

Louvain School of Management

Dans quelle mesure l'adaptation du paramètre de pondération β au niveau utilisateur permet-elle d'améliorer le compromis entre précision et durabilité dans les stratégies de post-processing des systèmes de recommandation ?

Auteur : Charles Molle

Promoteur : Prof. Chloé Satinet

Année académique 2025–2026

Master [120] en Ingénieur de gestion, à finalité spécialisée

Majeure Business Analytics

PRACTICAL DOS AND DONTs OF GENERATIVE AI

LSM adopts the following practical guidelines developed by Prof. Benoît Gailly³ in its “hitchhiker’s guide to a Master Thesis”:

DONTs	DOs
Delegate with no or limited understanding	Think first by yourself about the problem
Always use free and/or popular tools	Select the right source(s) of assistance
Share confidential, sensitive or proprietary content	Provide information regarding your context, motivations and expectations
Look for (or expect) definitive answers	Ask for suggestions and inspirations; iterate
Take for granted and integrate blindly	Review and challenge output and sources
Claim or make people believe that you did everything yourself	Disclose that you have been helped (and how)

DECLARATION

The declaration below is **mandatory and must appear on the first page (after the front page) of your master’s thesis.**

STATEMENTS ON YOUR USE OF GENERATIVE AI

Confirm the following statements:

Statements on responsible use of generative AI	Your answer
The content of my/our master’s thesis is my/our original output, even if I/we used generative AI to help prepare it.	☒ Yes ☐ No
I/we master the theories, tools and methods that I/we use for the thesis.	☒ Yes ☐ No
I/we verified that the output presented in the thesis is accurate and valid, and that it contains no hallucination, no false reference, etc.	☒ Yes ☐ No
I/we acknowledge that I/we master the final output and that I am/we are able to explain it and answer questions about it.	☒ Yes ☐ No
I/we made sure not to provide generative AI tools with access to confidential data or information	☒ Yes ☐ No

³ Gailly, Benoît (2025) *The hitchhiker’s guide to a Master Thesis supervised by Prof. Benoit Gailly at Louvain School of Management*. UCLouvain, LSM.

SIGNATURE

Sign your declaration:

	Author last name, first name(s)	Date	Signature
1	Molle Charles	27/05/2026	
2			

NOTE

During the preparation of this master's thesis, I, Charles Molle, utilized the following AI tools for the purposes described below:

1. Academic writing and paraphrasing assistance :

Claude (Anthropic) and ChatGPT (OpenAI) were used to reformulate and paraphrase written passages in order to improve clarity and academic register.

2. LaTeX typesetting assistance :

Claude (Anthropic) was used to assist with the typesetting and formatting of the thesis document in LaTeX, including syntax guidance for mathematical expressions, tables, figures, and document structure.

3. Code assistance and debugging :

Claude Code (Anthropic) was used to assist with the structuring, optimisation, and debugging of the Python codebase developed for the data pipeline and empirical analyses.

4. Document review and consistency checking :

NotebookLM (Google) was used to support the consultation and synthesis of academic sources during the literature review phase.

After using these tools, I diligently reviewed and edited all content produced. I take full responsibility for the final content presented in this thesis. By signing this declaration, I affirm that the content of this master's thesis reflects my original work, augmented by the responsible use of AI.

Résumé

Face aux limites d'une optimisation purement centrée sur la pertinence, l'intégration de la durabilité dans les systèmes de recommandation constitue un enjeu croissant pour orienter les comportements de consommation. Cependant, les approches existantes de post-processing reposent généralement sur un paramètre de pondération global (β), supposant implicitement une sensibilité homogène des utilisateurs aux enjeux environnementaux. Ce mémoire étudie dans quelle mesure l'adaptation d'un paramètre personnalisé au niveau de l'utilisateur (β_u) permet d'améliorer le compromis entre la précision des recommandations et l'intégration de la durabilité.

À cette fin, trois stratégies d'estimation du paramètre β_u sont proposées et évaluées : une approche comportementale basée sur l'historique d'interactions, une approche sémantique exploitant les titres des produits via un modèle de traitement du langage naturel, et une approche hybride combinant ces deux signaux via un mécanisme de *shrinkage*. Ces stratégies sont intégrées par le biais de deux méthodes de post-processing (ajustement linéaire et formation incrémentale avec calibration) appliquées à quatre modèles de base (User-kNN, Item-kNN, SVD, Content-Based). Le cadre expérimental s'appuie sur deux jeux de données e-commerce d'Amazon présentant des caractéristiques de sparsité contrastées.

Les expérimentations démontrent que la méthode incrémentale préserve mieux la précision globale que l'ajustement linéaire classique. L'efficacité des approches adaptatives dépend fortement de la disponibilité des données : l'approche comportementale différencie efficacement les profils utilisateurs lorsque le catalogue est riche en items durables, tandis que les approches sémantique et hybride permettent de pallier la rareté des données d'interaction en détectant des affinités implicites pour les produits durables. Bien que ces méthodes adaptatives ne surpassent pas systématiquement le β global, elles génèrent des compromis robustes et équilibrés entre précision et durabilité, sans nécessiter de réglage manuel préalable du paramètre.

En conclusion, l'adaptation du paramètre de post-processing au niveau utilisateur constitue une approche viable pour concilier recommandations durables et hétérogénéité des préférences. Les pistes futures incluent l'enrichissement du signal sémantique par des métadonnées explicites (matières, labels) et la validation de ces approches par des évaluations en ligne impliquant de véritables utilisateurs.

Mots-clés : Systèmes de recommandation, durabilité, post-processing, paramètre adaptatif, multi-objectif.

Remerciements

Je tiens tout d'abord à exprimer ma sincère gratitude à Madame Chloé Satinet, ma promotrice, pour son encadrement rigoureux et bienveillant tout au long de la réalisation de ce mémoire. Ses conseils avisés, sa disponibilité et ses retours constructifs ont été déterminants dans l'évolution de ce travail et m'ont permis de mener cette recherche avec méthode et rigueur.

Je souhaite également remercier ma famille, et en particulier mes parents, pour leur soutien indéfectible tout au long de mes études. Leur confiance, leurs encouragements constants et leur bienveillance ont été une source de motivation précieuse, notamment dans les moments les plus difficiles de ce parcours académique.

Je remercie aussi sincèrement mes amis, Haitam Belguenani, Cyril Demolin, Inas Nanat et Lisa Dounia, pour leur présence, leur bonne humeur et leur aide précieuse tout au long de mes études. Partager ces années avec eux a rendu ce parcours bien plus agréable. Leur soutien moral, leur écoute et les moments partagés ensemble ont été une source d'énergie et de motivation constante, et je suis reconnaissant de les avoir eu à mes côtés durant cette période.

