

# Fidélisation des assurés dans une mutuelle par des méthodes de machine learning, retour d'expérience



**Virginie Normand**

Responsable Domaine Décisionnel & Actuariat  
VIASANTE Mutuelle

**Vincent Dalon**

Responsable Pôle Actuariat  
VIASANTE Mutuelle



**Léonard Fontaine**

Associé  
Galea & Associés

**Alexandre Eby**

Manager  
Galea & Associés

## Fidéliser en santé Individuel : dans quel contexte?

### // Evolution de la réglementation en Santé

- // Résiliation Infra annuelle : **après un an, résiliation possible à tout moment**
- // Les contrats responsables et le 100% Santé : **encadrement des garantis (plafonds), augmentation des prestations**

### // Coûts d'acquisition : des coûts difficiles à réduire

- // Réseaux de distribution
- // Outils d'aide la vente, achat de lead..
- // Les parcours 100% digitaux...

### // Les comportements adhérents

- // Un départ peut être lié à une **insatisfaction** (possibilité de départ immédiat)
- // Des adhérents **satisfaits** changent d'assureur (démarchage de la concurrence, recommandation, remise en concurrence...)

## Prédire les « futurs radiés »

### // Objectifs de l'expérience

- // Identifier les adhérents avec **la plus forte probabilité** de se radier via un modèle machine learning
- // Définir une **démarche client adaptée** qui pourrait avoir un impact sensible sur la fidélité de l'adhérent

### // Projet d'entreprise :

- // Projet **transverse** : actuaires, data analystes, téléconseillers, marketing, communication
- // **Acculturation** des métiers aux enjeux et aux possibilités qu'ouvrent les études de machine learning
- // **Ouverture** des métiers de l'actuaire et des data analystes

### // Modélisation

- // Projet mené en interne
- // Volonté d'être accompagné à étapes clés

### // Cible : Go / No Go

- // Evaluer la **pertinence** du modèle
- // Mesurer **l'impact** de la démarche client
- // Go / No Go pour **industrialiser**

***Dans la présentation, les chiffres ont été modifiés***

# Modèle – données et méthodologie

## // Objectif :

// Attribuer une probabilité de radiation au cours de l'année → cas de la classification en apprentissage supervisé

## // Périmètre

- // Portefeuille individuel en gestion directe
- // Adhérents avec *a minima* 12 mois d'ancienneté au sein de la mutuelle
- // Motifs de radiation exclus : décès, départs vers le collectif et impayés

## // Contexte (exogène) :

- // RIA (1<sup>er</sup> décembre 2020)
- // Pandémie COVID-19


## // Données :

- // Adhérents : âge, département d'habitation, régime, ancienneté, composition familiale
- // Produits : gamme, multi-équipement, changements de produit
- // Techniques : cotisations, remboursements et reste à charge par risque, S/P produit
- // Relation client : réseau commercial d'origine, nombre et motifs de contacts CRC

# Modèle – calibrage et résultats


// Considérations techniques :

