Au-delà de la segmentation RFM : combinaison du Fuzzy C-Means et de la détection de saisonnalité pour réduire les faux positifs dans la gestion du *churn* BtoB dans la logistique viticole

Jean-Marc Joyeux
Enseignant – Chercheur
IAE Dijon - Université de Bourgogne
CREGO – CERMAB (EA 7317)
2 Bd Gabriel, 21000 Dijon
jean-marc.joyeux@u-bourgogne.fr

Thomas Largeron
PDG Groupe La Ruche
Voie communale 4,
21320 Créancey
contact@laruche-logistique.fr

Magali Zeller
DG Groupe La Ruche
Voie communale 4,
21320 Créancey
contact@laruche-logistique.fr

Au-delà de la segmentation RFM : combinaison du Fuzzy C-Means et de la détection de saisonnalité pour réduire les faux positifs dans la gestion du *churn* BtoB dans la logistique viticole

La segmentation RFM est un outil largement utilisé en marketing BtoB mais elle produit des signaux paradoxaux lorsqu'elle est appliquée statiquement : des clients apparemment actifs quittent massivement le portefeuille, tandis que des clients identifiés comme instables ne le quittent jamais. Cet article montre comment la combinaison d'un Fuzzy C-Means (FCM) et d'une détection de saisonnalité permet de lever ces paradoxes. Sur un portefeuille de 2 080 clients historiques actifs d'un logisticien viticole BtoB, les clients frontière FCM (8,2 % du portefeuille) présentent un taux de *churn* de 32 %, tandis que les clients saisonniers stables (16,9 %) affichent un *churn* nul sur deux années consécutives. Ces deux signaux sont statistiquement orthogonaux (V de Cramér = 0,021 ; p = 0,34) et apportent des informations complémentaires : le FCM identifie les instables structurels, la saisonnalité annule les faux positifs. La stabilité inter-annuelle de la saisonnalité est confirmée par un Kappa de Cohen de 0,607 et une corrélation de volatilité de r = 0,805 entre 2024 et 2025. La combinaison des deux filtres réduit de 70 % le périmètre des actions de rétention mal ciblées, avec un taux de *churn* des groupes ciblés de 32 % contre 16 % pour la base.

Mots-clés : *RFM – Fuzzy C-Means – Saisonnalité – Churn – BtoB*

Beyond RFM Segmentation: Combining Fuzzy C-Means and Seasonality Detection to Reduce False Positives in B2B Churn Management in the wine sector

RFM segmentation is widely used in B2B marketing as an operational proxy for customer value. However, when applied statically, it generates paradoxical signals: apparently active customers leave the portfolio in large numbers, while customers identified as unstable remain consistently active. This paper shows how combining Fuzzy C-Means (FCM) with seasonality detection can resolve these paradoxes. Based on a portfolio of 2,080 active historical customers from a B2B wine logistics provider, FCM “boundary” customers (8.2% of the portfolio) exhibit a churn rate of 32%, whereas stable seasonal customers (16.9%) show zero churn over two consecutive years. These two signals are statistically orthogonal (Cramér’s V = 0.021; p = 0.34) and provide complementary insights: FCM identifies structurally unstable customers, while seasonality eliminates false positives. The inter-annual stability of seasonality is confirmed by a Cohen’s Kappa of 0.607 and a volatility correlation of r = 0.805 between 2024 and 2025. Combining both filters reduces the scope of mis-targeted retention actions by 70%, while increasing the churn rate of targeted groups to 32% compared to 16% for the overall base.

Keywords: *RFM – Fuzzy C-Means – Seasonality – Churn – BtoB*

Résumé managérial

La segmentation RFM appliquée statiquement génère un paradoxe opérationnel coûteux : elle confond deux phénomènes radicalement distincts, l'instabilité structurelle d'un client, son incapacité à s'ancrer durablement dans un segment comportemental, et la temporalité de son usage, le rythme prévisible et répété de son activité. Sur un portefeuille de 2 080 clients historiques actifs d'un prestataire logistique viticole BtoB, 351 clients saisonniers stables affichent un taux de départ nul sur deux années consécutives, tandis que 147 clients à appartenance floue auront un taux de *churn* à 32 %, deux fois le taux de base. Ces deux signaux sont empiriquement indépendants et détectables à partir des seuls volumes mensuels d'expédition, sans aucune donnée supplémentaire. Leur combinaison réduit de 70 % le périmètre des interventions de rétention mal ciblées et double la précision de détection des clients réellement à risque.

De la segmentation à l'animation : trois leviers concrets pour le responsable marketing et commercial

Au-delà de la démonstration empirique, ce cadre d'analyse transforme la manière dont un responsable marketing et commercial peut piloter son portefeuille au quotidien. Il ouvre concrètement trois leviers d'action.

Le premier est la **priorisation des efforts de rétention**. Plutôt que d'intervenir sur l'ensemble des clients dont le score RFM se dégrade, un périmètre qui peut représenter plusieurs centaines de comptes, le dispositif permet de concentrer les actions sur une liste de 147 clients dont la probabilité de départ est objectivée à 32 %. L'économie de ressources marketing et commerciales est immédiate, et l'impact attendu sur le taux de rétention est mécaniquement plus élevé.

Le deuxième est la **détection précoce des signaux faibles**. Puisque le profil saisonnier de chaque client est connu et stable d'une année sur l'autre, toute déviation par rapport à son calendrier habituel d'expéditions, un vigneron à pic automne qui n'expédie pas en octobre, constitue un signal d'alerte bien plus précoce et fiable qu'une dégradation du score RFM annuel. Le suivi mensuel des déviations transforme la segmentation en outil d'alerte dynamique, là où elle n'est aujourd'hui qu'une photographie statique.