Enfin, je tiens à remercier tout particulièrement Ilénia Bonifacio, pour son soutien tout au long de cette aventure. Sa présence et ses encouragements dans les moments les plus intenses et les plus stressants de ce travail ont été d'une aide précieuse. Merci d'avoir été là et de m'avoir toujours poussée à donner le meilleur de moi-même.

Table des matières

1	Introduction	6
2	Revue de Littérature	8
2.1	Systèmes de recommandation	8
2.1.1	Définition d'un système de recommandation	8
2.1.2	Fonctionnement d'un système de recommandation	8
2.1.3	Types de systèmes de recommandation	9
2.1.3.1	Le filtrage basé sur le contenu (<i>Content-Based Filtering</i>)	9
2.1.3.2	Le filtrage collaboratif (<i>Collaborative Filtering</i>)	9
2.1.3.3	Les systèmes hybrides	10
2.1.4	Évaluation d'un système de recommandation	10
2.1.4.1	Méthodologies d'évaluation	10
	Évaluation hors ligne :	11
	Études utilisateurs (<i>User studies</i>) :	11
	Évaluation en ligne :	11
2.1.4.2	Métriques d'évaluation classiques	12
	Métriques de prédiction (<i>rating prediction</i>) :	12
	Métriques de recommandation <i>Top-N</i> :	12
	Métriques orientées classement (<i>Ranking metrics</i>) :	12
2.2	Limites des approches centrées sur la précision	13
2.2.1	Limites de la précision	13
2.3	Passage aux systèmes multi-objectifs	14
2.3.1	Diversité, nouveauté et sérendipité	15
2.3.2	Équité algorithmique	15
2.3.3	Compromis entre objectifs	16
2.4	Intégration de la durabilité dans les systèmes de recommandation	16
2.4.1	Recommandation durable	16
2.4.2	Méthodes d'intégration de la durabilité	18
2.4.2.1	Le post-processing comme méthode d'intégration	18
2.4.2.2	Les trois catégories de stratégies de post-processing	19
2.4.3	Limites des approches existantes	20

3	Méthodologie	21
3.1	Objectif de recherche	21
3.2	Description des données	21
3.2.1	Définition d'un utilisateur durable	23
3.3	Implémentation des modèles et stratégies de post-processing	24
3.3.1	Modèles de base	24
3.3.2	Stratégies de post-processing	26
3.3.2.1	Ajustement linéaire des scores (Stratégie A)	26
3.3.2.2	Formation incrémentale avec calibration (Stratégie B)	27
3.3.3	Estimation du paramètre β_u	28
3.3.3.1	Approche comportementale (Stratégie 1)	28
3.3.3.2	Approche sémantique (Stratégie 2)	29
3.3.3.3	Approche hybride avec <i>shrinkage</i> (Stratégie 3)	30
3.4	Cadre d'évaluation	31
3.4.1	Métriques de précision	31
3.4.2	Métriques de durabilité	32
3.4.3	Métrique de diversité	34
3.4.4	Protocole de comparaison	34
4	Analyse des résultats	35
4.1	Performances des modèles de base	35
4.2	Distribution des paramètres β_u adaptatifs	36
4.2.1	Distribution globale des β_u	36
4.2.2	Distribution des β_u par profil d'utilisateur	37
4.3	Compromis précision/durabilité : β global et β_u adaptatif	37
4.4	Analyse par profil d'utilisateur	39
4.5	Impact sur la diversité	40
4.6	Synthèse	41
5	Discussion	42
5.1	Réponse aux questions de recherche	42
5.2	Mise en perspective avec la littérature	43
5.3	Limites	44
5.4	Pistes futures	44
6	Conclusion	46
A	Annexes	49

Table des figures

A.1	Distribution des β_u adaptatifs — DS1 (haut) et DS2 (bas).	49
A.2	Distribution des β_u adaptatifs par profil d'utilisateur — DS1 (haut) et DS2 (bas).	50
A.3	Frontière Précision/Durabilité — Stratégie A, DS1 et DS2.	51
A.4	Frontière Précision/Durabilité — Stratégie B, DS1 et DS2.	51
A.5	Analyse gap utilisateurs durables/non durables — Stratégie A, DS1 (haut) et DS2 (bas).	52
A.6	Analyse gap utilisateurs durables/non durables — Stratégie B, DS1 (haut) et DS2 (bas).	53

Liste des tableaux

3.1	Synthèse et caractéristiques des jeux de données	23
3.2	Caractéristiques des modèles de base	26
4.1	Performances des modèles de base ($\beta = 0$, moyenne 5 folds)	35
4.2	Recall@5 et avg_EI par mode et stratégie (4 modèles agrégés, moyenne 5 folds)	38
4.3	Coverage et sust_coverage par mode et stratégie (4 modèles agrégés, moyenne 5 folds)	40

Liste des abréviations

AvgEI	<i>Average Environmental Impact</i>
CF	<i>Collaborative Filtering</i> — Filtrage Collaboratif
DS1	<i>Dataset 1</i> — Amazon Clothing, Shoes & Jewelry
DS2	<i>Dataset 2</i> — Amazon Clothing
Item-kNN	<i>Item-based k-Nearest Neighbors</i>
NDCG@K	<i>Normalized Discounted Cumulative Gain</i>
NLP	<i>Natural Language Processing</i> — Traitement du Langage Naturel
Recall@N	<i>Recall</i> — Rappel
RQ1/RQ2	<i>Research Question 1 et 2</i>
SVD	<i>Singular Value Decomposition</i>
TF-IDF	<i>Term Frequency-Inverse Document Frequency</i>
Top-N/Top-K	Liste des N ou K meilleures recommandations
User-kNN	<i>User-based k-Nearest Neighbors</i>

1. Introduction

Au cours des dernières années, les systèmes de recommandation ont pris une place importante dans notre société (Wei et al., 2025). Ces systèmes permettent d’analyser de vastes ensembles d’informations afin de proposer aux utilisateurs les options les plus pertinentes en fonction de leurs préférences ou de leur contexte (Zhang et al., 2025). Aujourd’hui, ils sont omniprésents, que ce soit sur les plateformes de streaming vidéo, de musique ou encore d’e-commerce.

Historiquement, les systèmes de recommandation ont principalement été conçus dans l’objectif de maximiser la pertinence des recommandations. Toutefois, de nombreux travaux récents montrent qu’optimiser la pertinence seule ne suffit pas à garantir une expérience utilisateur satisfaisante. D’autres critères, tels que la diversité, la nouveauté ou l’équité, ont progressivement été intégrés afin de mieux refléter la complexité des attentes des utilisateurs (Satinet et al., 2024).

Dans ce contexte, l’intégration d’objectifs sociétaux plus larges, et notamment environnementaux, apparaît comme une extension naturelle des systèmes de recommandation. Plusieurs travaux récents soulignent le rôle que ces systèmes peuvent jouer dans l’orientation des comportements de consommation et la nécessité d’y intégrer des considérations liées à la durabilité (Satinet et al., 2024 ; Zhou et al., 2024).