// Stabilité des résultats, arbitrage biais / variance

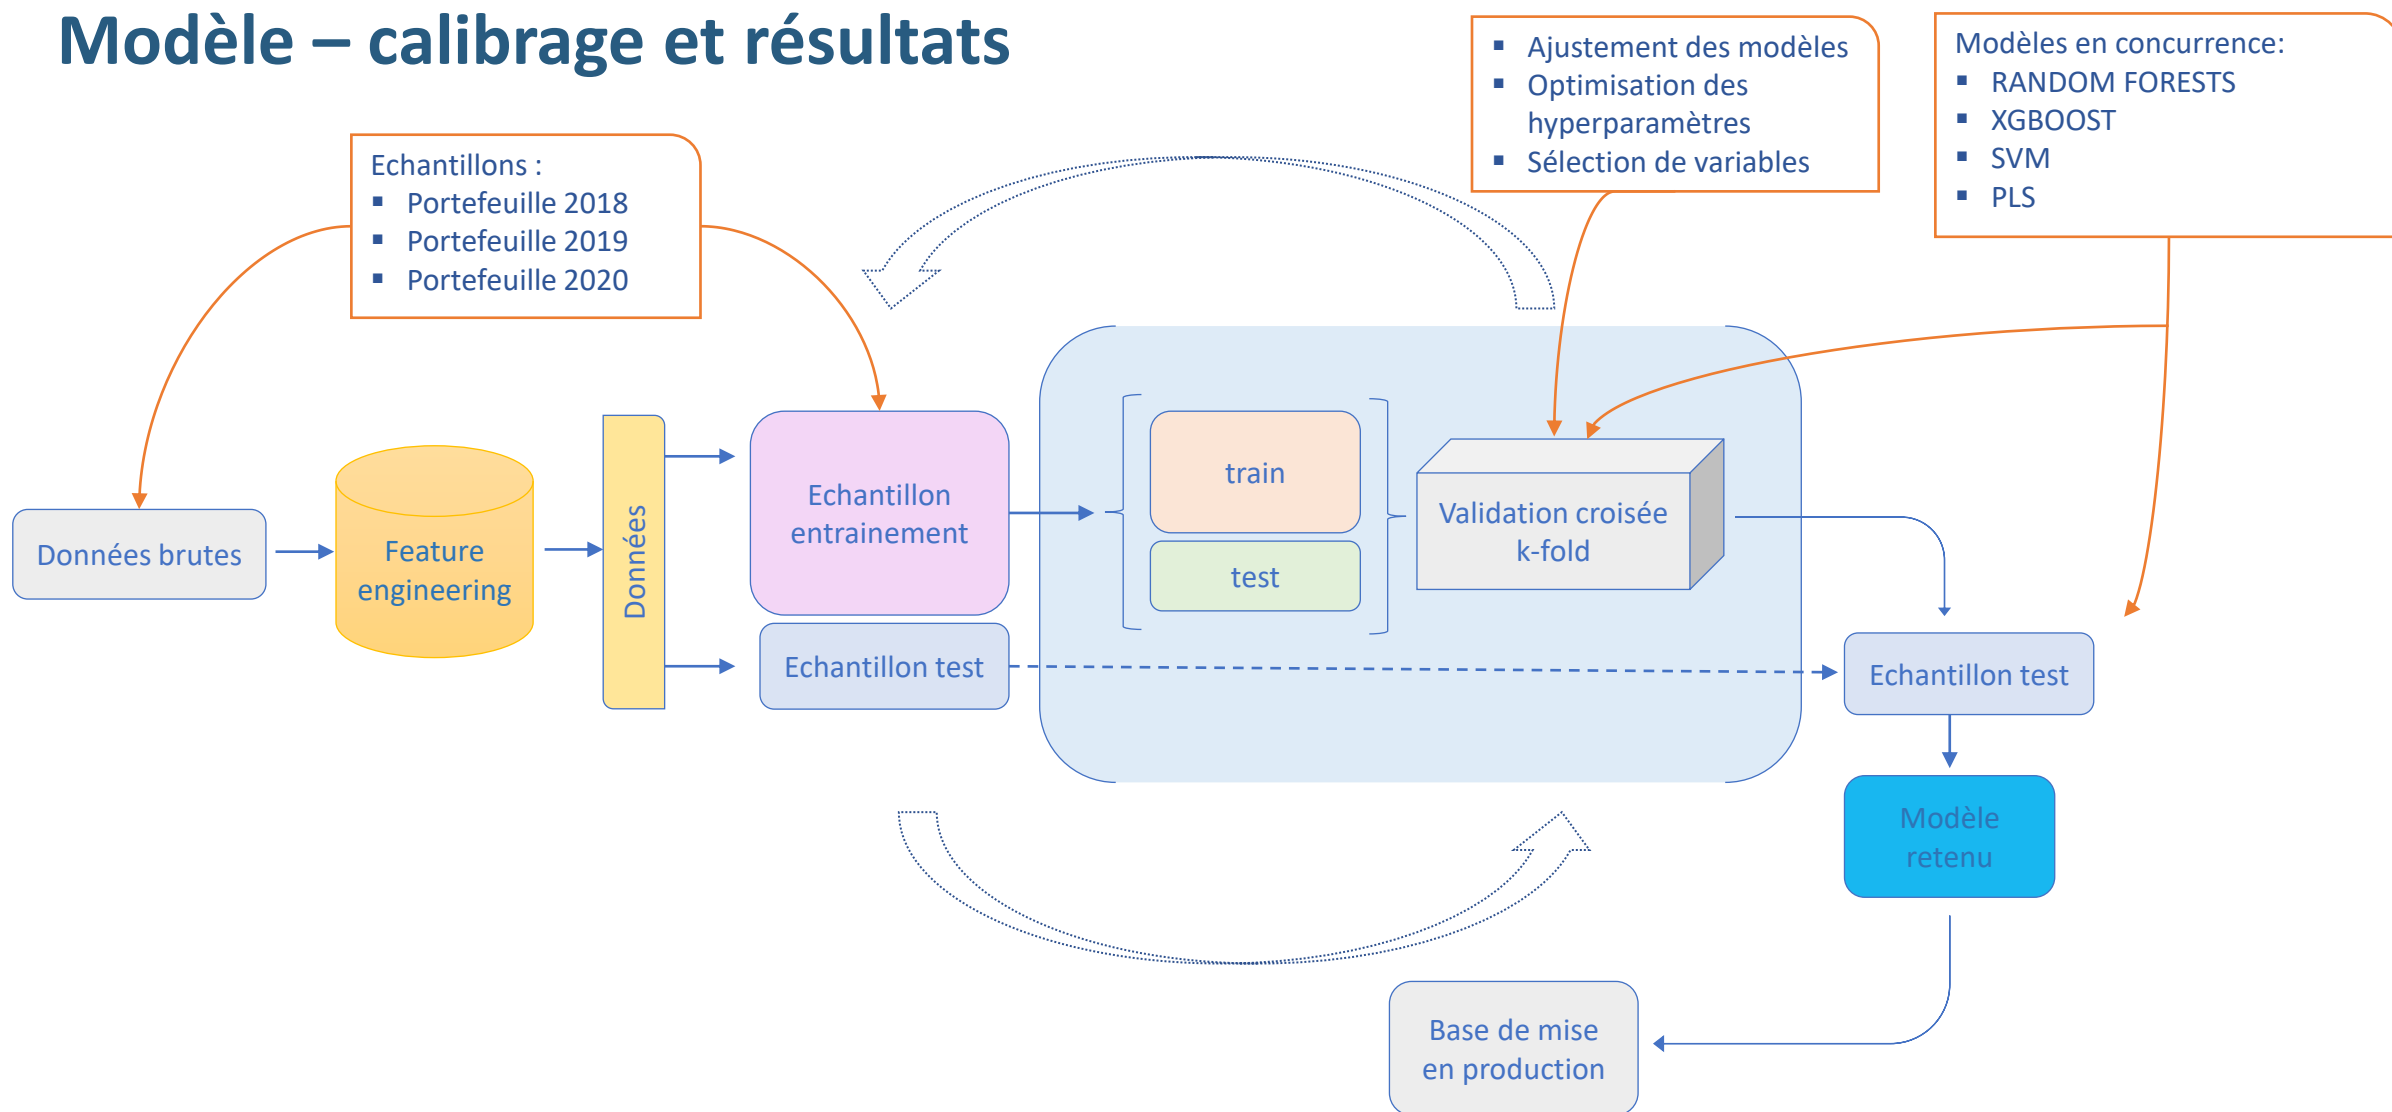


// Maximiser la pertinence d'un appel → critère de précision

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	<b>Sensitivity</b> $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	<b>Specificity</b> $\frac{TN}{(TN + FP)}$
		<b>Precision</b> $\frac{TP}{(TP + FP)}$	<b>Negative Predictive Value</b> $\frac{TN}{(TN + FN)}$	<b>Accuracy</b> $\frac{TP + TN}{(TP + TN + FP + FN)}$



