUSP	auto	2017Q3	7 531	1,49541	11 766	17 270	68,1%	69,9%	12 065
29	Bayesian Network for F1	50	10/1	1	BUSP	auto	2017Q3	7 531	1,499263	11 796	17 270	68,3%	70,0%	12 086
30	Bayesian Network for F1	51	1/10	1	BUSP	auto	2017Q3	7 531	1,500247	11 804	17 270	68,3%	70,0%	12 092
31	Bayesian Network for mix (Paid1+F1)	49-24	1/1	1	BUSP	auto	2017Q3	7 684	1,49541	12 006	17 270	69,5%	70,9%	12 239
32	Bayesian Network for mix (Paid1+F1)	50-25	10/1	1	BUSP	auto	2017Q3	7 718	1,499263	12 090	17 270	70,0%	71,2%	12 301
33	Bayesian Network for mix (Paid1+F1)	51-27	1/10	1	BUSP	auto	2017Q3	7 806	1,500247	12 235	17 270	70,8%	71,9%	12 412
34	Chain-ladder classical		sans objet		BUSP	auto	2017Q4	6 642	1,492849	10 356	18 669	55,5%	57,0%	10 644
35	Actual		sans objet		BUSP	auto	2017Q4	7 561	1,470176	11 547	18 669	61,9%	62,1%	11 586
36	Bayesian for Paid1	21	1/1	1	BUSP	auto	2017Q4	7 561	1,492849	11 787	18 669	63,1%	63,2%	11 804
37	Bayesian for Paid1	22	10/1	1	BUSP	auto	2017Q4	7 341	1,492849	11 445	18 669	61,3%	61,6%	11 496
38	Bayesian for Paid1	23	1/10	1	BUSP	auto	2017Q4	7 763	1,492849	12 103	18 669	64,8%	64,8%	12 104
39	Bayesian Network for F1	46	1/1	1	BUSP	auto	2017Q4	6 642	1,505015	10 445	18 669	55,9%	57,4%	10 707
40	Bayesian Network for F1	47	10/1	1	BUSP	auto	2017Q4	6 642	1,496697	10 387	18 669	55,6%	57,1%	10 666
41	Bayesian Network for F1	48	1/10	1	BUSP	auto	2017Q4	6 642	1,493973	10 368	18 669	55,5%	57,1%	10 653
42	Bayesian Network for mix (Paid1+F1)	46-21	1/1	1	BUSP	auto	2017Q4	7 561	1,505015	11 889	18 669	63,7%	63,7%	11 899
43	Bayesian Network for mix (Paid1+F1)	47-22	10/1	1	BUSP	auto	2017Q4	7 341	1,496697	11 480	18 669	61,5%	61,7%	11 527
44	Bayesian Network for mix (Paid1+F1)	48-23	1/10	1	BUSP	auto	2017Q4	7 763	1,493973	12 117	18 669	64,9%	64,9%	12 118
45	Chain-ladder classical		sans objet		BUSP	auto	2018Q1	7 984	1,494398	12 453	17 645	70,6%	70,6%	12 453
46	Actual		sans objet		BUSP	auto	2018Q1	8 596	1,244925	10 981	17 645	62,2%	62,3%	10 988
47	Bayesian for Paid1	18	1/1	1	BUSP	auto	2018Q1	7 638	1,494398	11 914	17 645	67,5%	67,5%	11 914
48	Bayesian for Paid1	19	10/1	1	BUSP	auto	2018Q1	7 411	1,494398	11 559	17 645	65,5%	65,5%	11 563
49	Bayesian for Paid1	20	1/10	1	BUSP	auto	2018Q1	7 792	1,494398	12 154	17 645	68,9%	68,9%	12 154
50	Bayesian Network for F1	43	1/1	1	BUSP	auto	2018Q1	7 984	1,485042	12 388	17 645	70,2%	70,2%	12 388
51	Bayesian Network for F1	44	10/1	1	BUSP	auto	2018Q1	7 984	1,481909	12 362	17 645	70,1%	70,1%	12 362
52	Bayesian Network for F1	45	1/10	1	BUSP	auto	2018Q1	7 984	1,482066	12 363	17 645	70,1%	70,1%	12 363
53	Bayesian Network for mix (Paid1+F1)	43-18	1/1	1	BUSP	auto	2018Q1	7 638	1,485042	11 852	17 645	67,2%	67,2%	11 852
54	Bayesian Network for mix (Paid1+F1)	44-19	10/1	1	BUSP	auto	2018Q1	7 411	1,481909	11 474	17 645	65,0%	65,1%	11 480
55	Bayesian Network for mix (Paid1+F1)	45-20	1/10	1	BUSP	auto	2018Q1	7 792	1,482066	12 066	17 645	68,4%	68,4%	12 066
56	Chain-ladder classical		sans objet		BUSP	auto	2018Q2	8 749	1,49068	13 626	17 821	76,5%	76,5%	13 626
57	Actual		sans objet		BUSP	auto	2018Q2	9 225	1,25622	12 090	17 821	67,8%	68,0%	12 114
58	Bayesian for Paid1	15	1/1	1	BUSP	auto	2018Q2	7 936	1,49068	12 360	17 821	69,4%	69,5%	12 385
59	Bayesian for Paid1	16	10/1	1	BUSP	auto	2018Q2	7 877	1,49068	12 268	17 821	68,8%	69,0%	12 298
60	Bayesian for Paid1	17	1/10	1	BUSP	auto	2018Q2	7 916	1,49068	12 329	17 821	69,2%	69,3%	12 356
61	Bayesian Network for F1	40	1/1	1	BUSP	auto	2018Q2	8 749	1,505319	13 760	17 821	77,2%	77,2%	13 760
62	Bayesian Network for F1	41	10/1	1	BUSP	auto	2018Q2	8 749	1,502456	13 734	17 821	77,1%	77,1%	13 734
63	Bayesian Network for F1	42	1/10	1	BUSP	auto	2018Q2	8 749	1,505572	13 763	17 821	77,2%	77,2%	13 763
64	Bayesian Network for mix (Paid1+F1)	40-15	1/1	1	BUSP	auto	2018Q2	7 936	1,505319	12 481	17 821	70,0%	70,1%	12 500
65	Bayesian Network for mix (Paid1+F1)	41-16	10/1	1	BUSP	auto	2018Q2	7 877	1,502456	12 365	17 821	69,4%	69,5%	12 389
66	Bayesian Network for mix (Paid1+F1)	42-17	1/10	1	BUSP	auto	2018Q2	7 916	1,505572	12 452	17 821	69,9%	70,0%	12 472
67	Chain-ladder classical		sans objet		BUSP	auto	2018Q3	10 154	1,474136	15 610	18 544	84,2%	84,2%	15 609
68	Actual		sans objet		BUSP	auto	2018Q3	9 539	1,448577	14 524	18 544	78,3%	78,3%	14 527
69	Bayesian for Paid1	13	1/1	1	BUSP	auto	2018Q3	8 013	1,474136	12 319	18 544	66,4%	68,0%	12 603
70	Bayesian for Paid1	14	10/1	1	BUSP	auto	2018Q3	7 947	1,474136	12 218	18 544	65,9%	67,5%	12 521
71	Bayesian for Paid1	15	1/10	1	BUSP	auto	2018Q3	7 936	1,474136	12 200	18 544	65,8%	67,4%	12 507
72	Bayesian Network for F1	37	1/1	1	BUSP	auto	2018Q3	10 154	1,5003	15 887	18 544	85,7%	85,7%	15 887
73	Bayesian Network for F1	38	10/1	1	BUSP	auto	2018Q3	10 154	1,504014	15 926	18 544	85,9%	85,9%	15 926
74	Bayesian Network for F1	39	1/10	1	BUSP	auto	2018Q3	10 154	1,503048	15 916	18 544	85,8%	85,8%	15 916
75	Bayesian Network for mix (Paid1+F1)	37-13	1/1	1	BUSP	auto	2018Q3	8 013	1,5003	12 538	18 544	67,6%	68,9%	12 783
76	Bayesian Network for mix (Paid1+F1)	38-14	10/1	1	BUSP	auto	2018Q3	7 947	1,504014	12 465	18 544	67,2%	68,6%	12 723
77	Bayesian Network for mix (Paid1+F1)	39-15	1/10	1	BUSP	auto	2018Q3	7 936	1,503048	12 439	18 544	67,1%	68,5%	12 702
78	Chain-ladder classical		sans objet		BUSP	auto	2018Q4	8 589	1,463088	13 103	18 730	70,0%	70,0%	13 102
79	Actual		sans objet		BUSP	auto	2018Q4	8 044		10 562	18 730	56,4%	57,7%	10 807
80	Bayesian for Paid1	10	1/1	1	BUSP	auto	2018Q4	8 070	1,463088	12 312	18 730	65,7%	65,7%	12 312
81	Bayesian for Paid1	11	10/1	1	BUSP	auto	2018Q4	8 015	1,463088	12 228	18 730	65,3%	65,3%	12 230
82	Bayesian for Paid1	12	1/10	1	BUSP	auto	2018Q4	8 077	1,463088	12 323	18 730	65,8%	65,8%	12 323
83	Bayesian Network for F1	34	1/1	1	BUSP	auto	2018Q4	8 589	1,487252	13 320	18 730	71,1%	71,1%	13 320
84	Bayesian Network for F1	35	10/1	1	BUSP	auto	2018Q4	8 589	1,486008	13 309	18 730	71,1%	71,1%	13 309
85	Bayesian Network for F1	36	1/10	1	BUSP	auto	2018Q4	8 589	1,491618	13 359	18 730	71,3%	71,3%	13 359
86	Bayesian Network for mix (Paid1+F1)	34-10	1/1	1	BUSP	auto	2018Q4	8 070	1,487252	12 515	18 730	66,8%	66,8%	12 512
87	Bayesian Network for mix (Paid1+F1)	35-11	10/1	1	BUSP	auto	2018Q4	8 015	1,486008	12 419	18 730	66,3%	66,3%	12 417
88	Bayesian Network for mix (Paid1+F1)	36-12	1/10	1	BUSP	auto	2018Q4	8 077	1,491618	12 563	18 730	67,1%	67,1%	12 558
89	Chain-ladder classical		sans objet		BUSP	auto	2019Q1	8 547	1,494398	13 332	17 887	74,5%	74,0%	13 230
90	Actual		sans objet		BUSP	auto	2019Q1	8 933		11 727	17 887	65,6%	64,8%	11 597
91	Bayesian for Paid1	7	1/1	1	BUSP	auto	2019Q1	8 165	1,525148	12 985	17 887	72,6%	72,2%	12 915
92	Bayesian for Paid1	8	10/1	1	BUSP	auto	2019Q1	8 444	1,525148	13 429	17 887	75,1%	74,4%	13 314
93	Bayesian for Paid1	9	1/10	1	BUSP	auto	2019Q1	8 113	1,525148	12 903	17 887	72,1%	71,8%	12 841
94	Bayesian Network for F1		1/1	1	BUSP	auto	2019Q1							
95	Bayesian Network for F1		10/1	1	BUSP	auto	2019Q1							
96	Bayesian Network for F1		1/10	1	BUSP	auto	2019Q1							
97	Bayesian Network for mix (Paid1+F1)	-7	1/1	1	BUSP	auto	2019Q1							
98	Bayesian Network for mix (Paid1+F1)	-8	10/1	1	BUSP	auto	2019Q1							
99	Bayesian Network for mix (Paid1+F1)	-9	1/10	1	BUSP	auto	2019Q1							
100	Chain-ladder classical		sans objet		BUSP	travel	2017Q1	192	2,556306	680	3 627	18,7%	20,4%	739

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
101	**Actual**		sans objet		BUSP	travel	2017Q1	173	2,442569	607	3 627	16,7%	19,5%	707
102	**Bayesian for Paid1**	82	1/1	1	BUSP	travel	2017Q1	208	2,556306	735	3 627	20,3%	21,2%	770
103	**Bayesian for Paid1**	83	10/1	1	BUSP	travel	2017Q1	217	2,556306	767	3 627	21,1%	21,8%	790
104	**Bayesian for Paid1**	84	1/10	1	BUSP	travel	2017Q1	204	2,556306	720	3 627	19,8%	21,0%	761
105	**Bayesian Network for F1**	106	1/1	1	BUSP	travel	2017Q1	192	2,328712	619	3 627	17,1%	19,7%	714
106	**Bayesian Network for F1**	107	10/1	1	BUSP	travel	2017Q1	192	2,314959	616	3 627	17,0%	19,6%	712
107	**Bayesian Network for F1**	108	1/10	1	BUSP	travel	2017Q1	192	2,47604	658	3 627	18,2%	20,1%	729
108	**Bayesian Network for mix (Paid1+F1)**	106-82	1/1	1	BUSP	travel	2017Q1	208	2,328712	670	3 627	18,5%	20,3%	735
109	**Bayesian Network for mix (Paid1+F1)**	107-83	10/1	1	BUSP	travel	2017Q1	217	2,314959	694	3 627	19,1%	20,6%	747
110	**Bayesian Network for mix (Paid1+F1)**	108-84	1/10	1	BUSP	travel	2017Q1	204	2,47604	697	3 627	19,2%	20,6%	748
111	**Chain-ladder classical**		sans objet		BUSP	travel	2017Q2	197	2,551411	701	4 408	15,9%	20,7%	913
112	**Actual**		sans objet		BUSP	travel	2017Q2	254	2,312248	891	4 408	20,2%	21,9%	966
113	**Bayesian for Paid1**	79	1/1	1	BUSP	travel	2017Q2	205	2,551411	729	4 408	16,5%	20,8%	918
114	**Bayesian for Paid1**	80	10/1	1	BUSP	travel	2017Q2	214	2,551411	760	4 408	17,2%	21,0%	926
115	**Bayesian for Paid1**	81	1/10	1	BUSP	travel	2017Q2	201	2,551411	716	4 408	16,3%	20,8%	916
116	**Bayesian Network for F1**	103	1/1	1	BUSP	travel	2017Q2	197	2,356593	648	4 408	14,7%	20,5%	906
117	**Bayesian Network for F1**	104	10/1	1	BUSP	travel	2017Q2	197	2,320535	638	4 408	14,5%	20,5%	905
118	**Bayesian Network for F1**	105	1/10	1	BUSP	travel	2017Q2	197	2,311118	635	4 408	14,4%	20,5%	905
119	**Bayesian Network for mix (Paid1+F1)**	103-79	1/1	1	BUSP	travel	2017Q2	205	2,356593	668	4 408	15,1%	20,6%	908
120	**Bayesian Network for mix (Paid1+F1)**	104-80	10/1	1	BUSP	travel	2017Q2	214	2,320535	686	4 408	15,6%	20,7%	910
121	**Bayesian Network for mix (Paid1+F1)**	105-81	1/10	1	BUSP	travel	2017Q2	201	2,47604	689	4 408	15,6%	20,7%	911
122	**Chain-ladder classical**		sans objet		BUSP	travel	2017Q3	378	2,541323	1 339	5 333	25,1%	25,1%	1 338
123	**Actual**		sans objet		BUSP	travel	2017Q3	421	2,191999	1 232	5 333	23,1%	23,3%	1 240
124	**Bayesian for Paid1**	76	1/1	1	BUSP	travel	2017Q3	397	2,541323	1 409	5 333	26,4%	26,4%	1 408
125	**Bayesian for Paid1**	77	10/1	1	BUSP	travel	2017Q3	396	2,541323	1 405	5 333	26,4%	26,3%	1 404
126	**Bayesian for Paid1**	78	1/10	1	BUSP	travel	2017Q3	396	2,541323	1 405	5 333	26,3%	26,3%	1 404
127	**Bayesian Network for F1**	100	1/1	1	BUSP	travel	2017Q3	378	2,353865	1 240	5 333	23,3%	23,5%	1 252
128	**Bayesian Network for F1**	101	10/1	1	BUSP	travel	2017Q3	378	2,317933	1 221	5 333	22,9%	23,2%	1 237
129	**Bayesian Network for F1**	102	1/10	1	BUSP	travel	2017Q3	378	2,494508	1 314	5 333	24,6%	24,7%	1 315
130	**Bayesian Network for mix (Paid1+F1)**	100-76	1/1	1	BUSP	travel	2017Q3	397	2,353865	1 305	5 333	24,5%	24,5%	1 307
131	**Bayesian Network for mix (Paid1+F1)**	101-77	10/1	1	BUSP	travel	2017Q3	396	2,317933	1 282	5 333	24,0%	24,1%	1 287
132	**Bayesian Network for mix (Paid1+F1)**	102-78	1/10	1	BUSP	travel	2017Q3	396	2,494508	1 379	5 333	25,9%	25,8%	1 377
133	**Chain-ladder classical**		sans objet		BUSP	travel	2017Q4	261	2,599145	940	2 796	33,6%	33,6%	940
134	**Actual**		sans objet		BUSP	travel	2017Q4	178	2,585906	604	2 796	21,6%	21,8%	610
135	**Bayesian for Paid1**	73	1/1	1	BUSP	travel	2017Q4	193	2,599145	693	2 796	24,8%	24,7%	692
136	**Bayesian for Paid1**	74	10/1	1	BUSP	travel	2017Q4	193	2,599145	696	2 796	24,9%	24,8%	695
137	**Bayesian for Paid1**	75	1/10	1	BUSP	travel	2017Q4	193	2,599145	695	2 796	24,9%	24,8%	694
138	**Bayesian Network for F1**	97	1/1	1	BUSP	travel	2017Q4	261	2,524269	912	2 796	32,6%	32,6%	912
139	**Bayesian Network for F1**	98	10/1	1	BUSP	travel	2017Q4	261	2,54026	918	2 796	32,8%	32,8%	918
140	**Bayesian Network for F1**	99	1/10	1	BUSP	travel	2017Q4	261	2,531197	915	2 796	32,7%	32,7%	915
141	**Bayesian Network for mix (Paid1+F1)**	97-73	1/1	1	BUSP	travel	2017Q4	193	2,524269	673	2 796	24,1%	24,0%	672
142	**Bayesian Network for mix (Paid1+F1)**	98-74	10/1	1	BUSP	travel	2017Q4	193	2,54026	680	2 796	24,3%	24,3%	679
143	**Bayesian Network for mix (Paid1+F1)**	99-75	1/10	1	BUSP	travel	2017Q4	193	2,531197	677	2 796	24,2%	24,2%	676
144	**Chain-ladder classical**		sans objet		BUSP	travel	2018Q1	161	2,556306	568	3 148	18,1%	18,8%	592
145	**Actual**		sans objet		BUSP	travel	2018Q1	211	2,029845	610	3 148	19,4%	19,7%	619
146	**Bayesian for Paid1**	70	1/1	1	BUSP	travel	2018Q1	185	2,556306	654	3 148	20,8%	21,0%	660
147	**Bayesian for Paid1**	71	10/1	1	BUSP	travel	2018Q1	176	2,556306	622	3 148	19,8%	20,1%	634
148	**Bayesian for Paid1**	72	1/10	1	BUSP	travel	2018Q1	189	2,556306	669	3 148	21,2%	21,4%	673
149	**Bayesian Network for F1**	94	1/1	1	BUSP	travel	2018Q1	161	2,27417	506	3 148	16,1%	17,5%	550
150	**Bayesian Network for F1**	95	10/1	1	BUSP	travel	2018Q1	161	2,202907	490	3 148	15,6%	17,1%	540
151	**Bayesian Network for F1**	96	1/10	1	BUSP	travel	2018Q1	161	2,460688	547	3 148	17,4%	18,3%	577
152	**Bayesian Network for mix (Paid1+F1)**	94-70	1/1	1	BUSP	travel	2018Q1	185	2,27417	582	3 148	18,5%	19,1%	602
153	**Bayesian Network for mix (Paid1+F1)**	95-71	10/1	1	BUSP	travel	2018Q1	176	2,202907	536	3 148	17,0%	18,1%	570
154	**Bayesian Network for mix (Paid1+F1)**	96-72	1/10	1	BUSP	travel	2018Q1	189	2,460688	644	3 148	20,4%	20,7%	652
155	**Chain-ladder classical**		sans objet		BUSP	travel	2018Q2	230	2,551411	820	3 850	21,3%	21,4%	825
156	**Actual**		sans objet		BUSP	travel	2018Q2	226	2,254744	753	3 850	19,6%	20,0%	771
157	**Bayesian for Paid1**	67	1/1	1	BUSP	travel	2018Q2	189	2,551411	672	3 850	17,5%	18,5%	711
158	**Bayesian for Paid1**	68	10/1	1	BUSP	travel	2018Q2	187	2,551411	664	3 850	17,3%	18,3%	705
159	**Bayesian for Paid1**	69	1/10	1	BUSP	travel	2018Q2	188	2,551411	670	3 850	17,4%	18,4%	709
160	**Bayesian Network for F1**	91	1/1	1	BUSP	travel	2018Q2	230	2,377909	764	3 850	19,9%	20,2%	779
161	**Bayesian Network for F1**	92	10/1	1	BUSP	travel	2018Q2	230	2,314959	744	3 850	19,3%	19,8%	763
162	**Bayesian Network for F1**	93	1/10	1	BUSP	travel	2018Q2	230	2,502189	804	3 850	20,9%	21,1%	812
163	**Bayesian Network for mix (Paid1+F1)**	91-67	1/1	1	BUSP	travel	2018Q2	189	2,377909	627	3 850	16,3%	17,7%	680
164	**Bayesian Network for mix (Paid1+F1)**	92-68	10/1	1	BUSP	travel	2018Q2	187	2,314959	603	3 850	15,7%	17,3%	666
165	**Bayesian Network for mix (Paid1+F1)**	93-69	1/10	1	BUSP	travel	2018Q2	188	2,502189	657	3 850	17,1%	18,2%	700
166	**Chain-ladder classical**		sans objet		BUSP	travel	2018Q3	349	2,541323	1 239	3 896	31,8%	31,8%	1 239
167	**Actual**		sans objet		BUSP	travel	2018Q3	379	1,753344	839	3 896	21,5%	21,7%	846
168	**Bayesian for Paid1**	64	1/1	1	BUSP	travel	2018Q3	410	2,541323	1 455	3 896	37,3%	37,3%	1 455
169	**Bayesian for Paid1**	65	10/1	1	BUSP	travel	2018Q3	415	2,541323	1 472	3 896	37,8%	37,8%	1 472
170	**Bayesian for Paid1**	66	1/10	1	BUSP	travel	2018Q3	394	2,541323	1 396	3 896	35,8%	35,8%	1 396
171	**Bayesian Network for F1**	88	1/1	1	BUSP	travel	2018Q3	349	2,223216	1 084	3 896	27,8%	27,8%	1 084
172	**Bayesian Network for F1**	89	10/1	1	BUSP	travel	2018Q3	349	1,983391	967	3 896	24,8%	24,6%	958
173	**Bayesian Network for F1**	90	1/10	1	BUSP	travel	2018Q3	349	2,469361	1 204	3 896	30,9%	30,9%	1 204
174	**Bayesian Network for mix (Paid1+F1)**	88-64	1/1	1	BUSP	travel	2018Q3	410	2,223216	1 273	3 896	32,7%	32,7%	1 273
175	**Bayesian Network for mix (Paid1+F1)**	89-65	10/1	1	BUSP	travel	2018Q3	415	1,983391	1 149	3 896	29,5%	29,5%	1 149
176	**Bayesian Network for mix (Paid1+F1)**	90-66	1/10	1	BUSP	travel	2018Q3	394	2,469361	1 357	3 896	34,8%	34,8%	1 357
177	**Chain-ladder classical**		sans objet		BUSP	travel	2018Q4	216	2,532839	763	2 544	30,0%	29,7%	756
178	**Actual**		sans objet		BUSP	travel	2018Q4	176	2,362388	578	2 544	22,7%	22,7%	577
179	**Bayesian for Paid1**	61	1/1	1	BUSP	travel	2018Q4	181	2,532839	641	2 544	25,2%	24,6%	626
180	**Bayesian for Paid1**	62	10/1	1	BUSP	travel	2018Q4	181	2,532839	639	2 544	25,1%	24,5%	624
181	**Bayesian for Paid1**	63	1/10	1	BUSP	travel	2018Q4	182	2,532839	642	2 544	25,2%	24,6%	627
182	**Bayesian Network for F1**	85	1/1	1	BUSP	travel	2018Q4	216	2,712017	817	2 544	32,1%	32,1%	817
183	**Bayesian Network for F1**	86	10/1	1	BUSP	travel	2018Q4	216	2,745608	827	2 544	32,5%	32,5%	827
184	**Bayesian Network for F1**	87	1/10	1	BUSP	travel	2018Q4	216	2,602451	784	2 544	30,8%	30,7%	780
185	**Bayesian Network for mix (Paid1+F1)**	85-61	1/1	1	BUSP	travel	2018Q4	181	2,712017	686	2 544	27,0%	26,4%	671
186	**Bayesian Network for mix (Paid1+F1)**	86-62	10/1	1	BUSP	travel	2018Q4	181	2,745608	693	2 544	27,2%	26,7%	679
187	**Bayesian Network for mix (Paid1+F1)**	87-63	1/10	1	BUSP	travel	2018Q4	182	2,602451	659	2 544	25,9%	25,3%	644
188	**Chain-ladder classical**		sans objet		BUSP	travel	2019Q1	170	2,584913	608	2 686	22,7%	20,4%	548
189	**Actual**		sans objet		BUSP	travel	2019Q1	152		445	2 016	22,1%	21,8%	440
190	**Bayesian for Paid1**	58	1/1	1	BUSP	travel	2019Q1	178	2,532839	629	2 686	23,4%	21,0%	563
191	**Bayesian for Paid1**	59	10/1	1	BUSP	travel	2019Q1	180	2,532839	635	2 686	23,6%	21,1%	567
192	**Bayesian for Paid1**	60	1/10	1	BUSP	travel	2019Q1	180	2,532839	637	2 686	23,7%	21,2%	569
193	**Bayesian Network for F1**		1/1	1	BUSP	travel	2019Q1							
194	**Bayesian Network for F1**		10/1	1	BUSP	travel	2019Q1							
195	**Bayesian Network for F1**		1/10	1	BUSP	travel	2019Q1							
196	**Bayesian Network for mix (Paid1+F1)**	-58	1/1	1	BUSP	travel	2019Q1							
197	**Bayesian Network for mix (Paid1+F1)**	-59	10/1	1	BUSP	travel	2019Q1							
198	**Bayesian Network for mix (Paid1+F1)**	-60	1/10	1	BUSP	travel	2019Q1							
199	**Bayesian for Paid1**	31	1/1	2	BUSP	auto	2017Q1	7 122	1,494398	11 110	16 343	68,0%	68,0%	11 110
200	**Bayesian for Paid1**	32	10/1	2	BUSP	auto	2017Q1	8 998	1,494398	14 035	16 343	85,9%	85,9%	14 035

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
201	**Bayesian for Paid1**	33	1/10	2	BUSP	auto	2017Q1	8 998	1,494398	14 035	16 343	85,9%	85,9%	14 035
202	**Bayesian Network for F1**	55	1/1	2	BUSP	auto	2017Q1	5 981	1,555933	9 713	16 343	59,4%	59,9%	9 791
203	**Bayesian Network for F1**	56	10/1	2	BUSP	auto	2017Q1	5 981	1,408017	8 789	16 343	53,8%	55,7%	9 107
204	**Bayesian Network for F1**	57	1/10	2	BUSP	auto	2017Q1	5 981	1,408017	8 789	16 343	53,8%	55,7%	9 107
205	**Bayesian Network for mix (Paid1+F1)**	55-31	1/1	2	BUSP	auto	2017Q1	7 122	1,555933	11 567	16 343	70,8%	70,8%	11 567
206	**Bayesian Network for mix (Paid1+F1)**	56-32	10/1	2	BUSP	auto	2017Q1	8 998	1,408017	13 223	16 343	80,9%	80,9%	13 223
207	**Bayesian Network for mix (Paid1+F1)**	57-33	1/10	2	BUSP	auto	2017Q1	8 998	1,408017	13 223	16 343	80,9%	80,9%	13 223
208	**Bayesian for Paid1**	28	1/1	2	BUSP	auto	2017Q2	7 184	1,49068	11 189	16 830	66,5%	66,8%	11 238
209	**Bayesian for Paid1**	29	10/1	2	BUSP	auto	2017Q2	7 184	1,49068	11 189	16 830	66,5%	66,8%	11 238
210	**Bayesian for Paid1**	30	1/10	2	BUSP	auto	2017Q2	7 184	1,49068	11 189	16 830	66,5%	66,8%	11 238
211	**Bayesian Network for F1**	52	1/1	2	BUSP	auto	2017Q2	6 068	1,555933	9 864	16 830	58,6%	60,8%	10 229
212	**Bayesian Network for F1**	53	10/1	2	BUSP	auto	2017Q2	6 068	1,555933	9 864	16 830	58,6%	60,8%	10 229
213	**Bayesian Network for F1**	54	1/10	2	BUSP	auto	2017Q2	6 068	1,555933	9 864	16 830	58,6%	60,8%	10 229
214	**Bayesian Network for mix (Paid1+F1)**	52-28	1/1	2	BUSP	auto	2017Q2	7 184	1,555933	11 679	16 830	69,4%	69,4%	11 685
215	**Bayesian Network for mix (Paid1+F1)**	53-29	10/1	2	BUSP	auto	2017Q2	7 184	1,555933	11 679	16 830	69,4%	69,4%	11 685
216	**Bayesian Network for mix (Paid1+F1)**	54-30	1/10	2	BUSP	auto	2017Q2	7 184	1,555933	11 679	16 830	69,4%	69,4%	11 685
217	**Bayesian for Paid1**	24	1/1	2	BUSP	auto	2017Q3	7 246	1,474136	11 139	17 270	64,5%	67,5%	11 651
218	**Bayesian for Paid1**	25	10/1	2	BUSP	auto	2017Q3	6 841	1,474136	10 517	17 270	60,9%	65,4%	11 296
219	**Bayesian for Paid1**	27	1/10	2	BUSP	auto	2017Q3	7 651	1,474136	11 762	17 270	68,1%	69,8%	12 062
220	**Bayesian Network for F1**	49	1/1	2	BUSP	auto	2017Q3	7 531	1,299289	10 223	17 270	59,2%	64,6%	11 148
221	**Bayesian Network for F1**	50	10/1	2	BUSP	auto	2017Q3	7 531	1,408017	11 078	17 270	64,1%	67,2%	11 614
222	**Bayesian Network for F1**	51	1/10	2	BUSP	auto	2017Q3	7 531	1,555933	12 242	17 270	70,9%	71,9%	12 417
223	**Bayesian Network for mix (Paid1+F1)**	49-24	1/1	2	BUSP	auto	2017Q3	7 246	1,299289	9 836	17 270	57,0%	63,5%	10 972
224	**Bayesian Network for mix (Paid1+F1)**	50-25	10/1	2	BUSP	auto	2017Q3	7 246	1,408017	10 659	17 270	61,7%	65,9%	11 373
225	**Bayesian Network for mix (Paid1+F1)**	51-27	1/10	2	BUSP	auto	2017Q3	8 151	1,555933	13 251	17 270	76,7%	76,9%	13 273
226	**Bayesian for Paid1**	21	1/1	2	BUSP	auto	2017Q4	7 308	1,492849	11 393	18 669	61,0%	61,3%	11 451
227	**Bayesian for Paid1**	22	10/1	2	BUSP	auto	2017Q4	7 308	1,492849	11 393	18 669	61,0%	61,3%	11 451
228	**Bayesian for Paid1**	23	1/10	2	BUSP	auto	2017Q4	7 308	1,492849	11 393	18 669	61,0%	61,3%	11 451
229	**Bayesian Network for F1**	46	1/1	2	BUSP	auto	2017Q4	6 642	1,743036	12 097	18 669	64,8%	64,8%	12 098
230	**Bayesian Network for F1**	47	10/1	2	BUSP	auto	2017Q4	6 642	1,299289	9 017	18 669	48,3%	52,8%	9 862
231	**Bayesian Network for F1**	48	1/10	2	BUSP	auto	2017Q4	6 642	1,299289	9 017	18 669	48,3%	52,8%	9 862
232	**Bayesian Network for mix (Paid1+F1)**	46-21	1/1	2	BUSP	auto	2017Q4	7 308	1,743036	13 308	18 669	71,3%	71,3%	13 308
233	**Bayesian Network for mix (Paid1+F1)**	47-22	10/1	2	BUSP	auto	2017Q4	7 308	1,299289	9 920	18 669	53,1%	55,5%	10 358
234	**Bayesian Network for mix (Paid1+F1)**	48-23	1/10	2	BUSP	auto	2017Q4	7 308	1,299289	9 920	18 669	53,1%	55,5%	10 358
235	**Bayesian for Paid1**	18	1/1	2	BUSP	auto	2018Q1	8 275	1,494398	12 907	17 645	73,1%	73,1%	12 907
236	**Bayesian for Paid1**	19	10/1	2	BUSP	auto	2018Q1	7 369	1,494398	11 494	17 645	65,1%	65,2%	11 500
237	**Bayesian for Paid1**	20	1/10	2	BUSP	auto	2018Q1	8 275	1,494398	12 907	17 645	73,1%	73,1%	12 907
238	**Bayesian Network for F1**	43	1/1	2	BUSP	auto	2018Q1	7 984	1,408017	11 745	17 645	66,6%	66,6%	11 746
239	**Bayesian Network for F1**	44	10/1	2	BUSP	auto	2018Q1	7 984	1,408017	11 745	17 645	66,6%	66,6%	11 746
240	**Bayesian Network for F1**	45	1/10	2	BUSP	auto	2018Q1	7 984	1,408017	11 745	17 645	66,6%	66,6%	11 746
241	**Bayesian Network for mix (Paid1+F1)**	43-18	1/1	2	BUSP	auto	2018Q1	8 275	1,408017	12 173	17 645	69,0%	69,0%	12 173
242	**Bayesian Network for mix (Paid1+F1)**	44-19	10/1	2	BUSP	auto	2018Q1	7 369	1,408017	10 841	17 645	61,4%	61,7%	10 881
243	**Bayesian Network for mix (Paid1+F1)**	45-20	1/10	2	BUSP	auto	2018Q1	8 275	1,408017	12 173	17 645	69,0%	69,0%	12 173
244	**Bayesian for Paid1**	15	1/1	2	BUSP	auto	2018Q2	8 398	1,49068	13 080	17 821	73,4%	73,4%	13 080
245	**Bayesian for Paid1**	16	10/1	2	BUSP	auto	2018Q2	7 431	1,49068	11 573	17 821	64,9%	65,4%	11 662
246	**Bayesian for Paid1**	17	1/10	2	BUSP	auto	2018Q2	8 336	1,49068	12 983	17 821	72,9%	72,9%	12 986
247	**Bayesian Network for F1**	40	1/1	2	BUSP	auto	2018Q2	8 749	1,408017	12 871	17 821	72,2%	72,2%	12 875
248	**Bayesian Network for F1**	41	10/1	2	BUSP	auto	2018Q2	8 749	1,743036	15 933	17 821	89,4%	89,4%	15 933
249	**Bayesian Network for F1**	42	1/10	2	BUSP	auto	2018Q2	8 749	1,743036	15 933	17 821	89,4%	89,4%	15 933
250	**Bayesian Network for mix (Paid1+F1)**	40-15	1/1	2	BUSP	auto	2018Q2	8 398	1,408017	12 354	17 821	69,3%	69,5%	12 379
251	**Bayesian Network for mix (Paid1+F1)**	41-16	10/1	2	BUSP	auto	2018Q2	7 431	1,743036	13 533	17 821	75,9%	75,9%	13 533
252	**Bayesian Network for mix (Paid1+F1)**	42-17	1/10	2	BUSP	auto	2018Q2	8 336	1,743036	15 181	17 821	85,2%	85,2%	15 181
253	**Bayesian for Paid1**	13	1/1	2	BUSP	auto	2018Q3	9 368	1,474136	14 402	18 544	77,7%	77,8%	14 435
254	**Bayesian for Paid1**	14	10/1	2	BUSP	auto	2018Q3	6 683	1,474136	10 273	18 544	55,4%	59,7%	11 075
255	**Bayesian for Paid1**	15	1/10	2	BUSP	auto	2018Q3	8 398	1,474136	12 910	18 544	69,6%	70,6%	13 097
256	**Bayesian Network for F1**	37	1/1	2	BUSP	auto	2018Q3	10 154	1,299289	13 758	18 544	74,2%	74,6%	13 842
257	**Bayesian Network for F1**	38	10/1	2	BUSP	auto	2018Q3	10 154	1,743036	18 457	18 544	99,5%	99,5%	18 457
258	**Bayesian Network for F1**	39	1/10	2	BUSP	auto	2018Q3	10 154	1,408017	14 910	18 544	80,4%	80,5%	14 919
259	**Bayesian Network for mix (Paid1+F1)**	37-13	1/1	2	BUSP	auto	2018Q3	9 368	1,299289	10 858	18 544	58,6%	61,9%	11 481
260	**Bayesian Network for mix (Paid1+F1)**	38-14	10/1	2	BUSP	auto	2018Q3	6 683	1,743036	12 147	18 544	65,5%	67,2%	12 464
261	**Bayesian Network for mix (Paid1+F1)**	39-15	1/10	2	BUSP	auto	2018Q3	8 398	1,408017	12 331	18 544	66,5%	68,0%	12 613
262	**Bayesian for Paid1**	10	1/1	2	BUSP	auto	2018Q4	8 460	1,463088	12 906	18 730	68,9%	68,9%	12 901
263	**Bayesian for Paid1**	11	10/1	2	BUSP	auto	2018Q4	8 460	1,463088	12 906	18 730	68,9%	68,9%	12 901
264	**Bayesian for Paid1**	12	1/10	2	BUSP	auto	2018Q4	8 460	1,463088	12 906	18 730	68,9%	68,9%	12 901
265	**Bayesian Network for F1**	34	1/1	2	BUSP	auto	2018Q4	8 589	1,555933	13 935	18 730	74,4%	74,4%	13 935
266	**Bayesian Network for F1**	35	10/1	2	BUSP	auto	2018Q4	8 589	1,408017	12 610	18 730	67,3%	67,3%	12 605
267	**Bayesian Network for F1**	36	1/10	2	BUSP	auto	2018Q4	8 589	1,555933	13 935	18 730	74,4%	74,4%	13 935
268	**Bayesian Network for mix (Paid1+F1)**	34-10	1/1	2	BUSP	auto	2018Q4	8 460	1,555933	13 725	18 730	73,3%	73,3%	13 725
269	**Bayesian Network for mix (Paid1+F1)**	35-11	10/1	2	BUSP	auto	2018Q4	8 460	1,408017	12 420	18 730	66,3%	66,3%	12 418
270	**Bayesian Network for mix (Paid1+F1)**	36-12	1/10	2	BUSP	auto	2018Q4	8 460	1,555933	13 725	18 730	73,3%	73,3%	13 725
271	**Bayesian for Paid1**	7	1/1	2	BUSP	auto	2019Q1	8 521	1,525148	13 552	17 887	75,8%	75,1%	13 425
272	**Bayesian for Paid1**	8	10/1	2	BUSP	auto	2019Q1	8 521	1,525148	13 552	17 887	75,8%	75,1%	13 425
273	**Bayesian for Paid1**	9	1/10	2	BUSP	auto	2019Q1	8 521	1,525148	13 552	17 887	75,8%	75,1%	13 425
274	**Bayesian Network for F1**		1/1	2	BUSP	auto	2019Q1							
275	**Bayesian Network for F1**		10/1	2	BUSP	auto	2019Q1							
276	**Bayesian Network for F1**		1/10	2	BUSP	auto	2019Q1							
277	**Bayesian Network for mix (Paid1+F1)**	-7	1/1	2	BUSP	auto	2019Q1							
278	**Bayesian Network for mix (Paid1+F1)**	-8	10/1	2	BUSP	auto	2019Q1							
279	**Bayesian Network for mix (Paid1+F1)**	-9	1/10	2	BUSP	auto	2019Q1							
280	**Bayesian for Paid1**	82	1/1	2	BUSP	travel	2017Q1	221	2,556306	780	3 627	21,5%	22,0%	800
281	**Bayesian for Paid1**	83	10/1	2	BUSP	travel	2017Q1	221	2,556306	780	3 627	21,5%	22,0%	800
282	**Bayesian for Paid1**	84	1/10	2	BUSP	travel	2017Q1	221	2,556306	780	3 627	21,5%	22,0%	800
283	**Bayesian Network for F1**	106	1/1	2	BUSP	travel	2017Q1	192	2,311118	615	3 627	16,9%	19,6%	712
284	**Bayesian Network for F1**	107	10/1	2	BUSP	travel	2017Q1	192	2,311118	615	3 627	16,9%	19,6%	712
285	**Bayesian Network for F1**	108	1/10	2	BUSP	travel	2017Q1	192	2,311118	615	3 627	16,9%	19,6%	712
286	**Bayesian Network for mix (Paid1+F1)**	106-82	1/1	2	BUSP	travel	2017Q1	221	2,311118	705	3 627	19,4%	20,7%	753
287	**Bayesian Network for mix (Paid1+F1)**	107-83	10/1	2	BUSP	travel	2017Q1	221	2,311118	705	3 627	19,4%	20,7%	753
288	**Bayesian Network for mix (Paid1+F1)**	108-84	1/10	2	BUSP	travel	2017Q1	221	2,311118	705	3 627	19,4%	20,7%	753
289	**Bayesian for Paid1**	79	1/1	2	BUSP	travel	2017Q2	218	2,551411	775	4 408	17,6%	21,1%	930
290	**Bayesian for Paid1**	80	10/1	2	BUSP	travel	2017Q2	218	2,551411	775	4 408	17,6%	21,1%	930
291	**Bayesian for Paid1**	81	1/10	2	BUSP	travel	2017Q2	218	2,551411	775	4 408	17,6%	21,1%	930
292	**Bayesian Network for F1**	103	1/1	2	BUSP	travel	2017Q2	197	2,311118	635	4 408	14,4%	20,5%	905
293	**Bayesian Network for F1**	104	10/1	2	BUSP	travel	2017Q2	197	2,311118	635	4 408	14,4%	20,5%	905
294	**Bayesian Network for F1**	105	1/10	2	BUSP	travel	2017Q2	197	2,311118	635	4 408	14,4%	20,5%	905
295	**Bayesian Network for mix (Paid1+F1)**	103-79	1/1	2	BUSP	travel	2017Q2	218	2,311118	696	4 408	15,8%	20,7%	912
296	**Bayesian Network for mix (Paid1+F1)**	104-80	10/1	2	BUSP	travel	2017Q2	218	2,311118	696	4 408	15,8%	20,7%	912
297	**Bayesian Network for mix (Paid1+F1)**	105-81	1/10	2	BUSP	travel	2017Q2	218	2,311118	696	4 408	15,8%	20,7%	912
298	**Bayesian for Paid1**	76	1/1	2	BUSP	travel	2017Q3	429	2,541323	1 520	5 333	28,5%	28,5%	1 520
299	**Bayesian for Paid1**	77	10/1	2	BUSP	travel	2017Q3	365	2,541323	1 294	5 333	24,3%	24,3%	1 297
300	**Bayesian for Paid1**	78	1/10	2	BUSP	travel	2017Q3	365	2,541323	1 294	5 333	24,3%	24,3%	1 297