Les travaux existants proposent différentes stratégies visant à intégrer la durabilité dans les systèmes de recommandation (Satinet et al., 2024). Dans le cadre de ce mémoire, nous nous concentrons sur les stratégies de *post-processing*, qui permettent d’ajuster les recommandations produites par un modèle de base afin d’y intégrer des objectifs environnementaux, tout en limitant la dégradation de la pertinence. Toutefois, ces approches supposent généralement une sensibilité homogène des utilisateurs aux enjeux environnementaux, ce qui apparaît restrictif face à l’hétérogénéité des préférences. Cette limite soulève la question de l’adaptation des stratégies de *post-processing* au niveau utilisateur, afin de mieux concilier précision et durabilité.

Dans ce cadre, la question de recherche principale de ce mémoire est la suivante :

« Dans quelle mesure l’adaptation du paramètre de pondération β au niveau utilisateur permet-elle d’améliorer le compromis entre la précision des recommandations et l’intégration de la durabilité dans les stratégies de post-processing des systèmes de recommandation ? »

Afin d’y répondre, cette question principale est déclinée en deux sous-questions :

1. **RQ1** : L’utilisation d’un paramètre β_u adaptatif permet-elle d’améliorer le compromis entre précision et durabilité des recommandations, par rapport à une approche basée sur un paramètre β global ?
2. **RQ2** : Quelles stratégies d’estimation du paramètre β_u au niveau utilisateur offrent les

meilleurs compromis entre précision et durabilité ?

Ce mémoire est structuré comme suit. Le chapitre 2 présente une revue de la littérature relative aux systèmes de recommandation et à l'intégration de critères environnementaux. Le chapitre 3 décrit la méthodologie employée, incluant les données utilisées, les modèles de recommandation considérés et les stratégies de *post-processing* étudiées. Le chapitre 4 présente les résultats expérimentaux obtenus, tandis que le chapitre 5 en propose une discussion approfondie et ouvre des perspectives de recherche futures. Enfin, le chapitre 6 conclut ce travail.

2. Revue de Littérature

Dans cette revue de littérature, nous commencerons par présenter les bases théoriques des systèmes de recommandation afin de poser le cadre conceptuel de ce travail, puis nous discuterons des limites des approches centrées sur la seule optimisation de la précision et de l'évolution vers des objectifs multiples, avant d'aborder les recommandations durables et leurs limites.

2.1 Systèmes de recommandation

2.1.1 Définition d'un système de recommandation

Commençons tout d'abord par définir de manière théorique les systèmes de recommandation et leurs rôles principaux. Les systèmes de recommandation peuvent être définis, selon Wei et al. (2025), comme des outils visant à fournir aux utilisateurs des recommandations personnalisées en fonction de leurs intérêts et de leurs caractéristiques.

Plus précisément, le fonctionnement de ces systèmes repose sur la capacité à prédire le degré d'intérêt qu'un utilisateur pourrait accorder à un item non encore consulté, généralement sous la forme d'un score permettant d'établir un classement personnalisé des recommandations (Ko et al., 2022 ; Muhammad et al., 2025).

Dans l'environnement numérique actuel, les systèmes de recommandation sont omniprésents, notamment dans les plateformes de streaming, de musique ou d'e-commerce. L'un des rôles majeurs mis en évidence par la littérature est leur capacité à faire face à la surcharge informationnelle, en facilitant la prise de décision des utilisateurs (Ma et al., 2025 ; Muhammad et al., 2025).

2.1.2 Fonctionnement d'un système de recommandation

Avant d'explorer les différentes familles de systèmes de recommandation, il est nécessaire d'en présenter le fonctionnement général. Un système de recommandation repose principalement sur deux catégories d'entités : les utilisateurs (*users*) et les *items*.

Dans la pratique, un utilisateur n'interagit qu'avec une partie limitée des *items* disponibles, ce qui rend les données observées incomplètes. Le système vise alors à prédire les interactions manquantes afin d'estimer l'intérêt potentiel d'un utilisateur pour un *item*.

Les systèmes de recommandation reposent principalement sur deux types de données : les données explicites et les données implicites (Ko et al., 2022). Les données explicites correspondent aux informations fournies directement par l'utilisateur (notes, avis, etc.), tandis que les données implicites sont issues de son comportement (clics, achats, temps passé). Ces dernières sont plus

abondantes mais plus difficiles à interpréter, car une interaction ne reflète pas nécessairement une préférence réelle (Muhammad et al., 2025 ; Wei et al., 2025).

Après avoir présenté les différents types de données, il est désormais pertinent de présenter le fonctionnement général de ces systèmes. Quelle que soit la famille à laquelle ils appartiennent, les systèmes de recommandation suivent généralement un processus organisé en trois étapes principales.

Tout d’abord, ils estiment un score de prédiction pour chaque paire utilisateur-item non observée, représentant le degré d’intérêt potentiel de l’utilisateur (Ko et al., 2022 ; Muhammad et al., 2025). Ces scores sont ensuite utilisés pour classer les *items* par ordre de pertinence. Afin de rendre les recommandations exploitables, le système sélectionne uniquement les N *items* les mieux classés, constituant ainsi la liste *Top-N* proposée à l’utilisateur. Enfin, la qualité des recommandations est évaluée afin de mesurer la pertinence des résultats et de comparer différentes approches.

2.1.3 Types de systèmes de recommandation

La littérature scientifique distingue généralement trois grandes familles de systèmes de recommandation, reposant sur des approches différentes pour modéliser les préférences des utilisateurs (Khadka & Sthapit, 2025 ; Ko et al., 2022).

2.1.3.1 Le filtrage basé sur le contenu (*Content-Based Filtering*)

Le filtrage basé sur le contenu s’appuie sur les caractéristiques des articles, telles que leurs descriptions ou leurs attributs. Il consiste à recommander des *items* similaires à ceux que l’utilisateur a déjà appréciés, en construisant un profil basé sur ses interactions passées (Khadka & Sthapit, 2025).

Cette approche permet notamment de recommander de nouveaux articles, mais peut limiter la diversité des recommandations en favorisant des contenus similaires (phénomène de sur-spécialisation) (Ko et al., 2022).

2.1.3.2 Le filtrage collaboratif (*Collaborative Filtering*)

Le filtrage collaboratif repose sur l’analyse des interactions passées entre les utilisateurs et les *items*. Il s’appuie sur l’idée que des utilisateurs ayant des comportements similaires auront des préférences similaires (Ko et al., 2022).

Cette famille regroupe deux grandes approches : les méthodes *memory-based* et les méthodes *model-based*.