# Modèle – calibrage et résultats



## Modèle – calibrage et résultats

Précision (calculée sur les 5% des plus hautes probabilités estimées)

Train	Test	Random Forest	XGBOOST
2018	2018	82%	45%
2019	2019	88%	55%
2020	2020	85%	68%
2018	2019	25%	38%
2019	2018	60%	71%

- // Random Forest surperforme XGBOOST sur une même année train / test
- // XGBOOST plus stable au changement d'échantillon

XGBOOST - précision

Train	Test	5% des plus hautes probabilités estimées	1% des plus hautes probabilités estimées
2018-2019	2018-2019	60%	73%
2018-2020	2018-2020	51%	90%

- // Modèle retenu : XGBOOST estimé / testé sur 2018-2019
- // La précision (TP/TP+FP) atteint 73% sur les 1% des adhérents avec la plus haute probabilité de radiation prédite


# Utilisation de SHAP pour l'interprétation du modèle retenu

- // SHAP donne une interprétation **locale** des modèles : chaque prédiction du modèle est décomposée en une somme de *shap values*
- // L'étude des distributions de l'ensemble des valeurs de Shapley peut permettre de déduire des influences globales à partir de valeurs locales. Pour ceci, on applique une approche par « élargissement progressif de la vue » :

Prédiction : shap values d'une ligne




« waterfall plot »




« force plot »

Variable : shap values d'une colonne pour l'ensemble des lignes



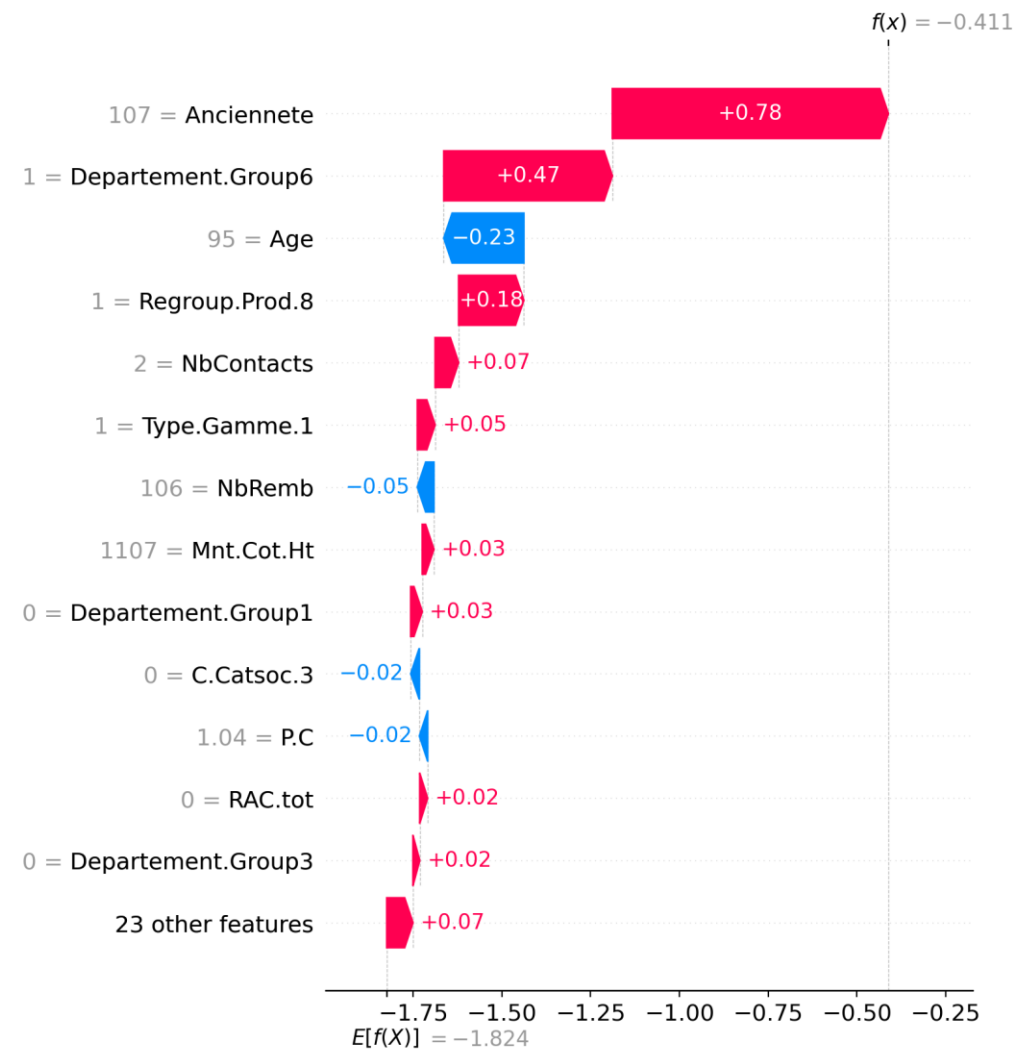
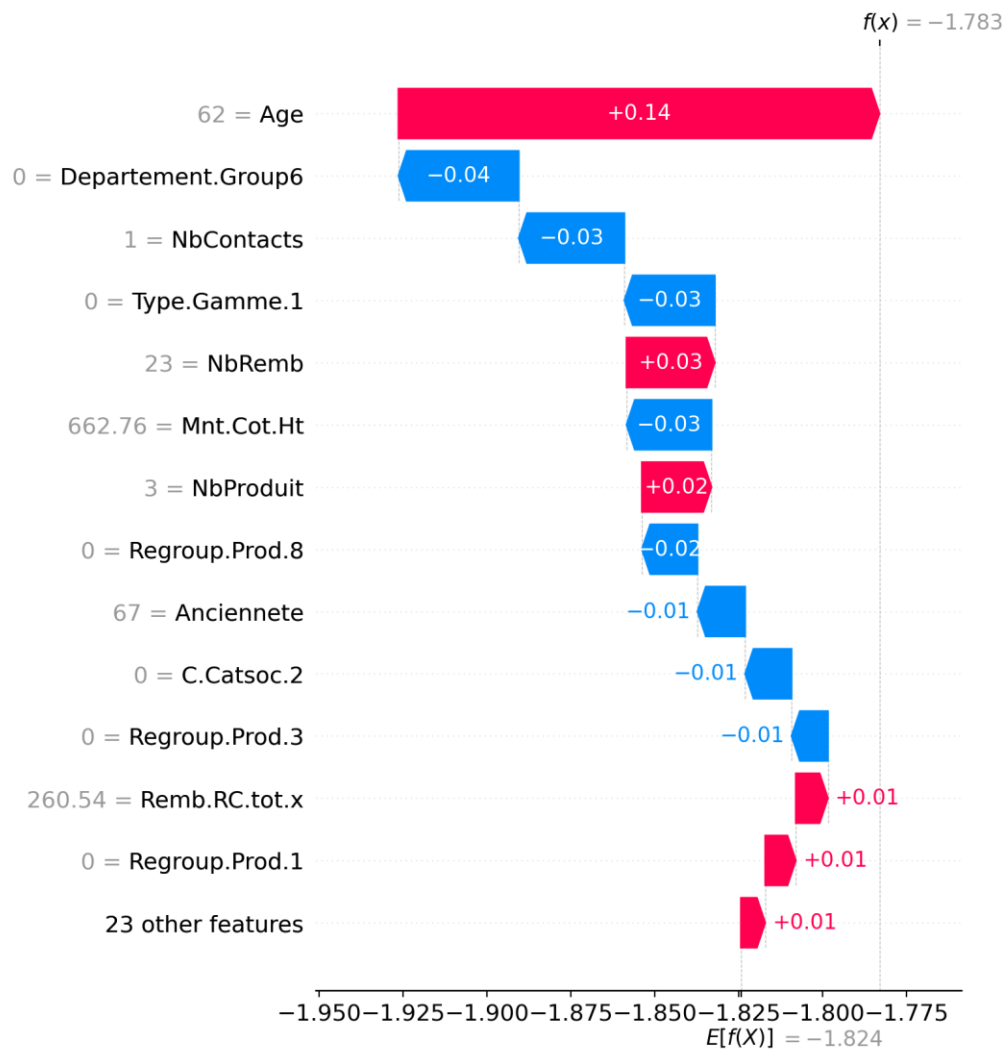
« dependence plot »