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
300	Bayesian for Paid1	78	1/10	2	BUSP	travel	2017Q3	365	2,541323	1 294	5 333	24,3%	24,3%	1 297
301	Bayesian Network for F1	100	1/1	2	BUSP	travel	2017Q3	378	2,311118	1 218	5 333	22,8%	23,1%	1 234
302	Bayesian Network for F1	101	10/1	2	BUSP	travel	2017Q3	378	2,311118	1 218	5 333	22,8%	23,1%	1 234
303	Bayesian Network for F1	102	1/10	2	BUSP	travel	2017Q3	378	2,311118	1 218	5 333	22,8%	23,1%	1 234
304	Bayesian Network for mix (Paid1+F1)	100-76	1/1	2	BUSP	travel	2017Q3	429	2,311118	1 383	5 333	25,9%	25,9%	1 381
305	Bayesian Network for mix (Paid1+F1)	101-77	10/1	2	BUSP	travel	2017Q3	365	2,311118	1 177	5 333	22,1%	22,6%	1 204
306	Bayesian Network for mix (Paid1+F1)	102-78	1/10	2	BUSP	travel	2017Q3	365	2,311118	1 177	5 333	22,1%	22,6%	1 204
307	Bayesian for Paid1	73	1/1	2	BUSP	travel	2017Q4	139	2,599145	501	2 796	17,9%	19,6%	549
308	Bayesian for Paid1	74	10/1	2	BUSP	travel	2017Q4	139	2,599145	501	2 796	17,9%	19,6%	549
309	Bayesian for Paid1	75	1/10	2	BUSP	travel	2017Q4	212	2,599145	762	2 796	27,3%	27,3%	762
310	Bayesian Network for F1	97	1/1	2	BUSP	travel	2017Q4	261	2,311118	835	2 796	29,9%	29,9%	835
311	Bayesian Network for F1	98	10/1	2	BUSP	travel	2017Q4	261	2,744865	992	2 796	35,5%	35,5%	992
312	Bayesian Network for F1	99	1/10	2	BUSP	travel	2017Q4	261	2,311118	835	2 796	29,9%	29,9%	835
313	Bayesian Network for mix (Paid1+F1)	97-73	1/1	2	BUSP	travel	2017Q4	139	2,311118	446	2 796	15,9%	18,9%	527
314	Bayesian Network for mix (Paid1+F1)	98-74	10/1	2	BUSP	travel	2017Q4	139	2,744865	530	2 796	18,9%	20,2%	564
315	Bayesian Network for mix (Paid1+F1)	99-75	1/10	2	BUSP	travel	2017Q4	212	2,311118	678	2 796	24,2%	24,2%	677
316	Bayesian for Paid1	70	1/1	2	BUSP	travel	2018Q1	173	2,556306	611	3 148	19,4%	19,9%	625
317	Bayesian for Paid1	71	10/1	2	BUSP	travel	2018Q1	173	2,556306	611	3 148	19,4%	19,9%	625
318	Bayesian for Paid1	72	1/10	2	BUSP	travel	2018Q1	173	2,556306	611	3 148	19,4%	19,9%	625
319	Bayesian Network for F1	94	1/1	2	BUSP	travel	2018Q1	161	2,311118	514	3 148	16,3%	17,6%	555
320	Bayesian Network for F1	95	10/1	2	BUSP	travel	2018Q1	161	2,311118	514	3 148	16,3%	17,6%	555
321	Bayesian Network for F1	96	1/10	2	BUSP	travel	2018Q1	161	2,311118	514	3 148	16,3%	17,6%	555
322	Bayesian Network for mix (Paid1+F1)	94-70	1/1	2	BUSP	travel	2018Q1	173	2,311118	552	3 148	17,5%	18,5%	581
323	Bayesian Network for mix (Paid1+F1)	95-71	10/1	2	BUSP	travel	2018Q1	173	2,311118	552	3 148	17,5%	18,5%	581
324	Bayesian Network for mix (Paid1+F1)	96-72	1/10	2	BUSP	travel	2018Q1	173	2,311118	552	3 148	17,5%	18,5%	581
325	Bayesian for Paid1	67	1/1	2	BUSP	travel	2018Q2	170	2,551411	605	3 850	15,7%	17,3%	667
326	Bayesian for Paid1	68	10/1	2	BUSP	travel	2018Q2	170	2,551411	605	3 850	15,7%	17,3%	667
327	Bayesian for Paid1	69	1/10	2	BUSP	travel	2018Q2	206	2,551411	734	3 850	19,1%	19,6%	755
328	Bayesian Network for F1	91	1/1	2	BUSP	travel	2018Q2	230	2,311118	743	3 850	19,3%	19,8%	762
329	Bayesian Network for F1	92	10/1	2	BUSP	travel	2018Q2	230	2,311118	743	3 850	19,3%	19,8%	762
330	Bayesian Network for F1	93	1/10	2	BUSP	travel	2018Q2	230	2,311118	743	3 850	19,3%	19,8%	762
331	Bayesian Network for mix (Paid1+F1)	91-67	1/1	2	BUSP	travel	2018Q2	170	2,311118	548	3 850	14,2%	16,5%	635
332	Bayesian Network for mix (Paid1+F1)	92-68	10/1	2	BUSP	travel	2018Q2	170	2,311118	548	3 850	14,2%	16,5%	635
333	Bayesian Network for mix (Paid1+F1)	93-69	1/10	2	BUSP	travel	2018Q2	206	2,311118	665	3 850	17,3%	18,3%	705
334	Bayesian for Paid1	64	1/1	2	BUSP	travel	2018Q3	417	2,541323	1 479	3 896	38,0%	38,0%	1 479
335	Bayesian for Paid1	65	10/1	2	BUSP	travel	2018Q3	417	2,541323	1 479	3 896	38,0%	38,0%	1 479
336	Bayesian for Paid1	66	1/10	2	BUSP	travel	2018Q3	417	2,541323	1 479	3 896	38,0%	38,0%	1 479
337	Bayesian Network for F1	88	1/1	2	BUSP	travel	2018Q3	349	1,939268	945	3 896	24,3%	24,0%	936
338	Bayesian Network for F1	89	10/1	2	BUSP	travel	2018Q3	349	1,939268	945	3 896	24,3%	24,0%	936
339	Bayesian Network for F1	90	1/10	2	BUSP	travel	2018Q3	349	2,744865	1 338	3 896	34,3%	34,3%	1 338
340	Bayesian Network for mix (Paid1+F1)	88-64	1/1	2	BUSP	travel	2018Q3	417	1,939268	1 129	3 896	29,0%	29,0%	1 129
341	Bayesian Network for mix (Paid1+F1)	89-65	10/1	2	BUSP	travel	2018Q3	417	1,939268	1 129	3 896	29,0%	29,0%	1 129
342	Bayesian Network for mix (Paid1+F1)	90-66	1/10	2	BUSP	travel	2018Q3	417	2,744865	1 598	3 896	41,0%	41,0%	1 598
343	Bayesian for Paid1	61	1/1	2	BUSP	travel	2018Q4	164	2,532839	580	2 544	22,8%	22,4%	569
344	Bayesian for Paid1	62	10/1	2	BUSP	travel	2018Q4	164	2,532839	580	2 544	22,8%	22,4%	569
345	Bayesian for Paid1	63	1/10	2	BUSP	travel	2018Q4	200	2,532839	708	2 544	27,8%	27,3%	695
346	Bayesian Network for F1	85	1/1	2	BUSP	travel	2018Q4	216	2,744865	827	2 544	32,5%	32,5%	827
347	Bayesian Network for F1	86	10/1	2	BUSP	travel	2018Q4	216	2,744865	827	2 544	32,5%	32,5%	827
348	Bayesian Network for F1	87	1/10	2	BUSP	travel	2018Q4	216	2,744865	827	2 544	32,5%	32,5%	827
349	Bayesian Network for mix (Paid1+F1)	85-61	1/1	2	BUSP	travel	2018Q4	164	2,744865	629	2 544	24,7%	24,1%	614
350	Bayesian Network for mix (Paid1+F1)	86-62	10/1	2	BUSP	travel	2018Q4	164	2,744865	629	2 544	24,7%	24,1%	614
351	Bayesian Network for mix (Paid1+F1)	87-63	1/10	2	BUSP	travel	2018Q4	200	2,744865	767	2 544	30,2%	29,9%	761
352	Bayesian for Paid1	58	1/1	2	BUSP	travel	2019Q1	161	2,532839	570	2 686	21,2%	19,4%	522
353	Bayesian for Paid1	59	10/1	2	BUSP	travel	2019Q1	197	2,532839	698	2 686	26,0%	22,8%	612
354	Bayesian for Paid1	60	1/10	2	BUSP	travel	2019Q1	197	2,532839	698	2 686	26,0%	22,8%	612
355	Bayesian Network for F1		1/1	2	BUSP	travel	2019Q1							
356	Bayesian Network for F1		10/1	2	BUSP	travel	2019Q1							
357	Bayesian Network for F1		1/10	2	BUSP	travel	2019Q1							
358	Bayesian Network for mix (Paid1+F1)	-58	1/1	2	BUSP	travel	2019Q1							
359	Bayesian Network for mix (Paid1+F1)	-59	10/1	2	BUSP	travel	2019Q1							
360	Bayesian Network for mix (Paid1+F1)	-60	1/10	2	BUSP	travel	2019Q1							
361	Bayesian for Paid1	31	1/1	3	BUSP	auto	2017Q1	6 718	1,494398	10 478	16 343	64,1%	64,1%	10 480
362	Bayesian for Paid1	32	10/1	3	BUSP	auto	2017Q1	8 528	1,494398	13 302	16 343	81,4%	81,4%	13 302
363	Bayesian for Paid1	33	1/10	3	BUSP	auto	2017Q1	8 528	1,494398	13 302	16 343	81,4%	81,4%	13 302
364	Bayesian Network for F1	55	1/1	3	BUSP	auto	2017Q1	5 981	1,462381	9 129	16 343	55,9%	57,1%	9 340
365	Bayesian Network for F1	56	10/1	3	BUSP	auto	2017Q1	5 981	1,353653	8 450	16 343	51,7%	54,4%	8 895
366	Bayesian Network for F1	57	1/10	3	BUSP	auto	2017Q1	5 981	1,353653	8 450	16 343	51,7%	54,4%	8 895
367	Bayesian Network for mix (Paid1+F1)	55-31	1/1	3	BUSP	auto	2017Q1	6 718	1,462381	10 253	16 343	62,7%	62,8%	10 266
368	Bayesian Network for mix (Paid1+F1)	56-32	10/1	3	BUSP	auto	2017Q1	8 528	1,353653	12 049	16 343	73,7%	73,7%	12 049
369	Bayesian Network for mix (Paid1+F1)	57-33	1/10	3	BUSP	auto	2017Q1	8 528	1,353653	12 049	16 343	73,7%	73,7%	12 049
370	Bayesian for Paid1	28	1/1	3	BUSP	auto	2017Q2	6 779	1,49068	10 558	16 830	62,7%	63,7%	10 721
371	Bayesian for Paid1	29	10/1	3	BUSP	auto	2017Q2	6 779	1,49068	10 558	16 830	62,7%	63,7%	10 721
372	Bayesian for Paid1	30	1/10	3	BUSP	auto	2017Q2	6 779	1,49068	10 558	16 830	62,7%	63,7%	10 721
373	Bayesian Network for F1	52	1/1	3	BUSP	auto	2017Q2	6 068	1,462381	9 271	16 830	55,1%	58,7%	9 872
374	Bayesian Network for F1	53	10/1	3	BUSP	auto	2017Q2	6 068	1,462381	9 271	16 830	55,1%	58,7%	9 872
375	Bayesian Network for F1	54	1/10	3	BUSP	auto	2017Q2	6 068	1,462381	9 271	16 830	55,1%	58,7%	9 872
376	Bayesian Network for mix (Paid1+F1)	52-28	1/1	3	BUSP	auto	2017Q2	6 779	1,462381	10 358	16 830	61,5%	62,8%	10 571
377	Bayesian Network for mix (Paid1+F1)	53-29	10/1	3	BUSP	auto	2017Q2	6 779	1,462381	10 358	16 830	61,5%	62,8%	10 571
378	Bayesian Network for mix (Paid1+F1)	54-30	1/10	3	BUSP	auto	2017Q2	6 779	1,462381	10 358	16 830	61,5%	62,8%	10 571
379	Bayesian for Paid1	24	1/1	3	BUSP	auto	2017Q3	6 841	1,474136	10 517	17 270	60,9%	65,4%	11 296
380	Bayesian for Paid1	25	10/1	3	BUSP	auto	2017Q3	7 651	1,474136	11 762	17 270	68,1%	69,8%	12 062
381	Bayesian for Paid1	27	1/10	3	BUSP	auto	2017Q3	8 652	1,474136	13 300	17 270	77,0%	77,1%	13 318
382	Bayesian Network for F1	49	1/1	3	BUSP	auto	2017Q3	7 531	1,244925	9 795	17 270	56,7%	63,4%	10 955
383	Bayesian Network for F1	50	10/1	3	BUSP	auto	2017Q3	7 531	1,353653	10 651	17 270	61,7%	65,8%	11 368
384	Bayesian Network for F1	51	1/10	3	BUSP	auto	2017Q3	7 531	1,462381	11 506	17 270	66,6%	68,8%	11 886
385	Bayesian Network for mix (Paid1+F1)	49-24	1/1	3	BUSP	auto	2017Q3	6 841	1,244925	8 898	17 270	51,5%	61,6%	10 636
386	Bayesian Network for mix (Paid1+F1)	50-25	10/1	3	BUSP	auto	2017Q3	6 841	1,353653	9 675	17 270	56,0%	63,1%	10 905
387	Bayesian Network for mix (Paid1+F1)	51-27	1/10	3	BUSP	auto	2017Q3	7 651	1,462381	11 690	17 270	67,7%	69,6%	12 012
388	Bayesian for Paid1	21	1/1	3	BUSP	auto	2017Q4	6 903	1,492849	10 761	18 669	57,6%	58,6%	10 939
389	Bayesian for Paid1	22	10/1	3	BUSP	auto	2017Q4	6 903	1,492849	10 761	18 669	57,6%	58,6%	10 939
390	Bayesian for Paid1	23	1/10	3	BUSP	auto	2017Q4	6 903	1,492849	10 761	18 669	57,6%	58,6%	10 939
391	Bayesian Network for F1	46	1/1	3	BUSP	auto	2017Q4	6 642	1,649485	11 447	18 669	61,3%	61,6%	11 498
392	Bayesian Network for F1	47	10/1	3	BUSP	auto	2017Q4	6 642	1,244925	8 640	18 669	46,3%	51,9%	9 695
393	Bayesian Network for F1	48	1/10	3	BUSP	auto	2017Q4	6 642	1,244925	8 640	18 669	46,3%	51,9%	9 695
394	Bayesian Network for mix (Paid1+F1)	46-21	1/1	3	BUSP	auto	2017Q4	6 903	1,649485	11 896	18 669	63,7%	63,8%	11 905
395	Bayesian Network for mix (Paid1+F1)	47-22	10/1	3	BUSP	auto	2017Q4	6 903	1,244925	8 978	18 669	48,1%	52,7%	9 844
396	Bayesian Network for mix (Paid1+F1)	48-23	1/10	3	BUSP	auto	2017Q4	6 903	1,244925	8 978	18 669	48,1%	52,7%	9 844
397	Bayesian for Paid1	18	1/1	3	BUSP	auto	2018Q1	7 774	1,494398	12 126	17 645	68,7%	68,7%	12 126
398	Bayesian for Paid1	19	10/1	3	BUSP	auto	2018Q1	6 964	1,494398	10 863	17 645	61,6%	61,8%	10 901
399	Bayesian for Paid1	20	1/10	3	BUSP	auto	2018Q1	7 774	1,494398	12 126	17 645	68,7%	68,7%	12 126
400	Bayesian Network for F1	43	1/1	3	BUSP	auto	2018Q1	7 984	1,353653	11 292	17 645	64,0%	64,1%	11 305

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
400	Bayesian Network for F1	43	1/1	3	BUSP	auto	2018Q1	7 984	1,353653	11 292	17 645	64,0%	64,1%	11 305
401	Bayesian Network for F1	44	10/1	3	BUSP	auto	2018Q1	7 984	1,353653	11 292	17 645	64,0%	64,1%	11 305
402	Bayesian Network for F1	45	1/10	3	BUSP	auto	2018Q1	7 984	1,353653	11 292	17 645	64,0%	64,1%	11 305
403	Bayesian Network for mix (Paid1+F1)	43-18	1/1	3	BUSP	auto	2018Q1	7 774	1,353653	10 995	17 645	62,3%	62,5%	11 024
404	Bayesian Network for mix (Paid1+F1)	44-19	10/1	3	BUSP	auto	2018Q1	6 964	1,353653	9 850	17 645	55,8%	56,7%	10 001
405	Bayesian Network for mix (Paid1+F1)	45-20	1/10	3	BUSP	auto	2018Q1	7 774	1,353653	10 995	17 645	62,3%	62,5%	11 024
406	Bayesian for Paid1	15	1/1	3	BUSP	auto	2018Q2	7 898	1,49068	12 300	17 821	69,0%	69,2%	12 329
407	Bayesian for Paid1	16	10/1	3	BUSP	auto	2018Q2	7 026	1,49068	10 943	17 821	61,4%	62,4%	11 113
408	Bayesian for Paid1	17	1/10	3	BUSP	auto	2018Q2	7 836	1,49068	12 204	17 821	68,5%	68,7%	12 239
409	Bayesian Network for F1	40	1/1	3	BUSP	auto	2018Q2	8 749	1,353653	12 374	17 821	69,4%	69,6%	12 398
410	Bayesian Network for F1	41	10/1	3	BUSP	auto	2018Q2	8 749	1,649485	15 078	17 821	84,6%	84,6%	15 078
411	Bayesian Network for F1	42	1/10	3	BUSP	auto	2018Q2	8 749	1,649485	15 078	17 821	84,6%	84,6%	15 078
412	Bayesian Network for mix (Paid1+F1)	40-15	1/1	3	BUSP	auto	2018Q2	7 898	1,353653	11 170	17 821	62,7%	63,5%	11 308
413	Bayesian Network for mix (Paid1+F1)	41-16	10/1	3	BUSP	auto	2018Q2	7 026	1,649485	12 108	17 821	67,9%	68,2%	12 149
414	Bayesian Network for mix (Paid1+F1)	42-17	1/10	3	BUSP	auto	2018Q2	7 836	1,649485	13 504	17 821	75,8%	75,8%	13 504
415	Bayesian for Paid1	13	1/1	3	BUSP	auto	2018Q3	8 898	1,474136	13 680	18 544	73,8%	74,3%	13 771
416	Bayesian for Paid1	14	10/1	3	BUSP	auto	2018Q3	6 278	1,474136	9 651	18 544	52,0%	57,5%	10 670
417	Bayesian for Paid1	15	1/10	3	BUSP	auto	2018Q3	7 898	1,474136	12 141	18 544	65,5%	67,2%	12 459
418	Bayesian Network for F1	37	1/1	3	BUSP	auto	2018Q3	10 154	1,244925	13 183	18 544	71,1%	71,9%	13 332
419	Bayesian Network for F1	38	10/1	3	BUSP	auto	2018Q3	10 154	1,649485	17 467	18 544	94,2%	94,2%	17 467
420	Bayesian Network for F1	39	1/10	3	BUSP	auto	2018Q3	10 154	1,353653	14 334	18 544	77,3%	77,5%	14 372
421	Bayesian Network for mix (Paid1+F1)	37-13	1/1	3	BUSP	auto	2018Q3	8 898	1,244925	11 553	18 544	62,3%	64,7%	11 997
422	Bayesian Network for mix (Paid1+F1)	38-14	10/1	3	BUSP	auto	2018Q3	6 278	1,649485	10 799	18 544	58,2%	61,7%	11 439
423	Bayesian Network for mix (Paid1+F1)	39-15	1/10	3	BUSP	auto	2018Q3	7 898	1,353653	11 149	18 544	60,1%	63,1%	11 693
424	Bayesian for Paid1	10	1/1	3	BUSP	auto	2018Q4	7 959	1,463088	12 142	18 730	64,8%	64,9%	12 148
425	Bayesian for Paid1	11	10/1	3	BUSP	auto	2018Q4	7 959	1,463088	12 142	18 730	64,8%	64,9%	12 148
426	Bayesian for Paid1	12	1/10	3	BUSP	auto	2018Q4	7 959	1,463088	12 142	18 730	64,8%	64,9%	12 148
427	Bayesian Network for F1	34	1/1	3	BUSP	auto	2018Q4	8 589	1,462381	13 097	18 730	69,9%	69,9%	13 095
428	Bayesian Network for F1	35	10/1	3	BUSP	auto	2018Q4	8 589	1,353653	12 123	18 730	64,7%	64,8%	12 130
429	Bayesian Network for F1	36	1/10	3	BUSP	auto	2018Q4	8 589	1,462381	13 097	18 730	69,9%	69,9%	13 095
430	Bayesian Network for mix (Paid1+F1)	34-10	1/1	3	BUSP	auto	2018Q4	7 959	1,462381	12 137	18 730	64,8%	64,8%	12 143
431	Bayesian Network for mix (Paid1+F1)	35-11	10/1	3	BUSP	auto	2018Q4	7 959	1,353653	11 234	18 730	60,0%	60,3%	11 301
432	Bayesian Network for mix (Paid1+F1)	36-12	1/10	3	BUSP	auto	2018Q4	7 959	1,462381	12 137	18 730	64,8%	64,8%	12 143
433	Bayesian for Paid1	7	1/1	3	BUSP	auto	2019Q1	8 021	1,525148	12 756	17 887	71,3%	71,1%	12 709
434	Bayesian for Paid1	8	10/1	3	BUSP	auto	2019Q1	8 021	1,525148	12 756	17 887	71,3%	71,1%	12 709
435	Bayesian for Paid1	9	1/10	3	BUSP	auto	2019Q1	8 021	1,525148	12 756	17 887	71,3%	71,1%	12 709
436	Bayesian Network for F1		1/1	3	BUSP	auto	2019Q1							
437	Bayesian Network for F1		10/1	3	BUSP	auto	2019Q1							
438	Bayesian Network for F1		1/10	3	BUSP	auto	2019Q1							
439	Bayesian Network for mix (Paid1+F1)	-7	1/1	3	BUSP	auto	2019Q1							
440	Bayesian Network for mix (Paid1+F1)	-8	10/1	3	BUSP	auto	2019Q1							
441	Bayesian Network for mix (Paid1+F1)	-9	1/10	3	BUSP	auto	2019Q1							
442	Bayesian for Paid1	82	1/1	3	BUSP	travel	2017Q1	239	2,556306	844	3 627	23,3%	23,4%	849
443	Bayesian for Paid1	83	10/1	3	BUSP	travel	2017Q1	239	2,556306	844	3 627	23,3%	23,4%	849
444	Bayesian for Paid1	84	1/10	3	BUSP	travel	2017Q1	239	2,556306	844	3 627	23,3%	23,4%	849
445	Bayesian Network for F1	106	1/1	3	BUSP	travel	2017Q1	192	2,125193	565	3 627	15,6%	19,2%	697
446	Bayesian Network for F1	107	10/1	3	BUSP	travel	2017Q1	192	2,125193	565	3 627	15,6%	19,2%	697
447	Bayesian Network for F1	108	1/10	3	BUSP	travel	2017Q1	192	2,125193	565	3 627	15,6%	19,2%	697
448	Bayesian Network for mix (Paid1+F1)	106-82	1/1	3	BUSP	travel	2017Q1	239	2,125193	702	3 627	19,3%	20,7%	751
449	Bayesian Network for mix (Paid1+F1)	107-83	10/1	3	BUSP	travel	2017Q1	239	2,125193	702	3 627	19,3%	20,7%	751
450	Bayesian Network for mix (Paid1+F1)	108-84	1/10	3	BUSP	travel	2017Q1	239	2,125193	702	3 627	19,3%	20,7%	751
451	Bayesian for Paid1	79	1/1	3	BUSP	travel	2017Q2	236	2,551411	840	4 408	19,0%	21,6%	952
452	Bayesian for Paid1	80	10/1	3	BUSP	travel	2017Q2	236	2,551411	840	4 408	19,0%	21,6%	952
453	Bayesian for Paid1	81	1/10	3	BUSP	travel	2017Q2	236	2,551411	840	4 408	19,0%	21,6%	952
454	Bayesian Network for F1	103	1/1	3	BUSP	travel	2017Q2	197	2,125193	584	4 408	13,2%	20,5%	903
455	Bayesian Network for F1	104	10/1	3	BUSP	travel	2017Q2	197	2,125193	584	4 408	13,2%	20,5%	903
456	Bayesian Network for F1	105	1/10	3	BUSP	travel	2017Q2	197	2,125193	584	4 408	13,2%	20,5%	903
457	Bayesian Network for mix (Paid1+F1)	103-79	1/1	3	BUSP	travel	2017Q2	236	2,125193	693	4 408	15,7%	20,7%	912
458	Bayesian Network for mix (Paid1+F1)	104-80	10/1	3	BUSP	travel	2017Q2	236	2,125193	693	4 408	15,7%	20,7%	912
459	Bayesian Network for mix (Paid1+F1)	105-81	1/10	3	BUSP	travel	2017Q2	236	2,125193	693	4 408	15,7%	20,7%	912
460	Bayesian for Paid1	76	1/1	3	BUSP	travel	2017Q3	397	2,541323	1 407	5 333	26,4%	26,4%	1 406
461	Bayesian for Paid1	77	10/1	3	BUSP	travel	2017Q3	333	2,541323	1 181	5 333	22,1%	22,6%	1 207
462	Bayesian for Paid1	78	1/10	3	BUSP	travel	2017Q3	333	2,541323	1 181	5 333	22,1%	22,6%	1 207
463	Bayesian Network for F1	100	1/1	3	BUSP	travel	2017Q3	378	2,125193	1 120	5 333	21,0%	21,8%	1 165
464	Bayesian Network for F1	101	10/1	3	BUSP	travel	2017Q3	378	2,125193	1 120	5 333	21,0%	21,8%	1 165
465	Bayesian Network for F1	102	1/10	3	BUSP	travel	2017Q3	378	2,125193	1 120	5 333	21,0%	21,8%	1 165
466	Bayesian Network for mix (Paid1+F1)	100-76	1/1	3	BUSP	travel	2017Q3	397	2,125193	1 366	5 333	25,6%	25,6%	1 365
467	Bayesian Network for mix (Paid1+F1)	101-77	10/1	3	BUSP	travel	2017Q3	333	2,125193	988	5 333	18,5%	20,5%	1 093
468	Bayesian Network for mix (Paid1+F1)	102-78	1/10	3	BUSP	travel	2017Q3	333	2,125193	988	5 333	18,5%	20,5%	1 093
469	Bayesian for Paid1	73	1/1	3	BUSP	travel	2017Q4	158	2,599145	567	2 796	20,3%	21,0%	586
470	Bayesian for Paid1	74	10/1	3	BUSP	travel	2017Q4	158	2,599145	567	2 796	20,3%	21,0%	586
471	Bayesian for Paid1	75	1/10	3	BUSP	travel	2017Q4	230	2,599145	827	2 796	29,6%	29,6%	827
472	Bayesian Network for F1	97	1/1	3	BUSP	travel	2017Q4	261	2,125193	768	2 796	27,5%	27,5%	768
473	Bayesian Network for F1	98	10/1	3	BUSP	travel	2017Q4	261	2,497042	903	2 796	32,3%	32,3%	903
474	Bayesian Network for F1	99	1/10	3	BUSP	travel	2017Q4	261	2,125193	768	2 796	27,5%	27,5%	768
475	Bayesian Network for mix (Paid1+F1)	97-73	1/1	3	BUSP	travel	2017Q4	158	2,125193	463	2 796	16,6%	19,1%	533
476	Bayesian Network for mix (Paid1+F1)	98-74	10/1	3	BUSP	travel	2017Q4	158	2,497042	544	2 796	19,5%	20,5%	572
477	Bayesian Network for mix (Paid1+F1)	99-75	1/10	3	BUSP	travel	2017Q4	230	2,125193	676	2 796	24,2%	24,2%	676
478	Bayesian for Paid1	70	1/1	3	BUSP	travel	2018Q1	191	2,556306	675	3 148	21,4%	21,6%	679
479	Bayesian for Paid1	71	10/1	3	BUSP	travel	2018Q1	191	2,556306	675	3 148	21,4%	21,6%	679
480	Bayesian for Paid1	72	1/10	3	BUSP	travel	2018Q1	191	2,556306	675	3 148	21,4%	21,6%	679
481	Bayesian Network for F1	94	1/1	3	BUSP	travel	2018Q1	161	2,125193	473	3 148	15,0%	16,8%	529
482	Bayesian Network for F1	95	10/1	3	BUSP	travel	2018Q1	161	2,125193	473	3 148	15,0%	16,8%	529
483	Bayesian Network for F1	96	1/10	3	BUSP	travel	2018Q1	161	2,125193	473	3 148	15,0%	16,8%	529
484	Bayesian Network for mix (Paid1+F1)	94-70	1/1	3	BUSP	travel	2018Q1	191	2,125193	455	3 148	14,4%	16,5%	519
485	Bayesian Network for mix (Paid1+F1)	95-71	10/1	3	BUSP	travel	2018Q1	191	2,125193	561	3 148	17,8%	18,7%	587
486	Bayesian Network for mix (Paid1+F1)	96-72	1/10	3	BUSP	travel	2018Q1	191	2,125193	561	3 148	17,8%	18,7%	587
487	Bayesian for Paid1	67	1/1	3	BUSP	travel	2018Q2	188	2,551411	669	3 850	17,4%	18,4%	709
488	Bayesian for Paid1	68	10/1	3	BUSP	travel	2018Q2	188	2,551411	669	3 850	17,4%	18,4%	709
489	Bayesian for Paid1	69	1/10	3	BUSP	travel	2018Q2	224	2,551411	798	3 850	20,7%	21,0%	807
490	Bayesian Network for F1	91	1/1	3	BUSP	travel	2018Q2	230	2,125193	683	3 850	17,7%	18,7%	718
491	Bayesian Network for F1	92	10/1	3	BUSP	travel	2018Q2	230	2,125193	683	3 850	17,7%	18,7%	718
492	Bayesian Network for F1	93	1/10	3	BUSP	travel	2018Q2	230	2,125193	683	3 850	17,7%	18,7%	718
493	Bayesian Network for mix (Paid1+F1)	91-67	1/1	3	BUSP	travel	2018Q2	188	2,125193	558	3 850	14,5%	16,6%	640
494	Bayesian Network for mix (Paid1+F1)	92-68	10/1	3	BUSP	travel	2018Q2	188	2,125193	558	3 850	14,5%	16,6%	640
495	Bayesian Network for mix (Paid1+F1)	93-69	1/10	3	BUSP	travel	2018Q2	224	2,125193	665	3 850	17,3%	18,3%	706
496	Bayesian for Paid1	64	1/1	3	BUSP	travel	2018Q3	385	2,541323	1 366	3 896	35,1%	35,1%	1 366
497	Bayesian for Paid1	65	10/1	3	BUSP	travel	2018Q3	385	2,541323	1 366	3 896	35,1%	35,1%	1 366
498	Bayesian for Paid1	66	1/10	3	BUSP	travel	2018Q3	385	2,541323	1 366	3 896	35,1%	35,1%	1 366
499	Bayesian Network for F1	88	1/1	3	BUSP	travel	2018Q3	349	1,753344	855	3 896	21,9%	21,8%	848
500	Bayesian Network for F1	89	10/1	3	BUSP	travel	2018Q3	349	1,753344	855	3 896	21,9%	21,8%	848