Le troisième est le **basculement de la rétention vers l'activation pendant les périodes creuses**. Les clients saisonniers stables ne nécessitent pas d'être retenus : ils reviennent. En revanche, leur creux d'activité prévisible représente une fenêtre marketing et commerciale sous-exploitée : relances sur des gammes complémentaires, offres de conditionnement anticipé, ou incitations à l'expédition précoce permettent de lisser la demande opérationnelle, de réduire les à-coups en entrepôt, et de générer du chiffre d'affaires additionnel sur des comptes dont la fidélité est structurellement acquise. C'est précisément la logique du *yield management* appliquée à la relation client : mobiliser la connaissance du calendrier d'activité pour optimiser l'allocation des efforts marketing et commerciaux dans le temps, et non plus seulement dans l'espace du portefeuille.

1. Introduction

La distribution de vins constitue un maillon stratégique de la chaîne de valeur viticole, directement exposé aux transformations structurelles qui affectent l'ensemble de la filière. Sur le plan économique, la filière vin représente environ 16 % de la valeur de la production agricole française, soit près de 15 milliards d'euros en 2023[1], et la France occupe une position de leader à l'export avec 11,96 milliards d'euros d'exportations en 2021. Sur le plan de la demande, la consommation intérieure recule de manière tendancielle : le secteur enregistre une baisse de 6 % en 2022 et de 4 % en 2023-2024 pour les achats à domicile, portée par une recomposition générationnelle profonde : les moins de 39 ans consomment significativement moins que les générations précédentes. Sur le plan de l'offre, le réchauffement climatique modifie les calendriers de récolte, les profils organoleptiques et les rendements, tandis que les tensions géopolitiques fragilisent les circuits d'approvisionnement des vignerons, des négociants et des cavistes. Ces mutations rendent les prévisions d'activité particulièrement incertaines pour les opérateurs logistiques BtoB (conditionnement, stockage, expédition) qui travaillent pour le compte des vignerons, négociants, cavistes et e-commerçants. Dans ce contexte, distinguer défections structurelles et baisses saisonnières devient un enjeu central, faisant du secteur viticole un laboratoire pertinent pour tester des approches dynamiques de la valeur client.

La gestion de la valeur client en BtoB repose souvent sur des outils de segmentation dont la puissance prédictive reste insuffisamment testée. La segmentation RFM (Récence, Fréquence, Montant) constitue l'un des outils les plus répandus (Fader et *al.*, 2005 ; Nguyen et *al.*, 2022 ; Auteurs, 2026), mais son application statique génère des paradoxes opérationnels coûteux : des clients classés « captifs » quittent massivement le portefeuille, tandis que des clients identifiés comme instables ne le quittent jamais. Dans la logistique viticole BtoB, ces paradoxes sont amplifiés par deux phénomènes structurels. D'une part, la saisonnalité marquée de la filière crée des profils RFM faibles en janvier qui ne reflètent pas une fragilité réelle mais un état de basse saison. D'autre part, l'appartenance floue de certains clients à plusieurs segments simultanément signale une instabilité structurelle que le K-means classique ne permet pas de détecter (Auteurs, 2023).

Cet article s'inscrit dans une lecture des paradoxes de la distribution appliqués à la gestion de la valeur client en BtoB. Il met en évidence un paradoxe structurel des approches de segmentation statiques : en cherchant à stabiliser la lecture du comportement client, elles tendent à confondre deux dimensions pourtant distinctes, l'instabilité comportementale et la temporalité d'usage. Cette confusion conduit à des erreurs de diagnostic coûteuses, en assimilant des clients saisonnièrement inactifs à des clients en défection, et inversement.

Pour dépasser ce paradoxe, cet article propose un cadre d'analyse fondé sur la dissociation de ces deux dimensions, en combinant trois couches appliquées aux mêmes données transactionnelles : une segmentation RFM K-means, un Fuzzy C-Means (FCM) pour capter l'instabilité structurelle, et une détection de saisonnalité sur les volumes mensuels bruts. La question de recherche est la suivante : *dans quelle mesure la dissociation entre instabilité structurelle et temporalité saisonnière permet-elle de réduire les faux positifs dans la gestion du churn BtoB ?*

La suite de l'article s'organise ainsi : la section 2 présente le cadre théorique et positionne la contribution par rapport à la littérature existante, ensuite la section 3 détaille le dispositif méthodologique en trois couches, puis la section 4 expose les résultats, enfin la section 5 discute les apports et limites de ce papier.

[1] FranceAgriMer, *Chiffres-clés de la filière viti-vinicole 2024*, publié le 01/01/2026

2. Cadre théorique et positionnement

2.1. RFM comme proxy opérationnel de la valeur client en BtoB

La segmentation RFM s'est imposée comme un proxy simple et opérationnel de la *Customer Lifetime Value* (CLV) en marketing relationnel BtoB (Fader et *al.*, 2005 ; Nguyen et *al.*, 2022). Dans les contextes BtoB, elle est fréquemment combinée au K-means pour construire des segments actionnables (Christy et *al.*, 2018). Des extensions comme le LRFM, qui intègre la durée de la relation client, ont enrichi la caractérisation de la valeur dans des contextes à cycles longs (Ariwiati et *al.*, 2025 ; Wang et *al.*, 2024). Ces approches partagent une limite commune : elles restent majoritairement statiques, sans intégrer la dynamique temporelle ni l'incertitude d'affectation des clients aux segments. Dans la logistique viticole BtoB, cette limite prend une acuité particulière et illustre les coûts opérationnels d'une lecture figée des centroïdes RFM. La présente recherche conserve la simplicité opérationnelle du RFM tout en proposant deux couches complémentaires pour dépasser ces paradoxes.