- **Memory-based** : Ces méthodes, telles que les algorithmes k -NN, exploitent directement les similarités entre utilisateurs ou entre *items* à partir de la matrice d’interactions. On distingue généralement deux variantes : le *User-based Collaborative Filtering*, qui recom-

mande des *items* appréciés par des utilisateurs similaires ; et le *Item-based Collaborative Filtering*, qui recommande des *items* similaires à ceux déjà appréciés par l'utilisateur (Ko et al., 2022).

- **Model-based** : Ces approches reposent sur des techniques d'apprentissage automatique afin de construire un modèle prédictif à partir des données. Elles incluent notamment les méthodes de factorisation de matrices, telles que la SVD (*Singular Value Decomposition*), qui permettent d'identifier des facteurs latents représentant les préférences des utilisateurs et les caractéristiques des *items* (Khadka & Sthapit, 2025).

Bien que le filtrage collaboratif permette de générer des recommandations pertinentes et parfois inattendues, il est fortement affecté par la rareté des données (*sparsity*) ainsi que les problèmes de démarrage à froid (*cold-start*) lorsqu'il s'agit de nouveaux utilisateurs ou de nouveaux articles (Ko et al., 2022).

2.1.3.3 Les systèmes hybrides

Les systèmes hybrides combinent les approches basées sur le contenu et collaboratives afin de tirer parti de leurs avantages respectifs et de limiter leurs faiblesses. Ils permettent notamment d'améliorer la robustesse des recommandations en réduisant les problèmes liés à la rareté des données, au démarrage à froid ou encore au manque de diversité (Khadka & Sthapit, 2025).

2.1.4 Évaluation d'un système de recommandation

L'évaluation des systèmes de recommandation est essentielle pour garantir la qualité et la pertinence des suggestions proposées aux utilisateurs. Elle permet de mesurer la capacité des algorithmes à répondre aux besoins des utilisateurs et à proposer et classer des *items* pertinents dans le cadre des recommandations *Top-N* (Ko et al., 2022 ; Wei et al., 2025). Elle permet également de comparer différentes approches à l'aide de métriques standardisées (Kuanr & Mohapatra, 2021).

La littérature distingue généralement trois principales approches d'évaluation : l'évaluation hors ligne, les études utilisateurs et l'évaluation en ligne.

2.1.4.1 Méthodologies d'évaluation

L'évaluation d'un système de recommandation s'inscrit généralement dans un processus progressif. Dans un premier temps, les modèles sont développés et validés à l'aide d'évaluations hors ligne fondées sur des données historiques. Toutefois, la performance algorithmique ne garantissant pas nécessairement la satisfaction des utilisateurs, les modèles les plus performants peuvent ensuite être soumis à des études utilisateurs dans un environnement contrôlé. Enfin, les systèmes peuvent être évalués en ligne lors de leur déploiement, afin d'observer les comportements réels des utilisateurs (Khadka & Sthapit, 2025).

Évaluation hors ligne : L'évaluation hors ligne est largement utilisée dans la recherche académique (Khadka & Sthapit, 2025). Elle vise à estimer la capacité d'un modèle à généraliser à partir de données passées, en simulant les interactions utilisateurs sans nécessiter d'expérimentation en temps réel (Ko et al., 2022 ; Ragain et al., 2018).

Dans ce cadre, les données sont généralement divisées en deux sous-ensembles distincts : un ensemble d'entraînement (*training set*), sur lequel le modèle est construit, et un ensemble de test (*testing set*), pour évaluer la capacité du modèle à prédire les interactions masquées (Kuanr & Mohapatra, 2021).

La fiabilité des résultats dépend fortement de la stratégie de partitionnement des données et du protocole de test. Des approches telles que la validation croisée, qui consiste à diviser les données en plusieurs sous-ensembles utilisés successivement pour l'entraînement et le test, ou le *leave-one-out*, où une interaction est conservée pour le test tandis que les autres servent à l'entraînement, sont couramment utilisées afin de limiter les biais d'évaluation (Khadka & Sthapit, 2025 ; Satinet et al., 2024 ; Zhao et al., 2025). Toutefois, ces méthodes doivent être appliquées avec précaution, car elles peuvent introduire des problèmes de fuite de données lorsque des informations futures influencent indirectement l'entraînement du modèle (Ma et al., 2025).

Études utilisateurs (*User studies*) : Les études utilisateurs constituent une approche d'évaluation reposant sur l'interaction directe de participants avec le système de recommandation. Elles permettent de collecter des retours afin d'évaluer la satisfaction et la perception des recommandations dans un environnement contrôlé (Khadka & Sthapit, 2025).

Elles sont particulièrement utiles pour capturer des dimensions qualitatives, telles que la satisfaction ou la nouveauté, qui ne sont pas toujours reflétées par les métriques de précision. Toutefois, cette approche présente des contraintes importantes en termes de coût et de mise en œuvre (Khadka & Sthapit, 2025).

Évaluation en ligne : L'évaluation en ligne consiste à tester les systèmes de recommandation en conditions réelles, directement auprès des utilisateurs (Khadka & Sthapit, 2025). Elle repose généralement sur des tests A/B, permettant de comparer les performances d'un nouveau modèle avec un système existant (Khadka & Sthapit, 2025 ; Kuanr & Mohapatra, 2021).

Elle permet d'analyser le comportement des utilisateurs à l'aide de métriques d'engagement, telles que le taux de clics, le taux de rétention ou le taux de conversion. Toutefois, bien que cette approche soit la plus réaliste, elle reste coûteuse, difficile à mettre en œuvre dans un contexte académique et peut être affectée par du bruit dans les données (Khadka & Sthapit, 2025).

2.1.4.2 Métriques d'évaluation classiques

Les performances des systèmes de recommandation sont généralement évaluées à l'aide de métriques quantitatives permettant de mesurer différents aspects de la qualité des recommandations. La littérature distingue trois grandes catégories : les métriques de prédiction, les métriques de recommandation *Top-N* et les métriques de classement.

Métriques de prédiction (*rating prediction*) : Les métriques de prédiction visent à évaluer la précision d'un modèle en mesurant l'écart entre la valeur estimée par le système et la valeur réelle donnée par l'utilisateur (Khadka & Sthapit, 2025). Les indicateurs les plus couramment utilisés sont le MAE (équation 1) et le RMSE (équation 2) (Ko et al., 2022 ; Kuanr & Mohapatra, 2021). Le MAE mesure l'erreur moyenne en valeur absolue, tandis que le RMSE accorde davantage de poids aux erreurs importantes.

MAE	RMSE
$\frac{1}{ Q } \sum_{(u,i) \in Q} r_{ui} - s_{ui} $	$\sqrt{\frac{1}{ Q } \sum_{(u,i) \in Q} (r_{ui} - s_{ui})^2}$
(1)	(2)

où r_{ui} est la note réelle de l'utilisateur u pour l'item i , s_{ui} la note prédite, et $|Q|$ le nombre total de paires évaluées.