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
501	**Bayesian Network for F1**	90	1/10	3	BUSP	travel	2018Q3	349	2,497042	1 217	3 896	31,2%	31,2%	1 217
502	**Bayesian Network for mix (Paid1+F1)**	88-64	1/1	3	BUSP	travel	2018Q3	385	1,753344	943	3 896	24,2%	24,0%	934
503	**Bayesian Network for mix (Paid1+F1)**	89-65	10/1	3	BUSP	travel	2018Q3	385	1,753344	943	3 896	24,2%	24,0%	934
504	**Bayesian Network for mix (Paid1+F1)**	90-66	1/10	3	BUSP	travel	2018Q3	385	2,497042	1 342	3 896	34,5%	34,5%	1 342
505	**Bayesian for Paid1**	61	1/1	3	BUSP	travel	2018Q4	182	2,532839	644	2 544	25,3%	24,7%	629
506	**Bayesian for Paid1**	62	10/1	3	BUSP	travel	2018Q4	182	2,532839	644	2 544	25,3%	24,7%	629
507	**Bayesian for Paid1**	63	1/10	3	BUSP	travel	2018Q4	219	2,532839	772	2 544	30,4%	30,1%	766
508	**Bayesian Network for F1**	85	1/1	3	BUSP	travel	2018Q4	216	2,497042	753	2 544	29,6%	29,2%	744
509	**Bayesian Network for F1**	86	10/1	3	BUSP	travel	2018Q4	216	2,497042	753	2 544	29,6%	29,2%	744
510	**Bayesian Network for F1**	87	1/10	3	BUSP	travel	2018Q4	216	2,497042	753	2 544	29,6%	29,2%	744
511	**Bayesian Network for mix (Paid1+F1)**	85-61	1/1	3	BUSP	travel	2018Q4	182	2,497042	635	2 544	25,0%	24,4%	620
512	**Bayesian Network for mix (Paid1+F1)**	86-62	10/1	3	BUSP	travel	2018Q4	182	2,497042	635	2 544	25,0%	24,4%	620
513	**Bayesian Network for mix (Paid1+F1)**	87-63	1/10	3	BUSP	travel	2018Q4	219	2,497042	761	2 544	29,9%	29,6%	754
514	**Bayesian for Paid1**	58	1/1	3	BUSP	travel	2019Q1	179	2,532839	634	2 686	23,6%	21,1%	567
515	**Bayesian for Paid1**	59	10/1	3	BUSP	travel	2019Q1	216	2,532839	762	2 686	28,4%	24,5%	658
516	**Bayesian for Paid1**	60	1/10	3	BUSP	travel	2019Q1	216	2,532839	762	2 686	28,4%	24,5%	658
517	**Bayesian Network for F1**		1/1	3	BUSP	travel	2019Q1							
518	**Bayesian Network for F1**		10/1	3	BUSP	travel	2019Q1							
519	**Bayesian Network for F1**		1/10	3	BUSP	travel	2019Q1							
520	**Bayesian Network for mix (Paid1+F1)**	-58	1/1	3	BUSP	travel	2019Q1							
521	**Bayesian Network for mix (Paid1+F1)**	-59	10/1	3	BUSP	travel	2019Q1							
522	**Bayesian Network for mix (Paid1+F1)**	-60	1/10	3	BUSP	travel	2019Q1							
523	**Bayesian for Paid1**	31	1/1	4	BUSP	auto	2017Q1	7 527	1,494398	11 741	16 343	71,8%	71,8%	11 741
524	**Bayesian for Paid1**	32	10/1	4	BUSP	auto	2017Q1	9 467	1,494398	14 767	16 343	90,4%	90,4%	14 767
525	**Bayesian for Paid1**	33	1/10	4	BUSP	auto	2017Q1	9 467	1,494398	14 767	16 343	90,4%	90,4%	14 767
526	**Bayesian Network for F1**	55	1/1	4	BUSP	auto	2017Q1	5 981	1,649485	10 297	16 343	63,0%	63,1%	10 307
527	**Bayesian Network for F1**	56	10/1	4	BUSP	auto	2017Q1	5 981	1,462381	9 129	16 343	55,9%	57,1%	9 340
528	**Bayesian Network for F1**	57	1/10	4	BUSP	auto	2017Q1	5 981	1,462381	9 129	16 343	55,9%	57,1%	9 340
529	**Bayesian Network for mix (Paid1+F1)**	55-31	1/1	4	BUSP	auto	2017Q1	7 527	1,649485	12 960	16 343	79,3%	79,3%	12 960
530	**Bayesian Network for mix (Paid1+F1)**	56-32	10/1	4	BUSP	auto	2017Q1	9 467	1,462381	14 451	16 343	88,4%	88,4%	14 451
531	**Bayesian Network for mix (Paid1+F1)**	57-33	1/10	4	BUSP	auto	2017Q1	9 467	1,462381	14 451	16 343	88,4%	88,4%	14 451
532	**Bayesian for Paid1**	28	1/1	4	BUSP	auto	2017Q2	7 589	1,49068	11 820	16 830	70,2%	70,2%	11 821
533	**Bayesian for Paid1**	29	10/1	4	BUSP	auto	2017Q2	7 589	1,49068	11 820	16 830	70,2%	70,2%	11 821
534	**Bayesian for Paid1**	30	1/10	4	BUSP	auto	2017Q2	7 589	1,49068	11 820	16 830	70,2%	70,2%	11 821
535	**Bayesian Network for F1**	52	1/1	4	BUSP	auto	2017Q2	6 068	1,649485	10 457	16 830	62,1%	63,2%	10 644
536	**Bayesian Network for F1**	53	10/1	4	BUSP	auto	2017Q2	6 068	1,649485	10 457	16 830	62,1%	63,2%	10 644
537	**Bayesian Network for F1**	54	1/10	4	BUSP	auto	2017Q2	6 068	1,649485	10 457	16 830	62,1%	63,2%	10 644
538	**Bayesian Network for mix (Paid1+F1)**	52-28	1/1	4	BUSP	auto	2017Q2	7 589	1,649485	13 079	16 830	77,7%	77,7%	13 079
539	**Bayesian Network for mix (Paid1+F1)**	53-29	10/1	4	BUSP	auto	2017Q2	7 589	1,649485	13 079	16 830	77,7%	77,7%	13 079
540	**Bayesian Network for mix (Paid1+F1)**	54-30	1/10	4	BUSP	auto	2017Q2	7 589	1,649485	13 079	16 830	77,7%	77,7%	13 079
541	**Bayesian for Paid1**	24	1/1	4	BUSP	auto	2017Q3	7 651	1,474136	11 762	17 270	68,1%	69,8%	12 062
542	**Bayesian for Paid1**	25	10/1	4	BUSP	auto	2017Q3	7 651	1,474136	11 762	17 270	68,1%	69,8%	12 062
543	**Bayesian for Paid1**	27	1/10	4	BUSP	auto	2017Q3	8 652	1,474136	13 300	17 270	77,0%	77,1%	13 318
544	**Bayesian Network for F1**	49	1/1	4	BUSP	auto	2017Q3	7 531	1,353653	10 651	17 270	61,7%	65,8%	11 368
545	**Bayesian Network for F1**	50	10/1	4	BUSP	auto	2017Q3	7 531	1,462381	11 506	17 270	66,6%	68,8%	11 886
546	**Bayesian Network for F1**	51	1/10	4	BUSP	auto	2017Q3	7 531	1,649485	12 978	17 270	75,1%	75,4%	13 027
547	**Bayesian Network for mix (Paid1+F1)**	49-24	1/1	4	BUSP	auto	2017Q3	7 651	1,353653	10 821	17 270	62,7%	66,4%	11 462
548	**Bayesian Network for mix (Paid1+F1)**	50-25	10/1	4	BUSP	auto	2017Q3	7 651	1,462381	11 690	17 270	67,7%	69,6%	12 012
549	**Bayesian Network for mix (Paid1+F1)**	51-27	1/10	4	BUSP	auto	2017Q3	8 652	1,649485	14 910	17 270	86,3%	86,3%	14 910
550	**Bayesian for Paid1**	21	1/1	4	BUSP	auto	2017Q4	7 712	1,492849	12 024	18 669	64,4%	64,4%	12 028
551	**Bayesian for Paid1**	22	10/1	4	BUSP	auto	2017Q4	7 712	1,492849	12 024	18 669	64,4%	64,4%	12 028
552	**Bayesian for Paid1**	23	1/10	4	BUSP	auto	2017Q4	7 712	1,492849	12 024	18 669	64,4%	64,4%	12 028
553	**Bayesian Network for F1**	46	1/1	4	BUSP	auto	2017Q4	6 642	1,836588	12 746	18 669	68,3%	68,3%	12 746
554	**Bayesian Network for F1**	47	10/1	4	BUSP	auto	2017Q4	6 642	1,353653	9 394	18 669	50,3%	53,9%	10 053
555	**Bayesian Network for F1**	48	1/10	4	BUSP	auto	2017Q4	6 642	1,353653	9 394	18 669	50,3%	53,9%	10 053
556	**Bayesian Network for mix (Paid1+F1)**	46-21	1/1	4	BUSP	auto	2017Q4	7 712	1,836588	14 799	18 669	79,3%	79,3%	14 799
557	**Bayesian Network for mix (Paid1+F1)**	47-22	10/1	4	BUSP	auto	2017Q4	7 712	1,353653	10 908	18 669	58,4%	59,2%	11 052
558	**Bayesian Network for mix (Paid1+F1)**	48-23	1/10	4	BUSP	auto	2017Q4	7 712	1,353653	10 908	18 669	58,4%	59,2%	11 052
559	**Bayesian for Paid1**	18	1/1	4	BUSP	auto	2018Q1	8 775	1,494398	13 687	17 645	77,6%	77,6%	13 687
560	**Bayesian for Paid1**	19	10/1	4	BUSP	auto	2018Q1	7 774	1,494398	12 126	17 645	68,7%	68,7%	12 126
561	**Bayesian for Paid1**	20	1/10	4	BUSP	auto	2018Q1	8 775	1,494398	13 687	17 645	77,6%	77,6%	13 687
562	**Bayesian Network for F1**	43	1/1	4	BUSP	auto	2018Q1	7 984	1,462381	12 199	17 645	69,1%	69,1%	12 199
563	**Bayesian Network for F1**	44	10/1	4	BUSP	auto	2018Q1	7 984	1,462381	12 199	17 645	69,1%	69,1%	12 199
564	**Bayesian Network for F1**	45	1/10	4	BUSP	auto	2018Q1	7 984	1,462381	12 199	17 645	69,1%	69,1%	12 199
565	**Bayesian Network for mix (Paid1+F1)**	43-18	1/1	4	BUSP	auto	2018Q1	8 775	1,462381	13 407	17 645	76,0%	76,0%	13 407
566	**Bayesian Network for mix (Paid1+F1)**	44-19	10/1	4	BUSP	auto	2018Q1	7 774	1,462381	11 878	17 645	67,3%	67,3%	11 878
567	**Bayesian Network for mix (Paid1+F1)**	45-20	1/10	4	BUSP	auto	2018Q1	8 775	1,462381	13 407	17 645	76,0%	76,0%	13 407
568	**Bayesian for Paid1**	15	1/1	4	BUSP	auto	2018Q2	8 898	1,49068	13 859	17 821	77,8%	77,8%	13 859
569	**Bayesian for Paid1**	16	10/1	4	BUSP	auto	2018Q2	7 836	1,49068	12 204	17 821	68,5%	68,7%	12 239
570	**Bayesian for Paid1**	17	1/10	4	BUSP	auto	2018Q2	8 837	1,49068	13 763	17 821	77,2%	77,2%	13 763
571	**Bayesian Network for F1**	40	1/1	4	BUSP	auto	2018Q2	8 749	1,462381	13 368	17 821	75,0%	75,0%	13 368
572	**Bayesian Network for F1**	41	10/1	4	BUSP	auto	2018Q2	8 749	1,836588	16 788	17 821	94,2%	94,2%	16 788
573	**Bayesian Network for F1**	42	1/10	4	BUSP	auto	2018Q2	8 749	1,836588	16 788	17 821	94,2%	94,2%	16 788
574	**Bayesian Network for mix (Paid1+F1)**	40-15	1/1	4	BUSP	auto	2018Q2	8 898	1,462381	13 596	17 821	76,3%	76,3%	13 596
575	**Bayesian Network for mix (Paid1+F1)**	41-16	10/1	4	BUSP	auto	2018Q2	7 836	1,836588	15 036	17 821	84,4%	84,4%	15 036
576	**Bayesian Network for mix (Paid1+F1)**	42-17	1/10	4	BUSP	auto	2018Q2	8 837	1,836588	16 956	17 821	95,1%	95,1%	16 956
577	**Bayesian for Paid1**	13	1/1	4	BUSP	auto	2018Q3	9 837	1,474136	15 123	18 544	81,6%	81,6%	15 127
578	**Bayesian for Paid1**	14	10/1	4	BUSP	auto	2018Q3	7 088	1,474136	10 896	18 544	58,8%	62,1%	11 509
579	**Bayesian for Paid1**	15	1/10	4	BUSP	auto	2018Q3	8 898	1,474136	13 680	18 544	73,8%	74,3%	13 771
580	**Bayesian Network for F1**	37	1/1	4	BUSP	auto	2018Q3	10 154	1,353653	14 334	18 544	77,3%	77,5%	14 372
581	**Bayesian Network for F1**	38	10/1	4	BUSP	auto	2018Q3	10 154	1,836588	19 448	18 544	104,9%	104,9%	19 448
582	**Bayesian Network for F1**	39	1/10	4	BUSP	auto	2018Q3	10 154	1,462381	15 485	18 544	83,5%	83,5%	15 484
583	**Bayesian Network for mix (Paid1+F1)**	37-13	1/1	4	BUSP	auto	2018Q3	9 837	1,353653	13 887	18 544	74,9%	75,3%	13 959
584	**Bayesian Network for mix (Paid1+F1)**	38-14	10/1	4	BUSP	auto	2018Q3	7 088	1,836588	13 575	18 544	73,2%	73,8%	13 677
585	**Bayesian Network for mix (Paid1+F1)**	39-15	1/10	4	BUSP	auto	2018Q3	8 898	1,462381	13 571	18 544	73,2%	73,7%	13 673
586	**Bayesian for Paid1**	10	1/1	4	BUSP	auto	2018Q4	8 960	1,463088	13 669	18 730	73,0%	73,0%	13 669
587	**Bayesian for Paid1**	11	10/1	4	BUSP	auto	2018Q4	8 960	1,463088	13 669	18 730	73,0%	73,0%	13 669
588	**Bayesian for Paid1**	12	1/10	4	BUSP	auto	2018Q4	8 960	1,463088	13 669	18 730	73,0%	73,0%	13 669
589	**Bayesian Network for F1**	34	1/1	4	BUSP	auto	2018Q4	8 589	1,649485	14 773	18 730	78,9%	78,9%	14 773
590	**Bayesian Network for F1**	35	10/1	4	BUSP	auto	2018Q4	8 589	1,462381	13 097	18 730	69,9%	69,9%	13 095
591	**Bayesian Network for F1**	36	1/10	4	BUSP	auto	2018Q4	8 589	1,649485	14 773	18 730	78,9%	78,9%	14 773
592	**Bayesian Network for mix (Paid1+F1)**	34-10	1/1	4	BUSP	auto	2018Q4	8 960	1,649485	15 411	18 730	82,3%	82,3%	15 411
593	**Bayesian Network for mix (Paid1+F1)**	35-11	10/1	4	BUSP	auto	2018Q4	8 960	1,462381	13 663	18 730	72,9%	72,9%	13 663
594	**Bayesian Network for mix (Paid1+F1)**	36-12	1/10	4	BUSP	auto	2018Q4	8 960	1,649485	15 411	18 730	82,3%	82,3%	15 411
595	**Bayesian for Paid1**	7	1/1	4	BUSP	auto	2019Q1	9 022	1,525148	14 348	17 887	80,2%	79,1%	14 146
596	**Bayesian for Paid1**	8	10/1	4	BUSP	auto	2019Q1	9 022	1,525148	14 348	17 887	80,2%	79,1%	14 146
597	**Bayesian for Paid1**	9	1/10	4	BUSP	auto	2019Q1	9 022	1,525148	14 348	17 887	80,2%	79,1%	14 146
598	**Bayesian Network for F1**		1/1	4	BUSP	auto	2019Q1							
599	**Bayesian Network for F1**		10/1	4	BUSP	auto	2019Q1							
600	**Bayesian Network for F1**		1/10	4	BUSP	auto	2019Q1							

Technical Tes	Model\information	Numéro_d	Niveau_de_crédibilité	Valorisati	Busines	LOB	Cohorte	PAID1 (k€)	F1	ULT (k€)	GEP (k€)	LR	LR-BF	ULT-BF (k€)
601	Bayesian Network for mix (Paid1+F1)	-7	1/1	4	BUSP	auto	2019Q1							
602	Bayesian Network for mix (Paid1+F1)	-8	10/1	4	BUSP	auto	2019Q1							
603	Bayesian Network for mix (Paid1+F1)	-9	1/10	4	BUSP	auto	2019Q1							
604	Bayesian for Paid1	82	1/1	4	BUSP	travel	2017Q1	203	2,556306	716	3 627	19,7%	20,9%	759
605	Bayesian for Paid1	83	10/1	4	BUSP	travel	2017Q1	203	2,556306	716	3 627	19,7%	20,9%	759
606	Bayesian for Paid1	84	1/10	4	BUSP	travel	2017Q1	203	2,556306	716	3 627	19,7%	20,9%	759
607	Bayesian Network for F1	106	1/1	4	BUSP	travel	2017Q1	192	2,497042	664	3 627	18,3%	20,2%	732
608	Bayesian Network for F1	107	10/1	4	BUSP	travel	2017Q1	192	2,497042	664	3 627	18,3%	20,2%	732
609	Bayesian Network for F1	108	1/10	4	BUSP	travel	2017Q1	192	2,497042	664	3 627	18,3%	20,2%	732
610	Bayesian Network for mix (Paid1+F1)	106-82	1/1	4	BUSP	travel	2017Q1	203	2,497042	699	3 627	19,3%	20,7%	749
611	Bayesian Network for mix (Paid1+F1)	107-83	10/1	4	BUSP	travel	2017Q1	203	2,497042	699	3 627	19,3%	20,7%	749
612	Bayesian Network for mix (Paid1+F1)	108-84	1/10	4	BUSP	travel	2017Q1	203	2,497042	699	3 627	19,3%	20,7%	749
613	Bayesian for Paid1	79	1/1	4	BUSP	travel	2017Q2	200	2,551411	711	4 408	16,1%	20,7%	915
614	Bayesian for Paid1	80	10/1	4	BUSP	travel	2017Q2	200	2,551411	711	4 408	16,1%	20,7%	915
615	Bayesian for Paid1	81	1/10	4	BUSP	travel	2017Q2	200	2,551411	711	4 408	16,1%	20,7%	915
616	Bayesian Network for F1	103	1/1	4	BUSP	travel	2017Q2	197	2,497042	686	4 408	15,6%	20,7%	910
617	Bayesian Network for F1	104	10/1	4	BUSP	travel	2017Q2	197	2,497042	686	4 408	15,6%	20,7%	910
618	Bayesian Network for F1	105	1/10	4	BUSP	travel	2017Q2	197	2,497042	686	4 408	15,6%	20,7%	910
619	Bayesian Network for mix (Paid1+F1)	103-79	1/1	4	BUSP	travel	2017Q2	200	2,497042	689	4 408	15,6%	20,7%	911
620	Bayesian Network for mix (Paid1+F1)	104-80	10/1	4	BUSP	travel	2017Q2	200	2,497042	689	4 408	15,6%	20,7%	911
621	Bayesian Network for mix (Paid1+F1)	105-81	1/10	4	BUSP	travel	2017Q2	200	2,497042	689	4 408	15,6%	20,7%	911
622	Bayesian for Paid1	76	1/1	4	BUSP	travel	2017Q3	461	2,541323	1 634	5 333	30,6%	30,6%	1 634
623	Bayesian for Paid1	77	10/1	4	BUSP	travel	2017Q3	397	2,541323	1 407	5 333	26,4%	26,4%	1 406
624	Bayesian for Paid1	78	1/10	4	BUSP	travel	2017Q3	397	2,541323	1 407	5 333	26,4%	26,4%	1 406
625	Bayesian Network for F1	100	1/1	4	BUSP	travel	2017Q3	378	2,497042	1 316	5 333	24,7%	24,7%	1 317
626	Bayesian Network for F1	101	10/1	4	BUSP	travel	2017Q3	378	2,497042	1 316	5 333	24,7%	24,7%	1 317
627	Bayesian Network for F1	102	1/10	4	BUSP	travel	2017Q3	378	2,497042	1 316	5 333	24,7%	24,7%	1 317
628	Bayesian Network for mix (Paid1+F1)	100-76	1/1	4	BUSP	travel	2017Q3	461	2,497042	1 605	5 333	30,1%	30,1%	1 605
629	Bayesian Network for mix (Paid1+F1)	101-77	10/1	4	BUSP	travel	2017Q3	397	2,497042	1 383	5 333	25,9%	25,9%	1 381
630	Bayesian Network for mix (Paid1+F1)	102-78	1/10	4	BUSP	travel	2017Q3	397	2,497042	1 383	5 333	25,9%	25,9%	1 381
631	Bayesian for Paid1	73	1/1	4	BUSP	travel	2017Q4	121	2,599145	436	2 796	15,6%	18,7%	524
632	Bayesian for Paid1	74	10/1	4	BUSP	travel	2017Q4	121	2,599145	436	2 796	15,6%	18,7%	524
633	Bayesian for Paid1	75	1/10	4	BUSP	travel	2017Q4	194	2,599145	697	2 796	24,9%	24,9%	696
634	Bayesian Network for F1	97	1/1	4	BUSP	travel	2017Q4	261	2,497042	903	2 796	32,3%	32,3%	903
635	Bayesian Network for F1	98	10/1	4	BUSP	travel	2017Q4	261	2,992688	1 082	2 796	38,7%	38,7%	1 082
636	Bayesian Network for F1	99	1/10	4	BUSP	travel	2017Q4	261	2,497042	903	2 796	32,3%	32,3%	903
637	Bayesian Network for mix (Paid1+F1)	97-73	1/1	4	BUSP	travel	2017Q4	121	2,497042	419	2 796	15,0%	18,6%	520
638	Bayesian Network for mix (Paid1+F1)	98-74	10/1	4	BUSP	travel	2017Q4	121	2,992688	502	2 796	18,0%	19,7%	550
639	Bayesian Network for mix (Paid1+F1)	99-75	1/10	4	BUSP	travel	2017Q4	194	2,497042	670	2 796	24,0%	23,9%	669
640	Bayesian for Paid1	70	1/1	4	BUSP	travel	2018Q1	155	2,556306	547	3 148	17,4%	18,3%	577
641	Bayesian for Paid1	71	10/1	4	BUSP	travel	2018Q1	155	2,556306	547	3 148	17,4%	18,3%	577
642	Bayesian for Paid1	72	1/10	4	BUSP	travel	2018Q1	155	2,556306	547	3 148	17,4%	18,3%	577
643	Bayesian Network for F1	94	1/1	4	BUSP	travel	2018Q1	161	2,497042	555	3 148	17,6%	18,5%	583
644	Bayesian Network for F1	95	10/1	4	BUSP	travel	2018Q1	161	2,497042	555	3 148	17,6%	18,5%	583
645	Bayesian Network for F1	96	1/10	4	BUSP	travel	2018Q1	161	2,497042	555	3 148	17,6%	18,5%	583
646	Bayesian Network for mix (Paid1+F1)	94-70	1/1	4	BUSP	travel	2018Q1	155	2,497042	534	3 148	17,0%	18,1%	568
647	Bayesian Network for mix (Paid1+F1)	95-71	10/1	4	BUSP	travel	2018Q1	155	2,497042	534	3 148	17,0%	18,1%	568
648	Bayesian Network for mix (Paid1+F1)	96-72	1/10	4	BUSP	travel	2018Q1	155	2,497042	534	3 148	17,0%	18,1%	568
649	Bayesian for Paid1	67	1/1	4	BUSP	travel	2018Q2	152	2,551411	540	3 850	14,0%	16,4%	631
650	Bayesian for Paid1	68	10/1	4	BUSP	travel	2018Q2	152	2,551411	540	3 850	14,0%	16,4%	631
651	Bayesian for Paid1	69	1/10	4	BUSP	travel	2018Q2	188	2,551411	669	3 850	17,4%	18,4%	709
652	Bayesian Network for F1	91	1/1	4	BUSP	travel	2018Q2	230	2,497042	803	3 850	20,8%	21,0%	810
653	Bayesian Network for F1	92	10/1	4	BUSP	travel	2018Q2	230	2,497042	803	3 850	20,8%	21,0%	810
654	Bayesian Network for F1	93	1/10	4	BUSP	travel	2018Q2	230	2,497042	803	3 850	20,8%	21,0%	810
655	Bayesian Network for mix (Paid1+F1)	91-67	1/1	4	BUSP	travel	2018Q2	152	2,497042	529	3 850	13,7%	16,2%	625
656	Bayesian Network for mix (Paid1+F1)	92-68	10/1	4	BUSP	travel	2018Q2	152	2,497042	529	3 850	13,7%	16,2%	625
657	Bayesian Network for mix (Paid1+F1)	93-69	1/10	4	BUSP	travel	2018Q2	188	2,497042	655	3 850	17,0%	18,2%	699
658	Bayesian for Paid1	64	1/1	4	BUSP	travel	2018Q3	449	2,541323	1 592	3 896	40,9%	40,9%	1 592
659	Bayesian for Paid1	65	10/1	4	BUSP	travel	2018Q3	449	2,541323	1 592	3 896	40,9%	40,9%	1 592
660	Bayesian for Paid1	66	1/10	4	BUSP	travel	2018Q3	449	2,541323	1 592	3 896	40,9%	40,9%	1 592
661	Bayesian Network for F1	88	1/1	4	BUSP	travel	2018Q3	349	2,125193	1 036	3 896	26,6%	26,5%	1 033
662	Bayesian Network for F1	89	10/1	4	BUSP	travel	2018Q3	349	2,125193	1 036	3 896	26,6%	26,5%	1 033
663	Bayesian Network for F1	90	1/10	4	BUSP	travel	2018Q3	349	2,992688	1 459	3 896	37,4%	37,4%	1 459
664	Bayesian Network for mix (Paid1+F1)	88-64	1/1	4	BUSP	travel	2018Q3	449	2,125193	1 332	3 896	34,2%	34,2%	1 332
665	Bayesian Network for mix (Paid1+F1)	89-65	10/1	4	BUSP	travel	2018Q3	449	2,125193	1 332	3 896	34,2%	34,2%	1 332
666	Bayesian Network for mix (Paid1+F1)	90-66	1/10	4	BUSP	travel	2018Q3	449	2,992688	1 875	3 896	48,1%	48,1%	1 875
667	Bayesian for Paid1	61	1/1	4	BUSP	travel	2018Q4	146	2,532839	516	2 544	20,3%	20,2%	515
668	Bayesian for Paid1	62	10/1	4	BUSP	travel	2018Q4	146	2,532839	516	2 544	20,3%	20,2%	515
669	Bayesian for Paid1	63	1/10	4	BUSP	travel	2018Q4	182	2,532839	644	2 544	25,3%	24,7%	629
670	Bayesian Network for F1	85	1/1	4	BUSP	travel	2018Q4	216	2,992688	902	2 544	35,5%	35,5%	902
671	Bayesian Network for F1	86	10/1	4	BUSP	travel	2018Q4	216	2,992688	902	2 544	35,5%	35,5%	902
672	Bayesian Network for F1	87	1/10	4	BUSP	travel	2018Q4	216	2,992688	902	2 544	35,5%	35,5%	902
673	Bayesian Network for mix (Paid1+F1)	85-61	1/1	4	BUSP	travel	2018Q4	146	2,992688	610	2 544	24,0%	23,4%	596
674	Bayesian Network for mix (Paid1+F1)	86-62	10/1	4	BUSP	travel	2018Q4	146	2,992688	610	2 544	24,0%	23,4%	596
675	Bayesian Network for mix (Paid1+F1)	87-63	1/10	4	BUSP	travel	2018Q4	182	2,992688	761	2 544	29,9%	29,6%	753
676	Bayesian for Paid1	58	1/1	4	BUSP	travel	2019Q1	143	2,532839	506	2 686	18,8%	17,8%	478
677	Bayesian for Paid1	59	10/1	4	BUSP	travel	2019Q1	179	2,532839	634	2 686	23,6%	21,1%	567
678	Bayesian for Paid1	60	1/10	4	BUSP	travel	2019Q1	179	2,532839	634	2 686	23,6%	21,1%	567
679	Bayesian Network for F1		1/1	4	BUSP	travel	2019Q1							
680	Bayesian Network for F1		10/1	4	BUSP	travel	2019Q1							
681	Bayesian Network for F1		1/10	4	BUSP	travel	2019Q1							
682	Bayesian Network for mix (Paid1+F1)	-58	1/1	4	BUSP	travel	2019Q1							
683	Bayesian Network for mix (Paid1+F1)	-59	10/1	4	BUSP	travel	2019Q1							
684	Bayesian Network for mix (Paid1+F1)	-60	1/10	4	BUSP	travel	2019Q1							

Après optimisation :

Technical I	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (ki	LR	LR-BF	ULT-BF (k
687	Bayesian for Paid1	133	1/1	1	BUSP	auto	2017Q1	7 357	1,494398	11 475	16 343	70,2%	70,2%	11 475
883	Bayesian for Paid1	145	1/1	2	BUSP	auto	2017Q1	6 699	1,494398	10 449	16 343	63,9%	64,0%	10 452
1045	Bayesian for Paid1	133	1/1	3	BUSP	auto	2017Q1	6 432	1,494398	10 033	16 343	61,4%	61,6%	10 066
1207	Bayesian for Paid1	145	1/1	4	BUSP	auto	2017Q1	6 966	1,494398	10 865	16 343	66,5%	66,5%	10 865
689	Bayesian for Paid1	135	1/10	1	BUSP	auto	2017Q1	7 510	1,494398	11 714	16 343	71,7%	71,7%	11 714
885	Bayesian for Paid1	147	1/10	2	BUSP	auto	2017Q1	6 699	1,494398	10 449	16 343	63,9%	64,0%	10 452
1047	Bayesian for Paid1	135	1/10	3	BUSP	auto	2017Q1	6 432	1,494398	10 033	16 343	61,4%	61,6%	10 066
1209	Bayesian for Paid1	147	1/10	4	BUSP	auto	2017Q1	6 966	1,494398	10 865	16 343	66,5%	66,5%	10 865
688	Bayesian for Paid1	134	10/1	1	BUSP	auto	2017Q1	7 264	1,494398	11 330	16 343	69,3%	69,3%	11 330
884	Bayesian for Paid1	146	10/1	2	BUSP	auto	2017Q1	6 699	1,494398	10 449	16 343	63,9%	64,0%	10 452
1046	Bayesian for Paid1	134	10/1	3	BUSP	auto	2017Q1	6 432	1,494398	10 033	16 343	61,4%	61,6%	10 066
1208	Bayesian for Paid1	146	10/1	4	BUSP	auto	2017Q1	6 966	1,494398	10 865	16 343	66,5%	66,5%	10 865
698	Bayesian for Paid1	133	1/1	1	BUSP	auto	2017Q2	7 189	1,49068	11 196	16 830	66,5%	66,8%	11 244
892	Bayesian for Paid1	142	1/1	2	BUSP	auto	2017Q2	6 760	1,49068	10 529	16 830	62,6%	63,6%	10 699
1054	Bayesian for Paid1	133	1/1	3	BUSP	auto	2017Q2	6 494	1,49068	10 114	16 830	60,1%	61,8%	10 397
1216	Bayesian for Paid1	142	1/1	4	BUSP	auto	2017Q2	7 027	1,49068	10 945	16 830	65,0%	65,5%	11 030
700	Bayesian for Paid1	135	1/10	1	BUSP	auto	2017Q2	7 621	1,49068	11 869	16 830	70,5%	70,5%	11 870
894	Bayesian for Paid1	144	1/10	2	BUSP	auto	2017Q2	7 294	1,49068	11 360	16 830	67,5%	67,7%	11 390
1056	Bayesian for Paid1	135	1/10	3	BUSP	auto	2017Q2	7 027	1,49068	10 945	16 830	65,0%	65,5%	11 030
1218	Bayesian for Paid1	144	1/10	4	BUSP	auto	2017Q2	7 561	1,49068	11 776	16 830	70,0%	70,0%	11 778
699	Bayesian for Paid1	134	10/1	1	BUSP	auto	2017Q2	6 830	1,49068	10 638	16 830	63,2%	64,1%	10 783
893	Bayesian for Paid1	143	10/1	2	BUSP	auto	2017Q2	6 760	1,49068	10 529	16 830	62,6%	63,6%	10 699
1055	Bayesian for Paid1	134	10/1	3	BUSP	auto	2017Q2	6 494	1,49068	10 114	16 830	60,1%	61,8%	10 397
1217	Bayesian for Paid1	143	10/1	4	BUSP	auto	2017Q2	7 027	1,49068	10 945	16 830	65,0%	65,5%	11 030
709	Bayesian for Paid1	130	1/1	1	BUSP	auto	2017Q3	7 745	1,474136	11 906	17 270	68,9%	70,4%	12 166
901	Bayesian for Paid1	139	1/1	2	BUSP	auto	2017Q3	8 685	1,474136	13 352	17 270	77,3%	77,4%	13 367
1063	Bayesian for Paid1	130	1/1	3	BUSP	auto	2017Q3	8 331	1,474136	12 808	17 270	74,2%	74,6%	12 879
1225	Bayesian for Paid1	139	1/1	4	BUSP	auto	2017Q3	9 040	1,474136	13 897	17 270	80,5%	80,5%	13 897
711	Bayesian for Paid1	132	1/10	1	BUSP	auto	2017Q3	7 739	1,474136	11 897	17 270	68,9%	70,4%	12 159
903	Bayesian for Paid1	141	1/10	2	BUSP	auto	2017Q3	8 685	1,474136	13 352	17 270	77,3%	77,4%	13 367
1065	Bayesian for Paid1	132	1/10	3	BUSP	auto	2017Q3	8 331	1,474136	12 808	17 270	74,2%	74,6%	12 879
1227	Bayesian for Paid1	141	1/10	4	BUSP	auto	2017Q3	9 040	1,474136	13 897	17 270	80,5%	80,5%	13 897
710	Bayesian for Paid1	131	10/1	1	BUSP	auto	2017Q3	7 722	1,474136	11 871	17 270	68,7%	70,3%	12 140
902	Bayesian for Paid1	140	10/1	2	BUSP	auto	2017Q3	6 822	1,474136	10 488	17 270	60,7%	65,3%	11 281
1064	Bayesian for Paid1	131	10/1	3	BUSP	auto	2017Q3	6 555	1,474136	10 078	17 270	58,4%	64,2%	11 080
1226	Bayesian for Paid1	140	10/1	4	BUSP	auto	2017Q3	7 089	1,474136	10 898	17 270	63,1%	66,6%	11 507
720	Bayesian for Paid1	127	1/1	1	BUSP	auto	2017Q4	7 459	1,492849	11 628	18 669	62,3%	62,4%	11 658
910	Bayesian for Paid1	139	1/1	2	BUSP	auto	2017Q4	6 884	1,492849	10 732	18 669	57,5%	58,5%	10 917
1072	Bayesian for Paid1	127	1/1	3	BUSP	auto	2017Q4	6 617	1,492849	10 316	18 669	55,3%	56,9%	10 617
1234	Bayesian for Paid1	139	1/1	4	BUSP	auto	2017Q4	7 151	1,492849	11 148	18 669	59,7%	60,2%	11 245
722	Bayesian for Paid1	129	1/10	1	BUSP	auto	2017Q4	7 735	1,492849	12 059	18 669	64,6%	64,6%	12 062
912	Bayesian for Paid1	141	1/10	2	BUSP	auto	2017Q4	8 038	1,492849	12 532	18 669	67,1%	67,1%	12 532
1074	Bayesian for Paid1	129	1/10	3	BUSP	auto	2017Q4	7 684	1,492849	11 980	18 669	64,2%	64,2%	11 985
1236	Bayesian for Paid1	141	1/10	4	BUSP	auto	2017Q4	8 393	1,492849	13 085	18 669	70,1%	70,1%	13 085
721	Bayesian for Paid1	128	10/1	1	BUSP	auto	2017Q4	7 061	1,492849	11 008	18 669	59,0%	59,6%	11 131
911	Bayesian for Paid1	140	10/1	2	BUSP	auto	2017Q4	6 884	1,492849	10 732	18 669	57,5%	58,5%	10 917
1073	Bayesian for Paid1	128	10/1	3	BUSP	auto	2017Q4	6 617	1,492849	10 316	18 669	55,3%	56,9%	10 617
1235	Bayesian for Paid1	140	10/1	4	BUSP	auto	2017Q4	7 151	1,492849	11 148	18 669	59,7%	60,2%	11 245
731	Bayesian for Paid1	124	1/1	1	BUSP	auto	2018Q1	7 738	1,494398	12 069	17 645	68,4%	68,4%	12 069
919	Bayesian for Paid1	136	1/1	2	BUSP	auto	2018Q1	7 479	1,494398	11 666	17 645	66,1%	66,1%	11 668
1081	Bayesian for Paid1	124	1/1	3	BUSP	auto	2018Q1	7 212	1,494398	11 250	17 645	63,8%	63,8%	11 265
1243	Bayesian for Paid1	136	1/1	4	BUSP	auto	2018Q1	7 746	1,494398	12 082	17 645	68,5%	68,5%	12 082
733	Bayesian for Paid1	126	1/10	1	BUSP	auto	2018Q1	7 756	1,494398	12 098	17 645	68,6%	68,6%	12 098
921	Bayesian for Paid1	138	1/10	2	BUSP	auto	2018Q1	7 479	1,494398	11 666	17 645	66,1%	66,1%	11 668
1083	Bayesian for Paid1	126	1/10	3	BUSP	auto	2018Q1	7 212	1,494398	11 250	17 645	63,8%	63,8%	11 265
1245	Bayesian for Paid1	138	1/10	4	BUSP	auto	2018Q1	7 746	1,494398	12 082	17 645	68,5%	68,5%	12 082
732	Bayesian for Paid1	125	10/1	1	BUSP	auto	2018Q1	7 563	1,494398	11 797	17 645	66,9%	66,9%	11 797
920	Bayesian for Paid1	137	10/1	2	BUSP	auto	2018Q1	7 479	1,494398	11 666	17 645	66,1%	66,1%	11 668
1082	Bayesian for Paid1	125	10/1	3	BUSP	auto	2018Q1	7 212	1,494398	11 250	17 645	63,8%	63,8%	11 265
1244	Bayesian for Paid1	137	10/1	4	BUSP	auto	2018Q1	7 746	1,494398	12 082	17 645	68,5%	68,5%	12 082
742	Bayesian for Paid1	124	1/1	1	BUSP	auto	2018Q2	7 716	1,49068	12 018	17 821	67,4%	67,7%	12 066
928	Bayesian for Paid1		1/1	2	BUSP	auto	2018Q2	8 162	1,49068	12 712	17 821	71,3%	71,4%	12 721
1090	Bayesian for Paid1	124	1/1	3	BUSP	auto	2018Q2	7 807	1,49068	12 160	17 821	68,2%	68,4%	12 197
1252	Bayesian for Paid1		1/1	4	BUSP	auto	2018Q2	8 516	1,49068	13 264	17 821	74,4%	74,4%	13 263
744	Bayesian for Paid1	126	1/10	1	BUSP	auto	2018Q2	7 842	1,49068	12 213	17 821	68,5%	68,7%	12 247
930	Bayesian for Paid1		1/10	2	BUSP	auto	2018Q2	8 162	1,49068	12 712	17 821	71,3%	71,4%	12 721
1092	Bayesian for Paid1	126	1/10	3	BUSP	auto	2018Q2	7 807	1,49068	12 160	17 821	68,2%	68,4%	12 197
1254	Bayesian for Paid1		1/10	4	BUSP	auto	2018Q2	8 516	1,49068	13 264	17 821	74,4%	74,4%	13 263
743	Bayesian for Paid1	125	10/1	1	BUSP	auto	2018Q2	7 587	1,49068	11 816	17 821	66,3%	66,7%	11 881
929	Bayesian for Paid1		10/1	2	BUSP	auto	2018Q2	7 007	1,49068	10 914	17 821	61,2%	62,2%	11 089
1091	Bayesian for Paid1	125	10/1	3	BUSP	auto	2018Q2	6 740	1,49068	10 498	17 821	58,9%	60,3%	10 743
1253	Bayesian for Paid1		10/1	4	BUSP	auto	2018Q2	7 274	1,49068	11 329	17 821	63,6%	64,2%	11 446
753	Bayesian for Paid1	121	1/1	1	BUSP	auto	2018Q3	7 911	1,474136	12 162	18 544	65,6%	67,3%	12 476
937	Bayesian for Paid1		1/1	2	BUSP	auto	2018Q3	7 602	1,474136	11 687	18 544	63,0%	65,3%	12 101
1099	Bayesian for Paid1	121	1/1	3	BUSP	auto	2018Q3	7 336	1,474136	11 277	18 544	60,8%	63,6%	11 789
1261	Bayesian for Paid1		1/1	4	BUSP	auto	2018Q3	7 869	1,474136	12 097	18 544	65,2%	67,0%	12 424
755	Bayesian for Paid1	123	1/10	1	BUSP	auto	2018Q3	7 936	1,474136	12 200	18 544	65,8%	67,4%	12 507
939	Bayesian for Paid1		1/10	2	BUSP	auto	2018Q3	7 069	1,474136	10 867	18 544	58,6%	62,0%	11 488
1101	Bayesian for Paid1	123	1/10	3	BUSP	auto	2018Q3	6 802	1,474136	10 457	18 544	56,4%	60,4%	11 200
1263	Bayesian for Paid1		1/10	4	BUSP	auto	2018Q3	7 336	1,474136	11 277	18 544	60,8%	63,6%	11 789
754	Bayesian for Paid1	122	10/1	1	BUSP	auto	2018Q3	7 954	1,474136	12 228	18 544	65,9%	67,6%	12 529
938	Bayesian for Paid1		10/1	2	BUSP	auto	2018Q3	8 223	1,474136	12 642	18 544	68,2%	69,4%	12 870
1100	Bayesian for Paid1	122	10/1	3	BUSP	auto	2018Q3	7 869	1,474136	12 097	18 544	65,2%	67,0%	12 424
1262	Bayesian for Paid1		10/1	4	BUSP	auto	2018Q3	8 578	1,474136	13 187	18 544	71,1%	71,9%	13 335
764	Bayesian for Paid1	118	1/1	1	BUSP	auto	2018Q4	7 766	1,463088	11 848	18 730	63,3%	63,4%	11 868
946	Bayesian for Paid1		1/1	2	BUSP	auto	2018Q4	7 131	1,463088	10 878	18 730	58,1%	58,6%	10 985
1108	Bayesian for Paid1	118	1/1	3	BUSP	auto	2018Q4	6 864	1,463088	10 471	18 730	55,9%	56,8%	10 634
1270	Bayesian for Paid1		1/1	4	BUSP	auto	2018Q4	7 397	1,463088	11 285	18 730	60,3%	60,6%	11 347
766	Bayesian for Paid1	120	1/10	1	BUSP	auto	2018Q4	7 922	1,463088	12 085	18 730	64,5%	64,6%	12 093
948	Bayesian for Paid1		1/10	2	BUSP	auto	2018Q4	7 131	1,463088	10 878	18 730	58,1%	58,6%	10 985
1110	Bayesian for Paid1	120	1/10	3	BUSP	auto	2018Q4	6 864	1,463088	10 471	18 730	55,9%	56,8%	10 634
1272	Bayesian for Paid1		1/10	4	BUSP	auto	2018Q4	7 397	1,463088	11 285	18 730	60,3%	60,6%	11 347
765	Bayesian for Paid1	119	10/1	1	BUSP	auto	2018Q4	7 661	1,463088	11 688	18 730	62,4%	62,6%	11 717
947	Bayesian for Paid1		10/1	2	BUSP	auto	2018Q4	7 131	1,463088	10 878	18 730	58,1%	58,6%	10 985
1109	Bayesian for Paid1	119	10/1	3	BUSP	auto	2018Q4	6 864	1,463088	10 471	18 730	55,9%	56,8%	10 634
1271	Bayesian for Paid1		10/1	4	BUSP	auto	2018Q4	7 397	1,463088	11 285	18 730	60,3%	60,6%	11 347
775	Bayesian for Paid1	115	1/1	1	BUSP	auto	2019Q1	8 148	1,466444	12 460	17 887	69,7%	69,6%	12 445
955	Bayesian for Paid1		1/1	2	BUSP	auto	2019Q1	8 347	1,466444	12 764	17 887	71,4%	71,1%	12 719
1117	Bayesian for Paid1	115	1/1	3	BUSP	auto	2019Q1	7 993	1,466444	12 222	17 887	68,3%	68,4%	12 230
1279	Bayesian for Paid1		1/1	4	BUSP	auto	2019Q1	8 701	1,466444	13 306	17 887	74,4%	73,9%	13 210