2.2. Apports du fuzzy clustering à la segmentation comportementale et au churn

Le Fuzzy C-Means (FCM) prolonge le K-means en remplaçant l'affectation binaire par des degrés d'appartenance continus (Bezdek, 1981). Les clients dont le degré maximal d'appartenance reste faible, les « clients frontière », oscillent entre plusieurs clusters et portent une information d'instabilité structurelle que le K-means masque. Marín Díaz (2025) montre que l'entropie d'appartenance constitue un signal prédictif plus précoce que les indicateurs RFM classiques. Ranjan et Kumar (2025) confirment dans une étude comparative que le FCM surpasse le K-means pour identifier les segments à comportement de *churn* hétérogène. Sivasankar et Vijaya (2017) soulignent que la combinaison de méthodes de *clustering* non supervisées avec des indicateurs de *churn* améliore significativement la segmentation dans des contextes à forte variabilité temporelle. Le FCM est ici utilisé non pour raffiner la segmentation, mais comme signal de fragilité complémentaire au RFM.

2.3. Saisonnalité, bruit RFM et gestion du churn

La saisonnalité constitue une source de bruit majeure dans les segmentations fondées sur des données transactionnelles agrégées à l'année. Wünderlich et *al.* (2022) montrent que les modèles de *churn* non contractuels ignorant la saisonnalité produisent des prévisions biaisées, en confondant baisses saisonnières et défections. Zammit et Zerafa (2025), dans le cadre du modèle BG/NBD, montrent que la définition du *churn* comme inactivité sur fenêtre fixe est particulièrement sensible aux effets saisonniers. Lee et *al.* (2024) proposent une approche hybride fondée sur une probabilité dynamique d'être « *alive* » pour distinguer les clients saisonnièrement inactifs des vrais *churners*. Ces travaux plaident pour une définition dynamique du *churn* : la saisonnalité n'est pas un bruit à corriger, mais un axe de segmentation temporelle à part entière.

2.4. Positionnement de la contribution

Cette recherche apporte une double contribution. Sur le plan théorique, elle propose une relecture des paradoxes de la segmentation client en montrant que les limites des approches RFM ne relèvent pas uniquement de leur caractère statique, mais d'une confusion plus profonde entre deux dimensions orthogonales du comportement client : l'instabilité structurelle, liée à une ambiguïté d'appartenance aux segments, et la temporalité d'usage, liée à des rythmes d'activité prévisibles. En dissociant explicitement ces deux dimensions, l'article met en évidence que certains paradoxes apparents de la segmentation, notamment le cas des « clients captifs » fortement *churners*, résultent d'un artefact de mesure plutôt que d'un comportement intrinsèquement incohérent.

Sur le plan méthodologique, l'article propose un cadre de filtrage des faux positifs de *churn* fondé sur la combinaison de deux signaux empiriquement orthogonaux : un signal d'instabilité issu du Fuzzy C-Means et un signal de temporalité issu de la saisonnalité. Cette combinaison permet de transformer une segmentation descriptive en un dispositif décisionnel, capable de distinguer de manière robuste les clients réellement à risque des clients saisonnièrement inactifs.

Enfin, cette recherche contribue à une conception dynamique de la segmentation client, non plus comme une photographie statique des comportements, mais comme un système d'interprétation intégrant simultanément incertitude et temporalité.

Courant	Apport au domaine	Ce que notre papier ajoute
RFM / CLV en BtoB	Segmentation opérationnelle, proxy CLV	Identification des paradoxes prédictifs, lecture dynamique des centroïdes
Fuzzy clustering et *churn*	Appartenance floue comme signal d'instabilité et de migration	Combinaison FCM + analyse de sensibilité du seuil, validation inter-annuelle
Saisonnalité et comportements clients	Distinction dormants saisonniers / vrais *churners*	Détection sur volumes bruts mensuels, stabilité longitudinale (Kappa, r)

Tableau 1. Positionnement de la contribution par rapport aux courants théoriques

3. Méthodologie

L'étude s'appuie sur les données transactionnelles d'un logisticien viticole BtoB couvrant 2 080 clients historiques actifs suivis sur deux années consécutives (2024-2025). Les volumes mensuels d'expédition constituent la seule source de données utilisée. Les traitements ont été réalisés en *Python* (*pandas, scikit-learn, scikit-fuzzy*).

Couche 1 : Segmentation RFM K-means. Un score RFM pondéré (5R + 3F + 2M) est calculé pour chaque client sur 12 mois (Jallat et *al.*, 2014 ; Auteurs, 2026). Un K-means (k=4, k-means++, n_init=20) produit quatre segments : « À ne pas perdre », « À travailler », « Clients captifs », « Clients à risque » (Annexe 1). La robustesse est validée par un ARI moyen > 0,8 et un test de sensibilité sur les pondérations ($\rho > 0,99$). Le choix de k=4 repose sur l'évaluation conjointe de l'indice de silhouette, de Davies-Bouldin et de Calinski-Harabasz pour k allant de 2 à 10 : k=4 offre le meilleur compromis entre qualité de partition et lisibilité managériale sur les deux années. Un panel longitudinal janvier-décembre permet de calculer le ΔRFM, le *churn* (absence totale d'activité en fin de période) et la matrice de transition entre segments.

Couche 2 : Fuzzy C-Means. Le FCM est appliqué aux mêmes variables R, F, M normalisées (c=4, m=2). Le Fuzzy Partition Coefficient (FPC = 0,79) confirme la qualité de la partition. Une analyse de sensibilité sur 101 seuils (0-100 %) détermine la zone optimale entre 40 % et 65 %, avec un *churn* frontière systématiquement 2 à 3 fois supérieur au taux général (Annexe 2 et 3). Le seuil de 60 % est retenu sur la base d'un double critère : statistiquement, il se situe dans la zone robuste ($p < 0,001$ en continu) ; opérationnellement, il identifie 170 clients actionnables contre seulement 11 à 36 % (seuil algorithmiquement optimal mais commercialement inutilisable). Cet arbitrage entre optimum statistique et pertinence managériale est reconnu comme une limite explicite (section 5).