Global : shap values de l'ensemble de la base

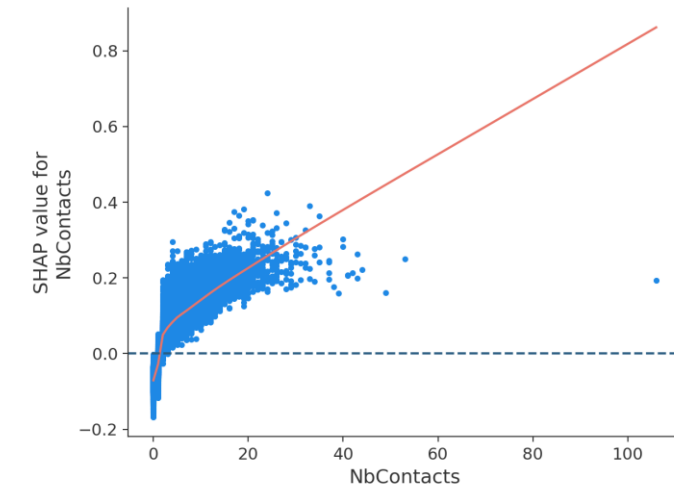

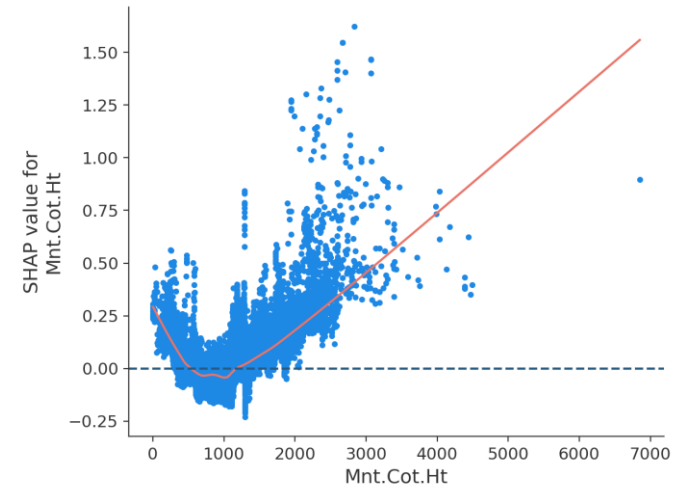
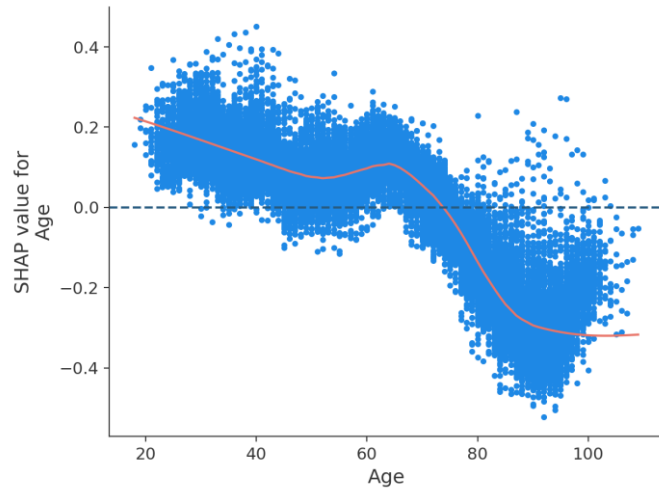