Métriques de recommandation *Top-N* : Les métriques *Top-N* évaluent la pertinence des items recommandés à partir d'une transformation binaire des préférences. Les principales métriques sont la précision, le rappel, le score F1 et le Hit Rate.

Precision	Recall	F1	HR@K
$\frac{TP}{TP + FP}$	$\frac{TP}{TP + FN}$	$\frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$	$\frac{1}{ U } \sum_{u \in U} I(y_u \in \text{Top-}K(u))$
(3)	(4)	(5)	(6)

où TP désigne les vrais positifs, FP les faux positifs, FN les faux négatifs, y_u l'item pertinent pour l'utilisateur u , et $I(\cdot)$ la fonction indicatrice valant 1 si l'item cible est dans la liste *Top-K*, et 0 sinon.

Métriques orientées classement (*Ranking metrics*) : Les métriques de classement prennent en compte la position des items dans la liste de recommandations, en partant du principe que les éléments pertinents doivent apparaître en tête de liste. Les indicateurs les plus utilisés sont le MRR et le NDCG.

MRR	NDCG@K
$\frac{1}{N} \sum_{i=1}^N \frac{1}{\text{rank}_i}$	$\frac{1}{ U } \sum_{u \in U} \frac{1}{\log_2(\text{rank}_u + 1)}$
(7)	(8)

où rank_i désigne la position du premier *item* pertinent pour le résultat i , et rank_u la position de l'*item* pertinent dans la liste de l'utilisateur u .

2.2 Limites des approches centrées sur la précision

Comme présenté dans la section précédente, les systèmes de recommandation ont historiquement été conçus afin de proposer des contenus pertinents aux utilisateurs. Les algorithmes et les métriques d'évaluation ont ainsi été principalement développés pour maximiser la précision des recommandations (Ko et al., 2022).

Cependant, la littérature met progressivement en évidence les limites d'une approche centrée uniquement sur cet objectif. En effet, recommander les *items* les plus susceptibles de plaire à l'utilisateur, sur la base de son historique, ne garantit pas toujours une expérience satisfaisante (Satinet et al., 2024). Cette focalisation peut notamment entraîner une réduction de la diversité (Satinet et al., 2024), un renforcement du biais de popularité, ou encore un enfermement dans des « bulles filtrantes » (*filter bubbles*) (Zhang et al., 2025).

Dans ce contexte, cette section vise à analyser les limites des approches centrées sur la précision et à introduire la nécessité de systèmes de recommandation multi-objectifs, intégrant d'autres dimensions telles que la diversité, la nouveauté, l'équité et, à terme, la durabilité.

2.2.1 Limites de la précision

Pendant de nombreuses années, les systèmes de recommandation ont été conçus avec un objectif unique : maximiser la précision des recommandations. Dans ce cadre, la performance d'un système est généralement évaluée à travers sa capacité à prédire correctement les préférences des utilisateurs, en minimisant l'écart entre les interactions réelles et les interactions estimées (Ko et al., 2022).

Cette approche repose sur l'hypothèse selon laquelle une amélioration de la précision conduit nécessairement à une meilleure expérience utilisateur. Toutefois, la littérature récente remet progressivement en question cette relation directe. En effet, plusieurs travaux soulignent qu'un système très précis ne garantit pas nécessairement la satisfaction des utilisateurs (Khadka & Sthapit, 2025). Un algorithme peut, par exemple, recommander des *items* très similaires à ceux déjà consommés par l'utilisateur. Bien que ces recommandations soient pertinentes du point de vue de la précision, elles peuvent manquer de nouveauté et d'intérêt, réduisant ainsi la valeur perçue du système (Khadka & Sthapit, 2025).

Par ailleurs, les systèmes optimisés pour la précision présentent également des biais algorithmiques importants. Parmi ceux-ci, le biais de popularité (*popularity bias*) constitue l'un des phénomènes les plus documentés dans la littérature (Satinet et al., 2024). En cherchant à maximiser la probabilité d'interactions, les algorithmes ont tendance à recommander prioritairement les *items* les plus populaires, c'est-à-dire ceux ayant déjà reçu un grand nombre d'interactions. Ce mécanisme est renforcé par la nature des données utilisées, en particulier les données implicites, qui favorisent les *items* déjà visibles. Les *items* populaires deviennent ainsi de plus en plus recommandés, tandis que les *items* moins connus restent sous-représentés, créant un cercle vicieux (Satinet et al., 2024).

Ce phénomène modifie la distribution des recommandations proposées en limitant notamment l'exposition des *items* appartenant à la « longue traîne », qui regroupe des produits moins populaires mais potentiellement pertinents pour certains utilisateurs (Mo & Wang, 2025 ; Satinet et al., 2024). Dans le cadre de ce mémoire, cette limite est particulièrement significative, dans la mesure où les produits durables sont souvent moins visibles dans les données historiques car moins populaires (Satinet et al., 2024). Les systèmes centrés sur la précision tendent donc à les recommander de manière moins importante, indépendamment de leur pertinence potentielle.

De plus, ces systèmes présentent également un manque de diversité, de nouveauté et de sérendipité (Khadka & Sthapit, 2025 ; Satinet et al., 2024). En se basant principalement sur les préférences passées de l'utilisateur, ils tendent à proposer des recommandations similaires entre elles. Or, les utilisateurs attendent de plus en plus des systèmes de recommandation qu'ils facilitent la découverte de nouveaux contenus, y compris des inattendus mais pertinents (Satinet et al., 2024).

À plus long terme, ces mécanismes peuvent conduire à un phénomène d'enfermement progressif de l'utilisateur dans des « bulles filtrantes » (*filter bubbles*) ou des cocons d'informations (Zhang et al., 2025). En recommandant de manière répétée des contenus homogènes, le système réduit progressivement la diversité des informations auxquelles l'utilisateur est exposé (Zhang et al., 2025). Cette dynamique peut limiter l'exploration et renforcer des schémas de consommation existants.

Face à ces différentes limites, il apparaît nécessaire de dépasser une approche strictement centrée sur la précision, en intégrant d'autres dimensions dans l'évaluation et la conception des systèmes de recommandation.

2.3 Passage aux systèmes multi-objectifs

Face aux limites liées à l'optimisation exclusive de la précision, la littérature met en évidence la nécessité de dépasser cette approche. L'évaluation de la qualité d'un système de recommandation évolue ainsi d'une approche centrée uniquement sur l'exactitude des prédictions vers des

dimensions plus complexes (Satinet et al., 2024). En effet, la littérature souligne qu’une focalisation exclusive sur la précision ne permet pas toujours de répondre aux attentes réelles des utilisateurs (Khadka & Sthapit, 2025).