Couche 3 : Détection de saisonnalité. Pour chaque client, l'écart-type du volume mensuel brut sur 12 mois mesure la volatilité de l'activité. Ce choix, plutôt qu'un score RFM dérivé, évite l'effet de fenêtre cumulative inhérent aux scores calculés sur des horizons glissants. Le seuil du 75^{e} percentile est retenu comme choix opératoire, et non standard théorique, pour deux raisons : il identifie le quart supérieur du portefeuille en termes de volatilité, et sa robustesse est validée *ex post* par la stabilité inter-annuelle du statut saisonnier obtenu (accord global = 85,6 % ; κ =

0,607). Quatre profils de pic sont identifiés selon le mois de volume maximum : hiver, printemps, été, automne (Annexe 4 et 5).

4. Résultats

4.1. Paradoxes de la segmentation RFM statique

L'ANOVA confirme que le segment RFM établi sur l'année 2024 prédit fortement le score RFM observé en fin d'année 2025 ($F = 575{,}36$; $p < 0{,}001$). Les tests *post hoc* de Tukey HSD montrent que tous les segments sont significativement distincts, avec des Cohen's d supérieurs à 0,8 pour cinq des six comparaisons. Le test du χ^2 révèle une association forte entre segment RFM initial et *churn* ($\chi^2 = 662{,}15$; ddl = 3 ; $p < 0{,}001$; V de Cramér = 0,564), indiquant que le segment d'appartenance explique une part substantielle de la variance du *churn*. Ces résultats confirment la robustesse apparente de la segmentation RFM, mais masquent un paradoxe central : les « Clients captifs » présentent le *churn* le plus élevé (57 %), malgré une récence initiale favorable. Ce segment, homogène en apparence, concentre l'essentiel des faux positifs en confondant clients durablement engagés et clients en sortie masquée. Ce résultat illustre pleinement le paradoxe central des approches RFM : des clients identifiés comme les plus sûrs deviennent empiriquement les plus risqués (Auteurs, 2026).

4.2. Apport du FCM

Le Fuzzy C-Means isole 170 « clients frontière » (8,2 % du portefeuille), caractérisés par une ambiguïté d'appartenance aux *clusters*. Ce groupe présente un *churn* de 32 %, contre 13,6 % pour les clients nets (OR = 2,42 ; $p < 0{,}001$; V de Cramér frontière × *churn* = 0,106), indiquant une association significative mais de force modeste. Le FCM capture un signal réel mais partiel. La stabilité inter-annuelle du signal est remarquable : même proportion de frontières (8,2 %), FPC constant à 0,79, et association avec le *churn* retrouvée avec la même intensité sur les deux années observées. Le FCM capte ainsi une instabilité structurelle du client que la segmentation RFM ne met pas en évidence.

L'examen de la composition segmentaire des 147 frontières non saisonniers, la cible prioritaire après filtrage, révèle que le FCM apporte sa valeur ajoutée la plus significative sur les segments apparemment sûrs. Les 90 frontières appartenant au segment « À travailler » (61,2 % de la cible) présentent un *churn* de 21,1 %, soit six fois le taux de référence de leur segment (3,6 %). Les 17 frontières « À ne pas perdre » (11,6 %) affichent un *churn* de 23,5 %, soit neuf fois le taux de référence (2,5 %). Ces clients, que la segmentation RFM protège à tort en raison de leurs bons scores, constituent les faux négatifs les plus coûteux du dispositif : sans le signal FCM, ils ne feraient l'objet d'aucune action de rétention. À l'inverse, les 38 frontières « Clients captifs » non saisonniers concentrent un *churn* de 60,5 %, confirmant que ce segment reste le plus hétérogène du portefeuille même après filtrage saisonnier.

Segment	***Churn* 170 frontières**	***Churn* 147 frontières**	**Écart**	***Churn* segment entier**
Clients captifs	43,4 %	60,5 %	+17,1 pts	57,1 %
À travailler	19,4 %	21,1 %	+1,7 pts	3,6 %
À ne pas perdre	23,5 %	23,5 %	0 pt	2,5 %
Clients à risque	50,0 %	50,0 %	0 pt	18,6 %

Tableau 2. L'effet du filtrage saisonnier sur les taux de churn par segment

4.3. Saisonnalité protectrice et stable

En 2025, 527 clients (24,8 % du portefeuille) sont identifiés comme saisonniers, dont 83 % concentrent leur activité sur l'automne-hiver. Leur taux de *churn* est nul dans tous les segments K-means, contre 68,6 % pour les « Clients captifs » non saisonniers ($OR \approx 0$; $p < 0{,}001$). Dans ce contexte, la saisonnalité apparaît comme un signal fortement protecteur et très stable. La

stabilité inter-annuelle est confirmée par trois indicateurs convergents : accord global 2024-2025 de 85,6 % (κ de Cohen = 0,607 ; V de Cramér = 0,606 ; $p < 0,001$) ; corrélation de volatilité r = 0,805 entre les deux années ; *churn* nul des saisonniers stables (n = 351 ; 16,9 % du portefeuille) maintenu après correction du biais de survie (inclusion des 307 *churns* reconstruits par différence de 2025 ne modifie pas le résultat). À l'inverse, les clients perdant leur statut saisonnier entre 2024 et 2025 (n = 168) retrouvent un *churn* de 18,5 %, comparable à la base de référence : c'est la stabilité de la saisonnalité, et non la simple présence d'un pic, qui constitue le facteur protecteur réel.