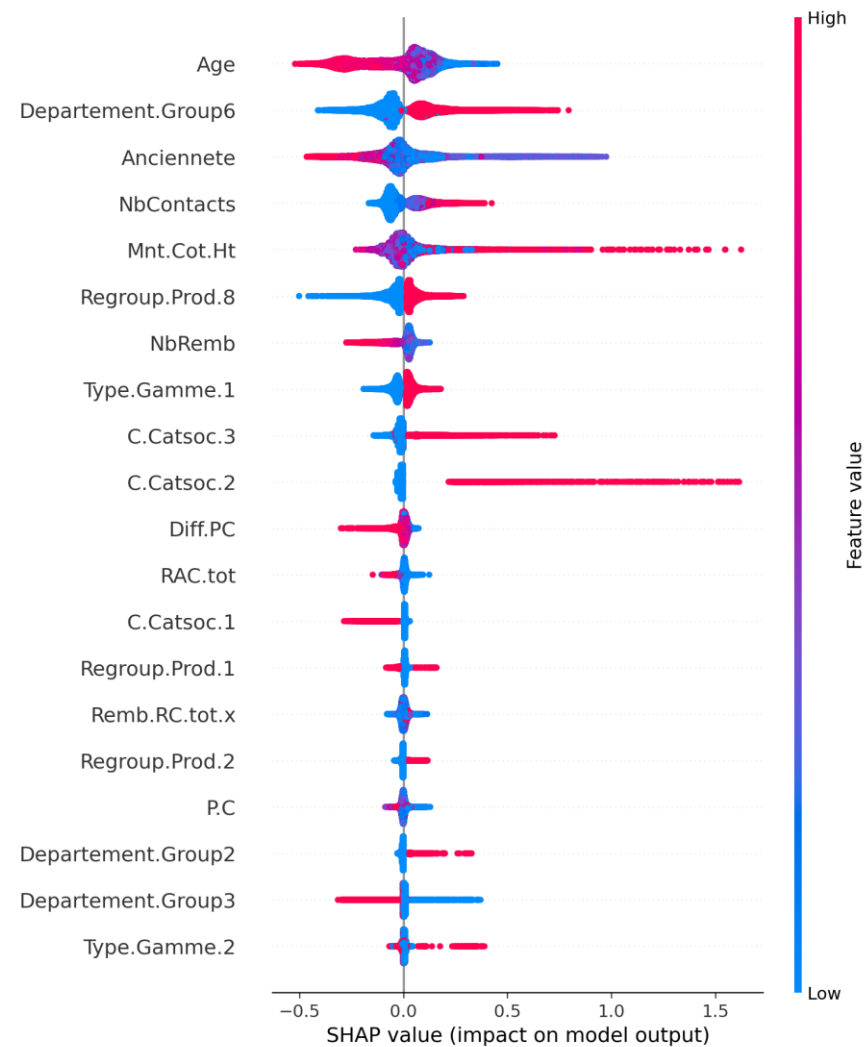
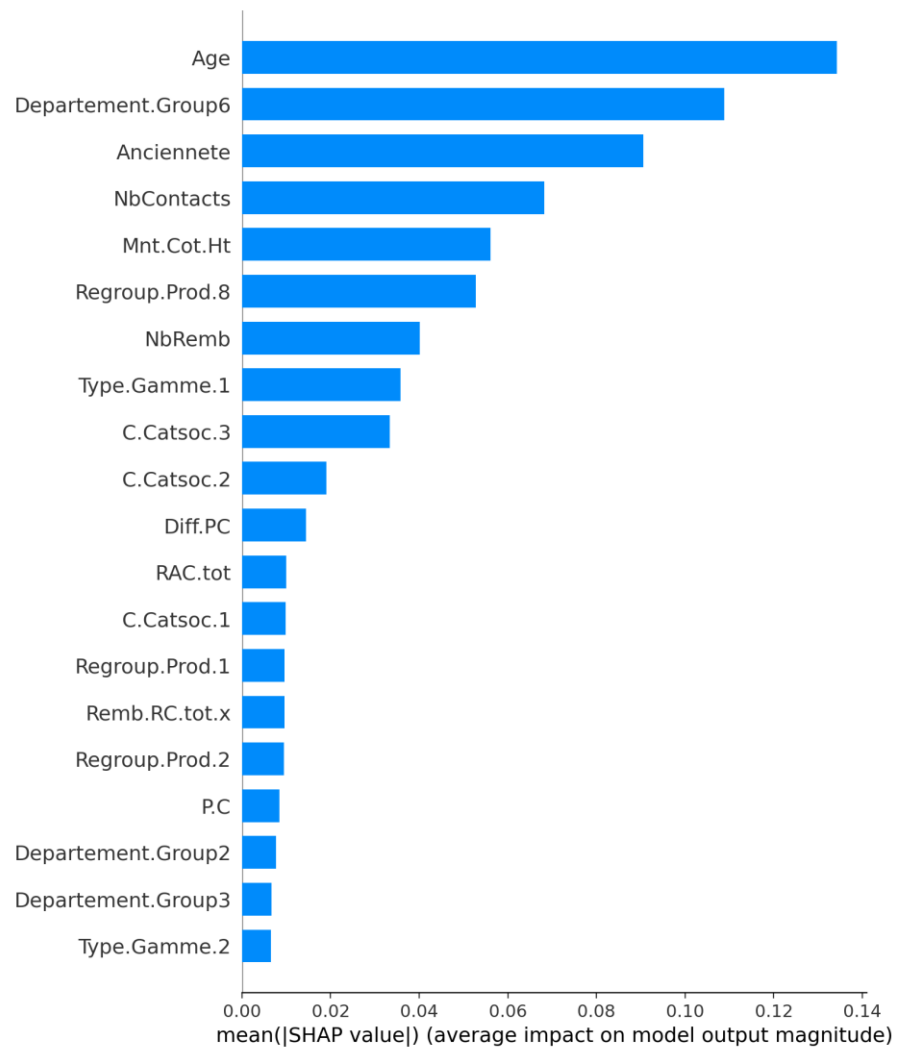
# SHAP : Compréhension d'une prédiction