Technical 1	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
687	Bayesian for Paid1	133	1/1	1	BUSP	auto	2017Q1	7 357	1,494398	11 475	16 343	70,2%	70,2%	11 475
883	Bayesian for Paid1	145	1/1	2	BUSP	auto	2017Q1	6 699	1,494398	10 449	16 343	63,9%	64,0%	10 452
1045	Bayesian for Paid1	133	1/1	3	BUSP	auto	2017Q1	6 432	1,494398	10 033	16 343	61,4%	61,6%	10 066
1207	Bayesian for Paid1	145	1/1	4	BUSP	auto	2017Q1	6 966	1,494398	10 865	16 343	66,5%	66,5%	10 865
689	Bayesian for Paid1	135	1/10	1	BUSP	auto	2017Q1	7 510	1,494398	11 714	16 343	71,7%	71,7%	11 714
885	Bayesian for Paid1	147	1/10	2	BUSP	auto	2017Q1	6 699	1,494398	10 449	16 343	63,9%	64,0%	10 452
1047	Bayesian for Paid1	135	1/10	3	BUSP	auto	2017Q1	6 432	1,494398	10 033	16 343	61,4%	61,6%	10 066
688	Bayesian for Paid1	134	10/1	1	BUSP	auto	2017Q1	7 264	1,494398	11 330	16 343	69,3%	69,3%	11 330
884	Bayesian for Paid1	146	10/1	2	BUSP	auto	2017Q1	6 699	1,494398	10 449	16 343	63,9%	64,0%	10 452
1046	Bayesian for Paid1	134	10/1	3	BUSP	auto	2017Q1	6 432	1,494398	10 033	16 343	61,4%	61,6%	10 066
1208	Bayesian for Paid1	146	10/1	4	BUSP	auto	2017Q1	6 966	1,494398	10 865	16 343	66,5%	66,5%	10 865
698	Bayesian for Paid1	133	1/1	1	BUSP	auto	2017Q2	7 189	1,49068	11 196	16 830	66,5%	66,8%	11 244
892	Bayesian for Paid1	142	1/1	2	BUSP	auto	2017Q2	6 760	1,49068	10 529	16 830	62,6%	63,6%	10 699
1054	Bayesian for Paid1	133	1/1	3	BUSP	auto	2017Q2	6 494	1,49068	10 114	16 830	60,1%	61,8%	10 397
1216	Bayesian for Paid1	142	1/1	4	BUSP	auto	2017Q2	7 027	1,49068	10 945	16 830	65,0%	65,5%	11 030
700	Bayesian for Paid1	135	1/10	1	BUSP	auto	2017Q2	7 621	1,49068	11 869	16 830	70,5%	70,5%	11 870
894	Bayesian for Paid1	144	1/10	2	BUSP	auto	2017Q2	7 294	1,49068	11 360	16 830	67,5%	67,7%	11 390
1056	Bayesian for Paid1	135	1/10	3	BUSP	auto	2017Q2	7 027	1,49068	10 945	16 830	65,0%	65,5%	11 030
1218	Bayesian for Paid1	144	1/10	4	BUSP	auto	2017Q2	7 561	1,49068	11 776	16 830	70,0%	70,0%	11 778
699	Bayesian for Paid1	134	10/1	1	BUSP	auto	2017Q2	6 830	1,49068	10 638	16 830	63,2%	64,1%	10 783
893	Bayesian for Paid1	143	10/1	2	BUSP	auto	2017Q2	6 760	1,49068	10 529	16 830	62,6%	63,6%	10 699
1055	Bayesian for Paid1	134	10/1	3	BUSP	auto	2017Q2	6 494	1,49068	10 114	16 830	60,1%	61,8%	10 397
1217	Bayesian for Paid1	143	10/1	4	BUSP	auto	2017Q2	7 027	1,49068	10 945	16 830	65,0%	65,5%	11 030
709	Bayesian for Paid1	130	1/1	1	BUSP	auto	2017Q3	7 745	1,474136	11 906	17 270	68,9%	70,4%	12 166
901	Bayesian for Paid1	139	1/1	2	BUSP	auto	2017Q3	8 685	1,474136	13 352	17 270	77,3%	77,4%	13 367
1063	Bayesian for Paid1	130	1/1	3	BUSP	auto	2017Q3	8 331	1,474136	12 808	17 270	74,2%	74,6%	12 879
1225	Bayesian for Paid1	139	1/1	4	BUSP	auto	2017Q3	9 040	1,474136	13 897	17 270	80,5%	80,5%	13 897
711	Bayesian for Paid1	132	1/10	1	BUSP	auto	2017Q3	7 739	1,474136	11 897	17 270	68,9%	70,4%	12 159
903	Bayesian for Paid1	141	1/10	2	BUSP	auto	2017Q3	8 685	1,474136	13 352	17 270	77,3%	77,4%	13 367
1065	Bayesian for Paid1	132	1/10	3	BUSP	auto	2017Q3	8 331	1,474136	12 808	17 270	74,2%	74,6%	12 879
1227	Bayesian for Paid1	141	1/10	4	BUSP	auto	2017Q3	9 040	1,474136	13 897	17 270	80,5%	80,5%	13 897
710	Bayesian for Paid1	131	10/1	1	BUSP	auto	2017Q3	7 722	1,474136	11 871	17 270	68,7%	70,3%	12 140
902	Bayesian for Paid1	140	10/1	2	BUSP	auto	2017Q3	6 822	1,474136	10 488	17 270	60,7%	65,3%	11 281
1064	Bayesian for Paid1	131	10/1	3	BUSP	auto	2017Q3	6 555	1,474136	10 078	17 270	58,4%	64,2%	11 080
1226	Bayesian for Paid1	140	10/1	4	BUSP	auto	2017Q3	7 089	1,474136	10 898	17 270	63,1%	66,6%	11 507
720	Bayesian for Paid1	127	1/1	1	BUSP	auto	2017Q4	7 459	1,492849	11 628	18 669	62,3%	62,4%	11 658
910	Bayesian for Paid1	139	1/1	2	BUSP	auto	2017Q4	6 884	1,492849	10 732	18 669	57,5%	58,5%	10 917
1072	Bayesian for Paid1	127	1/1	3	BUSP	auto	2017Q4	6 617	1,492849	10 316	18 669	55,3%	56,9%	10 617
1234	Bayesian for Paid1	139	1/1	4	BUSP	auto	2017Q4	7 151	1,492849	11 148	18 669	59,7%	60,2%	11 245
722	Bayesian for Paid1	129	1/10	1	BUSP	auto	2017Q4	7 735	1,492849	12 059	18 669	64,6%	64,6%	12 062
912	Bayesian for Paid1	141	1/10	2	BUSP	auto	2017Q4	8 038	1,492849	12 532	18 669	67,1%	67,1%	12 532
1074	Bayesian for Paid1	129	1/10	3	BUSP	auto	2017Q4	7 684	1,492849	11 980	18 669	64,2%	64,2%	11 985
1236	Bayesian for Paid1	141	1/10	4	BUSP	auto	2017Q4	8 393	1,492849	13 085	18 669	70,1%	70,1%	13 085
721	Bayesian for Paid1	128	10/1	1	BUSP	auto	2017Q4	7 061	1,492849	11 008	18 669	59,0%	59,6%	11 131
911	Bayesian for Paid1	140	10/1	2	BUSP	auto	2017Q4	6 884	1,492849	10 732	18 669	57,5%	58,5%	10 917
1073	Bayesian for Paid1	128	10/1	3	BUSP	auto	2017Q4	6 617	1,492849	10 316	18 669	55,3%	56,9%	10 617
1235	Bayesian for Paid1	140	10/1	4	BUSP	auto	2017Q4	7 151	1,492849	11 148	18 669	59,7%	60,2%	11 245
731	Bayesian for Paid1	124	1/1	1	BUSP	auto	2018Q1	7 738	1,494398	12 069	17 645	68,4%	68,4%	12 069
919	Bayesian for Paid1	136	1/1	2	BUSP	auto	2018Q1	7 479	1,494398	11 666	17 645	66,1%	66,1%	11 668
1081	Bayesian for Paid1	124	1/1	3	BUSP	auto	2018Q1	7 212	1,494398	11 250	17 645	63,8%	63,8%	11 265
1243	Bayesian for Paid1	136	1/1	4	BUSP	auto	2018Q1	7 746	1,494398	12 082	17 645	68,5%	68,5%	12 082
733	Bayesian for Paid1	126	1/10	1	BUSP	auto	2018Q1	7 756	1,494398	12 098	17 645	68,6%	68,6%	12 098
921	Bayesian for Paid1	138	1/10	2	BUSP	auto	2018Q1	7 479	1,494398	11 666	17 645	66,1%	66,1%	11 668
1083	Bayesian for Paid1	126	1/10	3	BUSP	auto	2018Q1	7 212	1,494398	11 250	17 645	63,8%	63,8%	11 265
1245	Bayesian for Paid1	138	1/10	4	BUSP	auto	2018Q1	7 746	1,494398	12 082	17 645	68,5%	68,5%	12 082
732	Bayesian for Paid1	125	10/1	1	BUSP	auto	2018Q1	7 563	1,494398	11 797	17 645	66,9%	66,9%	11 797
920	Bayesian for Paid1	137	10/1	2	BUSP	auto	2018Q1	7 479	1,494398	11 666	17 645	66,1%	66,1%	11 668
1082	Bayesian for Paid1	125	10/1	3	BUSP	auto	2018Q1	7 212	1,494398	11 250	17 645	63,8%	63,8%	11 265
1244	Bayesian for Paid1	137	10/1	4	BUSP	auto	2018Q1	7 746	1,494398	12 082	17 645	68,5%	68,5%	12 082
742	Bayesian for Paid1	124	1/1	1	BUSP	auto	2018Q2	7 716	1,49068	12 018	17 821	67,4%	67,7%	12 066
928	Bayesian for Paid1		1/1	2	BUSP	auto	2018Q2	8 162	1,49068	12 712	17 821	71,3%	71,4%	12 721
1090	Bayesian for Paid1	124	1/1	3	BUSP	auto	2018Q2	7 807	1,49068	12 160	17 821	68,2%	68,4%	12 197
1252	Bayesian for Paid1		1/1	4	BUSP	auto	2018Q2	8 516	1,49068	13 264	17 821	74,4%	74,4%	13 263
744	Bayesian for Paid1	126	1/10	1	BUSP	auto	2018Q2	7 842	1,49068	12 213	17 821	68,5%	68,7%	12 247
930	Bayesian for Paid1		1/10	2	BUSP	auto	2018Q2	8 162	1,49068	12 712	17 821	71,3%	71,4%	12 721
1092	Bayesian for Paid1	126	1/10	3	BUSP	auto	2018Q2	7 807	1,49068	12 160	17 821	68,2%	68,4%	12 197
1254	Bayesian for Paid1		1/10	4	BUSP	auto	2018Q2	8 516	1,49068	13 264	17 821	74,4%	74,4%	13 263
743	Bayesian for Paid1	125	10/1	1	BUSP	auto	2018Q2	7 587	1,49068	11 816	17 821	66,3%	66,7%	11 881
929	Bayesian for Paid1		10/1	2	BUSP	auto	2018Q2	7 007	1,49068	10 914	17 821	61,2%	62,2%	11 089
1091	Bayesian for Paid1	125	10/1	3	BUSP	auto	2018Q2	6 740	1,49068	10 498	17 821	58,9%	60,3%	10 743
1253	Bayesian for Paid1		10/1	4	BUSP	auto	2018Q2	7 274	1,49068	11 329	17 821	63,6%	64,2%	11 446
753	Bayesian for Paid1	121	1/1	1	BUSP	auto	2018Q3	7 911	1,474136	12 162	18 544	65,6%	67,3%	12 476
937	Bayesian for Paid1		1/1	2	BUSP	auto	2018Q3	7 602	1,474136	11 687	18 544	63,0%	65,3%	12 101
1099	Bayesian for Paid1	121	1/1	3	BUSP	auto	2018Q3	7 336	1,474136	11 277	18 544	60,8%	63,6%	11 789
1261	Bayesian for Paid1		1/1	4	BUSP	auto	2018Q3	7 869	1,474136	12 097	18 544	65,2%	67,0%	12 424
755	Bayesian for Paid1	123	1/10	1	BUSP	auto	2018Q3	7 936	1,474136	12 200	18 544	65,8%	67,4%	12 507
939	Bayesian for Paid1		1/10	2	BUSP	auto	2018Q3	7 069	1,474136	10 867	18 544	58,6%	62,0%	11 488
1101	Bayesian for Paid1	123	1/10	3	BUSP	auto	2018Q3	6 802	1,474136	10 457	18 544	56,4%	60,4%	11 200
1263	Bayesian for Paid1		1/10	4	BUSP	auto	2018Q3	7 336	1,474136	11 277	18 544	60,8%	63,6%	11 789
754	Bayesian for Paid1	122	10/1	1	BUSP	auto	2018Q3	7 954	1,474136	12 228	18 544	65,9%	67,6%	12 529
938	Bayesian for Paid1		10/1	2	BUSP	auto	2018Q3	8 223	1,474136	12 642	18 544	68,2%	69,4%	12 870
1100	Bayesian for Paid1	122	10/1	3	BUSP	auto	2018Q3	7 869	1,474136	12 097	18 544	65,2%	67,0%	12 424
1262	Bayesian for Paid1		10/1	4	BUSP	auto	2018Q3	8 578	1,474136	13 187	18 544	71,1%	71,9%	13 335
764	Bayesian for Paid1	118	1/1	1	BUSP	auto	2018Q4	7 766	1,463088	11 848	18 730	63,3%	63,4%	11 868
946	Bayesian for Paid1		1/1	2	BUSP	auto	2018Q4	7 131	1,463088	10 878	18 730	58,1%	58,6%	10 985
1108	Bayesian for Paid1	118	1/1	3	BUSP	auto	2018Q4	6 864	1,463088	10 471	18 730	55,9%	56,8%	10 634
1270	Bayesian for Paid1		1/1	4	BUSP	auto	2018Q4	7 397	1,463088	11 285	18 730	60,3%	60,6%	11 347
766	Bayesian for Paid1	120	1/10	1	BUSP	auto	2018Q4	7 922	1,463088	12 085	18 730	64,5%	64,6%	12 093
948	Bayesian for Paid1		1/10	2	BUSP	auto	2018Q4	7 131	1,463088	10 878	18 730	58,1%	58,6%	10 985
1110	Bayesian for Paid1	120	1/10	3	BUSP	auto	2018Q4	6 864	1,463088	10 471	18 730	55,9%	56,8%	10 634
1272	Bayesian for Paid1		1/10	4	BUSP	auto	2018Q4	7 397	1,463088	11 285	18 730	60,3%	60,6%	11 347
765	Bayesian for Paid1	119	10/1	1	BUSP	auto	2018Q4	7 661	1,463088	11 688	18 730	62,4%	62,6%	11 717
947	Bayesian for Paid1		10/1	2	BUSP	auto	2018Q4	7 131	1,463088	10 878	18 730	58,1%	58,6%	10 985
1109	Bayesian for Paid1	119	10/1	3	BUSP	auto	2018Q4	6 864	1,463088	10 471	18 730	55,9%	56,8%	10 634
1271	Bayesian for Paid1		10/1	4	BUSP	auto	2018Q4	7 397	1,463088	11 285	18 730	60,3%	60,6%	11 347
775	Bayesian for Paid1	115	1/1	1	BUSP	auto	2019Q1	8 148	1,466444	12 460	17 887	69,7%	69,6%	12 445
955	Bayesian for Paid1		1/1	2	BUSP	auto	2019Q1	8 347	1,466444	12 764	17 887	71,4%	71,1%	12 719
1117	Bayesian for Paid1	115	1/1	3	BUSP	auto	2019Q1	7 993	1,466444	12 222	17 887	68,3%	68,4%	12 230
1279	Bayesian for Paid1		1/1	4	BUSP	auto	2019Q1	8 701	1,466444	13 306	17 887	74,4%	73,9%	13 210

Technical I	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
777	Bayesian for Paid1	117	1/10	1	BUSP	auto	2019Q1	8 016	1,466444	12 257	17 887	68,5%	68,6%	12 262
957	Bayesian for Paid1		1/10	2	BUSP	auto	2019Q1	8 347	1,466444	12 764	17 887	71,4%	71,1%	12 719
1119	Bayesian for Paid1	117	1/10	3	BUSP	auto	2019Q1	7 993	1,466444	12 222	17 887	68,3%	68,4%	12 230
1281	Bayesian for Paid1		1/10	4	BUSP	auto	2019Q1	8 701	1,466444	13 306	17 887	74,4%	73,9%	13 210
776	Bayesian for Paid1	116	10/1	1	BUSP	auto	2019Q1	8 305	1,466444	12 699	17 887	71,0%	70,8%	12 661
956	Bayesian for Paid1		10/1	2	BUSP	auto	2019Q1	8 347	1,466444	12 764	17 887	71,4%	71,1%	12 719
1118	Bayesian for Paid1	116	10/1	3	BUSP	auto	2019Q1	7 993	1,466444	12 222	17 887	68,3%	68,4%	12 230
1280	Bayesian for Paid1		10/1	4	BUSP	auto	2019Q1	8 701	1,466444	13 306	17 887	74,4%	73,9%	13 210
690	Bayesian Network for F1	133	1/1	1	BUSP	auto	2017Q1	5 981	1,485745	9 265	16 343	56,7%	57,8%	9 439
886	Bayesian Network for F1	145	1/1	2	BUSP	auto	2017Q1	5 981	1,638842	10 220	16 343	62,5%	62,6%	10 236
1048	Bayesian Network for F1	133	1/1	3	BUSP	auto	2017Q1	5 981	1,580022	9 853	16 343	60,3%	60,6%	9 909
1210	Bayesian Network for F1	145	1/1	4	BUSP	auto	2017Q1	5 981	1,697663	10 587	16 343	64,8%	64,8%	10 587
692	Bayesian Network for F1	135	1/10	1	BUSP	auto	2017Q1	5 981	1,476943	9 210	16 343	56,4%	57,5%	9 399
888	Bayesian Network for F1	147	1/10	2	BUSP	auto	2017Q1	5 981	1,638842	10 220	16 343	62,5%	62,6%	10 236
1050	Bayesian Network for F1	135	1/10	3	BUSP	auto	2017Q1	5 981	1,580022	9 853	16 343	60,3%	60,6%	9 909
1212	Bayesian Network for F1	147	1/10	4	BUSP	auto	2017Q1	5 981	1,697663	10 587	16 343	64,8%	64,8%	10 587
691	Bayesian Network for F1	134	10/1	1	BUSP	auto	2017Q1	5 981	1,47905	9 224	16 343	56,4%	57,6%	9 409
887	Bayesian Network for F1	146	10/1	2	BUSP	auto	2017Q1	5 981	1,410841	8 798	16 343	53,8%	55,8%	9 112
1049	Bayesian Network for F1	134	10/1	3	BUSP	auto	2017Q1	5 981	1,359301	8 477	16 343	51,9%	54,5%	8 911
1211	Bayesian Network for F1	146	10/1	4	BUSP	auto	2017Q1	5 981	1,462381	9 120	16 343	55,8%	57,1%	9 333
701	Bayesian Network for F1	130	1/1	1	BUSP	auto	2017Q2	6 068	1,467618	9 285	16 830	55,2%	58,7%	9 880
895	Bayesian Network for F1	142	1/1	2	BUSP	auto	2017Q2	6 068	1,521202	9 624	16 830	57,2%	59,9%	10 078
1057	Bayesian Network for F1	130	1/1	3	BUSP	auto	2017Q2	6 068	1,462381	9 252	16 830	55,0%	58,6%	9 862
1219	Bayesian Network for F1	142	1/1	4	BUSP	auto	2017Q2	6 068	1,580022	9 997	16 830	59,4%	61,3%	10 317
703	Bayesian Network for F1	132	1/10	1	BUSP	auto	2017Q2	6 068	1,471091	9 307	16 830	55,3%	58,8%	9 893
897	Bayesian Network for F1	144	1/10	2	BUSP	auto	2017Q2	6 068	1,521202	9 624	16 830	57,2%	59,9%	10 078
1059	Bayesian Network for F1	132	1/10	3	BUSP	auto	2017Q2	6 068	1,462381	9 252	16 830	55,0%	58,6%	9 862
1221	Bayesian Network for F1	144	1/10	4	BUSP	auto	2017Q2	6 068	1,580022	9 997	16 830	59,4%	61,3%	10 317
702	Bayesian Network for F1	131	10/1	1	BUSP	auto	2017Q2	6 068	1,469311	9 296	16 830	55,2%	58,7%	9 886
896	Bayesian Network for F1	143	10/1	2	BUSP	auto	2017Q2	6 068	1,521202	9 624	16 830	57,2%	59,9%	10 078
1058	Bayesian Network for F1	131	10/1	3	BUSP	auto	2017Q2	6 068	1,462381	9 252	16 830	55,0%	58,6%	9 862
1220	Bayesian Network for F1	143	10/1	4	BUSP	auto	2017Q2	6 068	1,580022	9 997	16 830	59,4%	61,3%	10 317
712	Bayesian Network for F1	130	1/1	1	BUSP	auto	2017Q3	7 531	1,462336	11 483	17 270	66,5%	68,7%	11 871
904	Bayesian Network for F1	139	1/1	2	BUSP	auto	2017Q3	7 531	1,521202	11 945	17 270	69,2%	70,6%	12 194
1066	Bayesian Network for F1	130	1/1	3	BUSP	auto	2017Q3	7 531	1,462381	11 483	17 270	66,5%	68,7%	11 871
1228	Bayesian Network for F1	139	1/1	4	BUSP	auto	2017Q3	7 531	1,580022	12 407	17 270	71,8%	72,7%	12 547
714	Bayesian Network for F1	132	1/10	1	BUSP	auto	2017Q3	7 531	1,468953	11 535	17 270	66,8%	68,9%	11 906
906	Bayesian Network for F1	141	1/10	2	BUSP	auto	2017Q3	7 531	1,30776	10 269	17 270	59,5%	64,7%	11 170
1068	Bayesian Network for F1	132	1/10	3	BUSP	auto	2017Q3	7 531	1,25622	9 864	17 270	57,1%	63,6%	10 984
1230	Bayesian Network for F1	141	1/10	4	BUSP	auto	2017Q3	7 531	1,359301	10 674	17 270	61,8%	65,9%	11 380
713	Bayesian Network for F1	131	10/1	1	BUSP	auto	2017Q3	7 531	1,474474	11 578	17 270	67,0%	69,1%	11 935
905	Bayesian Network for F1	140	10/1	2	BUSP	auto	2017Q3	7 531	1,521202	11 945	17 270	69,2%	70,6%	12 194
1067	Bayesian Network for F1	131	10/1	3	BUSP	auto	2017Q3	7 531	1,462381	11 483	17 270	66,5%	68,7%	11 871
1229	Bayesian Network for F1	140	10/1	4	BUSP	auto	2017Q3	7 531	1,580022	12 407	17 270	71,8%	72,7%	12 547
723	Bayesian Network for F1	127	1/1	1	BUSP	auto	2017Q4	6 642	1,476077	10 223	18 669	54,8%	56,5%	10 554
913	Bayesian Network for F1	136	1/1	2	BUSP	auto	2017Q4	6 642	1,638842	11 351	18 669	60,8%	61,1%	11 415
1075	Bayesian Network for F1	127	1/1	3	BUSP	auto	2017Q4	6 642	1,580022	10 943	18 669	58,6%	59,4%	11 080
1237	Bayesian Network for F1	136	1/1	4	BUSP	auto	2017Q4	6 642	1,697663	11 758	18 669	63,0%	63,1%	11 777
725	Bayesian Network for F1	129	1/10	1	BUSP	auto	2017Q4	6 642	1,471325	10 191	18 669	54,6%	56,4%	10 532
915	Bayesian Network for F1	138	1/10	2	BUSP	auto	2017Q4	6 642	1,521202	10 536	18 669	56,4%	57,7%	10 772
1077	Bayesian Network for F1	129	1/10	3	BUSP	auto	2017Q4	6 642	1,462381	10 129	18 669	54,3%	56,2%	10 491
1239	Bayesian Network for F1	138	1/10	4	BUSP	auto	2017Q4	6 642	1,580022	10 943	18 669	58,6%	59,4%	11 080
724	Bayesian Network for F1	128	10/1	1	BUSP	auto	2017Q4	6 642	1,470294	10 183	18 669	54,5%	56,4%	10 527
914	Bayesian Network for F1	137	10/1	2	BUSP	auto	2017Q4	6 642	1,521202	10 536	18 669	56,4%	57,7%	10 772
1076	Bayesian Network for F1	128	10/1	3	BUSP	auto	2017Q4	6 642	1,462381	10 129	18 669	54,3%	56,2%	10 491
1238	Bayesian Network for F1	137	10/1	4	BUSP	auto	2017Q4	6 642	1,580022	10 943	18 669	58,6%	59,4%	11 080
734	Bayesian Network for F1	124	1/1	1	BUSP	auto	2018Q1	7 984	1,475384	12 283	17 645	69,6%	69,6%	12 283
922	Bayesian Network for F1	136	1/1	2	BUSP	auto	2018Q1	7 984	1,521202	12 664	17 645	71,8%	71,8%	12 664
1084	Bayesian Network for F1	124	1/1	3	BUSP	auto	2018Q1	7 984	1,462381	12 174	17 645	69,0%	69,0%	12 174
1246	Bayesian Network for F1	136	1/1	4	BUSP	auto	2018Q1	7 984	1,580022	13 154	17 645	74,5%	74,5%	13 154
736	Bayesian Network for F1	126	1/10	1	BUSP	auto	2018Q1	7 984	1,465617	12 201	17 645	69,1%	69,1%	12 201
924	Bayesian Network for F1	138	1/10	2	BUSP	auto	2018Q1	7 984	1,410841	11 745	17 645	66,6%	66,6%	11 746
1086	Bayesian Network for F1	126	1/10	3	BUSP	auto	2018Q1	7 984	1,359301	11 316	17 645	64,1%	64,2%	11 328
1248	Bayesian Network for F1	138	1/10	4	BUSP	auto	2018Q1	7 984	1,462381	12 174	17 645	69,0%	69,0%	12 174
735	Bayesian Network for F1	125	10/1	1	BUSP	auto	2018Q1	7 984	1,462718	12 177	17 645	69,0%	69,0%	12 177
923	Bayesian Network for F1	137	10/1	2	BUSP	auto	2018Q1	7 984	1,410841	11 745	17 645	66,6%	66,6%	11 746
1085	Bayesian Network for F1	125	10/1	3	BUSP	auto	2018Q1	7 984	1,359301	11 316	17 645	64,1%	64,2%	11 328
1247	Bayesian Network for F1	137	10/1	4	BUSP	auto	2018Q1	7 984	1,462381	12 174	17 645	69,0%	69,0%	12 174
745	Bayesian Network for F1	121	1/1	1	BUSP	auto	2018Q2	8 749	1,469116	13 402	17 821	75,2%	75,2%	13 402
931	Bayesian Network for F1		1/1	2	BUSP	auto	2018Q2	8 749	1,521202	13 878	17 821	77,9%	77,9%	13 878
1093	Bayesian Network for F1	121	1/1	3	BUSP	auto	2018Q2	8 749	1,462381	13 341	17 821	74,9%	74,9%	13 341
1255	Bayesian Network for F1		1/1	4	BUSP	auto	2018Q2	8 749	1,580022	14 414	17 821	80,9%	80,9%	14 414
747	Bayesian Network for F1	123	1/10	1	BUSP	auto	2018Q2	8 749	1,465596	13 370	17 821	75,0%	75,0%	13 370
933	Bayesian Network for F1		1/10	2	BUSP	auto	2018Q2	8 749	1,30776	11 930	17 821	66,9%	67,3%	11 985
1095	Bayesian Network for F1	123	1/10	3	BUSP	auto	2018Q2	8 749	1,25622	11 460	17 821	64,3%	64,9%	11 562
1257	Bayesian Network for F1		1/10	4	BUSP	auto	2018Q2	8 749	1,359301	12 401	17 821	69,6%	69,7%	12 423
746	Bayesian Network for F1	122	10/1	1	BUSP	auto	2018Q2	8 749	1,47231	13 432	17 821	75,4%	75,4%	13 432
932	Bayesian Network for F1		10/1	2	BUSP	auto	2018Q2	8 749	1,521202	13 878	17 821	77,9%	77,9%	13 878
1094	Bayesian Network for F1	122	10/1	3	BUSP	auto	2018Q2	8 749	1,462381	13 341	17 821	74,9%	74,9%	13 341
1256	Bayesian Network for F1		10/1	4	BUSP	auto	2018Q2	8 749	1,580022	14 414	17 821	80,9%	80,9%	14 414
756	Bayesian Network for F1	121	1/1	1	BUSP	auto	2018Q3	10 154	1,482592	15 697	18 544	84,6%	84,6%	15 696
940	Bayesian Network for F1		1/1	2	BUSP	auto	2018Q3	10 154	1,638842	17 351	18 544	93,6%	93,6%	17 351
1102	Bayesian Network for F1	121	1/1	3	BUSP	auto	2018Q3	10 154	1,580022	16 729	18 544	90,2%	90,2%	16 729
1264	Bayesian Network for F1		1/1	4	BUSP	auto	2018Q3	10 154	1,697663	17 974	18 544	96,9%	96,9%	17 974
758	Bayesian Network for F1	123	1/10	1	BUSP	auto	2018Q3	10 154	1,469705	15 561	18 544	83,9%	83,9%	15 560
942	Bayesian Network for F1		1/10	2	BUSP	auto	2018Q3	10 154	1,410841	14 937	18 544	80,6%	80,6%	14 946
1104	Bayesian Network for F1	123	1/10	3	BUSP	auto	2018Q3	10 154	1,359301	14 392	18 544	77,6%	77,8%	14 426
1266	Bayesian Network for F1		1/10	4	BUSP	auto	2018Q3	10 154	1,462381	15 483	18 544	83,5%	83,5%	15 482
757	Bayesian Network for F1	122	10/1	1	BUSP	auto	2018Q3	10 154	1,47605	15 628	18 544	84,3%	84,3%	15 627
941	Bayesian Network for F1		10/1	2	BUSP	auto	2018Q3	10 154	1,521202	16 106	18 544	86,9%	86,9%	16 106
1103	Bayesian Network for F1	122	10/1	3	BUSP	auto	2018Q3	10 154	1,462381	15 483	18 544	83,5%	83,5%	15 482
1265	Bayesian Network for F1		10/1	4	BUSP	auto	2018Q3	10 154	1,580022	16 729	18 544	90,2%	90,2%	16 729
767	Bayesian Network for F1	118	1/1	1	BUSP	auto	2018Q4	8 589	1,467603	13 144	18 730	70,2%	70,2%	13 143
949	Bayesian Network for F1		1/1	2	BUSP	auto	2018Q4	8 589	1,521202	13 624	18 730	72,7%	72,7%	13 624
1111	Bayesian Network for F1	118	1/1	3	BUSP	auto	2018Q4	8 589	1,462381	13 097	18 730	69,9%	69,9%	13 095
1273	Bayesian Network for F1		1/1	4	BUSP	auto	2018Q4	8 589	1,580022	14 151	18 730	75,6%	75,6%	14 151
769	Bayesian Network for F1	120	1/10	1	BUSP	auto	2018Q4	8 589	1,463703	13 109	18 730	70,0%	70,0%	13 107
951	Bayesian Network for F1		1/10	2	BUSP	auto	2018Q4	8 589	1,410841	12 635	18 730	67,5%	67,4%	12 630
1113	Bayesian Network for F1	120	1/10	3	BUSP	auto	2018Q4	8 589	1,359301	12 174	18 730	65,0%	65,0%	12 179
1275	Bayesian Network for F1		1/10	4	BUSP	auto	2018Q4	8 589	1,462381	13 097	18 730	69,9%	69,9%	13 095

Technical I	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
768	Bayesian Network for F1	119	10/1	1	BUSP	auto	2018Q4	8 589	1,467147	13 140	18 730	70,2%	70,1%	13 139
950	Bayesian Network for F1		10/1	2	BUSP	auto	2018Q4	8 589	1,521202	13 624	18 730	72,7%	72,7%	13 624
1112	Bayesian Network for F1	119	10/1	3	BUSP	auto	2018Q4	8 589	1,462381	13 097	18 730	69,9%	69,9%	13 095
1274	Bayesian Network for F1		10/1	4	BUSP	auto	2018Q4	8 589	1,580022	14 151	18 730	75,6%	75,6%	14 151
778	Bayesian Network for F1		1/1	1	BUSP	auto	2019Q1							
958	Bayesian Network for F1		1/1	2	BUSP	auto	2019Q1							
1120	Bayesian Network for F1	115	1/1	3	BUSP	auto	2019Q1							
1282	Bayesian Network for F1		1/1	4	BUSP	auto	2019Q1							
780	Bayesian Network for F1	117	1/10	1	BUSP	auto	2019Q1							
960	Bayesian Network for F1		1/10	2	BUSP	auto	2019Q1							
1122	Bayesian Network for F1	117	1/10	3	BUSP	auto	2019Q1							
1284	Bayesian Network for F1		1/10	4	BUSP	auto	2019Q1							
779	Bayesian Network for F1	116	10/1	1	BUSP	auto	2019Q1							
959	Bayesian Network for F1		10/1	2	BUSP	auto	2019Q1							
1121	Bayesian Network for F1	116	10/1	3	BUSP	auto	2019Q1							
1283	Bayesian Network for F1		10/1	4	BUSP	auto	2019Q1							
693	Bayesian Network for mix (Paid1+F1)	-117	1/1	1	BUSP	auto	2017Q1	7 357	1,485745	11 397	16 343	69,7%	69,7%	11 397
889	Bayesian Network for mix (Paid1+F1)	116-	1/1	2	BUSP	auto	2017Q1	6 699	1,638842	11 447	16 343	70,0%	70,0%	11 447
1051	Bayesian Network for mix (Paid1+F1)	-116	1/1	3	BUSP	auto	2017Q1	6 432	1,580022	10 597	16 343	64,8%	64,8%	10 597
1213	Bayesian Network for mix (Paid1+F1)	133-	1/1	4	BUSP	auto	2017Q1	6 966	1,697663	12 330	16 343	75,4%	75,4%	12 330
695	Bayesian Network for mix (Paid1+F1)	142-116	1/10	1	BUSP	auto	2017Q1	7 510	1,476943	11 565	16 343	70,8%	70,8%	11 565
891	Bayesian Network for mix (Paid1+F1)	133-	1/10	2	BUSP	auto	2017Q1	6 699	1,638842	11 447	16 343	70,0%	70,0%	11 447
1053	Bayesian Network for mix (Paid1+F1)	142-133	1/10	3	BUSP	auto	2017Q1	6 432	1,580022	10 597	16 343	64,8%	64,8%	10 597
1215	Bayesian Network for mix (Paid1+F1)	135-142	1/10	4	BUSP	auto	2017Q1	6 966	1,697663	12 330	16 343	75,4%	75,4%	12 330
694	Bayesian Network for mix (Paid1+F1)	144-133	10/1	1	BUSP	auto	2017Q1	7 264	1,47905	11 202	16 343	68,5%	68,5%	11 202
890	Bayesian Network for mix (Paid1+F1)	135-142	10/1	2	BUSP	auto	2017Q1	6 699	1,410841	9 855	16 343	60,3%	60,6%	9 911
1052	Bayesian Network for mix (Paid1+F1)	144-135	10/1	3	BUSP	auto	2017Q1	6 432	1,359301	9 117	16 343	55,8%	57,1%	9 331
1214	Bayesian Network for mix (Paid1+F1)	134-144	10/1	4	BUSP	auto	2017Q1	6 966	1,462381	10 621	16 343	65,0%	65,0%	10 621
704	Bayesian Network for mix (Paid1+F1)	143-135	1/1	1	BUSP	auto	2017Q2	7 189	1,467618	11 001	16 830	65,4%	65,8%	11 077
898	Bayesian Network for mix (Paid1+F1)	134-144	1/1	2	BUSP	auto	2017Q2	6 760	1,521202	10 723	16 830	63,7%	64,5%	10 850
1060	Bayesian Network for mix (Paid1+F1)	143-134	1/1	3	BUSP	auto	2017Q2	6 494	1,462381	9 902	16 830	58,8%	60,9%	10 254
1222	Bayesian Network for mix (Paid1+F1)	130-143	1/1	4	BUSP	auto	2017Q2	7 027	1,580022	11 577	16 830	68,8%	68,9%	11 589
706	Bayesian Network for mix (Paid1+F1)	142-134	1/10	1	BUSP	auto	2017Q2	7 621	1,471091	11 690	16 830	69,5%	69,5%	11 696
900	Bayesian Network for mix (Paid1+F1)	130-143	1/10	2	BUSP	auto	2017Q2	7 294	1,521202	11 570	16 830	68,7%	68,8%	11 582
1062	Bayesian Network for mix (Paid1+F1)	142-130	1/10	3	BUSP	auto	2017Q2	7 027	1,462381	10 715	16 830	63,7%	64,4%	10 844
1224	Bayesian Network for mix (Paid1+F1)	132-142	1/10	4	BUSP	auto	2017Q2	7 561	1,580022	12 456	16 830	74,0%	74,0%	12 456
705	Bayesian Network for mix (Paid1+F1)	144-130	10/1	1	BUSP	auto	2017Q2	6 830	1,469311	10 464	16 830	62,2%	63,3%	10 650
899	Bayesian Network for mix (Paid1+F1)	132-142	10/1	2	BUSP	auto	2017Q2	6 760	1,521202	10 723	16 830	63,7%	64,5%	10 850
1061	Bayesian Network for mix (Paid1+F1)	144-132	10/1	3	BUSP	auto	2017Q2	6 494	1,462381	9 902	16 830	58,8%	60,9%	10 254
1223	Bayesian Network for mix (Paid1+F1)	131-144	10/1	4	BUSP	auto	2017Q2	7 027	1,580022	11 577	16 830	68,8%	68,9%	11 589
715	Bayesian Network for mix (Paid1+F1)	143-132	1/1	1	BUSP	auto	2017Q3	7 745	1,462336	11 810	17 270	68,4%	70,0%	12 096
907	Bayesian Network for mix (Paid1+F1)	131-144	1/1	2	BUSP	auto	2017Q3	8 685	1,521202	13 777	17 270	79,8%	79,8%	13 777
1069	Bayesian Network for mix (Paid1+F1)	143-131	1/1	3	BUSP	auto	2017Q3	8 331	1,462381	12 704	17 270	73,6%	74,1%	12 790
1231	Bayesian Network for mix (Paid1+F1)	127-143	1/1	4	BUSP	auto	2017Q3	9 040	1,580022	14 893	17 270	86,2%	86,2%	14 893
717	Bayesian Network for mix (Paid1+F1)	139-131	1/10	1	BUSP	auto	2017Q3	7 739	1,468953	11 853	17 270	68,6%	70,2%	12 127
909	Bayesian Network for mix (Paid1+F1)	127-143	1/10	2	BUSP	auto	2017Q3	8 685	1,30776	11 844	17 270	68,6%	70,2%	12 120
1071	Bayesian Network for mix (Paid1+F1)	139-127	1/10	3	BUSP	auto	2017Q3	8 331	1,25622	10 913	17 270	63,2%	66,7%	11 515
1233	Bayesian Network for mix (Paid1+F1)	129-139	1/10	4	BUSP	auto	2017Q3	9 040	1,359301	12 813	17 270	74,2%	74,6%	12 883
716	Bayesian Network for mix (Paid1+F1)	141-127	10/1	1	BUSP	auto	2017Q3	7 722	1,474474	11 872	17 270	68,7%	70,3%	12 141
908	Bayesian Network for mix (Paid1+F1)	129-139	10/1	2	BUSP	auto	2017Q3	6 822	1,521202	10 821	17 270	62,7%	66,4%	11 463
1070	Bayesian Network for mix (Paid1+F1)	141-129	10/1	3	BUSP	auto	2017Q3	6 555	1,462381	9 996	17 270	57,9%	63,9%	11 042
1232	Bayesian Network for mix (Paid1+F1)	128-141	10/1	4	BUSP	auto	2017Q3	7 089	1,580022	11 679	17 270	67,6%	69,5%	12 004
726	Bayesian Network for mix (Paid1+F1)	140-129	1/1	1	BUSP	auto	2017Q4	7 459	1,476077	11 480	18 669	61,5%	61,7%	11 527
916	Bayesian Network for mix (Paid1+F1)	128-141	1/1	2	BUSP	auto	2017Q4	6 884	1,638842	11 763	18 669	63,0%	63,1%	11 782
1078	Bayesian Network for mix (Paid1+F1)	140-128	1/1	3	BUSP	auto	2017Q4	6 617	1,580022	10 902	18 669	58,4%	59,2%	11 047
1240	Bayesian Network for mix (Paid1+F1)	127-140	1/1	4	BUSP	auto	2017Q4	7 151	1,697663	12 658	18 669	67,8%	67,8%	12 658
728	Bayesian Network for mix (Paid1+F1)	136-128	1/10	1	BUSP	auto	2017Q4	7 735	1,471325	11 867	18 669	63,6%	63,6%	11 878
918	Bayesian Network for mix (Paid1+F1)	127-140	1/10	2	BUSP	auto	2017Q4	8 038	1,521202	12 750	18 669	68,3%	68,3%	12 750
1080	Bayesian Network for mix (Paid1+F1)	136-127	1/10	3	BUSP	auto	2017Q4	7 684	1,462381	11 717	18 669	62,8%	62,9%	11 739
1242	Bayesian Network for mix (Paid1+F1)	129-136	1/10	4	BUSP	auto	2017Q4	8 393	1,580022	13 827	18 669	74,1%	74,1%	13 827
727	Bayesian Network for mix (Paid1+F1)	138-127	10/1	1	BUSP	auto	2017Q4	7 061	1,470294	10 825	18 669	58,0%	58,9%	10 988
917	Bayesian Network for mix (Paid1+F1)	129-136	10/1	2	BUSP	auto	2017Q4	6 884	1,521202	10 919	18 669	58,5%	59,2%	11 061
1079	Bayesian Network for mix (Paid1+F1)	138-129	10/1	3	BUSP	auto	2017Q4	6 617	1,462381	10 090	18 669	54,0%	56,1%	10 466
1241	Bayesian Network for mix (Paid1+F1)	128-138	10/1	4	BUSP	auto	2017Q4	7 151	1,580022	11 781	18 669	63,1%	63,2%	11 798
737	Bayesian Network for mix (Paid1+F1)	137-129	1/1	1	BUSP	auto	2018Q1	7 738	1,475384	11 904	17 645	67,5%	67,5%	11 904
925	Bayesian Network for mix (Paid1+F1)	128-138	1/1	2	BUSP	auto	2018Q1	7 479	1,521202	11 863	17 645	67,2%	67,2%	11 863
1087	Bayesian Network for mix (Paid1+F1)	137-128	1/1	3	BUSP	auto	2018Q1	7 212	1,462381	10 998	17 645	62,3%	62,5%	11 026
1249	Bayesian Network for mix (Paid1+F1)	124-137	1/1	4	BUSP	auto	2018Q1	7 746	1,580022	12 761	17 645	72,3%	72,3%	12 761
739	Bayesian Network for mix (Paid1+F1)	-128	1/10	1	BUSP	auto	2018Q1	7 756	1,465617	11 854	17 645	67,2%	67,2%	11 854
927	Bayesian Network for mix (Paid1+F1)	124-137	1/10	2	BUSP	auto	2018Q1	7 479	1,410841	11 002	17 645	62,4%	62,5%	11 031
1089	Bayesian Network for mix (Paid1+F1)	-124	1/10	3	BUSP	auto	2018Q1	7 212	1,359301	10 222	17 645	57,9%	58,5%	10 323
1251	Bayesian Network for mix (Paid1+F1)	126-	1/10	4	BUSP	auto	2018Q1	7 746	1,462381	11 811	17 645	66,9%	66,9%	11 811
738	Bayesian Network for mix (Paid1+F1)	-124	10/1	1	BUSP	auto	2018Q1	7 563	1,462718	11 535	17 645	65,4%	65,4%	11 540
926	Bayesian Network for mix (Paid1+F1)	126-	10/1	2	BUSP	auto	2018Q1	7 479	1,410841	11 002	17 645	62,4%	62,5%	11 031
1088	Bayesian Network for mix (Paid1+F1)	-126	10/1	3	BUSP	auto	2018Q1	7 212	1,359301	10 222	17 645	57,9%	58,5%	10 323
1250	Bayesian Network for mix (Paid1+F1)	125-	10/1	4	BUSP	auto	2018Q1	7 746	1,462381	11 811	17 645	66,9%	66,9%	11 811
748	Bayesian Network for mix (Paid1+F1)	-126	1/1	1	BUSP	auto	2018Q2	7 716	1,469116	11 820	17 821	66,3%	66,7%	11 885
934	Bayesian Network for mix (Paid1+F1)	125-	1/1	2	BUSP	auto	2018Q2	8 162	1,521202	12 946	17 821	72,6%	72,7%	12 949
1096	Bayesian Network for mix (Paid1+F1)	-125	1/1	3	BUSP	auto	2018Q2	7 807	1,462381	11 905	17 821	66,8%	67,1%	11 962
1258	Bayesian Network for mix (Paid1+F1)	121-	1/1	4	BUSP	auto	2018Q2	8 516	1,580022	14 030	17 821	78,7%	78,7%	14 030
750	Bayesian Network for mix (Paid1+F1)	-125	1/10	1	BUSP	auto	2018Q2	7 842	1,465596	11 984	17 821	67,2%	67,5%	12 034
936	Bayesian Network for mix (Paid1+F1)	121-	1/10	2	BUSP	auto	2018Q2	8 162	1,30776	11 130	17 821	62,5%	63,3%	11 273
1098	Bayesian Network for mix (Paid1+F1)	-121	1/10	3	BUSP	auto	2018Q2	7 807	1,25622	10 227	17 821	57,4%	59,1%	10 525
1260	Bayesian Network for mix (Paid1+F1)	123-	1/10	4	BUSP	auto	2018Q2	8 516	1,359301	12 070	17 821	67,7%	68,0%	12 114
749	Bayesian Network for mix (Paid1+F1)	-121	10/1	1	BUSP	auto	2018Q2	7 587	1,47231	11 648	17 821	65,4%	65,8%	11 729
935	Bayesian Network for mix (Paid1+F1)	123-	10/1	2	BUSP	auto	2018Q2	7 007	1,521202	11 115	17 821	62,4%	63,2%	11 260
1097	Bayesian Network for mix (Paid1+F1)	-123	10/1	3	BUSP	auto	2018Q2	6 740	1,462381	10 278	17 821	57,7%	59,3%	10 566
1259	Bayesian Network for mix (Paid1+F1)	122-	10/1	4	BUSP	auto	2018Q2	7 274	1,580022	11 984	17 821	67,2%	67,5%	12 034
759	Bayesian Network for mix (Paid1+F1)	-123	1/1	1	BUSP	auto	2018Q3	7 911	1,482592	12 231	18 544	66,0%	67,6%	12 532
943	Bayesian Network for mix (Paid1+F1)	122-	1/1	2	BUSP	auto	2018Q3	7 602	1,638842	12 991	18 544	70,1%	71,0%	13 167
1105	Bayesian Network for mix (Paid1+F1)	-122	1/1	3	BUSP	auto	2018Q3	7 336	1,580022	12 086	18 544	65,2%	67,0%	12 415
1267	Bayesian Network for mix (Paid1+F1)	118-	1/1	4	BUSP	auto	2018Q3	7 869	1,697663	13 930	18 544	75,1%	75,5%	13 998
761	Bayesian Network for mix (Paid1+F1)	-122	1/10	1	BUSP	auto	2018Q3	7 936	1,469705	12 162	18 544	65,6%	67,3%	12 476
945	Bayesian Network for mix (Paid1+F1)	118-	1/10	2	BUSP	auto	2018Q3	7 069	1,410841	10 399	18 544	56,1%	60,2%	11 161
1107	Bayesian Network for mix (Paid1+F1)	-118	1/10	3	BUSP	auto	2018Q3	6 802	1,359301	9 641	18 544	52,0%	57,5%	10 665
1269	Bayesian Network for mix (Paid1+F1)	120-	1/10	4	BUSP	auto	2018Q3	7 336	1,462381	11 186	18 544	60,3%	63,2%	11 721
760	Bayesian Network for mix (Paid1+F1)	-118	10/1	1	BUSP	auto	2018Q3	7 954	1,47605	12 242	18 544	66,0%	67,6%	12 541
944	Bayesian Network for mix (Paid1+F1)	120-	10/1	2	BUSP	auto	2018Q3	8 223	1,521202	13 044	18 544	70,3%	71,2%	13 212
1106	Bayesian Network for mix (Paid1+F1)	-120	10/1	3	BUSP	auto	2018Q3	7 869	1,462381	11 999	18 544	64,7%	66,6%	12 346
1268	Bayesian Network for mix (Paid1+F1)	119-	10/1	4	BUSP	auto	2018Q3	8 578	1,580022	14 132	18 544	76,2%	76,5%	14 184