4.4. Les deux signaux sont orthogonaux et complémentaires

Le croisement FCM × saisonnalité montre que les deux méthodes captent des phénomènes statistiquement indépendants ($\chi^2 = 0,89$; $p = 0,34$; V de Cramér frontière FCM × statut saisonnier = 0,021). Le test de Mann-Whitney sur la distribution du degré d'appartenance maximal entre saisonniers et non-saisonniers ne détecte aucune différence significative ($p = 0,67$; moyennes respectives : 0,861 vs 0,864). L'absence de différence détectée reflète que les deux propriétés, instabilité d'appartenance et saisonnalité, ne partagent pas de substrat comportemental commun mesurable sur ces données. Les deux signaux étant orthogonaux, leur combinaison produit cinq catégories opérationnelles (tableau 3) :

Catégorie	**N**	***Churn* (%)**	**Interprétation**
Frontière + Saisonnier	23 (1,1 %)	0,0 %	Faux positif FCM
Frontière seul	147 (7,1 %)	**32,0 %**	Cible prioritaire
Saisonnier stable (2 ans)	351 (16,9 %)	0,0 %	Facteur protecteur stable
Saisonnier ponctuel (1 an)	176 (8,5 %)	~9 %	Signal transitoire
Ni frontière ni saisonnier	1 383 (66,5 %)	19,3 %	Base de référence

Tableau 3. Distribution et taux de churn par catégorie combinée FCM × saisonnalité (corrigé du biais de survie)

Le tableau 4 illustre le gain marginal de précision apporté par chaque couche : RFM seul, + FCM, + saisonnalité, puis combinaison complète.

Configuration	**Périmètre ciblé**	**Taux de *churn***	**Gain vs base**
RFM seul (tous historiques actifs)	2 080 clients (100 %)	14,7 %	—
RFM + FCM (frontières uniquement)	170 clients (8,2 %)	32,0 %	+17,3 pts
RFM + Saisonnalité (exclusion saisonniers stables)	1 729 clients (83,1 %)	17,7 %	+3,0 pts
RFM + FCM + Saisonnalité (frontières non saisonniers)	147 clients (7,1 %)	32,0 %	+17,3 pts / périmètre −70 %

Tableau 4. Gain marginal de précision par couche d'analyse

Au total, la combinaison des deux filtres, instabilité FCM et stabilité saisonnière, réduit d'environ 70 % le périmètre des interventions de rétention mal ciblées, tout en concentrant l'effort sur les clients véritablement à risque.

5. Discussion et limites

Ces résultats apportent trois contributions principales. Sur le plan théorique, ils suggèrent que les paradoxes de la segmentation RFM, notamment le cas des « Clients captifs », s'expliquent en partie par la confusion entre fragilité structurelle et basse saison, deux phénomènes que la segmentation annuelle ne distingue pas. Sur le plan méthodologique, la combinaison FCM + saisonnalité constitue un dispositif reproductible de filtrage des faux positifs, fondé sur les seules données transactionnelles disponibles dans tout système d'information logistique.

Un résultat particulièrement robuste mérite d'être souligné : la stabilité inter-annuelle de la saisonnalité ($\kappa = 0{,}607$; $r = 0{,}805$ entre les volatilités) confirme que ce signal peut être établi sur une seule année d'historique et utilisé de manière prospective. La distinction entre saisonniers stables (*churn* nul sur deux ans) et saisonniers ponctuels (*churn* intermédiaire) ouvre ainsi une voie de segmentation fine qui dépasse la dichotomie binaire saisonnier / non-saisonnier, et invite à considérer la saisonnalité comme une propriété structurelle du client plutôt que comme une simple fluctuation annuelle.

Sur le plan managérial, le dispositif proposé est conçu pour s'intégrer dans les processus CRM existants sans rupture organisationnelle. Les données requises, volumes mensuels d'expédition par client, sont disponibles dans tout système d'information logistique standard, sans collecte supplémentaire. Sur le plan de la mise en œuvre, le dispositif s'articule sur deux horizons temporels complémentaires. La segmentation de base (RFM K-means, FCM et classification saisonnière) est recalculée annuellement sur les douze mois écoulés : la stabilité inter-annuelle des structures observées (FPC constant à 0,79, proportion de frontières identique à 8,2% sur deux ans, $\kappa = 0{,}607$ pour la saisonnalité) valide cette fréquence pour la caractérisation des profils. En revanche, le suivi des alertes opérationnelles gagne à être mensuel : la connaissance du profil saisonnier de chaque client permet de détecter en temps quasi-réel toute déviation par rapport à son calendrier habituel d'expéditions, signal d'alerte bien plus précoce qu'une segmentation annuelle. Concrètement, ce dispositif permet au responsable commercial de concentrer ses actions de rétention sur une liste de 147 clients prioritaires avec une probabilité de *churn* deux fois supérieure au taux de référence, tout en substituant aux actions de rétention inutiles sur les saisonniers stables des actions d'activation ciblées pendant leurs périodes creuses.

Au-delà de la rétention, la connaissance du profil saisonnier ouvre une seconde dimension d'action marketing : l'activation des clients pendant leurs périodes creuses. Dès lors qu'un client est identifié comme saisonnier stable, et donc comme non *churner* structurel, son calendrier d'activité prévisible devient un levier d'optimisation du ROI commercial. Les clients à pic automne, qui représentent 83 % des saisonniers et concentrent leur activité d'octobre à décembre, présentent mécaniquement un creux d'expéditions de janvier à mars. Ce creux correspond précisément à la période où leur score RFM est le plus faible et où la segmentation statique les identifie à tort comme fragiles. Plutôt que de déclencher des actions de rétention coûteuses et inutiles sur ces clients, l'entreprise logistique pourrait y substituer des actions d'activation ciblées : relances commerciales sur des gammes complémentaires, offres de conditionnement anticipé, ou incitations à l'expédition précoce, conçues pour lisser la demande et réduire les à-coups opérationnels. Cette logique de *yield management* client, fondée sur la connaissance empirique du profil saisonnier plutôt que sur des hypothèses comportementales, constitue un prolongement naturel du dispositif proposé et représente une piste concrète d'amélioration du ROI des actions commerciales en logistique viticole BtoB.