Dans ce contexte, les travaux récents intègrent des métriques dites « au-delà de la précision » (*beyond accuracy*), telles que la diversité, la nouveauté, l’équité ou encore la durabilité (Satinet et al., 2024).

2.3.1 Diversité, nouveauté et sérendipité

L’intégration de la diversité dans les systèmes de recommandation constitue un enjeu important pour améliorer l’expérience utilisateur. En proposant des articles variés, le système couvre un ensemble plus large de préférences et limite la redondance des recommandations. Plus précisément, on parle souvent de diversité intra-liste, qui peut être évaluée en mesurant la dissimilarité entre les *items* recommandés, par exemple à travers la distance sémantique entre leurs représentations vectorielles (*embeddings*), notamment via la similarité cosinus (Zhang et al., 2025).

La nouveauté (*novelty*), quant à elle, vise à recommander des *items* peu connus ou non encore explorés par l’utilisateur. Elle s’oppose ainsi à la popularité et favorise l’exposition d’éléments issus de la « longue traîne » du catalogue (Khadka & Sthapit, 2025). Elle peut être mesurée en fonction de la popularité des *items*, les recommandations les moins populaires étant considérées comme les plus nouvelles.

Ces dimensions contribuent à améliorer l’expérience utilisateur en favorisant la sérendipité, c’est-à-dire la capacité du système à proposer des recommandations à la fois pertinentes et inattendues (Khadka & Sthapit, 2025 ; Satinet et al., 2024).

2.3.2 Équité algorithmique

Au-delà de l’expérience utilisateur, la littérature récente aborde également la notion d’équité (*fairness*) dans les systèmes de recommandation. Cette approche a pour objectif de corriger les biais algorithmiques et de prendre en compte les intérêts de différentes parties prenantes (Satinet et al., 2024).

Les systèmes dits multiparties prenantes (*multi-stakeholder*) ne se limitent plus à optimiser la satisfaction des utilisateurs, mais cherchent également à garantir une représentation équitable des fournisseurs et des *items*.

Une approche particulièrement étudiée est l’équité du côté des *items* (*item-side fairness*), qui consiste à assurer une visibilité équitable pour des groupes d’articles minoritaires. Dans le cadre de ce mémoire, cette dimension est essentielle, dans la mesure où les produits durables sont souvent défavorisés par les algorithmes classiques en raison de leur faible popularité initiale. L’intégration de critères d’équité vise ainsi à garantir une répartition plus juste de la visibilité

des *items*, qu'elle soit proportionnelle ou égalitaire (Satinet et al., 2024).

2.3.3 Compromis entre objectifs

L'intégration de ces différentes dimensions pose toutefois un défi important. La littérature met en évidence l'existence d'un compromis (*trade-off*) entre la précision et des objectifs tels que la diversité ou l'équité (Satinet et al., 2024).

En effet, favoriser la diversité ou promouvoir certains groupes *d'items* conduit à s'éloigner des préférences historiques des utilisateurs, ce qui peut entraîner une diminution de la précision du système (Kim et al., 2021).

Ainsi, l'objectif des systèmes de recommandation multi-objectifs n'est pas de maximiser un critère unique, mais de trouver un équilibre entre plusieurs dimensions. Il s'agit notamment de trouver un équilibre entre l'exploitation des préférences observées et l'exploration de nouvelles alternatives, en acceptant une perte de précision maîtrisée au profit d'autres objectifs, tels que la durabilité (Satinet et al., 2024 ; Zhou et al., 2024).

2.4 Intégration de la durabilité dans les systèmes de recommandation

Dans la continuité de la section précédente, qui a mis en évidence la nécessité de dépasser une optimisation strictement centrée sur la précision en faveur d'approches multi-objectifs, cette partie se concentre sur l'intégration d'un enjeu sociétal majeur : la durabilité.

Cette partie vise dans un premier temps à définir le concept de recommandation durable. Elle présente ensuite les principales méthodes permettant d'intégrer cette dimension au sein des systèmes de recommandation, en mettant particulièrement l'accent sur les approches de post-processing.

2.4.1 Recommandation durable

Les systèmes de recommandation ont initialement été développés dans le but d'aider les utilisateurs à naviguer dans des environnements riches en information, en identifiant les articles les plus pertinents au sein de catalogues de plus en plus vastes. Toutefois, leur conception a progressivement évolué vers des objectifs principalement orientés vers la performance économique, tels que l'augmentation de l'engagement des utilisateurs, des ventes ou encore des revenus (Satinet et al., 2024).

En réduisant l'effort de recherche du consommateur et en proposant en continu des produits adaptés à ses préférences, ces systèmes contribuent à augmenter la fréquence d'achat et le volume de consommation (Satinet et al., 2024). Si cette dynamique est bénéfique d'un point de vue

économique, elle soulève néanmoins des limites importantes. En effet, en stimulant la demande, les systèmes de recommandation peuvent encourager des comportements de surconsommation, et ainsi renforcer des modes de consommation non durables (Zhou et al., 2024).

Dans ce contexte, la littérature récente propose de reconsidérer le rôle des systèmes de recommandation. Plutôt que de se limiter à une optimisation centrée sur la performance économique, ils peuvent être envisagés comme des leviers permettant d’accompagner la transition écologique (Zhou et al., 2024).

Un argument central en faveur de cette évolution repose sur l’existence d’un écart entre les intentions environnementales des consommateurs et leurs comportements d’achat réels, communément désigné comme l’*intention-behavior gap* (Satinet et al., 2024; Zhou et al., 2024). Bien que de nombreux consommateurs expriment une volonté de consommer de manière plus responsable, cette intention se traduit rarement en décisions d’achat effectives, notamment en raison d’un manque d’information, de contraintes de temps ou encore d’une faible visibilité des produits durables.

Dans ce contexte, les systèmes de recommandation peuvent jouer un rôle clé en facilitant l’accès à des alternatives plus durables. En modifiant l’exposition des produits et en mettant en avant des options plus respectueuses de l’environnement, ils peuvent contribuer à orienter les choix des utilisateurs vers des comportements plus responsables (Zhou et al., 2024).

C’est dans ce cadre qu’émerge le concept de recommandation durable. Contrairement aux approches traditionnelles, un système de recommandation durable ne se limite pas à maximiser la pertinence des recommandations, mais intègre également des objectifs liés à l’environnement et à la société. Il s’inscrit ainsi dans une logique multi-parties prenantes, visant à prendre en compte à la fois les intérêts des utilisateurs, des entreprises et de la société (Satinet et al., 2024).