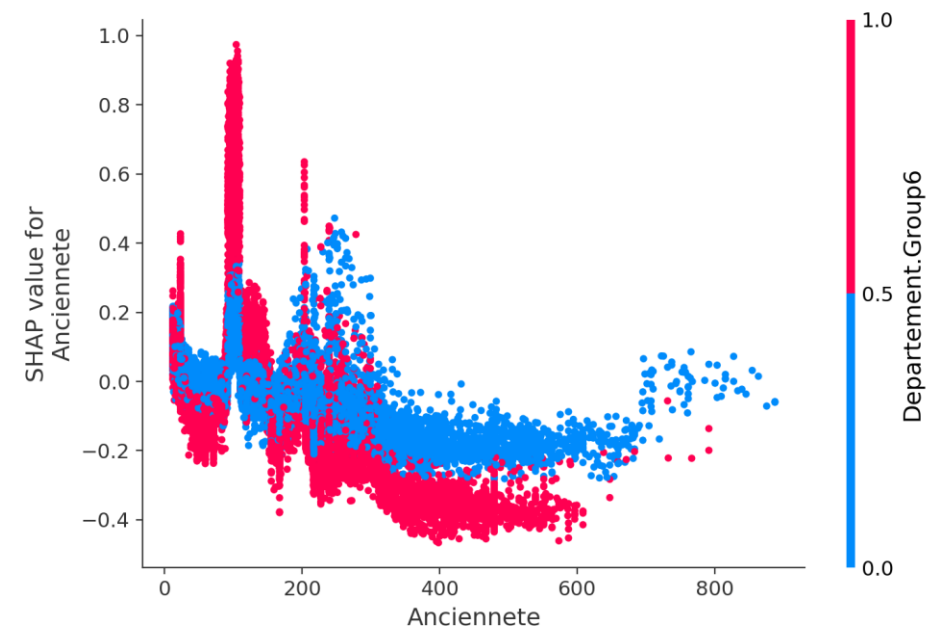

# SHAP : Dependence plots



# SHAP : Compréhension globale



# SHAP : Analyse des interactions



## Relation clients

### // Mise en œuvre

- // **1 conviction** : décorrélér l'action d'une démarche commerciale
- // **1eres secondes** de l'appel décisives pour convaincre l'adhérent de poursuivre l'appel.
- // **Discourt adapté** en fonction des segments
- // **Formation** des téléconseillers
- // **Process** de communication en interne
- // **Satisfaction** client mesurée post appel

### // Valorise le métier de téléconseiller

- // Démarche nouvelle pour les collaborateurs, **stimulante** et **challengeant**
- // Donne du **sens** à leur métier
- // Influe sur la **fidélisation**, sur la **motivation** et la **montée en compétence** des collaborateurs.

« Démarche gratifiante, notre métier prend tout son sens »

« L'appel arrive au bon moment pour nos clients »

« Favorise la recommandation »

### // Mesure de la satisfaction

 1 adhérent sur 3 a répondu

**4,4/5** Note de satisfaction suite à l'appel

#### Plus de 50% des répondants

- // Ont acquis une **meilleure** connaissance de leurs garanties et des services
- // Trouvent l'appel **utile**
- // Souhaitent être rappelés
- // Ont une meilleure image de VIASANTE

« J'apprécie votre démarche »

« Merci pour votre professionnalisme »

« Voilà, c'est ce que j'attendais de vos services »

« Je resterai chez vous pour conserver cette qualité de service »

## Analyse post campagne d'appel

// Nombre d'adhérents sur l'échantillon d'appel : 4 000 avec la plus forte probabilité de se radier, 34% ont répondu à l'appel, pour 57% un message a été laissé sur le répondeur, et 8% ont été injoignables

// Rétention

Probabilité de  
radiation estimée  
décroissante



10 fois plus de  
radiation avant  
l'appel

Répondants vs portefeuille	
Lot 01	-3,80%
Lot 02	-4,06%
Lot 03	-0,17%
Lot 04	+1,65%
Lot 05	+6,16%
Lot 06	+4,15%
Lot 07	+5,21%
Lot 08	+1,11%
<b>Total</b>	<b>+1,06%</b>

➤ **Augmentation  
de la rétention**

// **Activité post appel**

// L'appel a conduit à une inscription massive sur l'espace adhérent de **+12%**

// L'appel a favorisé le multi équipement : taux de souscription au multi équipement **1,6 fois supérieur** sur la population appelé comparée à l'échantillon témoin

➤ **Augmentation de la valeur client**

## Pour la suite...

### // Feature engineering / Données

- // Niveau de garantie
- // Intégration du RetEx de la campagne d'appel (durée des appels, qualification de l'appel *etc.*)

### // Intégration de données externes

- // Indicateurs de niveau de vie / emploi / ...
- // Densité de la population
- // Accès aux nouvelles technologies (qualité du réseau internet / fibre...)
- // Densité de la couverture médicale

### // Modèles


- // Modélisation de la durée de rétention de l'adhérent en portefeuille (survival analysis)
- // Introduction de la notion de temps (panel data) afin de capturer les ruptures de tendance
- // Modèle spécifique sur les tranches d'âges sensibles à l'appel

### // Process

- // Industrialisation : mise en place d'une plateforme de Data Science
- // Mise à jour en « temps réel » du modèle

## Ouverture : déséquilibre des classes et signal faible

- // Problème assez fréquent en classification, et notamment en assurance (résiliations, fraudes, consommations, *etc.*)
- // Lorsque le déséquilibre est trop prononcé, un algorithme d'apprentissage est forcément biaisé dans son apprentissage
- // Il est important de préciser que le déséquilibre n'est pas la seule source de complication, dans certains cas, il peut être nécessaire d'étudier la structure des données de manière préalable




- // Nous allons rappeler quelques méthodes assez classiques de rééquilibrage des données en se concentrant sur l'augmentation de données tabulaires, applicables à des problématiques actuarielles.