Cinq limites doivent être soulignées. Premièrement, la définition du *churn* comme absence totale d'activité en fin de période ne distingue pas clients perdus et inactifs temporaires ; des modèles de survie (Cox, BG/NBD) seraient plus adaptés (Ray, 1988). Deuxièmement, l'étude mono-secteur limite la généralisation à d'autres filières BtoB. Troisièmement, la détection de saisonnalité sur volumes bruts mensuels appelle, en prolongement, une décomposition STL ou ARIMA pour distinguer tendance, saisonnalité et bruit, et fournirait un critère théorique objectif pour le seuil de volatilité, actuellement retenu sur une base empirique. Quatrièmement, le seuil FCM de 60 % résulte d'un arbitrage explicite entre signal statistique maximal (36 %, $n = 11$) et pertinence opérationnelle (60 %, $n = 170$) ; de futurs travaux pourraient formaliser ce compromis en intégrant le coût relatif des faux positifs et faux négatifs. Enfin, cette étude ne prend pas en compte les actions marketing et commerciales susceptibles d'influencer le *churn*.

Néanmoins, l'absence d'actions en 2024 et le caractère non ciblé des actions déployées en 2025 réduisent le risque de biais sur les résultats observés.

En articulant instabilité structurelle et temporalité d'usage, cette recherche propose ainsi un cadre d'analyse simple mais généralisable, permettant de transformer une segmentation descriptive en un outil d'aide à la décision robuste dans des environnements marqués par l'incertitude et la variabilité temporelle.

Annexes

Annexe 1 : Traitement Python et résultat de la segmentation RFM K-means

```
Colonnes : ['Code_Client', 'Statut_Client', 'R_janv', 'F_janv', 'M_janv', 'Score_RFM_janv', 'Cluster_janv', 'Segment_janv', 'R_
dec', 'F_dec', 'M_dec', 'Score_RFM_dec', 'Cluster_dec', 'Segment_dec', 'Delta_RFM', 'Churn', 'Transition']
Clients historiques actifs retenus pour les analyses : 2428 (exclus : 0)
✅ stats_par_segment_janv.csv généré
      Segment_janv  N_clients  ...  Delta_RFM_moy  Churn_rate
0   Clients captifs        359  ...          -5.59        0.57
1  Clients à risque        285  ...         -12.12        0.19
2   À ne pas perdre        279  ...          -4.99        0.03
3      À travailler       1157  ...          -7.26        0.04

[4 rows x 6 columns]

✅ matrice_transition_janv_dec.csv généré
Segment_dec       Clients captifs  ...  À travailler
Segment_janv                       ...
Clients captifs             0.198  ...         0.117
Clients à risque            0.232  ...         0.344
À ne pas perdre             0.022  ...         0.301
À travailler                0.089  ...         0.796

[4 rows x 5 columns]

=== H1 : effet de Segment_janv sur Score_RFM_dec ===
Segments considérés : ['Clients captifs', 'Clients à risque', 'À ne pas perdre', 'À travailler']
F = 575.36 ; p-value = 4.06e-272

--- Tests post hoc : Tukey HSD (comparaisons par paires) ---
          Multiple Comparison of Means - Tukey HSD, FWER=0.05
=====================================================================
     group1           group2      meandiff p-adj  lower    upper  reject
---------------------------------------------------------------------
 Clients captifs Clients à risque  25.2691   0.0  20.6404 29.8978   True
 Clients captifs  À ne pas perdre   63.499   0.0  58.8426 68.1553   True
 Clients captifs     À travailler  49.2617   0.0   45.737 52.7864   True
Clients à risque  À ne pas perdre  38.2299   0.0  33.3163 43.1434   True
Clients à risque     À travailler  23.9926   0.0  20.1345 27.8507   True
 À ne pas perdre     À travailler -14.2373   0.0 -18.1285 -10.346   True
---------------------------------------------------------------------
✅ posthoc_tukey_H1.csv généré

--- Tailles d'effet (Cohen's d) par paire de segments ---
Groupe 1                 Groupe 2                    Cohen d  Interprétation
-------------------------------------------------------------------------------
Clients captifs          Clients à risque              0.888            fort
Clients captifs          À ne pas perdre               2.695            fort
Clients captifs          À travailler                  2.223            fort
Clients à risque         À ne pas perdre               1.588            fort
Clients à risque         À travailler                  1.076            fort
À ne pas perdre          À travailler                  0.728          modéré

=== H3 : lien Segment_janv × Churn ===
Churn                0    1
Segment_janv
Clients captifs    154  205
Clients à risque   232   53
À ne pas perdre    272    7
À travailler      1115   42

χ² = 662.15 ; ddl = 3 ; p-value = 3.387e-143
V de Cramér = 0.564  (0 = aucune association, 1 = parfaite)

=== H2 : À ne pas perdre stables vs dégradés (ΔRFM) ===
Nb stables   : 182
Nb dégradés  : 97
t = 5.26 ; p-value = 8.17e-07
ΔRFM moyen stables  : -0.76
ΔRFM moyen dégradés : -12.94
```