Technical I	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
770	Bayesian Network for mix (Paid1+F1)	-120	1/1	1	BUSP	auto	2018Q4	7 766	1,467603	11 885	18 730	63,5%	63,5%	11 902
952	Bayesian Network for mix (Paid1+F1)	119-	1/1	2	BUSP	auto	2018Q4	7 131	1,521202	11 310	18 730	60,4%	60,7%	11 370
1114	Bayesian Network for mix (Paid1+F1)	-119	1/1	3	BUSP	auto	2018Q4	6 864	1,462381	10 466	18 730	55,9%	56,8%	10 630
1276	Bayesian Network for mix (Paid1+F1)	118-	1/1	4	BUSP	auto	2018Q4	7 397	1,580022	12 187	18 730	65,1%	65,1%	12 191
772	Bayesian Network for mix (Paid1+F1)	-119	1/10	1	BUSP	auto	2018Q4	7 922	1,463703	12 090	18 730	64,6%	64,6%	12 098
954	Bayesian Network for mix (Paid1+F1)	118-	1/10	2	BUSP	auto	2018Q4	7 131	1,410841	10 490	18 730	56,0%	56,9%	10 650
1116	Bayesian Network for mix (Paid1+F1)	-118	1/10	3	BUSP	auto	2018Q4	6 864	1,359301	9 729	18 730	51,9%	53,5%	10 026
1278	Bayesian Network for mix (Paid1+F1)	120-	1/10	4	BUSP	auto	2018Q4	7 397	1,462381	11 280	18 730	60,2%	60,6%	11 342
771	Bayesian Network for mix (Paid1+F1)	-118	10/1	1	BUSP	auto	2018Q4	7 661	1,467147	11 720	18 730	62,6%	62,7%	11 748
953	Bayesian Network for mix (Paid1+F1)	120-	10/1	2	BUSP	auto	2018Q4	7 131	1,521202	11 310	18 730	60,4%	60,7%	11 370
1115	Bayesian Network for mix (Paid1+F1)	-120	10/1	3	BUSP	auto	2018Q4	6 864	1,462381	10 466	18 730	55,9%	56,8%	10 630
1277	Bayesian Network for mix (Paid1+F1)	119-	10/1	4	BUSP	auto	2018Q4	7 397	1,580022	12 187	18 730	65,1%	65,1%	12 191
781	Bayesian Network for mix (Paid1+F1)	-120	1/1	1	BUSP	auto	2019Q1							
961	Bayesian Network for mix (Paid1+F1)	119-	1/1	2	BUSP	auto	2019Q1							
1123	Bayesian Network for mix (Paid1+F1)	-119	1/1	3	BUSP	auto	2019Q1							
1285	Bayesian Network for mix (Paid1+F1)	x	1/1	4	BUSP	auto	2019Q1							
783	Bayesian Network for mix (Paid1+F1)	-119	1/10	1	BUSP	auto	2019Q1							
963	Bayesian Network for mix (Paid1+F1)	115-	1/10	2	BUSP	auto	2019Q1							
1125	Bayesian Network for mix (Paid1+F1)	-115	1/10	3	BUSP	auto	2019Q1							
1287	Bayesian Network for mix (Paid1+F1)		1/10	4	BUSP	auto	2019Q1							
782	Bayesian Network for mix (Paid1+F1)	-115	10/1	1	BUSP	auto	2019Q1							
962	Bayesian Network for mix (Paid1+F1)	117-	10/1	2	BUSP	auto	2019Q1							
1124	Bayesian Network for mix (Paid1+F1)	-117	10/1	3	BUSP	auto	2019Q1							
1286	Bayesian Network for mix (Paid1+F1)		10/1	4	BUSP	auto	2019Q1							
786	Bayesian for Paid1	166	1/1	1	BUSP	travel	2017Q1	211	2,556306	748	3 627	20,6%	21,4%	778
964	Bayesian for Paid1		1/1	2	BUSP	travel	2017Q1	201	2,556306	709	3 627	19,6%	20,8%	755
1126	Bayesian for Paid1	166	1/1	3	BUSP	travel	2017Q1	214	2,556306	757	3 627	20,9%	21,6%	784
1288	Bayesian for Paid1		1/1	4	BUSP	travel	2017Q1	187	2,556306	662	3 627	18,2%	20,1%	731
788	Bayesian for Paid1	168	1/10	1	BUSP	travel	2017Q1	213	2,556306	752	3 627	20,7%	21,5%	781
966	Bayesian for Paid1		1/10	2	BUSP	travel	2017Q1	229	2,556306	808	3 627	22,3%	22,6%	820
1128	Bayesian for Paid1	168	1/10	3	BUSP	travel	2017Q1	243	2,556306	859	3 627	23,7%	23,8%	863
1290	Bayesian for Paid1		1/10	4	BUSP	travel	2017Q1	214	2,556306	757	3 627	20,9%	21,6%	784
787	Bayesian for Paid1	167	10/1	1	BUSP	travel	2017Q1	213	2,556306	752	3 627	20,7%	21,5%	780
965	Bayesian for Paid1		10/1	2	BUSP	travel	2017Q1	201	2,556306	709	3 627	19,6%	20,8%	755
1127	Bayesian for Paid1	167	10/1	3	BUSP	travel	2017Q1	214	2,556306	757	3 627	20,9%	21,6%	784
1289	Bayesian for Paid1		10/1	4	BUSP	travel	2017Q1	187	2,556306	662	3 627	18,2%	20,1%	731
797	Bayesian for Paid1	163	1/1	1	BUSP	travel	2017Q2	213	2,551411	758	4 408	17,2%	21,0%	925
973	Bayesian for Paid1		1/1	2	BUSP	travel	2017Q2	226	2,551411	803	4 408	18,2%	21,3%	939
1135	Bayesian for Paid1	163	1/1	3	BUSP	travel	2017Q2	240	2,551411	855	4 408	19,4%	21,7%	959
1297	Bayesian for Paid1		1/1	4	BUSP	travel	2017Q2	211	2,551411	752	4 408	17,1%	21,0%	924
799	Bayesian for Paid1	165	1/10	1	BUSP	travel	2017Q2	213	2,551411	757	4 408	17,2%	21,0%	925
975	Bayesian for Paid1		1/10	2	BUSP	travel	2017Q2	226	2,551411	803	4 408	18,2%	21,3%	939
1137	Bayesian for Paid1	165	1/10	3	BUSP	travel	2017Q2	240	2,551411	855	4 408	19,4%	21,7%	959
1299	Bayesian for Paid1		1/10	4	BUSP	travel	2017Q2	211	2,551411	752	4 408	17,1%	21,0%	924
798	Bayesian for Paid1	164	10/1	1	BUSP	travel	2017Q2	223	2,551411	793	4 408	18,0%	21,2%	936
974	Bayesian for Paid1		10/1	2	BUSP	travel	2017Q2	226	2,551411	803	4 408	18,2%	21,3%	939
1136	Bayesian for Paid1	164	10/1	3	BUSP	travel	2017Q2	240	2,551411	855	4 408	19,4%	21,7%	959
1298	Bayesian for Paid1		10/1	4	BUSP	travel	2017Q2	211	2,551411	752	4 408	17,1%	21,0%	924
808	Bayesian for Paid1	160	1/1	1	BUSP	travel	2017Q3	427	2,541323	1 515	5 333	28,4%	28,4%	1 515
982	Bayesian for Paid1		1/1	2	BUSP	travel	2017Q3	474	2,541323	1 682	5 333	31,5%	31,5%	1 682
1144	Bayesian for Paid1	160	1/1	3	BUSP	travel	2017Q3	424	2,541323	1 503	5 333	28,2%	28,2%	1 503
1306	Bayesian for Paid1		1/1	4	BUSP	travel	2017Q3	525	2,541323	1 860	5 333	34,9%	34,9%	1 860
810	Bayesian for Paid1	162	1/10	1	BUSP	travel	2017Q3	392	2,541323	1 390	5 333	26,1%	26,0%	1 388
984	Bayesian for Paid1		1/10	2	BUSP	travel	2017Q3	474	2,541323	1 682	5 333	31,5%	31,5%	1 682
1146	Bayesian for Paid1	162	1/10	3	BUSP	travel	2017Q3	424	2,541323	1 503	5 333	28,2%	28,2%	1 503
1308	Bayesian for Paid1		1/10	4	BUSP	travel	2017Q3	525	2,541323	1 860	5 333	34,9%	34,9%	1 860
809	Bayesian for Paid1	161	10/1	1	BUSP	travel	2017Q3	467	2,541323	1 656	5 333	31,1%	31,1%	1 656
983	Bayesian for Paid1		10/1	2	BUSP	travel	2017Q3	474	2,541323	1 682	5 333	31,5%	31,5%	1 682
1145	Bayesian for Paid1	161	10/1	3	BUSP	travel	2017Q3	424	2,541323	1 503	5 333	28,2%	28,2%	1 503
1307	Bayesian for Paid1		10/1	4	BUSP	travel	2017Q3	525	2,541323	1 860	5 333	34,9%	34,9%	1 860
819	Bayesian for Paid1	208	1/1	1	BUSP	travel	2017Q4	188	2,599145	676	2 796	24,2%	24,2%	675
991	Bayesian for Paid1		1/1	2	BUSP	travel	2017Q4	192	2,599145	690	2 796	24,7%	24,6%	689
1153	Bayesian for Paid1	208	1/1	3	BUSP	travel	2017Q4	205	2,599145	739	2 796	26,4%	26,4%	739
1315	Bayesian for Paid1		1/1	4	BUSP	travel	2017Q4	178	2,599145	642	2 796	22,9%	23,0%	644
821	Bayesian for Paid1	210	1/10	1	BUSP	travel	2017Q4	199	2,599145	716	2 796	25,6%	25,6%	716
993	Bayesian for Paid1		1/10	2	BUSP	travel	2017Q4	192	2,599145	690	2 796	24,7%	24,6%	689
1155	Bayesian for Paid1	210	1/10	3	BUSP	travel	2017Q4	205	2,599145	739	2 796	26,4%	26,4%	739
1317	Bayesian for Paid1		1/10	4	BUSP	travel	2017Q4	178	2,599145	642	2 796	22,9%	23,0%	644
820	Bayesian for Paid1	209	10/1	1	BUSP	travel	2017Q4	174	2,599145	625	2 796	22,4%	22,5%	630
992	Bayesian for Paid1		10/1	2	BUSP	travel	2017Q4	150	2,599145	539	2 796	19,3%	20,4%	569
1154	Bayesian for Paid1	209	10/1	3	BUSP	travel	2017Q4	178	2,599145	642	2 796	22,9%	23,0%	644
1316	Bayesian for Paid1		10/1	4	BUSP	travel	2017Q4	121	2,599145	436	2 796	15,6%	18,7%	524
830	Bayesian for Paid1	208	1/1	1	BUSP	travel	2018Q1	185	2,556306	653	3 148	20,8%	21,0%	660
1000	Bayesian for Paid1		1/1	2	BUSP	travel	2018Q1	147	2,556306	520	3 148	16,5%	17,7%	559
1162	Bayesian for Paid1	208	1/1	3	BUSP	travel	2018Q1	176	2,556306	621	3 148	19,7%	20,1%	633
1324	Bayesian for Paid1		1/1	4	BUSP	travel	2018Q1	176	2,556306	621	3 148	19,7%	20,1%	633
832	Bayesian for Paid1	210	1/10	1	BUSP	travel	2018Q1	198	2,556306	699	3 148	22,2%	22,2%	700
1002	Bayesian for Paid1		1/10	2	BUSP	travel	2018Q1	189	2,556306	668	3 148	21,2%	21,4%	673
1164	Bayesian for Paid1	210	1/10	3	BUSP	travel	2018Q1	203	2,556306	716	3 148	22,7%	22,7%	716
1326	Bayesian for Paid1		1/10	4	BUSP	travel	2018Q1	176	2,556306	621	3 148	19,7%	20,1%	633
831	Bayesian for Paid1	209	10/1	1	BUSP	travel	2018Q1	161	2,556306	568	3 148	18,0%	18,8%	592
1001	Bayesian for Paid1		10/1	2	BUSP	travel	2018Q1	147	2,556306	520	3 148	16,5%	17,7%	559
1163	Bayesian for Paid1	209	10/1	3	BUSP	travel	2018Q1	176	2,556306	621	3 148	19,7%	20,1%	633
1325	Bayesian for Paid1		10/1	4	BUSP	travel	2018Q1	118	2,556306	419	3 148	13,3%	15,9%	501
841	Bayesian for Paid1	205	1/1	1	BUSP	travel	2018Q2	198	2,551411	706	3 850	18,3%	19,1%	734
1009	Bayesian for Paid1		1/1	2	BUSP	travel	2018Q2	214	2,551411	762	3 850	19,8%	20,2%	777
1171	Bayesian for Paid1	205	1/1	3	BUSP	travel	2018Q2	229	2,551411	814	3 850	21,1%	21,3%	819
1333	Bayesian for Paid1		1/1	4	BUSP	travel	2018Q2	200	2,551411	711	3 850	18,5%	19,2%	738
843	Bayesian for Paid1	207	1/10	1	BUSP	travel	2018Q2	200	2,551411	711	3 850	18,5%	19,2%	738
1011	Bayesian for Paid1		1/10	2	BUSP	travel	2018Q2	186	2,551411	663	3 850	17,2%	18,3%	704
1173	Bayesian for Paid1	207	1/10	3	BUSP	travel	2018Q2	200	2,551411	711	3 850	18,5%	19,2%	738
1335	Bayesian for Paid1		1/10	4	BUSP	travel	2018Q2	173	2,551411	614	3 850	16,0%	17,5%	673
842	Bayesian for Paid1	206	10/1	1	BUSP	travel	2018Q2	199	2,551411	709	3 850	18,4%	19,1%	736
1010	Bayesian for Paid1		10/1	2	BUSP	travel	2018Q2	214	2,551411	762	3 850	19,8%	20,2%	777
1172	Bayesian for Paid1	206	10/1	3	BUSP	travel	2018Q2	229	2,551411	814	3 850	21,1%	21,3%	819
1334	Bayesian for Paid1		10/1	4	BUSP	travel	2018Q2	200	2,551411	711	3 850	18,5%	19,2%	738
852	Bayesian for Paid1	202	1/1	1	BUSP	travel	2018Q3	404	2,541323	1 432	3 896	36,8%	36,8%	1 432
1018	Bayesian for Paid1		1/1	2	BUSP	travel	2018Q3	389	2,541323	1 378	3 896	35,4%	35,4%	1 378
1180	Bayesian for Paid1	202	1/1	3	BUSP	travel	2018Q3	365	2,541323	1 294	3 896	33,2%	33,2%	1 294
1342	Bayesian for Paid1		1/1	4	BUSP	travel	2018Q3	412	2,541323	1 462	3 896	37,5%	37,5%	1 462

Technical I	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
854	Bayesian for Paid1	204	1/10	1	BUSP	travel	2018Q3	381	2,541323	1 350	3 896	34,6%	34,6%	1 350
1020	Bayesian for Paid1		1/10	2	BUSP	travel	2018Q3	389	2,541323	1 378	3 896	35,4%	35,4%	1 378
1182	Bayesian for Paid1	204	1/10	3	BUSP	travel	2018Q3	365	2,541323	1 294	3 896	33,2%	33,2%	1 294
1344	Bayesian for Paid1		1/10	4	BUSP	travel	2018Q3	412	2,541323	1 462	3 896	37,5%	37,5%	1 462
853	Bayesian for Paid1	203	10/1	1	BUSP	travel	2018Q3	424	2,541323	1 504	3 896	38,6%	38,6%	1 504
1019	Bayesian for Paid1		10/1	2	BUSP	travel	2018Q3	389	2,541323	1 378	3 896	35,4%	35,4%	1 378
1181	Bayesian for Paid1	203	10/1	3	BUSP	travel	2018Q3	365	2,541323	1 294	3 896	33,2%	33,2%	1 294
1343	Bayesian for Paid1		10/1	4	BUSP	travel	2018Q3	412	2,541323	1 462	3 896	37,5%	37,5%	1 462
863	Bayesian for Paid1	199	1/1	1	BUSP	travel	2018Q4	193	2,532839	682	2 544	26,8%	26,3%	668
1027	Bayesian for Paid1		1/1	2	BUSP	travel	2018Q4	208	2,532839	736	2 544	28,9%	28,5%	726
1189	Bayesian for Paid1	199	1/1	3	BUSP	travel	2018Q4	223	2,532839	787	2 544	30,9%	30,8%	784
1351	Bayesian for Paid1		1/1	4	BUSP	travel	2018Q4	194	2,532839	685	2 544	26,9%	26,4%	671
865	Bayesian for Paid1	201	1/10	1	BUSP	travel	2018Q4	194	2,532839	684	2 544	26,9%	26,3%	670
1029	Bayesian for Paid1		1/10	2	BUSP	travel	2018Q4	208	2,532839	736	2 544	28,9%	28,5%	726
1191	Bayesian for Paid1	201	1/10	3	BUSP	travel	2018Q4	223	2,532839	787	2 544	30,9%	30,8%	784
1353	Bayesian for Paid1		1/10	4	BUSP	travel	2018Q4	194	2,532839	685	2 544	26,9%	26,4%	671
864	Bayesian for Paid1	200	10/1	1	BUSP	travel	2018Q4	195	2,532839	688	2 544	27,0%	26,5%	674
1028	Bayesian for Paid1		10/1	2	BUSP	travel	2018Q4	208	2,532839	736	2 544	28,9%	28,5%	726
1190	Bayesian for Paid1	200	10/1	3	BUSP	travel	2018Q4	223	2,532839	787	2 544	30,9%	30,8%	784
1352	Bayesian for Paid1		10/1	4	BUSP	travel	2018Q4	194	2,532839	685	2 544	26,9%	26,4%	671
874	Bayesian for Paid1	199	1/1	1	BUSP	travel	2019Q1	176	2,583767	629	2 686	23,4%	21,0%	563
1036	Bayesian for Paid1		1/1	2	BUSP	travel	2019Q1	205	2,583767	734	2 686	27,3%	23,7%	637
1198	Bayesian for Paid1	199	1/1	3	BUSP	travel	2019Q1	220	2,583767	786	2 686	29,3%	25,1%	674
1360	Bayesian for Paid1		1/1	4	BUSP	travel	2019Q1	191	2,583767	682	2 686	25,4%	22,4%	601
876	Bayesian for Paid1	201	1/10	1	BUSP	travel	2019Q1	191	2,583767	681	2 686	25,4%	22,3%	600
1038	Bayesian for Paid1		1/10	2	BUSP	travel	2019Q1	205	2,583767	734	2 686	27,3%	23,7%	637
1200	Bayesian for Paid1	201	1/10	3	BUSP	travel	2019Q1	220	2,583767	786	2 686	29,3%	25,1%	674
1362	Bayesian for Paid1		1/10	4	BUSP	travel	2019Q1	191	2,583767	682	2 686	25,4%	22,4%	601
875	Bayesian for Paid1	200	10/1	1	BUSP	travel	2019Q1	147	2,583767	524	2 686	19,5%	18,3%	490
1037	Bayesian for Paid1		10/1	2	BUSP	travel	2019Q1	135	2,583767	484	2 686	18,0%	17,2%	463
1199	Bayesian for Paid1	200	10/1	3	BUSP	travel	2019Q1	164	2,583767	586	2 686	21,8%	19,8%	533
1361	Bayesian for Paid1		10/1	4	BUSP	travel	2019Q1	107	2,583767	382	2 686	14,2%	14,7%	395
789	Bayesian Network for F1	163	1/1	1	BUSP	travel	2017Q1	192	2,30079	617	3 627	17,0%	19,7%	713
967	Bayesian Network for F1		1/1	2	BUSP	travel	2017Q1	192	2,380243	639	3 627	17,6%	19,9%	721
1129	Bayesian Network for F1	163	1/1	3	BUSP	travel	2017Q1	192	2,263444	607	3 627	16,7%	19,6%	709
1291	Bayesian Network for F1		1/1	4	BUSP	travel	2017Q1	192	2,497042	670	3 627	18,5%	20,3%	735
791	Bayesian Network for F1	165	1/10	1	BUSP	travel	2017Q1	192	2,699284	724	3 627	20,0%	21,0%	763
969	Bayesian Network for F1		1/10	2	BUSP	travel	2017Q1	192	3,145103	844	3 627	23,3%	23,4%	849
1131	Bayesian Network for F1	165	1/10	3	BUSP	travel	2017Q1	192	2,929083	786	3 627	21,7%	22,2%	804
1293	Bayesian Network for F1		1/10	4	BUSP	travel	2017Q1	192	3,361123	902	3 627	24,9%	24,9%	902
790	Bayesian Network for F1	164	10/1	1	BUSP	travel	2017Q1	192	2,262964	607	3 627	16,7%	19,6%	709
968	Bayesian Network for F1		10/1	2	BUSP	travel	2017Q1	192	2,146644	576	3 627	15,9%	19,3%	700
1130	Bayesian Network for F1	164	10/1	3	BUSP	travel	2017Q1	192	2,029845	545	3 627	15,0%	19,1%	693
1292	Bayesian Network for F1		10/1	4	BUSP	travel	2017Q1	192	2,263444	607	3 627	16,7%	19,6%	709
800	Bayesian Network for F1	163	1/1	1	BUSP	travel	2017Q2	197	2,742646	754	4 408	17,1%	21,0%	924
976	Bayesian Network for F1		1/1	2	BUSP	travel	2017Q2	197	2,380243	654	4 408	14,8%	20,6%	906
1138	Bayesian Network for F1	163	1/1	3	BUSP	travel	2017Q2	197	2,263444	622	4 408	14,1%	20,5%	904
1300	Bayesian Network for F1		1/1	4	BUSP	travel	2017Q2	197	2,497042	686	4 408	15,6%	20,7%	910
802	Bayesian Network for F1	165	1/10	1	BUSP	travel	2017Q2	197	2,699284	742	4 408	16,8%	20,9%	921
978	Bayesian Network for F1		1/10	2	BUSP	travel	2017Q2	197	3,145103	864	4 408	19,6%	21,8%	963
1140	Bayesian Network for F1	165	1/10	3	BUSP	travel	2017Q2	197	2,929083	805	4 408	18,3%	21,3%	940
1302	Bayesian Network for F1		1/10	4	BUSP	travel	2017Q2	197	3,361123	924	4 408	21,0%	22,5%	991
801	Bayesian Network for F1	164	10/1	1	BUSP	travel	2017Q2	197	2,772715	762	4 408	17,3%	21,0%	926
977	Bayesian Network for F1		10/1	2	BUSP	travel	2017Q2	197	3,145103	864	4 408	19,6%	21,8%	963
1139	Bayesian Network for F1	164	10/1	3	BUSP	travel	2017Q2	197	2,929083	805	4 408	18,3%	21,3%	940
1301	Bayesian Network for F1		10/1	4	BUSP	travel	2017Q2	197	3,361123	924	4 408	21,0%	22,5%	991
811	Bayesian Network for F1	160	1/1	1	BUSP	travel	2017Q3	378	2,224446	1 172	5 333	22,0%	22,5%	1 200
985	Bayesian Network for F1		1/1	2	BUSP	travel	2017Q3	378	2,146644	1 131	5 333	21,2%	22,0%	1 172
1147	Bayesian Network for F1	160	1/1	3	BUSP	travel	2017Q3	378	2,029845	1 070	5 333	20,1%	21,3%	1 135
1309	Bayesian Network for F1		1/1	4	BUSP	travel	2017Q3	378	2,263444	1 193	5 333	22,4%	22,8%	1 215
813	Bayesian Network for F1	162	1/10	1	BUSP	travel	2017Q3	378	2,456284	1 294	5 333	24,3%	24,3%	1 297
987	Bayesian Network for F1		1/10	2	BUSP	travel	2017Q3	378	2,146644	1 131	5 333	21,2%	22,0%	1 172
1149	Bayesian Network for F1	162	1/10	3	BUSP	travel	2017Q3	378	2,029845	1 070	5 333	20,1%	21,3%	1 135
1311	Bayesian Network for F1		1/10	4	BUSP	travel	2017Q3	378	2,263444	1 193	5 333	22,4%	22,8%	1 215
812	Bayesian Network for F1	161	10/1	1	BUSP	travel	2017Q3	378	2,164021	1 140	5 333	21,4%	22,1%	1 178
986	Bayesian Network for F1		10/1	2	BUSP	travel	2017Q3	378	2,146644	1 131	5 333	21,2%	22,0%	1 172
1148	Bayesian Network for F1	161	10/1	3	BUSP	travel	2017Q3	378	2,029845	1 070	5 333	20,1%	21,3%	1 135
1310	Bayesian Network for F1		10/1	4	BUSP	travel	2017Q3	378	2,263444	1 193	5 333	22,4%	22,8%	1 215
822	Bayesian Network for F1	208	1/1	1	BUSP	travel	2017Q4	261	2,592129	945	2 796	33,8%	33,8%	945
994	Bayesian Network for F1		1/1	2	BUSP	travel	2017Q4	261	2,146644	783	2 796	28,0%	28,0%	783
1156	Bayesian Network for F1	208	1/1	3	BUSP	travel	2017Q4	261	2,029845	740	2 796	26,5%	26,5%	740
1318	Bayesian Network for F1		1/1	4	BUSP	travel	2017Q4	261	2,263444	825	2 796	29,5%	29,5%	825
824	Bayesian Network for F1	210	1/10	1	BUSP	travel	2017Q4	261	2,572217	938	2 796	33,5%	33,5%	938
996	Bayesian Network for F1		1/10	2	BUSP	travel	2017Q4	261	2,146644	783	2 796	28,0%	28,0%	783
1158	Bayesian Network for F1	210	1/10	3	BUSP	travel	2017Q4	261	2,029845	740	2 796	26,5%	26,5%	740
1320	Bayesian Network for F1		1/10	4	BUSP	travel	2017Q4	261	2,263444	825	2 796	29,5%	29,5%	825
823	Bayesian Network for F1	209	10/1	1	BUSP	travel	2017Q4	261	2,564383	935	2 796	33,4%	33,4%	935
995	Bayesian Network for F1		10/1	2	BUSP	travel	2017Q4	261	2,146644	783	2 796	28,0%	28,0%	783
1157	Bayesian Network for F1	209	10/1	3	BUSP	travel	2017Q4	261	2,029845	740	2 796	26,5%	26,5%	740
1319	Bayesian Network for F1		10/1	4	BUSP	travel	2017Q4	261	2,263444	825	2 796	29,5%	29,5%	825
833	Bayesian Network for F1	205	1/1	1	BUSP	travel	2018Q1	161	2,378224	533	3 148	16,9%	18,0%	568
1003	Bayesian Network for F1		1/1	2	BUSP	travel	2018Q1	161	2,380243	534	3 148	17,0%	18,0%	568
1165	Bayesian Network for F1	205	1/1	3	BUSP	travel	2018Q1	161	2,263444	508	3 148	16,1%	17,5%	551
1327	Bayesian Network for F1		1/1	4	BUSP	travel	2018Q1	161	2,497042	560	3 148	17,8%	18,6%	586
835	Bayesian Network for F1	207	1/10	1	BUSP	travel	2018Q1	161	2,520733	565	3 148	18,0%	18,8%	590
1005	Bayesian Network for F1		1/10	2	BUSP	travel	2018Q1	161	2,380243	534	3 148	17,0%	18,0%	568
1167	Bayesian Network for F1	207	1/10	3	BUSP	travel	2018Q1	161	2,263444	508	3 148	16,1%	17,5%	551
1329	Bayesian Network for F1		1/10	4	BUSP	travel	2018Q1	161	2,497042	560	3 148	17,8%	18,6%	586
834	Bayesian Network for F1	206	10/1	1	BUSP	travel	2018Q1	161	2,300877	516	3 148	16,4%	17,7%	556
1004	Bayesian Network for F1		10/1	2	BUSP	travel	2018Q1	161	2,380243	534	3 148	17,0%	18,0%	568
1166	Bayesian Network for F1	206	10/1	3	BUSP	travel	2018Q1	161	2,263444	508	3 148	16,1%	17,5%	551
1328	Bayesian Network for F1		10/1	4	BUSP	travel	2018Q1	161	2,497042	560	3 148	17,8%	18,6%	586
844	Bayesian Network for F1	205	1/1	1	BUSP	travel	2018Q2	230	2,217988	713	3 850	18,5%	19,2%	740
1012	Bayesian Network for F1		1/1	2	BUSP	travel	2018Q2	230	2,146644	690	3 850	17,9%	18,8%	723
1174	Bayesian Network for F1	205	1/1	3	BUSP	travel	2018Q2	230	2,029845	653	3 850	16,9%	18,1%	697
1336	Bayesian Network for F1		1/1	4	BUSP	travel	2018Q2	230	2,263444	728	3 850	18,9%	19,5%	751
846	Bayesian Network for F1	207	1/10	1	BUSP	travel	2018Q2	230	2,429824	781	3 850	20,3%	20,6%	792
1014	Bayesian Network for F1		1/10	2	BUSP	travel	2018Q2	230	2,146644	690	3 850	17,9%	18,8%	723
1176	Bayesian Network for F1	207	1/10	3	BUSP	travel	2018Q2	230	2,029845	653	3 850	16,9%	18,1%	697
1338	Bayesian Network for F1		1/10	4	BUSP	travel	2018Q2	230	2,263444	728	3 850	18,9%	19,5%	751