# Rééchantillonnage, alternative simple mais limitée

Under-sampling



Tirage aléatoire de la classe majoritaire à supprimer

Over-sampling




tirages aléatoire avec remise de la classe minoritaire à dupliquer


## Approche machine learning : SMOTE et variantes

- // SMOTE (Synthetic Minority Over-sampling Technique) a été introduit en 2002, c'est une technique de sur-échantillonnage qui n'est pas basé sur la réutilisation des données réelles.
- // L'idée générale est d'étudier les plus proches voisins de l'ensemble de observations de la classe minoritaire pour générer de nouvelles données.
- // L'algorithme présente toutefois certaines limites : ne fonctionne qu'avec des données continues (il n'est pas conçu pour générer des données catégorielles) et les données générées sont linéairement dépendantes ce qui peut entraîner un biais et par conséquent produire un modèle sur-ajusté.
- // Des variantes sont ensuite apparues pour palier ces limites et se concentrer sur les observations dont la classes est la plus difficile à prédire :
  - Borderline-SMOTE (2005) se concentre sur les données à la « frontière » de deux classes distinctes
  - ADASYN (2008) ou Kmeans SMOTE se concentrent sur les échantillons de la classe minoritaire situés dans des espaces dominés par la classe majoritaire, et donc « noyés ».


# Approche machine learning : SMOTE et variantes




Données déséquilibrées



SMOTE



Borderline SMOTE



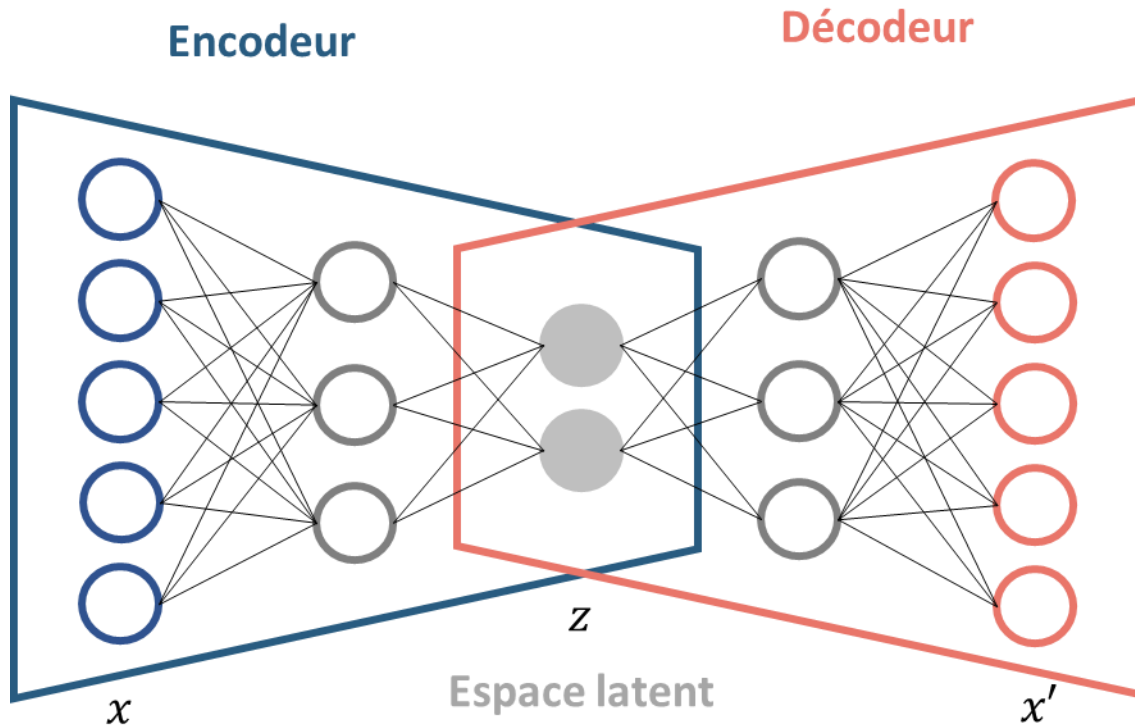
ADASYN

## Utilisation des autoencodeurs variationnels pour la détection de fraude

- // Les VaE sont des modèles génératifs (au même titre que les GAN), dont la structure est basée sur 2 réseaux de neurones : l'encodeur et le décodeur
- // L'encodeur simple, dit « vanille », produit d'abord une représentation compacte, purifiée, simplifiée de la donnée d'entrée  $x$  sous une forme vectorielle appartenant à une distribution latente, ces informations sont ensuite utilisées par le décodeur pour générer une sortie  $x'$
- // L'entraînement du modèle consiste à l'apprentissage de la meilleure façon de représenter les données dans cet espace latent pour minimiser la perte de reconstruction
- // Limite de l'autoencodeur vanille : forte propension au sur-apprentissage.
- // C'est ainsi que sont apparus les VaE : avec eux l'espace latente n'est plus décrit par un vecteur fixe, chaque dimension  $d$  est représentée par une distribution normale. Cette alternative permet de modifier la fonction de coût pour y ajouter un terme de régularisation, évitant le sur-apprentissage