Annexe 2 : Traitement Python et résultat du FCM

```
[panel] Colonnes détectées : ['Code_Client', 'Statut_Client', 'R_janv', 'F_janv', 'M_janv', 'Score_RFM_janv', 'Cluster_janv', '
Segment_janv', 'R_dec', 'F_dec', 'M_dec', 'Score_RFM_dec', 'Cluster_dec', 'Segment_dec', 'Delta_RFM', 'Churn', 'Transition']
[janvier] Colonnes détectées : ['Code Client', 'R', 'F', 'M', 'Score_RFM', 'Statut_Client', 'Cluster', 'Segment']
Clients historiques actifs pour FCM : 2080

Fuzzy Partition Coefficient (FPC) : 0.7931
  (1 = partition nette, 0.25 = aléatoire)

Centroïdes FCM (espace original) :
              R_cent  F_cent  M_cent
cluster_fcm
0               9.95    9.89    1.31
1               9.89    3.92    0.23
2               3.53    3.29    0.20
3               9.89    9.96    6.60

Correspondance cluster FCM → segment métier :
 cluster_fcm       Segment_FCM  R_cent  F_cent  M_cent
           3  À ne pas perdre    9.89    9.96    6.60
           0     À travailler    9.95    9.89    1.31
           1  Clients captifs    9.89    3.92    0.23
           2 Clients à risque    3.53    3.29    0.20

Clients nets (max_degré ≥ 0.6)   : 1910
Clients frontière (max_degré < 0.6) : 170

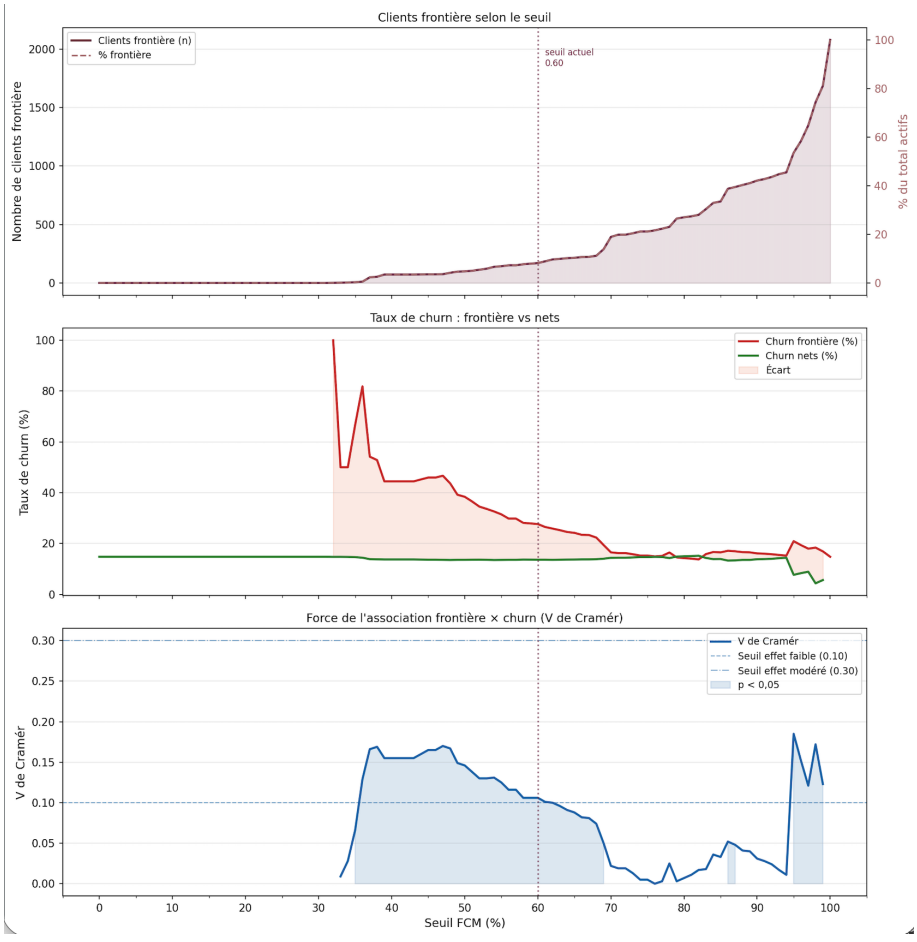
── Statistiques descriptives ──
                     N  RFM_janv_moy  RFM_dec_moy  Delta_RFM_moy  Churn_rate  max_degre_moy
Clients nets      1910        72.174       65.118         -7.056       0.136          0.899
Clients frontière  170        67.191       56.751        -10.441       0.276          0.458

── χ² frontière × Churn ──
Churn                0    1
client_frontiere
0                 1650  260
1                  123   47
χ² = 23.34 ; ddl = 1 ; p-value = 1.36e-06
V de Cramér = 0.106  (0=aucune association, 1=parfaite)

── Test t de Welch : ΔRFM frontière vs nets ──
ΔRFM moyen frontière : -10.44  (n=170)
ΔRFM moyen nets      : -7.06  (n=1910)
t = -1.50 ; p-value = 0.1362

✅ fcm_panel_enrichi.csv généré
```