Technical I	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busir	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
845	Bayesian Network for F1	206	10/1	1	BUSP	travel	2018Q2	230	2,155438	693	3 850	18,0%	18,8%	725
1013	Bayesian Network for F1		10/1	2	BUSP	travel	2018Q2	230	2,146644	690	3 850	17,9%	18,8%	723
1175	Bayesian Network for F1	206	10/1	3	BUSP	travel	2018Q2	230	2,029845	653	3 850	16,9%	18,1%	697
1337	Bayesian Network for F1		10/1	4	BUSP	travel	2018Q2	230	2,263444	728	3 850	18,9%	19,5%	751
855	Bayesian Network for F1	202	1/1	1	BUSP	travel	2018Q3	349	2,574547	1 255	3 896	32,2%	32,2%	1 255
1021	Bayesian Network for F1		1/1	2	BUSP	travel	2018Q3	349	2,713063	1 322	3 896	33,9%	33,9%	1 322
1183	Bayesian Network for F1	202	1/1	3	BUSP	travel	2018Q3	349	2,497042	1 217	3 896	31,2%	31,2%	1 217
1345	Bayesian Network for F1		1/1	4	BUSP	travel	2018Q3	349	2,929083	1 428	3 896	36,6%	36,6%	1 428
857	Bayesian Network for F1	204	1/10	1	BUSP	travel	2018Q3	349	2,565811	1 251	3 896	32,1%	32,1%	1 251
1023	Bayesian Network for F1		1/10	2	BUSP	travel	2018Q3	349	2,713063	1 322	3 896	33,9%	33,9%	1 322
1185	Bayesian Network for F1	204	1/10	3	BUSP	travel	2018Q3	349	2,497042	1 217	3 896	31,2%	31,2%	1 217
1347	Bayesian Network for F1		1/10	4	BUSP	travel	2018Q3	349	2,929083	1 428	3 896	36,6%	36,6%	1 428
856	Bayesian Network for F1	203	10/1	1	BUSP	travel	2018Q3	349	2,560697	1 248	3 896	32,0%	32,0%	1 248
1022	Bayesian Network for F1		10/1	2	BUSP	travel	2018Q3	349	2,713063	1 322	3 896	33,9%	33,9%	1 322
1184	Bayesian Network for F1	203	10/1	3	BUSP	travel	2018Q3	349	2,497042	1 217	3 896	31,2%	31,2%	1 217
1346	Bayesian Network for F1		10/1	4	BUSP	travel	2018Q3	349	2,929083	1 428	3 896	36,6%	36,6%	1 428
866	Bayesian Network for F1	199	1/1	1	BUSP	travel	2018Q4	216	2,692493	811	2 544	31,9%	31,9%	811
1030	Bayesian Network for F1		1/1	2	BUSP	travel	2018Q4	216	2,713063	818	2 544	32,1%	32,1%	818
1192	Bayesian Network for F1	199	1/1	3	BUSP	travel	2018Q4	216	2,497042	753	2 544	29,6%	29,2%	744
1354	Bayesian Network for F1		1/1	4	BUSP	travel	2018Q4	216	2,929083	883	2 544	34,7%	34,7%	883
868	Bayesian Network for F1	201	1/10	1	BUSP	travel	2018Q4	216	2,621145	790	2 544	31,1%	30,9%	787
1032	Bayesian Network for F1		1/10	2	BUSP	travel	2018Q4	216	2,713063	818	2 544	32,1%	32,1%	818
1194	Bayesian Network for F1	201	1/10	3	BUSP	travel	2018Q4	216	2,497042	753	2 544	29,6%	29,2%	744
1356	Bayesian Network for F1		1/10	4	BUSP	travel	2018Q4	216	2,929083	883	2 544	34,7%	34,7%	883
867	Bayesian Network for F1	200	10/1	1	BUSP	travel	2018Q4	216	2,713191	818	2 544	32,1%	32,1%	818
1031	Bayesian Network for F1		10/1	2	BUSP	travel	2018Q4	216	2,713063	818	2 544	32,1%	32,1%	818
1193	Bayesian Network for F1	200	10/1	3	BUSP	travel	2018Q4	216	2,497042	753	2 544	29,6%	29,2%	744
1355	Bayesian Network for F1		10/1	4	BUSP	travel	2018Q4	216	2,929083	883	2 544	34,7%	34,7%	883
877	Bayesian Network for F1	196	1/1	1	BUSP	travel	2019Q1							
1039	Bayesian Network for F1		1/1	2	BUSP	travel	2019Q1							
1201	Bayesian Network for F1	196	1/1	3	BUSP	travel	2019Q1							
1363	Bayesian Network for F1		1/1	4	BUSP	travel	2019Q1							
879	Bayesian Network for F1	198	1/10	1	BUSP	travel	2019Q1							
1041	Bayesian Network for F1		1/10	2	BUSP	travel	2019Q1							
1203	Bayesian Network for F1	198	1/10	3	BUSP	travel	2019Q1							
1365	Bayesian Network for F1	x	1/10	4	BUSP	travel	2019Q1							
878	Bayesian Network for F1	197	10/1	1	BUSP	travel	2019Q1							
1040	Bayesian Network for F1		10/1	2	BUSP	travel	2019Q1							
1202	Bayesian Network for F1	197	10/1	3	BUSP	travel	2019Q1							
1364	Bayesian Network for F1		10/1	4	BUSP	travel	2019Q1							
792	Bayesian Network for mix (Paid1+F1)	-198	1/1	1	BUSP	travel	2017Q1	211	2,30079	679	3 627	18,7%	20,4%	739
970	Bayesian Network for mix (Paid1+F1)	197-	1/1	2	BUSP	travel	2017Q1	201	2,380243	666	3 627	18,4%	20,2%	733
1132	Bayesian Network for mix (Paid1+F1)	-197	1/1	3	BUSP	travel	2017Q1	214	2,263444	676	3 627	18,6%	20,3%	738
1294	Bayesian Network for mix (Paid1+F1)	163-	1/1	4	BUSP	travel	2017Q1	187	2,497042	652	3 627	18,0%	20,0%	726
794	Bayesian Network for mix (Paid1+F1)	-197	1/10	1	BUSP	travel	2017Q1	213	2,699284	802	3 627	22,1%	22,5%	815
972	Bayesian Network for mix (Paid1+F1)	163-	1/10	2	BUSP	travel	2017Q1	229	3,145103	1 003	3 627	27,7%	27,7%	1 003
1134	Bayesian Network for mix (Paid1+F1)	-163	1/10	3	BUSP	travel	2017Q1	243	2,929083	993	3 627	27,4%	27,4%	993
1296	Bayesian Network for mix (Paid1+F1)	165-	1/10	4	BUSP	travel	2017Q1	214	3,361123	1 004	3 627	27,7%	27,7%	1 004
793	Bayesian Network for mix (Paid1+F1)	-163	10/1	1	BUSP	travel	2017Q1	213	2,262964	671	3 627	18,5%	20,3%	735
971	Bayesian Network for mix (Paid1+F1)	165-	10/1	2	BUSP	travel	2017Q1	201	2,146644	601	3 627	16,6%	19,5%	707
1133	Bayesian Network for mix (Paid1+F1)	-165	10/1	3	BUSP	travel	2017Q1	214	2,029845	606	3 627	16,7%	19,5%	709
1295	Bayesian Network for mix (Paid1+F1)	164-	10/1	4	BUSP	travel	2017Q1	187	2,263444	591	3 627	16,3%	19,4%	704
803	Bayesian Network for mix (Paid1+F1)	-165	1/1	1	BUSP	travel	2017Q2	213	2,742646	815	4 408	18,5%	21,4%	943
979	Bayesian Network for mix (Paid1+F1)	164-	1/1	2	BUSP	travel	2017Q2	226	2,380243	750	4 408	17,0%	20,9%	923
1141	Bayesian Network for mix (Paid1+F1)	-164	1/1	3	BUSP	travel	2017Q2	240	2,263444	758	4 408	17,2%	21,0%	925
1303	Bayesian Network for mix (Paid1+F1)	160-	1/1	4	BUSP	travel	2017Q2	211	2,497042	736	4 408	16,7%	20,9%	920
805	Bayesian Network for mix (Paid1+F1)	-164	1/10	1	BUSP	travel	2017Q2	213	2,699284	801	4 408	18,2%	21,3%	938
981	Bayesian Network for mix (Paid1+F1)	160-	1/10	2	BUSP	travel	2017Q2	226	3,145103	990	4 408	22,5%	23,4%	1 030
1143	Bayesian Network for mix (Paid1+F1)	-160	1/10	3	BUSP	travel	2017Q2	240	2,929083	981	4 408	22,3%	23,2%	1 025
1305	Bayesian Network for mix (Paid1+F1)	162-	1/10	4	BUSP	travel	2017Q2	211	3,361123	991	4 408	22,5%	23,4%	1 031
804	Bayesian Network for mix (Paid1+F1)	-160	10/1	1	BUSP	travel	2017Q2	223	2,772715	862	4 408	19,6%	21,8%	962
980	Bayesian Network for mix (Paid1+F1)	162-	10/1	2	BUSP	travel	2017Q2	226	3,145103	990	4 408	22,5%	23,4%	1 030
1142	Bayesian Network for mix (Paid1+F1)	-162	10/1	3	BUSP	travel	2017Q2	240	2,929083	981	4 408	22,3%	23,2%	1 025
1304	Bayesian Network for mix (Paid1+F1)	161-	10/1	4	BUSP	travel	2017Q2	211	3,361123	991	4 408	22,5%	23,4%	1 031
814	Bayesian Network for mix (Paid1+F1)	-162	1/1	1	BUSP	travel	2017Q3	427	2,224446	1 326	5 333	24,9%	24,9%	1 326
988	Bayesian Network for mix (Paid1+F1)	161-	1/1	2	BUSP	travel	2017Q3	474	2,146644	1 420	5 333	26,6%	26,6%	1 420
1150	Bayesian Network for mix (Paid1+F1)	-161	1/1	3	BUSP	travel	2017Q3	424	2,029845	1 201	5 333	22,5%	22,9%	1 221
1312	Bayesian Network for mix (Paid1+F1)	160-	1/1	4	BUSP	travel	2017Q3	525	2,263444	1 657	5 333	31,1%	31,1%	1 657
816	Bayesian Network for mix (Paid1+F1)	-161	1/10	1	BUSP	travel	2017Q3	392	2,456284	1 344	5 333	25,2%	25,2%	1 343
990	Bayesian Network for mix (Paid1+F1)	160-	1/10	2	BUSP	travel	2017Q3	474	2,146644	1 420	5 333	26,6%	26,6%	1 420
1152	Bayesian Network for mix (Paid1+F1)	-160	1/10	3	BUSP	travel	2017Q3	424	2,029845	1 201	5 333	22,5%	22,9%	1 221
1314	Bayesian Network for mix (Paid1+F1)	162-	1/10	4	BUSP	travel	2017Q3	525	2,263444	1 657	5 333	31,1%	31,1%	1 657
815	Bayesian Network for mix (Paid1+F1)	-160	10/1	1	BUSP	travel	2017Q3	467	2,164021	1 410	5 333	26,4%	26,4%	1 409
989	Bayesian Network for mix (Paid1+F1)	162-	10/1	2	BUSP	travel	2017Q3	474	2,146644	1 420	5 333	26,6%	26,6%	1 420
1151	Bayesian Network for mix (Paid1+F1)	-162	10/1	3	BUSP	travel	2017Q3	424	2,029845	1 201	5 333	22,5%	22,9%	1 221
1313	Bayesian Network for mix (Paid1+F1)	161-	10/1	4	BUSP	travel	2017Q3	525	2,263444	1 657	5 333	31,1%	31,1%	1 657
825	Bayesian Network for mix (Paid1+F1)	-162	1/1	1	BUSP	travel	2017Q4	188	2,592129	680	2 796	24,3%	24,3%	679
997	Bayesian Network for mix (Paid1+F1)	161-	1/1	2	BUSP	travel	2017Q4	192	2,146644	575	2 796	20,6%	21,2%	592
1159	Bayesian Network for mix (Paid1+F1)	-161	1/1	3	BUSP	travel	2017Q4	205	2,029845	582	2 796	20,8%	21,3%	597
1321	Bayesian Network for mix (Paid1+F1)	208-	1/1	4	BUSP	travel	2017Q4	178	2,263444	563	2 796	20,2%	20,9%	584
827	Bayesian Network for mix (Paid1+F1)	-161	1/10	1	BUSP	travel	2017Q4	199	2,572217	715	2 796	25,6%	25,6%	715
999	Bayesian Network for mix (Paid1+F1)	208-	1/10	2	BUSP	travel	2017Q4	192	2,146644	575	2 796	20,6%	21,2%	592
1161	Bayesian Network for mix (Paid1+F1)	-208	1/10	3	BUSP	travel	2017Q4	205	2,029845	582	2 796	20,8%	21,3%	597
1323	Bayesian Network for mix (Paid1+F1)	210-	1/10	4	BUSP	travel	2017Q4	178	2,263444	563	2 796	20,2%	20,9%	584
826	Bayesian Network for mix (Paid1+F1)	-208	10/1	1	BUSP	travel	2017Q4	174	2,564383	622	2 796	22,2%	22,4%	627
998	Bayesian Network for mix (Paid1+F1)	210-	10/1	2	BUSP	travel	2017Q4	150	2,146644	449	2 796	16,1%	18,9%	528
1160	Bayesian Network for mix (Paid1+F1)	-210	10/1	3	BUSP	travel	2017Q4	178	2,029845	505	2 796	18,1%	19,7%	551
1322	Bayesian Network for mix (Paid1+F1)	209-	10/1	4	BUSP	travel	2017Q4	121	2,263444	383	2 796	13,7%	18,3%	512
836	Bayesian Network for mix (Paid1+F1)	-210	1/1	1	BUSP	travel	2018Q1	185	2,378224	613	3 148	19,5%	19,9%	627
1006	Bayesian Network for mix (Paid1+F1)	209-	1/1	2	BUSP	travel	2018Q1	147	2,380243	488	3 148	15,5%	17,1%	539
1168	Bayesian Network for mix (Paid1+F1)	-209	1/1	3	BUSP	travel	2018Q1	176	2,263444	554	3 148	17,6%	18,5%	582
1330	Bayesian Network for mix (Paid1+F1)	205-	1/1	4	BUSP	travel	2018Q1	118	2,497042	413	3 148	13,1%	15,8%	498
838	Bayesian Network for mix (Paid1+F1)	-209	1/10	1	BUSP	travel	2018Q1	198	2,520733	695	3 148	22,1%	22,1%	697
1008	Bayesian Network for mix (Paid1+F1)	205-	1/10	2	BUSP	travel	2018Q1	189	2,380243	628	3 148	19,9%	20,3%	638
1170	Bayesian Network for mix (Paid1+F1)	-205	1/10	3	BUSP	travel	2018Q1	203	2,263444	640	3 148	20,3%	20,6%	648
1332	Bayesian Network for mix (Paid1+F1)	207-	1/10	4	BUSP	travel	2018Q1	176	2,497042	612	3 148	19,4%	19,9%	625
837	Bayesian Network for mix (Paid1+F1)	-205	10/1	1	BUSP	travel	2018Q1	161	2,300877	516	3 148	16,4%	17,7%	556
1007	Bayesian Network for mix (Paid1+F1)	207-	10/1	2	BUSP	travel	2018Q1	147	2,380243	488	3 148	15,5%	17,1%	539
1169	Bayesian Network for mix (Paid1+F1)	-207	10/1	3	BUSP	travel	2018Q1	176	2,263444	554	3 148	17,6%	18,5%	582
1331	Bayesian Network for mix (Paid1+F1)	206-	10/1	4	BUSP	travel	2018Q1	118	2,497042	413	3 148	13,1%	15,8%	498

Technical T	Model\information	Numéro	Niveau_de_crédibilit	Valoris	Busi	LOB	Cohor	PAID1 (k	F1	ULT (k€)	GEP (k	LR	LR-BF	ULT-BF (k
847	Bayesian Network for mix (Paid1+F1)	-207	1/1	1	BUSP	travel	2018Q2	198	2,217988	614	3 850	15,9%	17,5%	672
1015	Bayesian Network for mix (Paid1+F1)	206-	1/1	2	BUSP	travel	2018Q2	214	2,146644	641	3 850	16,7%	17,9%	690
1177	Bayesian Network for mix (Paid1+F1)	-206	1/1	3	BUSP	travel	2018Q2	229	2,029845	647	3 850	16,8%	18,0%	694
1339	Bayesian Network for mix (Paid1+F1)	190-	1/1	4	BUSP	travel	2018Q2	200	2,263444	630	3 850	16,4%	17,7%	683
849	Bayesian Network for mix (Paid1+F1)	-206	1/10	1	BUSP	travel	2018Q2	200	2,429824	677	3 850	17,6%	18,6%	714
1017	Bayesian Network for mix (Paid1+F1)	202-	1/10	2	BUSP	travel	2018Q2	186	2,146644	557	3 850	14,5%	16,6%	640
1179	Bayesian Network for mix (Paid1+F1)	-190	1/10	3	BUSP	travel	2018Q2	200	2,029845	565	3 850	14,7%	16,7%	644
1341	Bayesian Network for mix (Paid1+F1)	204-	1/10	4	BUSP	travel	2018Q2	173	2,263444	545	3 850	14,2%	16,5%	633
848	Bayesian Network for mix (Paid1+F1)	-202	10/1	1	BUSP	travel	2018Q2	199	2,155438	599	3 850	15,5%	17,2%	663
1016	Bayesian Network for mix (Paid1+F1)	204-	10/1	2	BUSP	travel	2018Q2	214	2,146644	641	3 850	16,7%	17,9%	690
1178	Bayesian Network for mix (Paid1+F1)	-204	10/1	3	BUSP	travel	2018Q2	229	2,029845	647	3 850	16,8%	18,0%	694
1340	Bayesian Network for mix (Paid1+F1)	203-	10/1	4	BUSP	travel	2018Q2	200	2,263444	630	3 850	16,4%	17,7%	683
858	Bayesian Network for mix (Paid1+F1)	-204	1/1	1	BUSP	travel	2018Q3	404	2,574547	1 451	3 896	37,2%	37,2%	1 451
1024	Bayesian Network for mix (Paid1+F1)	203-	1/1	2	BUSP	travel	2018Q3	389	2,713063	1 471	3 896	37,8%	37,8%	1 471
1186	Bayesian Network for mix (Paid1+F1)	-203	1/1	3	BUSP	travel	2018Q3	365	2,497042	1 271	3 896	32,6%	32,6%	1 271
1348	Bayesian Network for mix (Paid1+F1)	202-	1/1	4	BUSP	travel	2018Q3	412	2,929083	1 685	3 896	43,3%	43,3%	1 685
860	Bayesian Network for mix (Paid1+F1)	-203	1/10	1	BUSP	travel	2018Q3	381	2,565811	1 363	3 896	35,0%	35,0%	1 363
1026	Bayesian Network for mix (Paid1+F1)	202-	1/10	2	BUSP	travel	2018Q3	389	2,713063	1 471	3 896	37,8%	37,8%	1 471
1188	Bayesian Network for mix (Paid1+F1)	-202	1/10	3	BUSP	travel	2018Q3	365	2,497042	1 271	3 896	32,6%	32,6%	1 271
1350	Bayesian Network for mix (Paid1+F1)	204-	1/10	4	BUSP	travel	2018Q3	412	2,929083	1 685	3 896	43,3%	43,3%	1 685
859	Bayesian Network for mix (Paid1+F1)	-202	10/1	1	BUSP	travel	2018Q3	424	2,560697	1 515	3 896	38,9%	38,9%	1 515
1025	Bayesian Network for mix (Paid1+F1)	204-	10/1	2	BUSP	travel	2018Q3	389	2,713063	1 471	3 896	37,8%	37,8%	1 471
1187	Bayesian Network for mix (Paid1+F1)	-204	10/1	3	BUSP	travel	2018Q3	365	2,497042	1 271	3 896	32,6%	32,6%	1 271
1349	Bayesian Network for mix (Paid1+F1)	203-	10/1	4	BUSP	travel	2018Q3	412	2,929083	1 685	3 896	43,3%	43,3%	1 685
869	Bayesian Network for mix (Paid1+F1)	-204	1/1	1	BUSP	travel	2018Q4	193	2,692493	725	2 544	28,5%	28,1%	714
1033	Bayesian Network for mix (Paid1+F1)	203-	1/1	2	BUSP	travel	2018Q4	208	2,713063	789	2 544	31,0%	30,9%	785
1195	Bayesian Network for mix (Paid1+F1)	-203	1/1	3	BUSP	travel	2018Q4	223	2,497042	776	2 544	30,5%	30,3%	771
1357	Bayesian Network for mix (Paid1+F1)	199-	1/1	4	BUSP	travel	2018Q4	194	2,929083	792	2 544	31,1%	31,0%	790
871	Bayesian Network for mix (Paid1+F1)	-203	1/10	1	BUSP	travel	2018Q4	194	2,621145	708	2 544	27,8%	27,3%	695
1035	Bayesian Network for mix (Paid1+F1)	199-	1/10	2	BUSP	travel	2018Q4	208	2,713063	789	2 544	31,0%	30,9%	785
1197	Bayesian Network for mix (Paid1+F1)	-199	1/10	3	BUSP	travel	2018Q4	223	2,497042	776	2 544	30,5%	30,3%	771
1359	Bayesian Network for mix (Paid1+F1)	201-	1/10	4	BUSP	travel	2018Q4	194	2,929083	792	2 544	31,1%	31,0%	790
870	Bayesian Network for mix (Paid1+F1)	-199	10/1	1	BUSP	travel	2018Q4	195	2,713191	737	2 544	29,0%	28,6%	726
1034	Bayesian Network for mix (Paid1+F1)	201-	10/1	2	BUSP	travel	2018Q4	208	2,713063	789	2 544	31,0%	30,9%	785
1196	Bayesian Network for mix (Paid1+F1)	-201	10/1	3	BUSP	travel	2018Q4	223	2,497042	776	2 544	30,5%	30,3%	771
1358	Bayesian Network for mix (Paid1+F1)	200-	10/1	4	BUSP	travel	2018Q4	194	2,929083	792	2 544	31,1%	31,0%	790
880	Bayesian Network for mix (Paid1+F1)	-201	1/1	1	BUSP	travel	2019Q1							
1042	Bayesian Network for mix (Paid1+F1)	200-	1/1	2	BUSP	travel	2019Q1							
1204	Bayesian Network for mix (Paid1+F1)	-200	1/1	3	BUSP	travel	2019Q1							
1366	Bayesian Network for mix (Paid1+F1)		1/1	4	BUSP	travel	2019Q1							
882	Bayesian Network for mix (Paid1+F1)	-200	1/10	1	BUSP	travel	2019Q1							
1044	Bayesian Network for mix (Paid1+F1)	196-	1/10	2	BUSP	travel	2019Q1							
1206	Bayesian Network for mix (Paid1+F1)	-196	1/10	3	BUSP	travel	2019Q1							
1368	Bayesian Network for mix (Paid1+F1)		1/10	4	BUSP	travel	2019Q1							
881	Bayesian Network for mix (Paid1+F1)	-196	10/1	1	BUSP	travel	2019Q1							
1043	Bayesian Network for mix (Paid1+F1)	198-	10/1	2	BUSP	travel	2019Q1							
1205	Bayesian Network for mix (Paid1+F1)	-198	10/1	3	BUSP	travel	2019Q1							
1367	Bayesian Network for mix (Paid1+F1)		10/1	4	BUSP	travel	2019Q1							

6. Code de programmation des graphes de résultats

```
##tracage des graphes avec intervalles de confiance
# installation du package gplots pour dessiner les intervalles de confiance
install.packages("gplots")
library(gplots)
#chargement de la feuille Excel qui porte tous les données des graphiques
Graphiques_resultats <- read_excel("E://Mémoire-document et résultats/Memoire_graphes résultats.xlsx")
View(Graphiques_resultats)
#chargement de la table des outliers
OUTLIERS <- read_excel("E:/Mémoire-document et résultats/Mémoire_résultats_analyse_points_hors_canal.xlsx")
View(OUTLIERS)
#test de visualisation des outliers (ici la borne inférieure... la borne superieure étant dans OuTLIERS [[7]])
OUTLIERS[[6]]
#test d'accès au 14ème terme du vecteur avec nettoyage pour affichage en milliers d'euros arrondis
trunc(OUTLIERS[[6]][14]/1000)
######################## 1er GRAPHIQUE ######################################
#chargement d'une des tables de résultats (l'intitulé de table donne le périmètre)
Graph_TRAV_mix_Ult<-Graphiques_resultats[91:107,2:11]
View(Graph_TRAV_mix_Ult) #visualisation pour vérification
# définition d'un tableau de référence à peupler qui servira à "plotter" des valeurs
array(,c(15,9))->GRAPH
View(GRAPH)
for (j in 1:15)
{ for (i in 2:10) Graph_TRAV_mix_Ult[[i]][j+1]->GRAPH[j,i-1]}
as.numeric(GRAPH)->GRAPH #conversion en numérique pour avoir des nombres à partir du dataframe
dim(GRAPH)=c(15,9) #dimensionnement du tableau des résultats
round(GRAPH/1000)->GRAPH #données arrondies en kilo-euros pour les montants
#tracé de la courbe : paramètrage
abs=c(1,2,3,4,5,6,7,8,9)
names(abs)=c("2017Q1","2017Q2","2017Q3","2017Q4","2018Q1","2018Q2","2018Q3","2018Q4","2019Q1")
abs_min=min(GRAPH[c(1,2,3,4),],na.rm = TRUE)
abs_max=max(GRAPH[c(1,2,3,4),],na.rm = TRUE)
#construction du graphique
## pour avoir un seul graphique correspondant à une solution sur une même ligne
par(mfrow = c(1,1))
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Charge à l'ultime (k€)",main="Valorisation des charges à l'ultime (k€)", sub="Activité Assistance Voyages (crédibilité 1/1 avec valorisation de type 1)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[4,],col="blue",pch=8,type="o",lty="dotted")
#REMARQUE : sauvegarde du graphique avec les dimensions 750*500 (commande export de RStudio dans l'onglet Plots)

######################## 2eme GRAPHIQUE#####################################
#chargement d'une des tables de résultats (l'intitulé de table donne le périmètre)
Graph_TRAV_MontantInitial_MontantInitial<-Graphiques_resultats[56:71,2:11]
View(Graph_TRAV_MontantInitial_MontantInitial)#visualisation pour vérification
# définition d'un tableau de référence à peupler qui servira à "plotter" des valeurs
array(,c(15,9))->GRAPH
View(GRAPH)
for (j in 1:15)
{ for (i in 2:10) Graph_TRAV_MontantInitial_MontantInitial[[i]][j]->GRAPH[j,i-1]}
```

```
as.numeric(GRAPH)->GRAPH #conversion en numérique pour avoir des nombres à partir du dataframe
dim(GRAPH)=c(15,9)#dimensionnement du tableau des résultats
round(GRAPH/1000)->GRAPH #données arrondies en kilo-euros pour les montants
#tracé de la courbe : paramètrage
abs=c(1,2,3,4,5,6,7,8,9)
names(abs)=c("2017Q1","2017Q2","2017Q3","2017Q4","2018Q1","2018Q2","2018Q3","2018Q4","2019Q1")
abs_min=min(GRAPH[c(1,2,3,4),],na.rm = TRUE)
abs_max=max(GRAPH[c(1,2,3,4),],na.rm = TRUE)
#construction du graphique
## pour avoir deux graphiques correspondant à deux solutions sur une même ligne
par(mfrow = c(1,1))
###1er des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Montant Initial (k€)",main="Valorisation des montants initiaux (k€)", sub="Activité Assistance Voyages (crédibilité 1/1 avec valorisation de type 3)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
points(abs,GRAPH[6,],col="blue",pch=8,type="o",lty="dotted")
#points(abs,GRAPH[8,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(trunc(OUTLIERS[[6]][14]/1000),trunc(OUTLIERS[[7]][14]/1000)),col="blue",pch=6,type="o",lty="solid")
#points(c(1,1),c(trunc(OUTLIERS[[6]][17]/1000),trunc(OUTLIERS[[7]][17]/1000)),col="orange",pch=6,type="o",lty="solid")
points(c(6,6),c(trunc(OUTLIERS[[6]][15]/1000),trunc(OUTLIERS[[7]][15]/1000)),col="blue",pch=6,type="o",lty="solid")
#points(c(6,6),c(trunc(OUTLIERS[[6]][18]/1000),trunc(OUTLIERS[[7]][18]/1000)),col="orange",pch=6,type="o",lty="solid")
points(c(9,9),c(trunc(OUTLIERS[[6]][16]/1000),trunc(OUTLIERS[[7]][16]/1000)),col="blue",pch=6,type="o",lty="solid")
#points(c(9,9),c(trunc(OUTLIERS[[6]][19]/1000),trunc(OUTLIERS[[7]][19]/1000)),col="orange",pch=6,type="o",lty="solid")
###2eme des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Montant Initial (k€)",main="Valorisation des montants initiaux (k€)", sub="Activité Assistance Voyages (crédibilité 1/10 avec valorisation de type 1)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
#points(abs,GRAPH[6,],col="blue",pch=8,type="o",lty="dotted")
points(abs,GRAPH[8,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
#points(c(1,1),c(trunc(OUTLIERS[[6]][14]/1000),trunc(OUTLIERS[[7]][14]/1000)),col="blue",pch=6,type="o",lty="solid")
points(c(1,1),c(trunc(OUTLIERS[[6]][17]/1000),trunc(OUTLIERS[[7]][17]/1000)),col="orange",pch=6,type="o",lty="solid")
#points(c(6,6),c(trunc(OUTLIERS[[6]][15]/1000),trunc(OUTLIERS[[7]][15]/1000)),col="blue",pch=6,type="o",lty="solid")
points(c(6,6),c(trunc(OUTLIERS[[6]][18]/1000),trunc(OUTLIERS[[7]][18]/1000)),col="orange",pch=6,type="o",lty="solid")
#points(c(9,9),c(trunc(OUTLIERS[[6]][16]/1000),trunc(OUTLIERS[[7]][16]/1000)),col="blue",pch=6,type="o",lty="solid")
points(c(9,9),c(trunc(OUTLIERS[[6]][19]/1000),trunc(OUTLIERS[[7]][19]/1000)),col="orange",pch=6,type="o",lty="solid")
```

```
#REMARQUE : sauvegarde du graphique avec les dimensions 750*500 (commande export de RStudio dans l'onglet Plots)
######################  3eme GRAPHIQUE#####################################
#chargement d'une des tables de résultats (l'intitulé de table donne le périmètre)
Graph_TRAV_F1_F1<-Graphiques_resultats[74:89,2:11]
View(Graph_TRAV_F1_F1) #visualisation pour vérification
# définition d'un tableau de référence à peupler qui servira à "plotter" des valeurs
array(,c(15,9))->GRAPH
View(GRAPH)
for (j in 1:15)
{  for (i in 2:10) Graph_TRAV_F1_F1[[i]][j]->GRAPH[j,i-1]}
as.numeric(GRAPH)->GRAPH #conversion en numérique pour avoir des nombres à partir du dataframe
dim(GRAPH)=c(15,9) #dimensionnement du tableau des résultats
#round(GRAPH/1000)->GRAPH #données arrondies en kilo-euros pour les montants
#tracé de la courbe : paramètrage
abs=c(1,2,3,4,5,6,7,8,9)
names(abs)=c("2017Q1","2017Q2","2017Q3","2017Q4","2018Q1","2018Q2","2018Q3","2018Q4","2019Q1")
abs_min=min(GRAPH[c(1,2,3,4),],na.rm = TRUE)
abs_max=max(GRAPH[c(1,2,3,4),],na.rm = TRUE)+0.3
#construction du graphique
## pour avoir deux graphiques correspondant à deux solutions sur une même ligne
par(mfrow = c(1,1))
###1er des deux graphiques
plot(abs,GRAPH[1,],col="red",                                    type="o",tck=1,lty="solid",
xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Facteur de développement",main="Valorisation des facteurs de développement initiaux", sub="Activité Assistance Voyages (crédibilité 1/1 avec valorisation de type 3)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
points(abs,GRAPH[6,],col="blue",pch=8,type="o",lty="dotted")
#points(abs,GRAPH[14,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(OUTLIERS[[6]][20],OUTLIERS[[7]][20]),col="blue",pch=6,type="o",lty="solid")
points(c(4,4),c(OUTLIERS[[6]][22],OUTLIERS[[7]][22]),col="blue",pch=6,type="o",lty="solid")
###2eme des deux graphiques
plot(abs,GRAPH[1,],col="red",                                    type="o",tck=1,lty="solid",
xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Facteur de développement",main="Valorisation des facteurs de développement initiaux", sub="Activité Assistance Voyages (crédibilité 10/1 avec valorisation de type 3)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
#points(abs,GRAPH[6,],col="blue",pch=8,type="o",lty="dotted")
points(abs,GRAPH[14,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(OUTLIERS[[6]][21],OUTLIERS[[7]][21]),col="orange",pch=6,type="o",lty="solid")
points(c(4,4),c(OUTLIERS[[6]][23],OUTLIERS[[7]][23]),col="orange",pch=6,type="o",lty="solid")
#REMARQUE : sauvegarde du graphique avec les dimensions 750*500 (commande export de RStudio dans l'onglet Plots)
######################  4eme GRAPHIQUE#####################################
#chargement d'une des tables de résultats (l'intitulé de table donne le périmètre)
Graph_AUTO_MONT_MONT<-Graphiques_resultats[2:17,2:11]
View(Graph_AUTO_MONT_MONT) #visualisation pour vérification
# définition d'un tableau de référence à peupler qui servira à "plotter" des valeurs
array(,c(15,9))->GRAPH
View(GRAPH)
```

```
for (j in 1:15)
{  for (i in 2:10) Graph_AUTO_MONT_MONT[[i]][j]->GRAPH[j,i-1]}
as.numeric(GRAPH)->GRAPH #conversion en numérique pour avoir des nombres à partir du dataframe
dim(GRAPH)=c(15,9) #dimensionnement du tableau des résultats
round(GRAPH/1000)->GRAPH #données arrondies en kilo-euros pour les montants
#tracé de la courbe : paramètrage
abs=c(1,2,3,4,5,6,7,8,9)
names(abs)=c("2017Q1","2017Q2","2017Q3","2017Q4","2018Q1","2018Q2","2018Q3","2018Q4","2019Q1")
abs_min=min(GRAPH[c(1,2,3,4),],na.rm = TRUE)
abs_max=max(GRAPH[c(1,2,3,4),],na.rm = TRUE)
#construction du graphique
## pour avoir un seul graphique correspondant à une solution sur une même ligne
par(mfrow = c(1,1))
###1er des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Montant Initial (k€)",main="Valorisation des montants initiaux (k€)", sub="Activité Assistance Auto (crédibilité 1/1 avec valorisation de type 4)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
points(abs,GRAPH[7,],col="blue",pch=8,type="o",lty="dotted")
#points(abs,GRAPH[14,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points po(ur faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(trunc(OUTLIERS[[6]][1]/1000),trunc(OUTLIERS[[7]][1]/1000)),col="blue",pch=6,type="o",lty="soli
d")
points(c(2,2),c(trunc(OUTLIERS[[6]][2]/1000),trunc(OUTLIERS[[7]][2]/1000)),col="blue",pch=6,type="o",lty="soli
d")
points(c(8,8),c(trunc(OUTLIERS[[6]][3]/1000),trunc(OUTLIERS[[7]][3]/1000)),col="blue",pch=6,type="o",lty="soli
d")
#######################  5eme GRAPHIQUE ##################################
#chargement d'une des tables de résultats (l'intitulé de table donne le périmètre)
Graph_AUTO_F1_F1<-Graphiques_resultats[20:35,2:11]
View(Graph_AUTO_F1_F1) #visualisation pour vérification
# définition d'un tableau de référence à peupler qui servira à "plotter" des valeurs
array(,c(15,9))->GRAPH
View(GRAPH)
for (j in 1:15)
{  for (i in 2:10) Graph_AUTO_F1_F1[[i]][j]->GRAPH[j,i-1]}
as.numeric(GRAPH)->GRAPH #conversion en numérique pour avoir des nombres à partir du dataframe
dim(GRAPH)=c(15,9) #dimensionnement du tableau des résultats
#round(GRAPH/1000)->GRAPH #données arrondies en kilo-euros pour les montants
#tracé de la courbe : paramètrage
abs=c(1,2,3,4,5,6,7,8,9)
names(abs)=c("2017Q1","2017Q2","2017Q3","2017Q4","2018Q1","2018Q2","2018Q3","2018Q4","2019Q1")
abs_min=min(GRAPH[c(1,2,3,4),],na.rm = TRUE)
abs_max=max(GRAPH[c(1,2,3,4),],na.rm = TRUE)
#construction du graphique
## pour avoir deux graphiques correspondant à deux solutions sur une même ligne
par(mfrow = c(1,1))
###1er des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Facteur de développement",main="Valorisation des facteurs de développement initiaux", sub="Activité Assistance Voyages (crédibilité 1/1 avec valorisation de type 2)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
```

```
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
points(abs,GRAPH[5,],col="blue",pch=8,type="o",lty="dotted")
#points(abs,GRAPH[11,],col="orange",pch=8,type="o",lty="dotted")

#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(3,3),c(OUTLIERS[[6]][4],OUTLIERS[[7]][4]),col="blue",pch=6,type="o",lty="solid")
points(c(4,4),c(OUTLIERS[[6]][5],OUTLIERS[[7]][5]),col="blue",pch=6,type="o",lty="solid")
points(c(7,7),c(OUTLIERS[[6]][6],OUTLIERS[[7]][6]),col="blue",pch=6,type="o",lty="solid")
###2eme des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Facteur de développement",main="Valorisation des facteurs de développement initiaux", sub="Activité Assistance Voyages (crédibilité 1/10 avec valorisation de type 4)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
#points(abs,GRAPH[5,],col="blue",pch=8,type="o",lty="dotted")
points(abs,GRAPH[11,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(OUTLIERS[[6]][7],OUTLIERS[[7]][7]),col="orange",pch=6,type="o",lty="solid")
points(c(4,4),c(OUTLIERS[[6]][8],OUTLIERS[[7]][8]),col="orange",pch=6,type="o",lty="solid")
points(c(6,6),c(OUTLIERS[[6]][9],OUTLIERS[[7]][9]),col="orange",pch=6,type="o",lty="solid")
#REMARQUE : sauvegarde du graphique avec les dimensions 750*500 (commande export de RStudio dans l'onglet Plots)
#######################  6eme GRAPHIQUE#####################################
#chargement d'une des tables de résultats (l'intitulé de table donne le périmètre)
Graph_AUTO_ULT_MIX<-Graphiques_resultats[38:53,2:11]
View(Graph_AUTO_ULT_MIX) #visualisation pour vérification
# définition d'un tableau de référence à peupler qui servira à "plotter" des valeurs
array(,c(15,9))->GRAPH
View(GRAPH)
for (j in 1:15)
{  for (i in 2:10) Graph_AUTO_ULT_MIX[[i]][j]->GRAPH[j,i-1] }
as.numeric(GRAPH)->GRAPH #conversion en numérique pour avoir des nombres à partir du dataframe
dim(GRAPH)=c(15,9) #dimensionnement du tableau des résultats
round(GRAPH/1000)->GRAPH #données arrondies en kilo-euros pour les montants
#tracé de la courbe : paramètrage
abs=c(1,2,3,4,5,6,7,8,9)
names(abs)=c("2017Q1","2017Q2","2017Q3","2017Q4","2018Q1","2018Q2","2018Q3","2018Q4","2019Q1")
abs_min=min(GRAPH[c(1,2,3,4),],na.rm=TRUE)
abs_max=max(GRAPH[c(1,2,3,4),],na.rm=TRUE)
#construction du graphique
## pour avoir deux graphiques correspondant à deux solutions sur une même ligne
par(mfrow=c(1,1))
###1er des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Charge à l'ultime (k€)",main="Valorisation des charges à l'ultime (k€)", sub="Activité Assistance Auto (crédibilité 1/1 avec valorisation de type 1)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
points(abs,GRAPH[4,],col="blue",pch=8,type="o",lty="dotted")
#points(abs,GRAPH[12,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(trunc(OUTLIERS[[6]][10]/1000),trunc(OUTLIERS[[7]][10]/1000)),col="blue",pch=6,type="o",lty="solid")
```

```
points(c(7,7),c(trunc(OUTLIERS[[6]][11]/1000),trunc(OUTLIERS[[7]][11]/1000)),col="blue",pch=6,type="o",lty="solid")
###2eme des deux graphiques
plot(abs,GRAPH[1,],col="red", type="o",tck=1,lty="solid", xaxt="n",ylim=c(abs_min,abs_max),cex.axis=1,xlab="Période de survenance",ylab="Charge à l'ultime (k€)",main="Valorisation des charges à l'ultime (k€)", sub="Activité Assistance Auto (crédibilité 10/1 avec valorisation de type 1)")
axis(1,at=c(1:9), labels=names(abs))
points(abs,GRAPH[2,],col="green",pch=16,type="o",lwd=2)
points(abs,GRAPH[3,],col="green",pch=16,type="o",,lwd=2)
#points(abs,GRAPH[4,],col="blue",pch=8,type="o",lty="dotted")
points(abs,GRAPH[12,],col="orange",pch=8,type="o",lty="dotted")
#rajout des points pour faire l'intervalle de confiance sur les cas hors canaux
points(c(1,1),c(trunc(OUTLIERS[[6]][12]/1000),trunc(OUTLIERS[[7]][12]/1000)),col="blue",pch=6,type="o",lty="solid")
points(c(7,7),c(trunc(OUTLIERS[[6]][13]/1000),trunc(OUTLIERS[[7]][13]/1000)),col="blue",pch=6,type="o",lty="solid")
```

7. Table des « outliers »

Numéro	Branche d'activité	Réseau bayésien mis en œuvre	Variable objet	Période	Borne inférieure	Borne supérieure	Proba (Montant initial) s	Proba (Montant initial) vs	Proba (Montant initial) vw	Proba (Montant initial) w	Proba (F1) s	Proba (F1) vs	Proba (F1) vw	Proba (F1) w
1	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "4"	Montant initial	2017Q1	6 718	7 527	0,234	0,234	0,254	0,278				
2	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "4"	Montant initial	2017Q2	6 779	7 589	0,102	0,116	0,128	0,654				
3	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "4"	Montant initial	2018Q4	7 959	8 960	0,454	0,088	0,074	0,384				
4	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "2"	Facteur F1	2017Q3	1,245	1,354					0,232	0,248	0,276	0,244
5	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "2"	Facteur F1	2017Q4	1,649	1,837					0,252	0,262	0,258	0,228
6	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "2"	Facteur F1	2018Q3	1,245	1,354					0,262	0,25	0,278	0,21
7	Assistance automobile	Test Crédibilité 1/10 avec valorisation des catégories "4"	Facteur F1	2017Q1	1,354	1,462					0,232	0,238	0,256	0,274
8	Assistance automobile	Test Crédibilité 1/10 avec valorisation des catégories "4"	Facteur F1	2017Q4	1,245	1,354					0,236	0,24	0,27	0,254
9	Assistance automobile	Test Crédibilité 1/10 avec valorisation des catégories "4"	Facteur F1	2018Q2	1,649	1,837					0,256	0,258	0,246	0,24
10	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "1"	Mixte	2017Q1			0,234	0,234	0,254	0,278	0,26	0,26	0,246	0,234
11	Assistance automobile	Test Crédibilité 1/1 avec valorisation des catégories "1"	Mixte	2018Q3			0,24	0,268	0,246	0,246	0,414	0,064	0,052	0,47
12	Assistance automobile	Test Crédibilité 10/1 avec valorisation des catégories "1"	Mixte	2017Q1			0,232	0,292	0,206	0,27	0,238	0,23	0,264	0,268
13	Assistance automobile	Test Crédibilité 10/1 avec valorisation des catégories "1"	Mixte	2018Q3			0,252	0,24	0,276	0,232	0,25	0,256	0,246	0,248
14	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "3"	Montant initial	2017Q1	203	239	0,286	0,058	0,054	0,602				
15	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "3"	Montant initial	2018Q2	152	188	0,44	0,074	0,112	0,374				
16	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "3"	Montant initial	2019Q1	143	179	0,468	0,048	0,024	0,46				
17	Assistance Voyages	Test Crédibilité 1/10 avec valorisation des catégories "1"	Montant initial	2017Q1	203	239	0,386	0,086	0,086	0,442				
18	Assistance Voyages	Test Crédibilité 1/10 avec valorisation des catégories "1"	Montant initial	2018Q2	188	224	0,4	0,086	0,076	0,438				
19	Assistance Voyages	Test Crédibilité 1/10 avec valorisation des catégories "1"	Montant initial	2019Q1	179	216	0,41	0,072	0,078	0,44				
20	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "3"	Facteur F1	2017Q1	2,125	2,497					0,02	0,02	0,026	0,934
21	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "3"	Facteur F1	2017Q4	2,125	2,497					0,446	0,034	0,032	0,488
22	Assistance Voyages	Test Crédibilité 10/1 avec valorisation des catégories "3"	Facteur F1	2017Q1	2,125	2,497					0,002	0,004	0,002	0,992
23	Assistance Voyages	Test Crédibilité 10/1 avec valorisation des catégories "3"	Facteur F1	2017Q4	2,497	2,993					0,527	0,001	0,001	0,471
24	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "1"	Mixte	2017Q2			0,288	0,06	0,054	0,598	0,05	0,044	0,046	0,86
25	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "1"	Mixte	2018Q2			0,44	0,074	0,112	0,374	0,04	0,062	0,022	0,876
26	Assistance Voyages	Test Crédibilité 1/1 avec valorisation des catégories "1"	Mixte	2018Q3			0,806	0,07	0,052	0,072	0,208	0,022	0,534	0,236

8. Impact sur le provisionnement du portefeuille BUSP (années 2017 et 2018)

Le tableau suivant indique les gains et pertes de ratios sinistres sur primes pour les périodes de survenance entre 2017 et 2018, par LOB et au global.