D’un point de vue plus formel, la durabilité peut être intégrée dans les systèmes de recommandation à travers des métriques spécifiques. Par exemple, Satinet et al. (2024) proposent de mesurer la durabilité d’un système à l’aide de l’Impact Environnemental Moyen (*AvgEI – Average Environmental Impact*) des recommandations générées. Cette métrique correspond à la moyenne des scores d’impact environnemental des *items* recommandés aux utilisateurs.

$$\mathbf{AvgEI} = \frac{1}{|U|} \sum_{u \in U} \frac{\sum_{j \in RL_u} s_j}{|RL_u|} \quad (9)$$

où U est l’ensemble de tous les utilisateurs évalués, $|U|$ le nombre total d’utilisateurs, RL_u la liste des N recommandations générées pour l’utilisateur u , $|RL_u|$ la taille de cette liste (généralement égale à N), et s_j le score de durabilité de l’article j .

L’objectif d’un système de recommandation durable est alors de minimiser cet impact environnemental global, tout en maintenant un niveau de pertinence satisfaisant pour l’utilisateur. Cela implique de trouver un équilibre entre l’exploitation des préférences observées et la mise en

avant d’alternatives plus durables.

Enfin, cette problématique est étroitement liée aux biais identifiés dans les sections précédentes. Les produits durables étant souvent moins populaires ou moins visibles dans les données historiques, ils sont généralement sous-représentés dans les recommandations. L’intégration de critères de durabilité vise ainsi à corriger ce déséquilibre en améliorant leur visibilité au sein des systèmes de recommandation (Satinet et al., 2024).

2.4.2 Méthodes d’intégration de la durabilité

Afin d’intégrer des objectifs tels que la durabilité au sein des systèmes de recommandation, la littérature distingue généralement deux grandes familles d’approches : les approches *in-processing* et *post-processing* (Satinet et al., 2024).

Les approches *in-processing* consistent à modifier directement l’algorithme de recommandation lors de sa phase d’apprentissage. Cela peut, par exemple, se traduire par l’ajout d’un terme lié à la durabilité dans la fonction de perte du modèle, afin d’influencer directement l’optimisation des paramètres (Satinet et al., 2024).

Toutefois, dans le cadre de ce mémoire, les approches *post-processing* sont privilégiées. Celles-ci consistent à conserver le modèle de recommandation initial inchangé, et à intervenir uniquement sur les résultats générés. Le modèle produit ainsi des scores de pertinence classiques, qui sont ensuite ajustés à l’aide d’un module supplémentaire appliqué *a posteriori* (Satinet et al., 2024).

Cette approche présente plusieurs avantages. Elle est tout d’abord simple à mettre en œuvre, puisqu’elle ne nécessite pas de modifier ni de réentraîner le modèle initial. Elle est également flexible, car elle peut être appliquée à différents types de systèmes de recommandation, quel que soit le modèle utilisé (Satinet et al., 2024).

2.4.2.1 Le post-processing comme méthode d’intégration

Parmi les approches visant à intégrer de nouveaux objectifs comme la durabilité, le *post-processing* constitue l’une des méthodes les plus utilisées et les plus flexibles (Satinet et al., 2024).

Généralement, un algorithme de recommandation classique opère en trois étapes successives : il génère un score de pertinence pour chaque article, il classe les articles selon ce score, puis il sélectionne les N meilleurs articles (le *Top-N*) pour l’utilisateur. Le principe du *post-processing* consiste à intervenir sur l’une de ces trois étapes pour y combiner le score de pertinence initial avec une dimension supplémentaire, telle que la durabilité.

Afin de contrôler l’importance relative de ces différentes dimensions, ces approches introduisent un paramètre de pondération, noté β , généralement compris entre 0 et 1. Ce paramètre permet d’arbitrer le compromis entre la précision et la durabilité. Lorsque β est faible, le système privi-

légie la pertinence des recommandations. À l'inverse, lorsque β augmente, les *items* présentant un meilleur score de durabilité sont davantage mis en avant dans la liste finale (Satinet et al., 2024).

2.4.2.2 Les trois catégories de stratégies de post-processing

Selon la littérature, il est possible de catégoriser ces stratégies en fonction de l'étape du processus qu'elles modifient (Satinet et al., 2024).

— Catégorie 1 : Modification des scores (Ajustement linéaire des scores)

La première approche consiste à ajuster directement les scores de pertinence à l'aide d'une combinaison linéaire entre le score de prédiction initial et le score de durabilité de chaque *item* (Satinet et al., 2024). Dans ce cadre, le score final correspond à une pondération entre ces deux composantes, contrôlée par le paramètre β :

Ajustement linéaire des scores

$$r'_{ui} = (1 - \beta)s_{ui} + \beta w_i \quad (10)$$

où r'_{ui} est le score final de l'article i pour l'utilisateur u , s_{ui} le score de pertinence initial prédit par le modèle de base, β le paramètre de pondération (compris entre 0 et 1), et $w_i = e^{-s_i}$ le poids de durabilité de l'article i calculé à partir de son score d'impact environnemental s_i .

Cette méthode est simple à mettre en œuvre et permet d'intégrer directement la durabilité dans le processus de classement. Elle offre également un contrôle explicite sur le compromis entre précision et impact environnemental (Satinet et al., 2024).

— Catégorie 2 : Modification du classement (Reclassement par agrégation)

Cette deuxième approche intervient après la génération des scores initiaux. Elle consiste à reclasser les articles une fois qu'ils ont été ordonnés par le modèle de base, par exemple en appliquant un seuil et en agrégeant ce classement avec un autre classement basé exclusivement sur les scores de durabilité (Satinet et al., 2024).

— Catégorie 3 : Modification de la sélection du Top-N (Formation incrémentale avec calibration)

Une troisième approche consiste à construire la liste de recommandations de manière incrémentale, en intégrant un mécanisme de calibration (Satinet et al., 2024). Contrairement à la méthode précédente, cette stratégie sélectionne les *items* un par un. À chaque étape, le système évalue la composition de la liste en cours de construction et ajuste la sélection afin d'assurer une meilleure représentation des *items* durables.

Dans sa version non sensible à l'intention (*non-intent-aware*), cette calibration repose uniquement sur les caractéristiques des *items*, sans prendre en compte les préférences

passées de l'utilisateur en matière de durabilité (Satinet et al., 2024) :

Formation incrémentale avec calibration

$$\text{score}_{ui} = (1 - \beta)L(i|u) + \beta(1 - L(\Theta_C|RL_u))L(i|s) \quad (11)$$

où score_{ui} est le score d'évaluation final de l'article candidat i pour l'utilisateur u , $L(i|u)$ la probabilité que l'utilisateur u soit intéressé par l'article i (équivalent au score de pertinence initial $\hat{r}_{ui}$), β le paramètre d'arbitrage (compris entre 0 et 1), $L(\Theta_C|RL_u) = \frac{|RL_u \cap \Theta_C|}{|RL_u|}$ le terme de calibration représentant la proportion d'articles durables déjà présents dans la liste en cours de formation RL_u , et $L(i|s)$ l'évaluation de la durabilité de l'article i , par exemple e^{-s_i} où s_i est le score d'impact environnemental.