Annexe 3 : Analyse de sensibilité du seuil FCM



Annexe 4 : Traitement Python et résultat de la saisonnalité

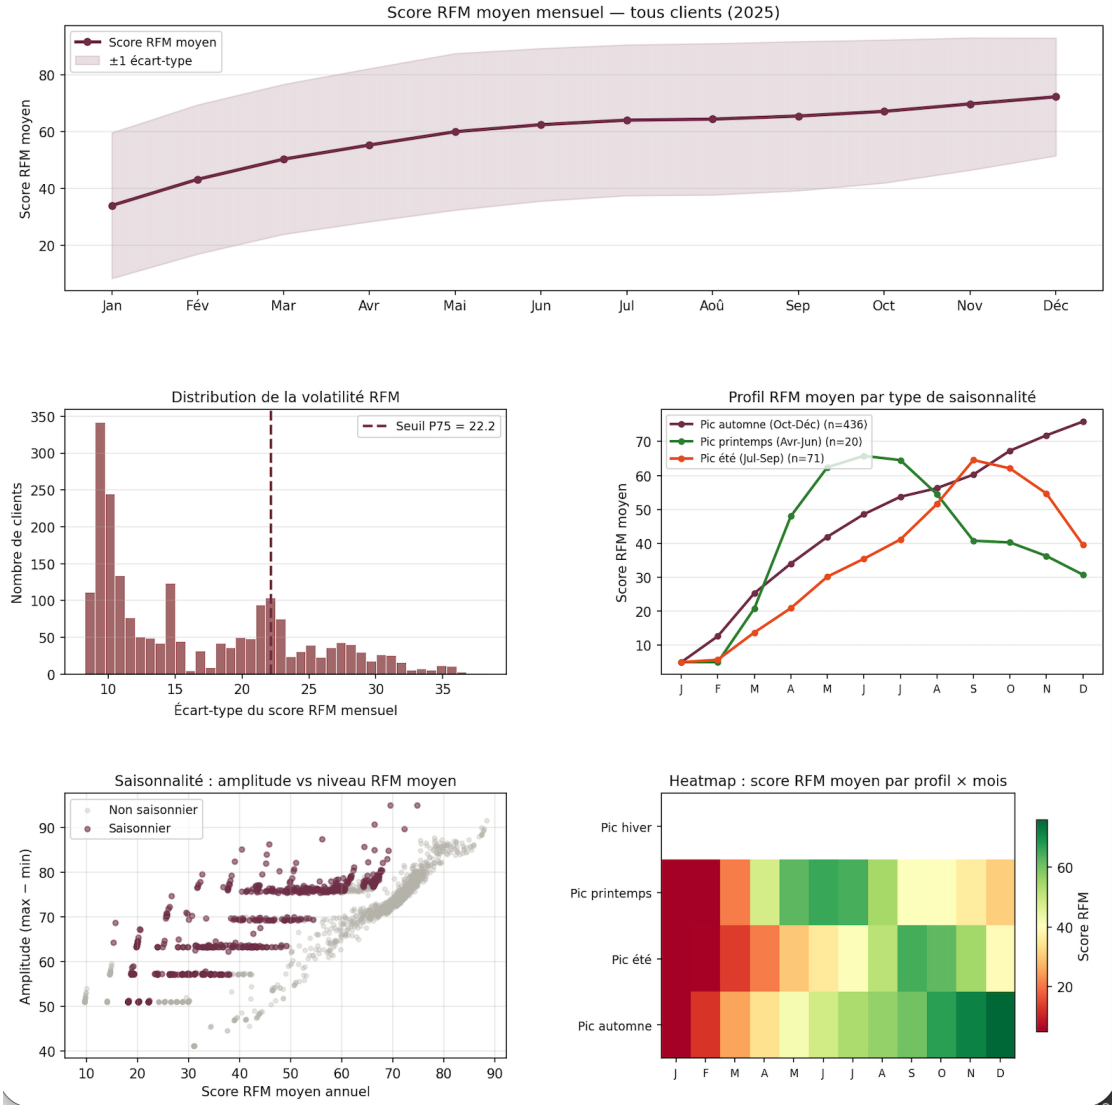
```
Colonnes mois détectées : ['Mois1', 'Mois2', 'Mois3', 'Mois4', 'Mois5', 'Mois6', 'Mois7', 'Mois8', 'Mois9', 'Mois10', 'Mois11',
'Mois12']
Nombre de clients : 2121
✅ rfm_mensuel_2025.csv généré (25452 lignes)

Seuil écart-type saisonnalité : 22.17
Clients saisonniers détectés  : 527 (24.8%)

── Distribution des profils saisonniers ──
                          N  RFM_moy  Amplitude  Volatilite
profil_pic
Pic automne (Oct-Déc)     436    44.64      70.89       27.48
Pic printemps (Avr-Jun)    20    38.28      60.78       23.39
Pic été (Jul-Sep)          71    34.62      59.55       25.39

✅ saisonnalite_segments.csv généré (527 clients)
✅ Graphique sauvegardé : saisonnalite_plot.png
```

Annexe 5 : Analyse de la saisonnalité RFM 2025



Références bibliographiques

Auteurs (2023).

Auteurs (2026).

Ariwiati, Susanty A. et Batu K. (2025), An Integrated Lrfm and CLV-Based Customer Segmentation Model for B2B E-Marketplace Platform, *2025 12th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE).*

Bezdek J.C. (1981), Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York.

Christy A., Umamakeswari A., Priyatharsini L. et Neyaa A. (2021), RFM ranking — An effective approach to customer segmentation, *Journal of King Saud University — Computer and Information Sciences,* 33(8), 1251-1257.

Fader P.S., Hardie B.G.S. et Lee K.L. (2005), RFM and CLV: Using iso-value curves for customer base analysis, *Journal of Marketing Research,* 42(4), 415-430.

Jallat F., Peelen E., Stevens É. et Volle P. (2014), Gestion de la relation client, 4e éd., Pearson Education, Paris.

Lee N., Lee H., Hsin J. et Fang S. (2024), Prediction of Customer Behavior Changing via a Hybrid Approach, *IEEE Open Journal of the Computer Society,* 5, 27-38.

Laksono F.A., Rachmat B. et Sutasrso Y. (2023), B2B Customer Segmentation Based on Customer Lifetime Value with RFM Modeling, *International Journal of Economics Development Research,* 4(3), 1856-1874.

Marín Díaz G. (2025), A Fuzzy-XAI Framework for Customer Segmentation and Risk Detection, *Mathematics,* 13(2141), 1-28.

Nguyen P.S., Trinh T.M.L., Ngo G.T., Luu V.P.T. et Tu V.B. (2022), B2B and Its Market Segmentation Based On RFM with Clustering Technique, *American International Journal of Business Management,* 5(3), 114-124.

Ranjan A. et Kumar A. (2025), Unsupervised Clustering-Based Behavioral Segmentation for Customer Churn Prediction, *Proc. ICoEIT 2025,* 1550-1555.

Ray J.-C. (1988), Données censurées et modèles de durées, *Recherche et Applications en Marketing,* 3(2), 77-88.

Sivasankar E. et Vijaya J. (2017), Customer Segmentation by Various Clustering Approaches and Building an Effective Hybrid Learning System on Churn Prediction Dataset, *Advances in Intelligent Systems and Computing,* vol. 556, Springer, 181-191.

Wang S., Sun L. et Yu Y. (2024), A dynamic customer segmentation approach by combining LRFMS and multivariate time series clustering, *Scientific Reports,* 14, 17491.

Wünderlich R., Wünderlich N. et Wangenheim F. (2022), A Seasonal Model with Dropout to Improve Forecasts of Purchase Levels, *Journal of Interactive Marketing,* 57, 212-236.

Zammit D. et Zerafa C. (2025), A Simplified and Numerically Stable Approach to the BG/NBD Churn Prediction Model, *ArXiv,* abs/2502.12912, 1-4.