Période de survenance	LOB	Prime acquise (GEP -k€)	Charge à l'ultime DFM (k€)	Charge à l'ultime Réseau bayésien (k€)	Charge observée a posteriori (k€)	Ratio sinistres sur primes DFM (LR DFM)	Ratio sinistres sur primes Réseau bayésien (LR RB)	Ratio sinistres sur primes observé a posteriori	Ecart DFM/observé a posteriori	Ecart Réseau bayésien/observé a posteriori	Gain de précision sur le ratio	Gain de précision sur le ratio (valeur)
2017Q1	AUTO	16 343	9 329	11 447	10 110	57,08%	70,04%	61,86%	-4,78%	8,18%	NON	-3,40%
2017Q2	AUTO	16 830	9 450	10 723	11 586	56,15%	63,72%	68,84%	-12,69%	-5,12%	OUI	7,56%
2017Q3	AUTO	17 270	11 577	13 777	13 358	67,03%	79,77%	77,35%	-10,31%	2,43%	OUI	7,89%
2017Q4	AUTO	18 669	10 356	11 763	11 547	55,47%	63,01%	61,85%	-6,38%	1,16%	OUI	5,22%
2018Q1	AUTO	17 645	12 453	11 863	10 981	70,58%	67,23%	62,23%	8,34%	5,00%	OUI	3,34%
2018Q2	AUTO	17 821	13 626	12 946	12 090	76,46%	72,65%	67,84%	8,62%	4,80%	OUI	3,82%
2018Q3	AUTO	18 544	15 610	12 991	14 524	84,18%	70,06%	78,32%	5,86%	-8,26%	NON	-2,41%
2018Q4	AUTO	18 730	13 103	11 310	10 562	69,96%	60,39%	56,39%	13,57%	3,99%	OUI	9,57%
2017Q1	TRAVEL	3 627	680	676	607	18,74%	18,64%	16,72%	2,02%	1,92%	OUI	0,10%
2017Q2	TRAVEL	4 408	701	758	891	15,90%	17,20%	20,21%	-4,31%	-3,01%	OUI	1,30%
2017Q3	TRAVEL	5 333	1 339	1 201	1 232	25,11%	22,52%	23,10%	2,01%	-0,58%	OUI	1,44%
2017Q4	TRAVEL	2 796	940	582	604	33,60%	20,81%	21,60%	12,00%	-0,79%	OUI	11,21%
2018Q1	TRAVEL	3 148	568	554	610	18,06%	17,61%	19,38%	-1,32%	-1,76%	NON	-0,45%
2018Q2	TRAVEL	3 850	820	647	753	21,30%	16,82%	19,56%	1,75%	-2,74%	NON	-0,99%
2018Q3	TRAVEL	3 896	1 239	1 271	839	31,79%	32,63%	21,53%	10,26%	11,10%	NON	-0,84%
2018Q4	TRAVEL	2 544	763	776	578	30,01%	30,51%	22,71%	7,30%	7,80%	NON	-0,50%
2017Q1	HOME	4 705			1 574	-	-	33,45%				
2017Q2	HOME	5 655			1 671	-	-	29,55%				
2017Q3	HOME	5 879			1 887	-	-	32,09%				
2017Q4	HOME	5 461			1 909	-	-	34,96%				
2018Q1	HOME	378			32	-	-	8,43%				
2018Q2	HOME	383			40	-	-	10,49%				
2018Q3	HOME	455			44	-	-	9,75%				
2018Q4	HOME	536			31	-	-	5,82%				
2017Q1	LEGAL	866			247			28,57%				
2017Q2	LEGAL	919			243			26,45%				
2017Q3	LEGAL	964			261			27,08%				
2017Q4	LEGAL	960			342			35,61%				
2018Q1	LEGAL	1 074			597			55,56%				
2018Q2	LEGAL	1 022			778			76,11%				
2018Q3	LEGAL	1 044			504			48,33%				
2018Q4	LEGAL	1 070			432			40,37%				
2017Q1	GLOBAL	25 542			12 538	46,32%	54,60%	49,09%	-2,77%	5,51%	NON	-2,74%
2017Q2	GLOBAL	27 813			14 391	43,38%	48,17%	51,74%	-8,36%	-3,58%	OUI	4,78%
2017Q3	GLOBAL	29 446			16 737	51,16%	58,16%	56,84%	-5,68%	1,32%	OUI	4,37%
2017Q4	GLOBAL	27 885			14 402	48,58%	52,34%	51,65%	-3,07%	0,70%	OUI	2,37%
2018Q1	GLOBAL	22 245			12 220	61,36%	58,65%	54,93%	6,43%	3,71%	OUI	2,72%
2018Q2	GLOBAL	23 076			13 661	66,15%	62,45%	59,20%	6,95%	3,25%	OUI	3,70%
2018Q3	GLOBAL	23 939			15 911	72,67%	61,87%	66,47%	6,21%	-4,60%	OUI	1,61%
2018Q4	GLOBAL	22 879			11 603	62,63%	54,85%	50,71%	11,92%	4,14%	OUI	7,78%

Nom du réseau	Type de score	Structure du réseau	sous-score sur Val_In	sous-score sur Val_Init_min	sous-score sur nœud Trimest	sous-score sur nœud I	sous-score sur nœud F1_mi	sous-score sur nœud F1_min	Score
bn_auto_7	Logvraisemblance	[Trimestre][ValInit_minq][ValInit|ValInit_minq:Trimestre]	- 283	- 326	- 357				- 967
bn_auto_7	AIC	[Trimestre][ValInit_minq][ValInit|ValInit_minq:Trimestre]	- 331	- 329	- 360				- 1 021
bn_auto_7	BIC	[Trimestre][ValInit_minq][ValInit|ValInit_minq:Trimestre]	- 416	- 335	- 366				- 1 117
OtherBN1	Logvraisemblance	[Trimestre][ValInit][ValInit_minq|ValInit:Trimestre]	- 326	- 278	- 357				- 962
OtherBN1	AIC	[Trimestre][ValInit][ValInit_minq|ValInit:Trimestre]	- 329	- 326	- 360				- 1 016
OtherBN1	BIC	[Trimestre][ValInit][ValInit_minq|ValInit:Trimestre]	- 335	- 411	- 366				- 1 112
OtherBN2	Logvraisemblance	[ValInit][ValInit_minq][Trimestre|ValInit:ValInit_minq]	- 326	- 326	- 311				- 964
OtherBN2	AIC	[ValInit][ValInit_minq][Trimestre|ValInit:ValInit_minq]	- 329	- 329	- 359				- 1 018
OtherBN2	BIC	[ValInit][ValInit_minq][Trimestre|ValInit:ValInit_minq]	- 335	- 335	- 444				- 1 114
OtherBN3	Logvraisemblance	[ValInit][Trimestre|ValInit][ValInit_minq|Trimestre]	- 326	- 310	- 346				- 983
OtherBN3	AIC	[ValInit][Trimestre|ValInit][ValInit_minq|Trimestre]	- 329	- 322	- 358				- 1 010
OtherBN3	BIC	[ValInit][Trimestre|ValInit][ValInit_minq|Trimestre]	- 335	- 344	- 380				- 1 058
OtherBN4	Logvraisemblance	[ValInit][ValInit_minq|ValInit][Trimestre|ValInit_minq]	- 326	- 313	- 341				- 981
OtherBN4	AIC	[ValInit][ValInit_minq|ValInit][Trimestre|ValInit_minq]	- 329	- 325	- 353				- 1 008
OtherBN4	BIC	[ValInit][ValInit_minq|ValInit][Trimestre|ValInit_minq]	- 335	- 347	- 375				- 1 056
bn_auto_6	Logvraisemblance	[Trimestre][F1_minq][F1_min4q][F1|F1_minq:F1_min4q:Trimestre]			- 1 288	- 796	- 1 228	- 1 239	- 4 551
bn_auto_6	AIC	[Trimestre][F1_minq][F1_min4q][F1|F1_minq:F1_min4q:Trimestre]			- 1 291	- 988	- 1 231	- 1 242	- 4 752
bn_auto_6	BIC	[Trimestre][F1_minq][F1_min4q][F1|F1_minq:F1_min4q:Trimestre]			- 1 299	- 1 452	- 1 238	- 1 249	- 5 238
OtherBN5	Logvraisemblance	[F1][F1_minq][F1_min4q][Trimestre|F1_minq:F1_min4q:F1]			- 933	- 1 210	- 1 228	- 1 239	- 4 609
OtherBN5	AIC	[F1][F1_minq][F1_min4q][Trimestre|F1_minq:F1_min4q:F1]			- 1 125	- 1 213	- 1 231	- 1 242	- 4 810
OtherBN5	BIC	[F1][F1_minq][F1_min4q][Trimestre|F1_minq:F1_min4q:F1]			- 1 589	- 1 220	- 1 238	- 1 249	- 5 296
OtherBN6	Logvraisemblance	[F1][Trimestre][F1_min4q][F1_minq|Trimestre:F1_min4q:F1]			- 1 288	- 1 210	- 827	- 1 239	- 4 564
OtherBN6	AIC	[F1][Trimestre][F1_min4q][F1_minq|Trimestre:F1_min4q:F1]			- 1 291	- 1 213	- 1 019	- 1 242	- 4 765
OtherBN6	BIC	[F1][Trimestre][F1_min4q][F1_minq|Trimestre:F1_min4q:F1]			- 1 299	- 1 220	- 1 483	- 1 249	- 5 251
OtherBN7	Logvraisemblance	[F1][Trimestre][F1_minq][F1_min4q|Trimestre:F1_minq:F1]			- 1 288	- 1 210	- 1 228	- 794	- 4 520
OtherBN7	AIC	[F1][Trimestre][F1_minq][F1_min4q|Trimestre:F1_minq:F1]			- 1 291	- 1 213	- 1 231	- 986	- 4 721
OtherBN7	BIC	[F1][Trimestre][F1_minq][F1_min4q|Trimestre:F1_minq:F1]			- 1 299	- 1 220	- 1 238	- 1 450	- 5 207
OtherBN8	Logvraisemblance	[F1][Trimestre][F1_min4q|Trimestre:F1][F1_minq|F1_min4q]			- 1 288	- 1 210	- 1 190	- 1 046	- 4 734
OtherBN8	AIC	[F1][Trimestre][F1_min4q|Trimestre:F1][F1_minq|F1_min4q]			- 1 291	- 1 213	- 1 202	- 1 094	- 4 800
OtherBN8	BIC	[F1][Trimestre][F1_min4q|Trimestre:F1][F1_minq|F1_min4q]			- 1 299	- 1 220	- 1 231	- 1 210	- 4 960
OtherBN9	Logvraisemblance	[F1_min4q][Trimestre][F1|Trimestre:F1_min4q][F1_minq|F1]			- 1 288	- 1 010	- 1 197	- 1 239	- 4 734
OtherBN9	AIC	[F1_min4q][Trimestre][F1|Trimestre:F1_min4q][F1_minq|F1]			- 1 291	- 1 058	- 1 209	- 1 242	- 4 800
OtherBN9	BIC	[F1_min4q][Trimestre][F1|Trimestre:F1_min4q][F1_minq|F1]			- 1 299	- 1 174	- 1 238	- 1 249	- 4 960
OtherBN10	Logvraisemblance	[F1][F1_minq][F1_min4q|F1_minq:F1][Trimestre|F1_min4q]			- 1 253	- 1 210	- 1 228	- 988	- 4 679
OtherBN10	AIC	[F1][F1_minq][F1_min4q|F1_minq:F1][Trimestre|F1_min4q]			- 1 265	- 1 213	- 1 231	- 1 036	- 4 745
OtherBN10	BIC	[F1][F1_minq][F1_min4q|F1_minq:F1][Trimestre|F1_min4q]			- 1 294	- 1 220	- 1 238	- 1 152	- 4 904
OtherBN11	Logvraisemblance	[F1][F1_minq][F1_min4q|F1_minq:F1][Trimestre|F1_minq:F1]			- 1 127	- 1 210	- 1 228	- 988	- 4 553
OtherBN11	AIC	[F1][F1_minq][F1_min4q|F1_minq:F1][Trimestre|F1_minq:F1]			- 1 175	- 1 213	- 1 231	- 1 036	- 4 655
OtherBN11	BIC	[F1][F1_minq][F1_min4q|F1_minq:F1][Trimestre|F1_minq:F1]			- 1 291	- 1 220	- 1 238	- 1 152	- 4 901
OtherBN12	Logvraisemblance	[Trimestre][F1][F1_min4q|Trimestre:F1][F1_minq|F1:Trimestre]			- 1 288	- 1 210	- 1 079	- 1 046	- 4 623
OtherBN12	AIC	[Trimestre][F1][F1_min4q|Trimestre:F1][F1_minq|F1:Trimestre]			- 1 291	- 1 213	- 1 127	- 1 094	- 4 725
OtherBN12	BIC	[Trimestre][F1][F1_min4q|Trimestre:F1][F1_minq|F1:Trimestre]			- 1 299	- 1 220	- 1 243	- 1 210	- 4 972
OtherBN13	Logvraisemblance	[F1_min4q][F1_minq|F1_min4q][F1|F1_minq][Trimestre|F1_minq]			- 1 249	- 1 180	- 1 190	- 1 239	- 4 857
OtherBN13	AIC	[F1_min4q][F1_minq|F1_min4q][F1|F1_minq][Trimestre|F1_minq]			- 1 261	- 1 192	- 1 202	- 1 242	- 4 896
OtherBN13	BIC	[F1_min4q][F1_minq|F1_min4q][F1|F1_minq][Trimestre|F1_minq]			- 1 290	- 1 221	- 1 231	- 1 249	- 4 990
OtherBN14	Logvraisemblance	[F1_min4q][F1_minq|F1_min4q][F1|F1_minq][Trimestre|F1]			- 1 246	- 1 180	- 1 190	- 1 239	- 4 854
OtherBN14	AIC	[F1_min4q][F1_minq|F1_min4q][F1|F1_minq][Trimestre|F1]			- 1 258	- 1 192	- 1 202	- 1 242	- 4 893
OtherBN14	BIC	[F1_min4q][F1_minq|F1_min4q][F1|F1_minq][Trimestre|F1]			- 1 287	- 1 221	- 1 231	- 1 249	- 4 987

10. Synthèse bibliographique des méthodes de provisionnement en non vie

Le modèle de Mack (version stochastique de la méthode DFM)

Le modèle de Mack (*Mack, 1993*) est un modèle non-paramétrique (il ne fait pas appel à un modèle de distribution) qui permet d'estimer une marge d'erreur sur le montant des provisions. La méthode de Mack constitue le pendant stochastique de la méthode DFM. En effet, elle fait appel aux hypothèses du modèle DFM et détermine un estimateur $C_{i,n}$ sans biais de $\mathrm{E}\left[C_{i,n}|\mathcal{H}_n\right]$ (c'est-à-dire de l'espérance de la charge ultime connaissant l'information disponible aujourd'hui). De plus, ce modèle est markovien.

Hypothèses

Le modèle de Mack repose sur les trois hypothèses suivantes (dénommées H2,H3 et H4) :

Hypothèse H2 : les paiements cumulés $(\mathrm{C_{i,j}})_{\mathrm{j}\geq 0}$ sont indépendants quelle que soit l'année de survenance i, c'est-à-dire :

$$\forall \mathrm{i} \neq \mathrm{i}', (\mathrm{C_{i,j}})_{\mathrm{j}\geq 0} \text{ et } (\mathrm{C_{i',j}})_{\mathrm{j}\geq 0} \text{ sont indépendants}$$

Hypothèse H3 : il existe des paramètres $\mathrm{f}_0, \dots, \mathrm{f}_{\mathrm{n}-1}$ tels que :

$$\mathrm{E}\left[\mathrm{C_{i,j+1}}|\mathrm{C_{i,j}}, \dots, \mathrm{C_{i,0}}\right] = \mathrm{E}\left[\mathrm{C_{i,j+1}}|\mathrm{C_{i,j}}\right] = \mathrm{f_j} \times \mathrm{C_{i,j}}$$

Hypothèse H4 :

$$\mathrm{Var}\left[\mathrm{C_{i,j+1}}|\mathrm{C_{i,j}}, \dots, \mathrm{C_{i,0}}\right] = \mathrm{Var}\left[\mathrm{C_{i,j+1}}|\mathrm{C_{i,j}}\right] = \sigma^2{}_{\mathrm{j}} \times \mathrm{C_{i,j}} \text{ pour j = 0,..., n-1}$$

Estimation

Sous les hypothèses H2 et H3, il peut être montré, en utilisant la loi des espérances itérées :

$$\mathrm{E}\left[\mathrm{C_{i,n}}|\mathcal{H}_\mathrm{n}\right] = \mathrm{f_{j-1}} \times \mathrm{f_{j-2}} \times \dots \times \mathrm{f_{n-i}} \times \mathrm{C_{i,n-i}}$$

Ceci a pour conséquence que les estimateurs existant dans la méthode DFM $\hat{\mathrm{f}}_\mathrm{j}$ sont des estimateurs non biaisés et non corrélés de $\mathrm{f_j}$. Ainsi, l'estimateur DFM de la charge ultime pour l'année i est un estimateur non biaisé de $\mathrm{E}\left[\mathrm{C_{i,n}}|\mathcal{H}_\mathrm{n}\right]$ (*Hainaut, 2013*).

Un estimateur de la variance est donné par :

- Pour j = 0, 1, 2, ...n − 2 :

$$\hat{\sigma}_j^2 = \frac{1}{n-j-1} \sum_{i=0}^{i=n-j} C_{i,j} \left(\frac{C_{i,j+1}}{C_{i,j}} - \hat{f}_j \right)$$

- Si le dernier facteur de développement est égal à un et que les règlements sont supposés constants (tous les sinistres sont clos à cette date en n), on a $\hat{\sigma}_{n-1}^2 = 0$. Dans le cas contraire, on estime $\hat{\sigma}_{n-1}^2$ par :

$$\hat{\sigma}_{n-1}^2 = min\left(\frac{\hat{\sigma}_{n-2}^4}{\hat{\sigma}_{n-3}^4}, \hat{\sigma}_{n-2}^2, \hat{\sigma}_{n-3}^2\right)$$

Validation du modèle

L'hypothèse H2 peut être validée de la même manière qu'avec la méthode DFM en étudiant la volatilité des facteurs de développement individuels $f_{i,j}$.

De même, l'hypothèse H3 peut être validée graphiquement en utilisant des C-C plots. Il est également possible d'effectuer un test de non corrélation des facteurs de développement successifs, comme le test de Spearman (*Hubert et Guay, 2009*).

Pour tester l'hypothèse 4, il est possible de tracer le graphique des résidus normalisés en fonction de $C_{i,j}$, (*Fort, 2010*) où les résidus normalisés sont définis par :

$$r_{i,j} = \frac{Ci,j - \hat{f}_j Ci,j}{\sqrt{C_{i,j}}}$$

Les résidus ne doivent pas présenter de tendance.

Erreurs de prédiction

Le modèle de Mack permet d'obtenir un estimateur de la variance des provisions :

$$\widehat{Var[R_i^u|\mathcal{H}_n]} = \hat{C}_{i,n}^2 \sum_{j=n-i}^{j=n-1} \frac{\hat{\sigma}_j^2}{\hat{f}_i} \frac{1}{\sum_{i=0}^{i=n-j} C_{i,j}}$$

L'erreur de prédiction MSEP (Mean Squared Error of Prediction) de l'estimation de la charge ultime $\widehat{R}_i^u$ pour les sinistres survenus durant l'année i est donnée par :

$$\text{MSEP}\left(\widehat{R}_i^u\right) = E\left[\left(\widehat{R}_i^u - R_i^u\right)^2 | \mathcal{H}_n\right]$$

La MSEP quantifie la différence entre l'estimation de la provision $\widehat{R}_i^u$ et la vraie valeur (aléatoire) R_i^u, la différence étant mesurée en terme d'écarts quadratiques espérés. Il peut être montré que :

$$\text{MSEP}\left(\widehat{R}_i^u\right) = \widehat{Var}[R_i^u|\mathcal{H}_n] + \left(E[R_i^u|\mathcal{H}_n] - \widehat{R}_i^u\right)^2$$

Une estimation de la MSEP pour les réserves à l'ultime correspondant aux sinistres survenus en année i est alors :

$$\widehat{\mathrm{MSEP}}\left(\hat{R}_i^u\right) = \hat{C}_{i,n}^2 \sum_{j=n-i}^{j=n-1} \frac{\hat{\sigma}_j^2}{\hat{f}_j}\left(\frac{1}{\hat{C}_{i,j}} + \frac{1}{\sum_{i=0}^{i=n-j} C_{i,j}}\right)$$

De même, Mack dérive un estimateur de la MSEP pour la réserve ultime totale.

Remarque pour l'usage du modèle de Mack dans le contexte d'un calcul de VaR :

Comme Mack considère un modèle non-paramétrique, avec seulement des hypothèses sur les deux premiers moments, il n'est pas possible d'obtenir la distribution complète des réserves. Seuls les deux premiers moments sont disponibles. Il n'est donc pas possible de calculer avec ce modèle une VaR à 99,5% par exemple, dans une perspective de solvabilité.

Cependant, en pratique, une hypothèse de distribution sur les réserves est généralement faites (par exemple la normalité ou la log-normalité) afin d'obtenir des quantiles des provisions à l'ultime.

La famille des méthodes s'appuyant sur l'exposition

La méthode du Ratio Sinistres/ Primes attendu (ou ELR –« Expected Loss Ratio »-)

La méthode ELR projette la charge à l'ultime comme le produit d'un ratio Sinistres/Primes par l'exposition du contrat (c'est-à-dire la prime acquise sur la période). Le ratio Sinistres/Primes est connu avant que le triangle ne se développe.

La méthode de Bornehuetter-Ferguson (BF)

La méthode BF (*Bornehuetter et Ferguson, 1972*) calcule la charge à l'ultime comme la somme pondérée des pertes déjà constatées et d'une provision de charges restantes calculée sur la base d'un ratio Sinistres/Primes a priori (en utilisant la prime acquise).

Pratiquement, une information complémentaire sur la sinistralité a priori (par le biais d'un ratio « sinistres sur primes ») est incorporée dans le triangle de développement sur la partie du triangle qui n'est pas encore développé. Ceci permet de prendre en considération l'expérience qui n'est pas dans le triangle (par exemple dans le cas d'un triangle de développement des sinistres payés, il y a dans le triangle l'information sur ce qui est déjà payé).

La méthode de Bornehuetter-Ferguson modifiée (MBF) –« Modified BF »-

La méthode MBF (*Pentikaïnen et Rantala, 1995*) est identique à la méthode BF à l'exception de la détermination du ratio Sinistres/Primes modifié. Dans le cadre de la méthode MBF, le ratio Sinistres/Primes est défini comme celui qui permet en moyenne de retrouver les charges Sinistres/Primes à l'ultime constatée pour les années précédentes (quand les sinistres sont totalement développés).

La méthode de Benktander (BT)

La méthode de Benktander (*Mack, 2000*) est une variante de la méthode de Bornehueter-Ferguson pour laquelle le ratio Sinistres/Prime utilisé *a priori* est remplacé par un ratio construit par pondération (selon la crédibilité) de l'*a priori* avec l'expérience acquise dans le cadre de la méthode de développement des facteurs (DFM)

La méthode Cape-cod (CC)

La méthode Cape-Cod (*Boles et Staudt, 2010*) est une variante de la méthode de Bornehueter pour laquelle le ratio Sinistres/Primes utilisé *a priori* vaut la valeur moyenne des ratios sinistres sur prime constaté pour les années précédentes. Ces ratios sinistres sur primes sont déterminés comme le rapport des pertes constatées (la dernière diagonale) à la prime acquise jusqu'à l'année en cours.

La famille des méthodes de régression

La régressions aux moindres carrés (LS) -« Least Square »-

La méthode de développement aux moindres carrés (*Brosius, 1993*) établit de façon itérative pour chaque cohorte (sinistres par année de survenance), en partant de la dernière créée, une relation de régression entre les pertes constatées et la charge à l'ultime. Chaque relation de régression produit de nouvelles valorisations de la charge à l'ultime qui sont réutilisées dans la régression suivante.

Les régressions multivariées (MV)

De nombreux modèles de régression multivariée existent. Comme il serait très compliqué de décrire tous les variétés incluant des données indépendantes ou non, il est souligné (*Boles et Staudt, 2010*), à titre d'exemple un modèle ou les pertes sont fonction à la fois des réserves dossier par dossier et des pertes cumulées réalisées au moment de la période de comptage précédente. La détermination des pertes sur la dernière diagonale, par itération, conduit à la détermination de la charge de sinistres à l'ultime.

Le modèle log-linéaire de Verral (LL)

Les régressions log-linéaires ont été développés par Verral (*Boles et Staudt, 2010*). La raison d'être de ce type de modèle est de pallier aux faiblesses de la méthode DFM : avec cette méthode, toutes les années de survenance sont traitées de façon indépendante, ce qui se traduit par une multiplication des paramètres, et par conséquent des prévisions aléatoires liés à la non-robustesse de ceux-ci.

De plus le développement des sinistres est unique par hypothèse du modèle. Or en réalité, ce développement peut devenir différent.

Concrètement, l'hypothèse est faite que les pertes suivent une distribution log-normale. La méthode consiste alors à fabriquer la distribution normale par changement de variable, puis

à résoudre le système multivarié *ad hoc*, ce qui est pertinent car les outils statistiques et algébriques sont disponibles.

La famille des méthodes fréquence-gravité

Le modèle Adler-Kline (AK)

Le modèle d'Adler-Kline (*Boles et Staudt, 2010*) est un modèle fréquence-gravité pour lesquels le nombre de sinistres fermés est multiplié par la valeur projetée du coût de sinistre. Tout d'abord, le nombre de sinistres clos est calculé avec un ratio qui lie les sinistres fermés aux sinistres ouverts, sachant que les sinistres ouverts sont développés en projetant les sinistres reportés jusqu'à l'ultime, puis à déduire les sinistres déjà fermés. Le nombre de sinistres ouvert, et le ratio sinistres ouverts/sinistres fermés permet d'accéder au nombre de sinistres fermés à l'ultime. La détermination de la gravité est revue selon la tendance dégagée en observant chaque année de survenance. Cette méthode est typiquement applicable dans les LOB pour lesquels les sinistres sont reportés rapidement.

Le modèle de Fischer-Lange (FL)

Le modèle de Fisher et Lange (*Fischer et Lange, 1973)* est similaire à celui d'Adler et Kline (voir ci-dessus). Cependant la distinction tient à l'obtention des ratios de sinistres clos, c'est-à-dire la fraction de sinistres clos par rapport aux sinistres vus à l'ultime. Ce nombre de sinistres à l'ultime est quant à lui obtenu par la méthode DFM appliquée au nombre de sinistres reportés (à la différence de la méthode AK (voir ci-dessus) qui s'appuie sur le rapport de transformation entre le nombre de sinistres fermés par rapport au nombre de sinistres ouverts). L'usage des données de sinistres reportés est primordial parce que le développement des sinistres n'est pas encore tangible.

Les modèles fréquence-gravité de Ghezzi (GH)

Deux modèles existent (*Ghezzi, 2001*).

Tout d'abord, les nombre de sinistres clos futurs peuvent être projetés en appliquant un ratio de passage des sinistres ouverts aux sinistres fermés. La gravité à l'ultime est quant à elle obtenue sur une hypothèse de croissance des gravités constatées pour les sinistres clos. La prévision de la charge de sinistres est obtenue en multipliant, pour chaque année de survenance, la fréquence et la gravité qui sont prévues par le modèle. La particularité de ce modèle tient à ce que seuls les ratios antérieurs aux changements significatifs sont considérés.

Une autre approche est de considérer les montants de sinistres ouverts en utilisant la méthode DFM sur les sinistres payés ou reportés, et en soustrayant le montant des sinistres déjà payés. Pour la détermination de la fréquence des sinistres ouverts, le processus est similaire : estimer le nombre de sinistres à l'ultime avec la méthode DFM sur le nombre de sinistres reportés ou clos. La projection de la gravité se fait de façon analogue en faisant une hypothèse sur la croissance de la gravité.

Le modèle fréquence-gravité sur données cumulatives (FS) –« Frequency-Severity »-

L'idée simple de faire le produit de la fréquence et de la gravité qui sont déterminés indépendamment en utilisant la méthode DFM. Le produit des deux valorisations obtenues (gravité à l'ultime et fréquence à l'ultime) fournit la charge à l'ultime. Ce modèle contraste avec les autres modèles fréquence-gravité déjà mentionnés parce qu'il s'appuie sur des triangles de données cumulées.

La famille des méthodes sur provision dossier par dossier

Le développement des provisions dossier à dossier de Marker-Mohl (MM)

Cette méthode récursive (*Marker et Mohl, 1980*) de développement des provisions dossier par dossier démarre en calculant la fraction de sinistres payés (par rapport aux provisions dossier par dossier, sur les années de survenance antérieures) et la fraction de provisions dossier par dossier payés (par rapport aux provisions dossier par dossier, sur les années de survenance antérieures). Par itération, ces ratios sont appliqués aux nouvelles provisions de dossier par dossier pour produire une estimation future du paiement de sinistres et de la provision dossier par dossier pour toutes les étapes du développement. Cette méthode s'applique bien pour les LOB pour lesquels les sinistres sont reportés plutôt rapidement.

Le développement de provision dossier par dossier de Atkinson (ACD)

C'est une méthode DFM appliquée aux provisions dossier par dossier (*Atkinson, 1989*) qui se déroule en faisant l'hypothèse que les facteurs de développement des sinistres reportés et payé (qui sont fournis extérieurement, comme un « benchmark ») sont légitimes. Puis, en utilisant la relation qui lie les provisions dossier par dossier aux sinistres reportés et payés, il est possible de dériver des facteurs de développement pour les provisions dossier par dossier. Ils sont alors exploités pour calculer la charge à l'ultime.

La famille des méthodes incrémentales

La méthode multiplicative incrémentale (IM) -« Incremental Multiplicative »-

La méthode multiplicative incrémentale (*Boles et Staudt, 2010*).utilise les pertes incrémentales pour calculer des facteurs de développement, qui s'apparentent à des « ratios de diminution », définis comme le rapport de pertes entre deux périodes. Avec ces ratios, il est possible d'extrapoler les futurs paiements incrémentaux, pour compléter le triangle des sinistres payés avec les projections de paiements futurs.

La méthode incrémentale additive (IA) -« Incremental Addititive »-

La méthode incrémentale additive (*Boles et Staudt, 2010*).utilise à la fois le triangle des pertes incrémentales et l'exposition de chaque cohorte (année de survenance des sinistres). Les ratios incrémentaux additifs sont calculés comme le rapport des sinistres payés à l'exposition (qui aura été corrigé de l'effet de l'inflation) pour chaque cohorte. De cette façon se constitue

une valorisation des pertes incrémentales pour chaque période et pour chaque année de survenance. Ces informations inscrites dans le triangle sont utilisés pour projeter les sinistres futurs.

La méthode du ratio sinistres sur primes complémentaire de Bühlmann (CLR) - «Complementary Loss Ratio »-

La méthode du ratio de sinistres sur primes complémentaire ((*Boles et Staudt, 2010*).permet le calcul des projections de paiements de sinistres incrémentaux en utilisant la continuation de la tendance des paiements historiques dans le futur, pour des périodes d'évaluation analogues. Ces projections de paiements incrémentaux sont alors sommées pour produire un estimé des pertes cumulées à venir.

Encore d'autres méthodes

La méthode Munich Chain Ladder

Il est fréquent de constater que les calculs de provisions à l'ultime sont souvent divergentes, si la base retenue est un triangle de sinistres payés ou un triangle de sinistres survenus. Cet écart n'est pas le moindre problème : la projection obtenue avec le triangle de sinistres payés peut être parfois supérieure, parfois inférieure à celle obtenue avec le triangle de sinistres survenus. La méthode dénommée « Munich Chain Ladder » (*Quarg et Mach, 2008*) s'appuie sur le degré de corrélation entre les montants de sinistres survenus et payés pour pallier aux anomalies présentées (comportement erratique des deux valorisations).

En utilisant la relation (linéairement approximée) qui lie les sinistres payés au ratio I/P (rapport des montants de sinistres survenus aux sinistres payés), et en utilisant ses résidus, il est possible d'estimer la corrélation, et la valeur du facteur de développement avec la relation, puis de l'injecter dans le triangle ad hoc pour calculer une projection de sinistre à l'ultime.

L'ajustement de Berquist-Sherman pour changement du taux de sinistres clos (BSCS)

Cette méthode (*Berquist et Sherman, 1977*) a pour objet de compenser le changement de vitesse de clôture des sinistres (qui semble être obsolète) dans un triangle de sinistres payés en utilisant pour chaque ligne, comme intermédiaire, des ratios synthétiques (décalés) du montant de sinistres clos par rapport au montant de sinistres à l'ultime, ce qui permet d'abord de réévaluer les montants de sinistres sur la diagonale, puis d'exploiter les cadences de la méthode DFM historique.

Du fait du changement de cadence (constaté sur la dernière ligne du triangle), le taux du nombre de sinistres payés a augmenté ou diminué. L'amplitude de ce changement (variation de taux) est estimée. Il faut ensuite utiliser la relation existant entre le taux de sinistres clos et le taux du montant de sinistres payés pour recalculer (par interpolation) les nouveaux ratios synthétiques de montant payé (en se déplaçant le long de la courbe caractéristique de cette relation). Cet exercice est réalisé pour chacun des éléments de la diagonale.

Par la suite, la méthode DFM (avec les coefficients historiques) peut être utilisée pour calculer le montant des paiements à l'ultime [19].

L'ajustement de Berquist-Sherman pour changement d'adéquation du niveau des réserves (BSRA)

Cette méthode (*Berquist et Sherman, 1977*) permet l'ajustement des provisions dossier par dossier à un niveau adéquat en utilisant la même logique que pour la méthode BSCS présentée ci-avant. Les montants de provisions dossier par dossier sur la dernière diagonale d'un triangle de provision dossier par dossier pour des sinistres ouverts sont ré-estimés en exploitant la relation existant entre le nombre de sinistres ouverts (calculé sur l'hypothèse de la nouvelle valorisation de la provision dossier par dossier) et la charge de sinistres (en lieu et place du nombre de sinistres fermés et du montant des sinistres payés dans la CSCS). La même logique d'interpolation s'applique pour construire une diagonale synthétique sur laquelle la méthode DFM est exploitée.

L'ajustement de Fleming-Meyer pour changement du taux de sinistres clos (FMCS)

L'ajustement de Fleming-Meyer (*Fleming et Meyer, 1998*) est analogue à celui de Berquist-Sherman (BSCS), à la différence que l'ajustement se fait sur les sinistres survenus et non pas sur les sinistres clos. La contribution du montant de sinistre payé (au montant de sinistre survenu) est faite selon la méthode BSCS, mais pour ce qui concerne la composante de provision dossier par dossier, elle est aussi ajustée, de façon analogue pour refléter l'éventuel changement de rythme dans la vitesse de clôture des sinistres.

La méthode London Chain Ladder

Cette méthode (*Jaziri, 2011)* fait partie des méthodes dites autorégressives qui s'appuient sur une hypothèse moins contraignante que la méthode DFM. Au lieu de considérer par hypothèse une stricte proportionnalité entre deux termes de développement successifs, l'hypothèse est amoindrie en faisant l'hypothèse d'une fonction affine entre ces deux termes.

$$C_{i,j+1} = f_j \times C_{i,j} + a_j \; pour \; i = 0, \dots, i - j - 1$$

Les paramètres $f_j \; et \; a_j$ sont estimés par la méthode des moindres carrés. Cette méthode demande bien évidemment de déterminer des paramètres plus nombreux, ce qui la rend plus contraignante.

La méthode London Pivot

Cette méthode (*Straub, 1988*) est un intermédiaire entre la méthode DFM et la méthode London-Chain Ladder. La relation qui relie deux termes de développement successif est une forme différente de proportionnalité :

$$C_{i,j+1} + a = f_j \times (C_{i,j} + a) \; pour \; i = 0, \dots, i - j - 1$$

Dans cette hypothèse le coefficient qui rend la relation affine ne dépend pas de l'année de survenance. Deux facteurs de développement successifs sont alors alignés. Les i+1 paramètres (f_j et a) sont estimés par la méthode des moindres carrés en utilisant les données du triangle. Il n'y a pas de solution analytique et un algorithme itératif est nécessaire, ce qui rend la solution contraignante à mettre en œuvre.

Liste des acronymes dans le cadre de la bibliographie des méthodes de provisionnenement en non vie :

ACD : développement des provisions dossier par dossier de Atkinson (traduction de « Atkinson Case Development »)

AK : méthode d'Adler-Kline

BF : Bornehuetter-Ferguson

BSCS : ajustement de Berquist-Sherman pour les taux de sinistres fermés (traduction de Berquist-Sherman for Claim Settlement rate)

BSRA : ajustement de Berquist-Sherman pour le niveau des provisions (traduction de Berquist-Sherman for case Reserve adequacy)

CLM : traduction de « Chain Ladder Method » (méthode de développement des facteurs de perte appelée aussi DFM)

CLR : traduction de méthode du ratio sinistres sur primes complémentaire (traduction de Complementary Loss Ratio)

CC : méthode Cape-Cod

FL : méthode des sinistres clos de Fisher-Lange

FMCS : ajustement de Fleming-Meyer pour les taux de sinistres fermés (traduction de Fleming-Meyer for Claim Settlement rate)

GH : modèle fréquence-gravité de Ghezzi

IA : méthode additive incrémentale (traduction de Incremental Additive)

IM : méthode multiplicative incrémentale (traduction de Incremental Multiplicative)

LL : modèles log-linéaires de Verral (traduction de « Log Linear »)

LS : Least Squares (traduction de régression aux moindres carrés)

MBF : Modified Bornehuetter-Ferguson (traduction de « Bornehuetter-Ferguson modifiée »)

MCL : la méthode Munich Chain Ladder

MM : méthode de provisionnement dossier par dossier de Marker-Mohl

MSEP : Mean Square Error of Prediction (traduction de la moyenne quadratique de l'erreur)

Mur LSL : Méthode de Murphy utilisant la paramétrisation de régression aux moindres carrés

Mur LSM : Méthode de Murphy utilisant la paramétrisation de régression aux moindres carrés multiplicatifs

Mur SA : Méthode de Murphy utilisant le développement en moyenne simple

Mur VWL : Méthode de Murphy utilisant le développement en moyenne pondérée

Mur GA : Méthode de Murphy utilisant le développement en moyenne géométrique

MV : régression multivariée (traduction de l'acronyme pour « multi variate »)

11. Mise en oeuvre du package BnLearn

11-A : liste des algorithmes disponibles dans la bibliothèque:

- Des algorithmes d'apprentissage de structure sous contrainte :
  - PC (« parents-children),
  - Grow-Shrink (GS),
  - Incremental Association Markov Blanket (IAMB),
  - Fast Incremental Association (Fast-IAMB),
  - Interleaved Incremental Association (Inter-IAMB),
  - Incremental Association with FDR Correction (IAMB-FDR),
  - Max-Min Parents & Children (MMPC),
  - Semi-Interleaved Hiton-PC (SI-HITON-PC),
  - Hybrid Parents & Children (HPC),
- Des algorithmes d'apprentissage de structure basés sur des scores :
  - Hill Climbing (HC),
  - Tabu Search (Tabu),
- Des algorithmes d'apprentissage de structure hybrides :
  - Max-Min Hill Climbing (MMHC),
  - Hybrid HPC (H2PC),
  - General 2-Phase Restricted Maximization (RSMAX2),
- Des algorithmes de découverte locale:
  - Chow-Liu,
  - ARACNE,
- Et des classificateurs de réseaux bayésiens :
  - Naive Bayes,
  - Tree-Augmented Naive Bayes (TAN).

11-B : liste des tests d'indépendance à exploiter pour l'apprentissage

- Données catégorielles (selon une distribution multinomiale) :
  - information redondante (paramétrique, semi-paramétrique et tests de permutation),
  - estimateur de réduction (« shrinkage-estimator ») pour l'information mutuelle,

    - test du χ^2 de Pearson (paramétrique, semi-paramétrique et tests de permutation),
- Données numériques ordinales :
    - Jonckheere-Terpstra (paramétrique et tests de permutation),
- Données numériques continues (distribution normale multivariée):
    - corrélation linéaire (paramétrique, semi-paramétrique et tests de permutation),
    - test Z de Fisher (paramétrique, semi-paramétrique et tests de permutation),
    - information redondante (paramétrique, semi-paramétrique et tests de permutation),
    - estimateur de réduction (« shrinkage-estimator ») pour l'information mutuelle,
- Données mixtes (distribution gaussienne conditionnelle) :
    - information redondante (paramétrique, semi-paramétrique).

11-C : liste des scores pour évaluer les algorithmes :

- Données catégorielles (distribution multinomiale) :
    - Logvraisemblance multinomiales,
    - Critère d'information d'Akaike (AIC),
    - Critère d'information Bayésien (BIC),
    - Score BDe de Dirichlet (BDe),
    - Score BD de Dirichlet (BDs),
    - Score BDJ de Dirichlet basé sur l'a priori de Jeffrey,
    - Score modifié Bayes-Dirichlet pour des mélanges de données observées et ajoutées
    - Score BDe en moyenne locale (BDla),
    - Score K2 score
- Données numériques continues (distribution normale multivariée):
    - La logvraisemblance gaussienne multivariée,
    - Critère d'information d'Akaike (AIC),
    - Critère d'information Bayésien (BIC),
    - Score BGe, équivalent gaussien à densité postérieure
- Données mixtes (distribution gaussienne conditionnelle) :
    - La logvraisemblance conditionnelle,
    - Equivalence du critère d'information d'Akaike (AIC),
    - Equivalence du critère d'information Bayésien (BIC).