# Utilisation des autoencodeurs variationnels pour la détection de fraude

Autoencodeur vanille



$$L = \|x - x'\|^2$$

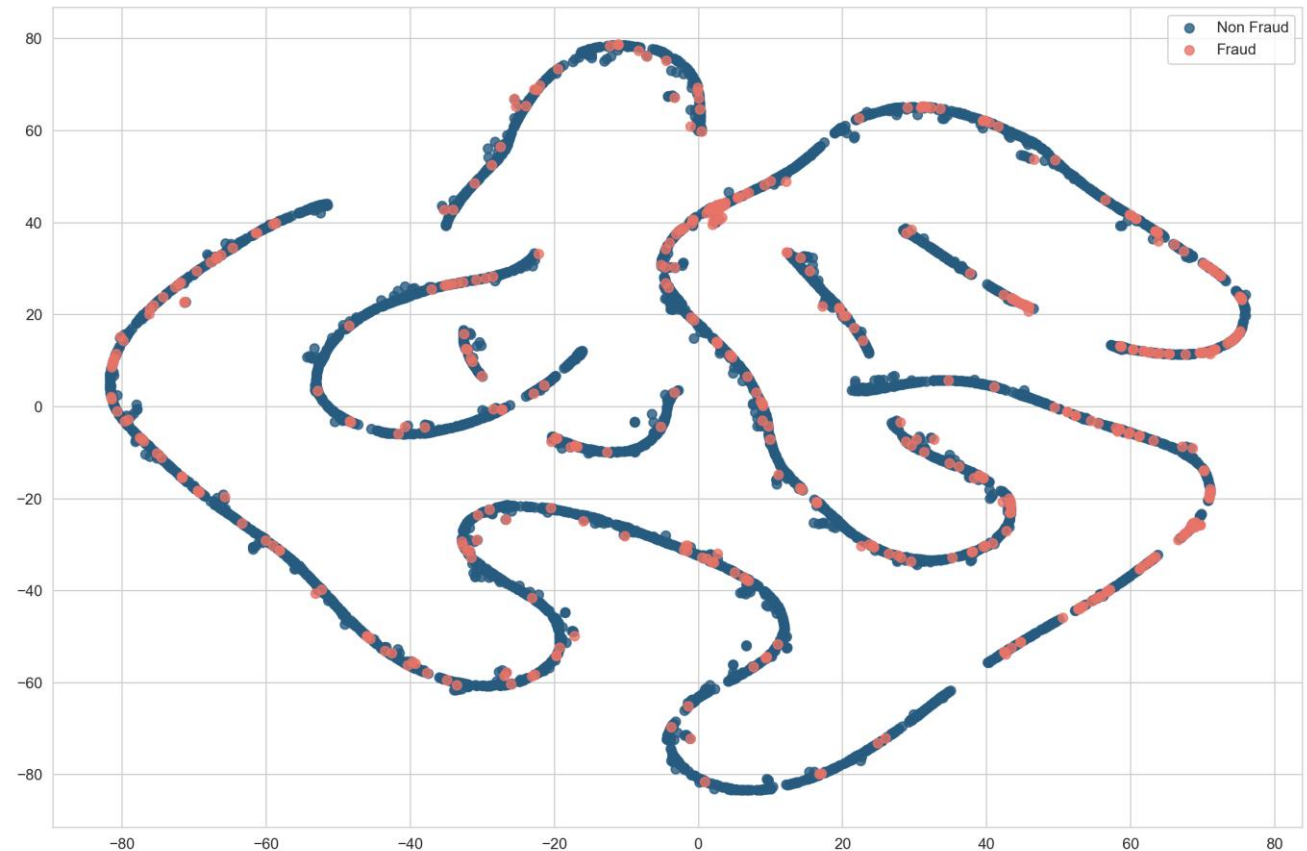
Autoencodeur variationnel (VaE)



$$L = \|x - x'\|^2 + \frac{1}{2} \sum_d (\mu_d^2 + \sigma_d^2 + \log(\sigma_d^2) - 1)$$

# Utilisation des autoencodeurs variationnels pour la détection de fraude

- // Afin de démontrer la pertinence de cette approche, on présente un cas d'usage à un jeu de données Kaggle de fraude à la carte bancaire
- // 492 transactions frauduleuses sur 284 807 transactions totales, **soit 0,142% de signal de fraudes**
- // L'objectif est de détecter les transaction frauduleuse à l'aide d'un modèle de classification binaire
- // Commençons par représenter les données par le biais d'un modèle de réduction de dimension T-SNE



# Utilisation des autoencodeurs variationnels pour la détection de fraude

Random Forest  
entraîné sans augmentation de données

	0 (non frauduleux)	1 (frauduleux)
train	199 011	353
test	85 304	139

		Classe estimée	
		0	1
Classe réelle	0	85 298	6
	1	107	32

précision	84%
rappel	23%
F1 score	36%

Random Forest (iso hyperparamètres)  
entraîné avec augmentation de données

	0 (non frauduleux)	1 (frauduleux)
train	199 011	<b>190 035</b>
test	85 304	139

		Classe estimée	
		0	1
Classe réelle	0	85 239	65
	1	11	<b>128</b>

précision	66%
rappel	<b>92%</b>
F1 score	77%

## Génération de données : limites et applications

- // Les résultats probants sont également liés à la bonne qualité du jeu de données Kaggle
- // Il existe également des techniques de rééchantillonnage basées sur la repondération des individus en fonction de la classe, implémentées par défaut dans certaines bibliothèques communes.
- // Point d'attention : l'interprétation métier d'un modèle entraîné sur des données générées peut être très délicate. On se retrouve face au dilemme performance / interprétabilité.
- // Dans notre secteur, la génération de données peut être très utile :
  - Enrichissement des datasets avec des données réalistes pour combler un manque de données
  - Imputation des valeurs manquantes
  - Anonymisation : à partir des données réelles, génération de données anonymes semblables, pouvant servir de bases aux calculs actuariels



## Conclusion : et la suite?

### // Objectifs

- // En 2023 : reconduire la démarche 3 fois
- // A partir de 2024 : en fil rouge

### // En amélioration continue

- // Enrichir les données du modèle
- // Ajuster le paramétrage modèle
- // Certaines périodes de contact sont-elles plus pertinentes?
- // Affiner les cibles à contacter et l'approche commerciale
- // Suivi du ROI

**Le run « Prédiction des radiés » concernera qu'une partie des adhérents.**

**Que faisons nous pour les autres?**