11-D : fonctions effectivement mises en œuvre

- Pour la construction de réseaux:
    - Model2network() : cette fonction sert à fabriquer une structure de réseau à partir de sa définition littérale (sous la forme d'une chaîne de caractères qui est codifiée pour construire les liens dans le réseau),
    - Plot() : cette fonction sert à tracer un graphique représentatif de la topologie d'un réseau (c'est-à-dire le lieu des nœuds et des arcs),

- Summary() : cette fonction est générique. Elle a pour objet de fournir les informations concernant son objet (concrètement lui-même obtenu comme le résultat d'une fonction). Ces informations peuvent être constitutives ou de synthèse, selon le cas. Appliqué aux objets 'bn' qui sont des topologies de réseau, cette fonction fournit la liste des nœuds, la listes des arcs, et les liens existants entre arcs et nœuds.

- Pour la paramétrisation des réseaux :
  - Bn.fit() : cette fonction sert paramétrer le réseau (qui est juste une structure). Cette fonction appelle donc *a minima* deux variables qui sont d'une part le schéma topologique du réseau, et d'autre part une table de données permettant d'établir les relations entre les valeurs obtenus sur chacun des nœuds du réseau. Le résultat est concrètement un ensemble de tables de probabilités conditionnelles qui couvre l'ensemble des nœuds du réseau. Les contraintes à respecter sont d'une part des noms de nœuds qui correspondent aux colonnes de la table, et d'autre part, des formats d'information adaptés (par exemple pour faire des réseaux bayésiens discrets, les données doivent être données sous la forme de catégories). Finalement, les tables de probabilités conditionnelles peuvent être obtenues selon plusieurs méthodes de calibration. Par défaut, pour les données discrètes, c'est l'estimation du paramètre bayésien qui est mis en œuvre,
  - Summary() : cette fonction est générique. Elle a pour objet de fournir les informations concernant son objet (concrètement lui-même obtenu comme le résultat d'une fonction). Ces informations peuvent être constitutives ou de synthèse, selon le cas. Appliquée aux objets 'bn.fit' qui sont des réseaux bayésiens, cette fonction fournit la combinatoire de toute la collection des tables de probabilités conditionnelles qui existent dans le réseau.
- Pour l'inférence :
  - Predict() : cette fonction sert en particulier à faire du calcul d'inférence dans un réseau bayésien. Concrètement, quand de l'information à propos d'un (ou de plusieurs) nœud est recherchée, il suffit d'ajuster la valeur des nœuds du réseau qui sont connus (par expérience, ou par hypothèse) comme une variable de cette fonction, sachant que l'autre variable est le nom d'un réseau paramétré. Le résultat obtenu peut être selon les cas une probabilité ou une table de probabilité au cas particulier des hypothèses. Le réseau paramétré est un objet bn.fit, et l'hypothèse faite sur la valorisation des probabilités des nœuds est restitué sous la forme d'un « data-frame » (pour simplifier une table comportant les informations du contexte, nœud connu par nœud connu),
  - Attr() : cette fonction est générique. Elle a pour objet de fournir les attributs concernant son objet (comme cela est le cas pour des fonctions plus classique comme 'class' qui donne la classe d'un objet, ou 'dim' qui donne la dimension d'un tableau, ou 'names' qui restitue la liste des noms des variables dans un

tableau). Elle permet de récupérer la valeur de la probabilité obtenue lors de la prédiction sur un réseau bayésien, puisque l'inférence permet d'isoler une instance du réseau, au cas particulier des informations qui ont été définies.

Pour la manipulation des données, d'autres fonctions standards sont utiles :

- Pour le chargement des bibliothèques :
  - Library() : cette fonction est générique. Elle permet de charger la bibliothèque des fonctions dans le logiciel R, pour que celui-ci puisse exécuter les programmes représentatifs des fonctions qui sont mises en œuvre. Les bibliothèques utiles doivent systématiquement être appelées au démarrage d'une session de travail avec le logiciel R ou RStudio,
  - Factor() : cette fonction est utile pour formater un ensemble de données (disponible par défaut sous la forme d'un vecteur de format numérique ou alphanumérique) comme un collection de valeurs constitutives d'une catégorie. C'est une condition nécessaire de disposer les informations sous la forme de catégories pour pouvoir faire fonctionner un réseau bayésien discret sous BnLearn,
  - Data.frame() : cette fonction sert à structure de l'information (de manière très souple et très générale) sous la forme de listes de données formatées (qui doivent elles-mêmes êtres des vecteurs, des matrices… et des data-frames). C'est un format d'entrée important pour les objets utiles dans le cadre de l'exploitation de BnLearn,
  - View() : cette fonction est un utilitaire qui permet de publier des informations de type matricielle (tableaux d'information) sous la forme d'une table visible sous RStudio. Elle sert pratiquement à contrôler les informations dans les phases intermédiaires du programme (bon respect des chargements d'information, visualisation de la cohérence des résultats, etc.).

12. Complément d'instruction sur les réseaux bayésiens, leur fonctionnement et leurs potentialités

Propriétés

Couverture et bordure de Markov

Dans un réseau bayésien, une couverture de Markov (MB) d'une variable cible T est un ensemble de variables tel que conditionnellement à la connaissance de MB, T est indépendante de toutes les autres variables du réseau.

L'ensemble des couvertures de Markov de T a un ensemble minimal appelé « bordure de Markov » de T. Cet ensemble minimal est représenté dans le graphe par les parents, les enfants, ainsi que les autres parents des enfants (appelés les « époux ») de la variable T. Un exemple illustré est donné dans le graphe ci-dessous.

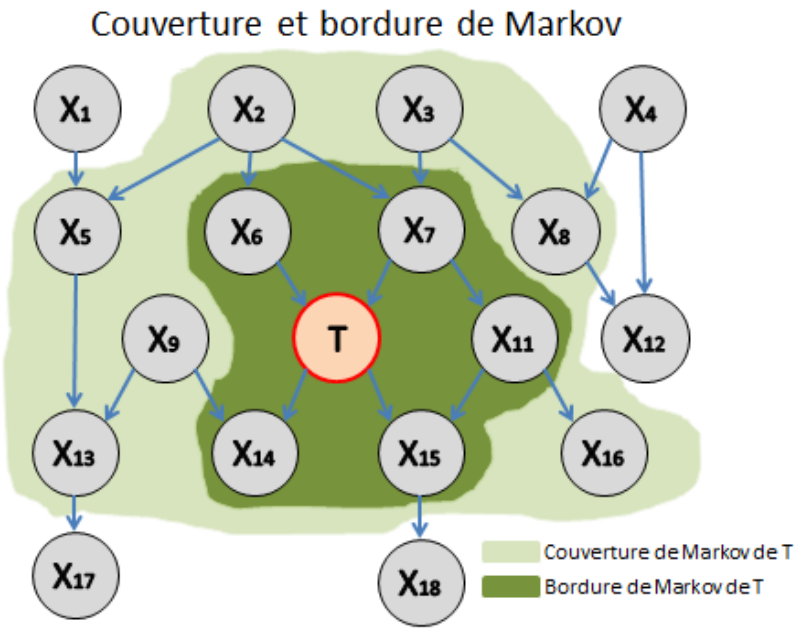

La couverture de Markov est particulièrement intéressante lorsqu'une analyse cible une variable en particulier, puisqu'elle renferme les variables les plus proches de la cible qui sont dépendantes. Cette couverture est utilisée à plusieurs fins : en classification, en sélection de variables ou en recherche de structure locale.

Apprentissage de paramètres à partir d'un jeu de données « complet »

Approche fréquentiste

L'apprentissage statistique consiste à estimer les probabilités conditionnelles en fonction de la fréquence d'apparition des événements dans le jeu de données. C'est l'approche par maximum de vraisemblance.

$$\hat{P}(X_i = x_k | pa(X_i) = x_j) = \frac{N_{ijk}}{\sum_k N_{ijk}}$$

avec N_{ijk} le nombre de fois où la valeur k est observée pour X_i lorsque ses parents sont dans la configuration x_j .

Apprentissage de paramètres à partir d'un jeu de données « incomplet »

Quand les données sont incomplètes, la démarche d'apprentissage des paramètres dépend de la nature plus ou moins aléatoire des données manquantes. Elles peuvent être totalement aléatoires (elles ne dépendent pas de la base de données), pseudo-aléatoires (elles dépendent des données observées) ou non-aléatoires. Dans les deux premiers cas, il est possible

d'estimer une distribution des données manquantes. Dans le dernier cas, il faut disposer d'autres informations.

Plusieurs approches ont été proposées pour cet apprentissage dont la plus connue est basée sur l'algorithme EM permettant l'estimation de la log-vraisemblance des valeurs manquantes. L'algorithme EM se répète en deux étapes jusqu'à convergence du maximum de vraisemblance, après avoir initialisé les valeurs manquantes :

- première étape E («espérance») : estimation des valeurs manquantes en calculant leur espérance selon les paramètres du modèle (ces valeurs sont initialisées aléatoirement lors de la première itération),
- deuxième étape M («maximisation») : estimation des paramètres par maximum de vraisemblance (de la même façon qu'avec les données complètes).

Une version de l'algorithme EM peut être adaptée à l'approche fréquentiste ou à l'approche bayésienne.

Apprentissage de la structure d'un réseau bayésien

Quand la structure du réseau bayésien (i.e. le graphe) n'est pas connue, le travail avec les réseaux bayésiens peut donc démarrer par une recherche de cette structure (le graphe) en faisant l'hypothèse que le système peut être lui aussi être modélisé par un réseau bayésien.

Les variables choisies pour le système suffisent à représenter toutes les indépendances du système (condition de suffisance causale), et tous les éléments sont présents dans les données pour les retrouver (condition de fidélité). Dès que le nombre de variables est conséquent, il est très rare qu'un graphe soit connu. La recherche d'un graphe bayésien peut être à dessein utilisée pour faire de l'inférence dans le graphe, mais la «simple» obtention de ce graphe peut aussi être un but en soi. Il est effectivement souvent intéressant d'avoir une image des relations entre variables qui prend en compte les propriétés d'indépendance conditionnelle inhérentes exclusivement à la modélisation par réseaux bayésiens. Retrouver une telle structure promet donc des résultats originaux.

Il faut néanmoins être conscient de deux limitations.

La première tient directement au nombre dit « super-exponentiel » de graphes dirigés sans circuit en fonction du nombre de variables. La formule suivante indique le nombre de graphes possibles :

$$G(n) = \sum_{k=1}^{k=n} (-1)^{k+1} \binom{n}{k} 2^{k(n-k)} G(n-k)$$

A titre d'exemple, le nombre de graphes possibles avec trois nœuds est 25, celui avec sept nœuds est d'environ 1 milliard, celui avec dix nœuds environ d'4.10^{18}. A partir d'un certain nombre restreint de variables, il est impossible de parcourir ou de tester de façon exhaustive tout l'espace des graphes. En conséquence, cela constitue une limitation combinatoire, dont le contournement (difficile) passera par la limitation de l'espace de recherche.

La deuxième limitation est liée à l'information au mieux contenue dans un jeu de données statiques. L'orientation des arcs n'est pas déductible du jeu de données, même si certaines orientations sont détectables en s'intéressant aux propriétés d'indépendance conditionnelle. En effet, rechercher une structure de réseau bayésien passe par l'estimation des lois conjointes de probabilité, et il a été expliqué précédemment (trois cas d'indépendance conditionnelle) que selon la configuration des liens, l'orientation était déductible.

Il existe deux familles de méthodes d'apprentissage de la structure d'un réseau. La première est basée sur des tests d'indépendance (approche dite « sous contrainte ») alors que la seconde est basée sur le calcul d'un score.

Approche « sous contrainte »

Une première méthode pour rechercher la structure d'un réseau est de tester l'indépendance entre toutes les paires de variables du jeu de données. A partir d'un graphe complet, une arête non-dirigée est supprimée entre les deux variables testées dès lors que le test les déclare significativement indépendantes. Ensuite, le graphe est modifié avec des tests d'indépendance entre deux variables, conditionnés à un ensemble de variables tierces. L'indépendance conditionnelle entre deux variables est testée en appliquant le principe de la d-séparation. Les tests généralement utilisés sont basés sur la statistique du χ^2.

Test du χ^2

Soient deux variables discrètes X_i et X_j, ayant respectivement la possibilité d'être dans r_i et r_j états. Par définition, X_i et X_j sont indépendantes si et seulement si :

$$\forall x_i, x_j \;\; P(X_i = x_i, X_j = x_{j)} = P(X_{i=} x_i) P(X_j = x_j)$$

Donc dans le jeu de données, l'estimation de $P(X_i)$ *et* $P(X_j)$ permet de montrer l'indépendance de X_i *et* X_j en calculant les fréquences, Xi et Xj. Elles sont en théorie indépendantes (i.e $X_i \perp X_j$) si pour tout état $X_{i=} x_i$ et $X_j = x_j$:

$$E(O_{ij}) = T_{ij} = \frac{N_{x_{i,\cdot}} N_{\cdot,x_j}}{N}$$

avec $N_{x_{i.}}$ comme le nombre de fois où Xi est observée dans la configuration X_i quelle que soit $x_{j)}$ et $N_{.,x_j}$ comme le nombre de fois où X_j est observée dans la configuration $x_{j)}$ quelle que soit x_i.

Le test du χ^2 d'indépendance compare le nombre d'éléments T_{ij} attendu sous l'hypothèse d'indépendance entre les deux variables X_i et X_j et le nombre d'éléments observés dans le jeu de données :

$$O_{ij} = N_{x_i,x_j}$$

La statistique en fonction des valeurs observées et des valeurs attendues sous l'hypothèse d'indépendance est calculée de la façon suivante :

$$S = \sum_{i=1}^{i=r_i} \sum_{j=1}^{j=r_j} \frac{(O_{ij} - T_{ij})^2}{T_{ij}}$$

L'approximation de la loi S par une loi de χ^2 permet la construction d'un test d'indépendance entre X_i *et* X_j. Si la valeur observée est inférieure au seuil du test choisi en fonction d'un risque de première espèce α, l'hypothèse d'indépendance entre les deux variables est acceptée. Une arête est alors ajoutée ou retirée du graphe en cours de construction selon la conclusion du test.

Un deuxième test : la G-statistique

Un autre test très couramment utilisé dans ce contexte est basé sur la G-statistique. La statistique observée (explicitée ci-dessous) est supposée suivre comme précédemment une loi de χ^2.

$$G^2 = 2 \sum_{i=1}^{i=r_i} \sum_{j=1}^{j=r_j} O_{ij}.ln\frac{O_{ij}.N}{T_{ij}}$$

Cette G-statistique présente l'avantage d'une meilleure robustesse par rapport à la statistique S.

Jusqu'à cette étape, le principe de la recherche de structure ne diffère pas d'une démarche de recherche de réseau de pertinence qui a été présenté ci-avant. Le développement ci-dessous présente la plus-value de l'approche par réseau bayésien (en vertu du principe de d-séparation).

Il s'agit de simplement adapter le calcul du χ^2 ou du G^2 en comptant $N_{x_{i,}}$ et N_{x_j} pour chaque configuration d'un ensemble de variables tierces $X_{k.}$ donnée. Cela revient à tester le critère d'indépendance suivant :

$$\forall x_i,x_j,\boldsymbol{x_k}\ \ P(X_i = x_i,X_j = x_j|X_k = \boldsymbol{x_k}) = P(X_{i=}x_i|X_k = \boldsymbol{x_k})P(X_j = x_j|X_k = \boldsymbol{x_k})$$

Dans le jeu de données, dans l'hypothèse où $X_i \perp X_j | X_k$ la théorie indique que l'égalité suivante est respectée :

$$T_{ijk} = \frac{N_{x_i,.,x_k} N_{.,x_j,x_k}}{N_{x_i,x_j,x_k}}$$

Les valeurs observées en fonction de $|X_k = \boldsymbol{x}_k$ sont :

$$O_{ijk} = N_{x_i,x_j,x_k}$$

Le calcul de S est alors :

$$S = \sum_{i=1}^{i=r_i} \sum_{j=1}^{j=r_j} \sum_{k=1}^{k=r_k} \frac{(O_{ijk} - T_{ijk})^2}{T_{ijk}}$$

Parallèlement, si la G-statistique est choisie, elle se calcule ainsi :

$$G^2 = 2 \sum_{i=1}^{i=r_i} \sum_{j=1}^{j=r_j} \sum_{k=1}^{k=r_k} O_{ijk} . ln \frac{O_{ijk} . N_{.,.,x_k}}{T_{ijk}}$$

Selon le graphe obtenu à l'étape précédente et les résultats des tests « conditionnés », le graphe peut se modifier le graphe de plusieurs façons :

- si X_i *et* $X_j$ne sont pas reliées par une arête, et que l'indépendance conditionnée à l'ensemble de variables X_k n'est pas vérifiée, une « dépendance conditionnelle » est déclarée, ce qui se traduit dans le graphe par une convergence de X_i *et* X_j versX_k,
- si X_i *et* X_j sont reliées par une arête, et que l'indépendance conditionnée à l'ensemble de variables X_k est vérifiée, une indépendance conditionnellement est déclarée, ce qui se traduit dans le graphe par une divergence ou une chaîne de X_i vers X_j en passant par X_k. Comme il n'est pas possible de décider entre les deux, la méthode se limite à dessiner les arêtes sans direction, et à supprimer l'arête entre X_i *et* X_j.

Il est obtenu au final un graphe partiellement dirigé représentant la classe d'équivalence de Markov regroupant tous les graphes dirigés supports de la même loi conjointe de probabilité. Les décisions de direction des arcs sont alors possibles, de façon aléatoire en évitant les cycles et un changement de classe markovienne.

Cette stratégie se heurte cependant à une limite directement liée au nombre de variables maximum à tester dans l'ensemble de conditionnement (X_k). En effet, d'une part le nombre de tests est exponentiel en fonction du nombre de variables, ce qui pose un problème combinatoire, et d'autre part le degré de liberté devient très faible rapidement lorsque la taille de X_k augmente, ce qui rend les tests inapplicables. C'est pourquoi des heuristiques « utilisables » ont été proposées :

- L'algorithme PC suit sensiblement le principe présenté, mais en choisissant l'ordre du test (i.e. la taille de X_k),
- Une stratégie nommée IC pour « Inductive Causation » similaire mais inverse aux deux approches qui viennent d'être présentées (en partant du graphe vide, avec les arêtes qui sont ajoutées au fur et à mesure des tests),
- Quelques améliorations ont été apportées par la suite à ces approches. Par exemple, l'approche « Bayesian Network Power Constructor » initialise la recherche à partir d'un graphe obtenu par la méthode d'arbre des poids maximum au lieu d'utiliser un graphe complet ou vide. Ce graphe est l'arbre dont la somme des poids affectés à chaque arête est maximisée. Ces poids peuvent être par exemple l'information mutuelle ou la corrélation,
- Enfin, des méthodes plus spécifiques puisqu'elles se focalisent sur une variable cible ont été par la suite développées, pour rechercher directement la couverture de Markov de cette cible sans rechercher tout le réseau.

Approches basées sur le calcul d'un score

Dans la partie précédente, des tests d'indépendances étaient produits pour ajouter ou supprimer des arêtes ou des arcs. Les approches basées sur un score sont radicalement différente dans leur principe. L'évaluation du réseau est faite en associant un score généralement basé sur la vraisemblance du graphe face aux observations. La stratégie de parcours de l'espace des graphes est la composante de l'approche qui choisit et propose le réseau à l'évaluation. Pour appliquer cette stratégie, d'une part une fonction de calcul de score est nécessaire (on parle parfois « d'oracle », car c'est elle qui guide le reste), d'autre part une stratégie de parcours de l'espace des graphes.

Tout comme pour l'estimation des distributions, le calcul du score peut être soit basé sur le calcul d'une vraisemblance, soit sur une probabilité a posteriori dans le cadre bayésien. Il est ici considéré ici uniquement un réseau bayésien à variables multinomiales. Comme l'apprentissage de structure passe par un apprentissage des paramètres à la volée, ce qui sera obtenu a posteriori est une collection de distributions multinomiales. A cet effet, la notion de lois conjuguées est introduite.

Les scores cités ici sont, soit issus de la famille bayésienne, soit basés sur la recherche de parcimonie. Les deux qualités essentielles pour un score sont d'une part leur décomposabilité, et d'autre part le respect des classes d'équivalence.

Décomposabilité et équivalence d'un score

Un score S est dit décomposable s'il est égal à une somme ou un produit de scores locaux c'est-à-dire calculé à partir de chacune des variables et de leur(s) parent(s).

$$S(B) = \sum_{i=1}^{i=n} s(X_i, P_a(X_i)) \; ou \; S(B) = \prod_{i=1}^{i=n} s(X_i, P_a(X_i))$$

Une fonction de score respecte les classes d'équivalence si elle attribue le même score à tous les graphes appartenant à une même classe d'équivalence de Markov.

Scores parcimonieux

Les scores parcimonieux formalisent le compromis entre vraisemblance et complexité d'un modèle. En effet, en cherchant uniquement à maximiser la vraisemblance (à cause de la corrélation positive avec le nombre de probabilités à estimer), les modèles ayant le plus de paramètres sont privilégiés de façon abusive au détriment de la recherche d'un bon modèle simple. C'est pourquoi les fonctions de scores parcimonieuses ajoutent un terme de pénalité à ce calcul de vraisemblance, qui croît avec la complexité du modèle. Un tel critère d'information a d'abord été introduit par Akaike en 1974 avec le score AIC, dont l'expression dans le cadre des réseaux bayésiens est introduite ci-après. Un prérequis est le calcul de la complexité d'un modèle bayésien.

Détermination de la complexité d'un réseau bayésien, introduction de la dimension du réseau

La complexité d'un réseau bayésien est une notion pouvant faire intervenir différents critères (le degré des nœuds, le nombre de modalités d'une variable, leur fonction de distribution). Une manière simple de formaliser cette complexité est de calculer la dimension du réseau, qui peut être écrite comme une somme de dimensions de chacune des variables :

$$Dim(B) = \sum_{i=1}^{i=n} Dim(X_i, B)$$

La dimension de chacune des variables $Dim(X_i, B)$ est le nombre de paramètres indépendants nécessaires pour la définir. Celui-ci dépend du nombre de configurations possibles r_i de X_i, ainsi que celui de l'ensemble de ses parents q_i :

$$Dim(X_i, B) = (r_i - 1)q_i$$

avec :

$$q_i = \begin{cases} 1 & si \; P_a(X_i) = \emptyset \\ \prod_{X_i \in P_a(X_i)} r_j & si \; P_a(X_i) \neq \emptyset \end{cases}$$

Exemple : calcul de la dimension du réseau RB ci-dessous :

Représentation d'un réseau bayésien avec ses états potentiels

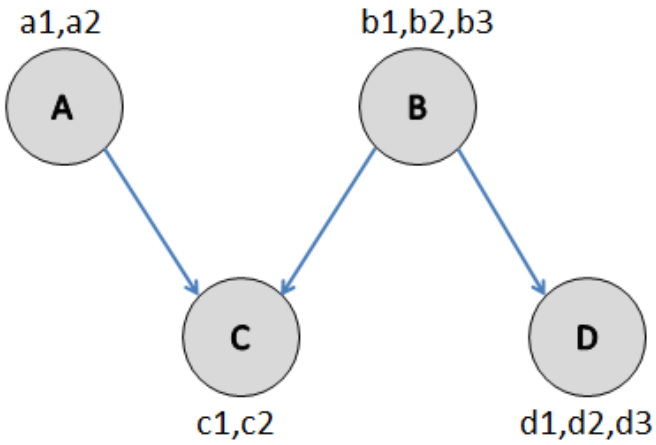

- Dim(A,RB) = (2 − 1) × 1 = 1
- Dim(B,RB) = (3 − 1) × 1 = 2
- Dim(C,RB) = (2 − 1) × (2 × 3) = 6
- Dim(D,RB) = (3 − 1) × 3 = 6
- Dim(B) = 1 + 2 + 6 + 6 = 15

Cette expression de la complexité peut être utilisée comme le terme de pénalité dans le calcul d'un score utilisant la vraisemblance, en considérant que maximiser cette dernière privilégie exagérément les modèles complexes (avec beaucoup de paramètres, et donc avec une grande dimension). Il reste à bien équilibrer la valeur du terme de vraisemblance et celle du terme de pénalité.

Quelques scores basés sur la recherche de parcimonie

La vraisemblance des paramètres du réseau utilisée ici s'appuie sur toutes les données. Pour mémoire,

$$\hat{P}(X_i = x_k | pa(X_i) = x_j) = \frac{N_{ijk}}{\sum_k N_{ijk}}$$

avec N_{ijk} le nombre de fois où la valeur k est observée pour X_i lorsque ses parents sont dans la configuration x_j. La vraisemblance pour un réseau bayésien B donné, s'écrit alors :

$$L(D|\Theta, B) = \prod_{i=1}^{i=n} \prod_{j=1}^{j=q_i} \prod_{k=1}^{k=r_i} \Theta_{ijk}^{N_{ijk}}$$

dont la transformation avec le logarithme s'écrit :

$$LL(D|\Theta,B)=\sum_{i=1}^{i=n}\sum_{j=1}^{j=q_i}\sum_{k=1}^{k=r_i}N_{ijk}log\Theta_{ijk}$$

et lorsque les paramètres sont estimés par maximum de vraisemblance :

$$LL(D|\Theta^{MV},B)=\sum_{i=1}^{i=n}\sum_{j=1}^{j=q_i}\sum_{k=1}^{k=r_i}N_{ijk}\,log\,\frac{N_{ijk}}{N_{ij}}$$

Score AIC

Une première fonction de score suivant ce principe a été directement adaptée du critère d'information d'Akaike et a été en toute logique nommée le score AIC.

$$AIC(B|D)=LL(D|\Theta^{MV},B)-Dim(B)$$

Score BIC

Le critère BIC (« Bayesian Information Criterion ») est une version modifiée du critère AIC, pour qu'il converge vers un score bayésien lorsque le nombre de répétitions dans la base D tend vers l'infini. Mais contrairement aux « vrais » scores bayésiens, il ne tient pas compte de la probabilité de la structure a priori.

$$BIC(B|D)=LL(D|\Theta^{MV},B)-\frac{1}{2}Dim(B)\log(n)$$

Scores bayésiens

Pour définir un score bayésien, l'écriture suivante est remarquable :

$$\frac{P(G_1|D)}{P(G_{12}|D)}=\frac{\frac{P(G_1,D)}{P(D)}}{\frac{P(G_2,D)}{P(D)}}=\frac{P(G_1,D)}{P(G_2,D)}$$

Cela signifie que la variation de $P(G|D)$ en fonction de différents graphes et à partir d'une même base d'apprentissage est la même que la variation de $P(G,D)$. Cette dernière valeur est donc utile pour le calcul d'un score :

$$P(G|D)=P(G)P(D|G)$$

Les scores bayésiens dépendent d'un *a priori*. Ils sont aussi parcimonieux, mais le terme pénalisant la complexité du graphe est moins explicite que pour les deux scores décrits précédemment. En effet, ce terme est pris en compte dans le calcul de la vraisemblance marginale du graphe $L(G|D)=P(D|G)$:

Vraisemblance marginale d'une structure

L'expression de la vraisemblance de la structure s'écrit :

$$P(D|G) = \prod_{i=1}^{i=n} \prod_{j=1}^{j=q_i} \frac{(r_i - 1)!}{(N_{ij} + r_{i-1})!} \prod_{k=1}^{k=r_i} N_{ijk}!$$

En prenant les *a priori* de Dirichlet sur les paramètres, le calcul de la vraisemblance marginale est simplifié (ceci évite l'utilisation des factorielles). Cela mène au score BD (Bayesian Dirichlet):

$$BD = P(B) \prod_{i=1}^{i=n} \prod_{j=1}^{j=q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(N_{ij} + \alpha_{ij})} \prod_{k=1}^{k=r_i} \frac{\Gamma(N_{ijk} + \alpha_{ijk})}{\Gamma(\alpha_{ijk})}$$

Ce score est intéressant, car il est plus rapide à calculer que les précédents, il peut tenir compte de probabilités a priori sur les structures et il est décomposable. L'inconvénient est que ce score n'est pas « markoviennement » équivalent. En rajoutant une contrainte sur les *a priori* de Dirichlet, le problème de non-équivalence markovienne est résolu. Pour ce faire, il est utilisé des probabilités conditionnées à leur valeur dans un graphe complètement connecté B_c, et un paramètre N' correspondant au nombre d'exemples équivalents défini directement par l'utilisateur :

$$\alpha_{ijk} = N' * P(X_i = x_k, pa(X_i) = x_j | B_c)$$

Il existe encore d'autres scores, soit parcimonieux, soit bayésiens. Pour n'en citer que certains, il y a le score MDL (Minimum Description Length), le score BDeu (qui simplifie les (*a priori*) du score BDe) et le score BDγ (aussi appelé score BDe généralisé).

Parcours de l'espace des graphes

Pour apprendre la structure d'un réseau à partir d'une base de données, le score ne suffit pas. Il faut « proposer » à ces fonctions des structures potentielles. Il suffirait donc de calculer un score pour tous les graphes possibles, puis de sélectionner la structure qui obtient le meilleur score. Comme la combinatoire empêche de calculer tous les scores dès lors que le nombre de nœuds excède quelques dizaines, la méthode restante consiste à parcourir l'espace des structures avec une stratégie de recherche la plus performante possible. Il existe plusieurs approches, que l'on peut combiner à des connaissances sur les variables du jeu de données.
L'utilisation d'un score décomposable est très fortement conseillée pour ne pas avoir à recalculer le score pour la totalité du graphe à chaque modification de celui-ci.

Parcours de l'espace de recherche sans information contextuelle

La stratégie de la recherche gloutonne est semble-t-il actuellement la plus utilisée. Le principe est de partir d'un graphe quelconque (vide ou autre), de calculer le score de celui-ci, puis de modifier le dit graphe. Partant d'un nœud pris au hasard, la modification proposée peut être l'ajout, la suppression, ou l'inversion d'un arc (voir schéma ci-dessous), tout en évitant l'introduction d'un circuit. Un nouveau score est calculé pour chacun des nouveaux graphes. Si la valeur obtenue est supérieure à la valeur précédente, on garde le nouveau graphe puis on relance une nouvelle modification. Cette étape est répétée jusqu'à obtenir un maximum, c'est-à-dire qu'aucune nouvelle modification ne conduise à un accroissement du score.

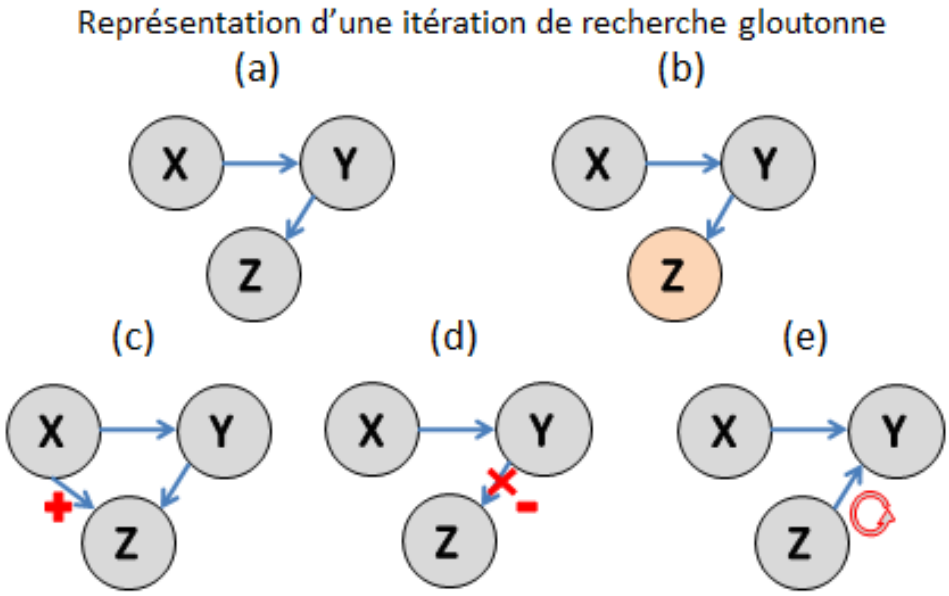

Représentation d'une itération de la recherche gloutonne au parcours de l'espace de recherche d'un graphe bayésien. (a) représente le graphe à l'itération i. En (b), l'algorithme a choisi aléatoirement la variable Z dont la modification des connexions va être testée. (c) Addition, (d) délétion et (e) inversion d'un arc, sont trois propositions de graphe à l'itération i + 1 si on se focalise sur Z. Un score est attribué à chacune d'entre-elles, puis la procédure retiendra celle qui a le score le plus important pour l'itération suivante.

Il y a un écueil: selon les choix opérés par l'algorithme au cours de son exploration de l'espace de recherche, la procédure conduit dans l'écrasante majorité des cas à un maximum local du score. Le contournement de ce problème est de recommencer la recherche en partant du graphe initial et de maximiser une nouvelle fois le score en proposant successivement de nouvelles structures, et ainsi de suite, sans jamais n'avoir la garantie d'obtenir un maximum global.

Une accélération de la procédure d'apprentissage de structure peut se faire par la réduction de l'espace de recherche de l'algorithme en parcourant l'espace des graphes équivalents de Markov au lieu de tous les DAG : la méthode GES (« Greedy Equivalence Search »). Pour éviter de « s'engouffrer » trop rapidement dans un maximum local, la démarche est de revenir un peu en arrière après avoir atteint un maximum local, pour avoir la possibilité de tester d'autres chemins sans repartir de zéro. C'est la philosophie des algorithmes de recuit simulé. L'analogie

a été empruntée au monde de la métallurgie : après la cuisson d'un métal, celui-ci peut être refroidi lentement pour être ensuite recuit afin de modifier ses propriétés.

L'algorithme utilisé généralement est celui de « Metropolis-Hastings ». Le comportement de cet algorithme est contrôlé par deux paramètres supplémentaires qui sont la température, et le refroidissement maximum.

13. Mécanisme de dé-catégorisation (pour constituer des montants initiaux exploitables pour les analyses actuarielles)

Pour la branche automobile

Le signal se décompose comme la tendance moyen terme et la valeur associée à la catégorie. A chaque fois qu'il est recherché une valeur à partir d'une catégorie, il faut donc aussi prendre en considération la cohorte, calculer la valeur obtenue en tendance moyen terme pour cette cohorte (c'est une information temporelle), et ajouter la valorisation dans la catégorie (voir dans le paragraphe ci-dessus, en suivant une règle, même si celle-ci introduit un biais).

Pour la branche voyage

Le signal se décompose aussi comme une tendance moyen-terme et une valeur associée à la catégorie. Mais dans ce cas précis, il y a un codage spécifique de la catégorie, car l'activité d'assistance voyage est très saisonnière et la catégorie mesure l'intensité du pic de sinistralité. Pour mémoire, le pic est mesuré relativement au pic maximal constaté dans l'historique en considérant sa hauteur, et qui est arbitrairement identifié comme valant 300 % de la valeur moyenne. Les autres pics sont étalonnés en conséquent (donc avec des valorisations entre 0 et 3). Un coefficient multiplicateur permet d'associer à cet étalonnage du pic sa grandeur (ce coefficient multiplicateur vaut donc un tiers de la valeur du pic maximal observé). Le mécanisme de dé-catégorisation est alors identique à celui présenté pour les montants initiaux de sinistres automobiles, la seule différence est que la catégorie permet de revenir à une valeur de grandeur de pic, et non pas à un montant directement. Comme précédemment aussi, cette dé-catégorisation entraîne automatiquement la création d'un biais parce que l'on passe d'un mode catégoriel discret à un mode numérique continu.

Tables des acronymes :

ACDM : modèle de données utile dans le cadre du processus actuariel (traduction de « Actuarial Core Data Model »)

AIC : critère d'information d'Akaike (traduction de « Akaike Information Criterion »)

BD : Bayesian Dirichlet (score bayésien incorporant une hypothèse avec une distribution de Dirichlet)

BF : Bornehuetter-Ferguson

BIC : critère d'information bayésien (traduction de « Bayesian Information Criterion »)

BU : Business Unit

CLM : traduction de « Chain Ladder Method » (méthode de développement des facteurs de perte appelée aussi DFM)

CY : année courant comptable (traduction de « Current Year »)

DAG : graphe dirigé sans circuit (traduction de « Direct Acyclic Graph »)

EAP : Espérance a posteriori

ELR : Expected Loss Ratio (traduction de Ratio Sinistres/Primes a priori)

EM : algorithme dit « expectation-maximisation »

IBNR : les tardifs (traduction de « Incurred But Not Reported »)

LOB : Ligne d'affaires/ ligne de produits (traduction de « Line of Business »)

MAP : Maximum a posteriori

MB : couverture de Markov (traduction de « Markov Blanket »)

MDDR : risques digitaux et appareils nomades (traduction de « Mobile Devices and Data Risks »)

PY : années comptables antérieures à l'année en cours (traduction de « Prior Year »)

RSA : Assistance automobile (traduction de « Roadside Assistance »)

T&A : Travel & Assistance

VAR : Value at Risk

Bibliographie

Articles :

ATKINSON, R. (1989). *Calculating IBNR based on Case* Reserves, CAS Forum, Fall 1989, 39-44.

BERQUIST, J. SHERMAN, R. (1977). *Loss Reserve Adequacy Testing: A Comprehensive Systematic* Approach, PCAS, Vol. LXVII, 123-184.

BOLES, T. STAUDT, A. (2010). *On the accuracy of Loss Reserving Methodology*, Casualty Actuarial Society , E-Forum, Fall 2010.

BORNHUETTER, R. FERGUSON, R.(1972). *The Actuary and IBNR*, PCAS, Vol. LIX, 181-195.

BROSIUS, E. (1993). *Loss Development using Credibility*, CAS Exam Study Note, 1-19.

FISHER, W. LANGE, J. (1973). *Loss Reserve Testing: A Report Year Approach*, PCAS, Vol.LX, 189-207.

FLEMING, K. MAYER, J. (1998). *Adjusted Incurred Loss for Simultaneous Shifts in Payment Patterns and Case Reserve Adequacy Levels*, CAS Discussion Paper Program, 189-214.

FRIEDLAND, J. (2009). *Estimating Unpaid Claims using Basic Techniques*, CAS.

GHEZZI, T. (2001). *Loss Reserving without Loss Development Patterns: Beyond Berquist*-Sherman, CAS Forum, Fall 2001, 43-104.

MACK, T. (1993). *Distribution-free calculation of the standard error of chain ladder reserve Estimate*, Astin Bulletin, 23(2).

MACK, T. (2000). *Credible Claims Reserve: The Benktander Method,* ASTIN Bulletin, Vol. 30, No. 2, 333-347.

MARKER, J. MOHL, J. (1980), *Rating Claims-Made Insurance* Policies, CAS Discussion Paper Program, 265-304.

MURPHY, D. (1993). *Unbiased Loss Development Factors*, PCAS, Vol. LXXXI, 154-222.

PENTIKÄINEN, T. RANTALA, J. (1995). *A Simulation Procedure for Comparing Different Claims Reserving Methods,* CAS Forum, Fall 1995, 128-156.

QUARG, G. MACK, T. (2008). *Munich Chain Ladder: A Reserving Method that Reduces the Gap between IBNR Projections based on Paid Losses and IBNR Projections based on Incurred Losses*, Variance, Vol. 2, Issue 2, 266-299.

Ouvrages :

HAINAUT, D. (2013). *Econométrie de l'assurance*, Cours 3A, ENSAE.

HASTIE, T. TIBSHIRANI, R. FRIEDMAN,J. (2008). *The elements of statistical learning : data mining inference and prediction*, second edition, Springer series in Statistics.

PARTRAT, C. LECŒUR, E. NESSI, J-M. NISIPASU, E. REIZ, O. (2007). *Provisionnement Technique en Assurance Non Vie : Perspectives actuarielles modernes,* Assurance Audit Actuariat. Economica.

Mémoires:

FORT, M. (2010). *Méthodes de provisionnement en assurance non-vie et extrapolation des triangles*, Mémoire IA, EURIA.

HABIB, I. RIBAN, S. (2012)..*Quelle méthode de provisionnement pour des engagements non-vie dans Solvabilité 2 ?*, Mémoire IA, ENSAE.

HUBERT, C. GUAY, P. (2009). *Mesure d'incertitude sur en provisionnement IARD : Modélisation des branches longues et traitement des valeurs extrêmes*, Mémoire IA, CEA.

JAZIRI, S. (2011). *Méthodes de provisionnement non-vie et risque de réserve à un an*, Mémoire IA, ISFA.

PRESTAT, E. (2010). *Les réseaux bayésiens : classification et recherche de réseaux locaux en cancérologie*, Thèse de doctorat, Sciences agricoles, Université Claude Bernard-Lyon I.