Cette approche permet ainsi de contrôler plus directement la structure de la liste finale (Satinet et al., 2024).

2.4.3 Limites des approches existantes

Bien que les approches de *post-processing*, telles que le re-ranking, permettent d'intégrer efficacement la durabilité dans les systèmes de recommandation, elles présentent certaines limites importantes.

En particulier, la littérature existante repose majoritairement sur l'utilisation d'un paramètre de pondération β défini de manière globale et appliqué de façon identique à l'ensemble des utilisateurs (Satinet et al., 2024). Ce paramètre permet de contrôler le compromis entre la précision et la durabilité. Toutefois, son utilisation sous une forme fixe suppose implicitement que tous les utilisateurs partagent une sensibilité homogène aux enjeux environnementaux, ainsi qu'une même disposition à accepter une éventuelle perte de précision dans leurs recommandations.

Or, cette hypothèse apparaît restrictive en pratique. Les préférences en matière de durabilité sont hétérogènes et varient significativement d'un individu à l'autre. Cette limite met en évidence la nécessité de dépasser les approches globales, au profit de modèles capables d'adapter l'intégration de la durabilité en fonction des caractéristiques et des comportements des utilisateurs.

3. Méthodologie

3.1 Objectif de recherche

La littérature montre que les approches de *post-processing* existantes reposent majoritairement sur un paramètre β global, appliqué de manière uniforme à l'ensemble des utilisateurs. Cette hypothèse d'homogénéité des préférences apparaît comme une limite importante, dans la mesure où les comportements et les sensibilités en matière de durabilité varient significativement d'un individu à l'autre (Zhou et al., 2024).

C'est dans ce contexte que se pose la question de recherche principale de ce mémoire : dans quelle mesure l'adaptation du paramètre de pondération β au niveau utilisateur permet-elle d'améliorer le compromis entre la précision des recommandations et l'intégration de la durabilité dans les stratégies de *post-processing* des systèmes de recommandation ? Cette question se décline en deux sous-questions : d'une part, l'utilisation d'un paramètre β_u adaptatif permet-elle d'améliorer le compromis entre précision et durabilité par rapport à une approche basée sur un β global (RQ1) ? D'autre part, quelles stratégies d'estimation du paramètre β_u au niveau utilisateur offrent les meilleurs compromis entre précision et durabilité (RQ2) ?

Afin de répondre à ces questions, ce mémoire propose trois stratégies d'estimation du paramètre β_u : une approche comportementale reposant sur l'historique d'interactions de l'utilisateur, une approche sémantique exploitant le contenu textuel des *items* via des techniques de traitement du langage naturel (NLP), et une approche hybride combinant ces deux signaux via un mécanisme de *shrinkage*. Ces stratégies sont comparées à une approche basée sur un β global, utilisée comme baseline de référence. La méthodologie mise en œuvre pour répondre à ces objectifs est décrite dans les sections suivantes.

3.2 Description des données

Les données exploitées dans le cadre de ce mémoire proviennent de la base de données publique Amazon Product Reviews (Hou et al., 2024 ; Ni et al., 2019). Plus précisément, ce travail s'appuie sur deux jeux de données distincts issus de cette source : Amazon Clothing, Shoes & Jewelry (ci-après DS1), utilisé comme jeu de données principal, et Amazon Clothing (ci-après DS2), utilisé comme jeu de données de validation.

La structure de ces données repose sur deux fichiers complémentaires pour chaque ensemble. Le premier fichier est un fichier d'interactions utilisateur-article comportant trois variables : l'identifiant de l'utilisateur (`User_ID`), l'identifiant du produit (`Item_ID`) et la note d'évaluation (`Rating`). Le second fichier rassemble les métadonnées relatives aux produits, à savoir l'identifiant de l'article (`Item_ID`), son titre (`Item_title`) et son score d'impact environnemental.

Pour DS1, le score d'impact environnemental est représenté par la variable `Pred_EI` (*Environmental Impact*), un score entier allant de 1 à 5, où une valeur élevée indique un impact environnemental plus négatif (Satinet & Fouss, 2022). Dans ce mémoire, un article est considéré comme durable lorsque son score satisfait la condition $\text{Pred_EI} \leq 3$ (Satinet et al., 2024).

Pour DS2, ce critère est représenté par deux variables complémentaires : `co2e_kg`, qui exprime l'empreinte carbone estimée en kg de CO₂ équivalent, et `sustainability_score`, un score normalisé dérivé de `co2e_kg` via une transformation log-minmax, où une valeur proche de 1 indique un produit très durable. Un article est considéré comme durable dans DS2 lorsque le `co2e_kg` est inférieur ou égal au 33^e percentile de la distribution empirique (5,14 kg), classant ainsi le tiers des articles les moins émetteurs comme durables. La distribution présente une forte asymétrie positive (*skewness* = 3,31), avec une moyenne de 13,76 kg fortement influencée par des valeurs extrêmes atteignant 217,2 kg. Ce choix repose sur deux motivations complémentaires. D'une part, il s'inscrit dans la continuité méthodologique de Spillo et al. (2026), qui recourent aux percentiles de la distribution empirique pour catégoriser l'impact environnemental de leurs produits en trois classes d'impact (faible, moyen et élevé). D'autre part, ce seuil est retenu afin d'assurer un contraste avec DS1, qui ne compte que 2% d'articles durables. En fixant le seuil au tertile inférieur, DS2 dispose d'une proportion plus importante d'articles durables (33%), favorisant davantage d'interactions avec ces articles et, par conséquent, un nombre plus élevé d'utilisateurs au profil durable au sens de la définition adoptée dans la section 3.2.1.

Par ailleurs, une analyse par catégorie confirme la cohérence de ce seuil global : les catégories légères (accessoires, lingerie) se situent en dessous, tandis que les catégories volumineuses (jeans, manteaux) s'en éloignent nettement. Un seuil P33 par catégorie a été considéré mais écarté : il mesure la durabilité de façon relative au sein de chaque catégorie, classant par exemple un jean à 17,86 kg de CO₂e comme durable, ce qui va à l'encontre de l'objectif d'orienter la consommation vers des produits réellement moins émetteurs.

Pour DS1, les descriptions des produits et les scores environnementaux ne figuraient pas dans les fichiers sources originaux (Ni et al., 2019). Ces données ont donc été enrichies par des techniques de *web scraping* et par l'application d'un modèle de prédiction d'impact environnemental basé sur l'apprentissage automatique (Satinet & Fouss, 2022). En revanche, pour DS2, l'empreinte carbone `co2e_kg` a été estimée par un grand modèle de langage (LLM) en exploitant directement les titres et métadonnées déjà présents dans la base de données (Spillo et al., 2026), puis transformée en `sustainability_score` via une normalisation log-minmax.

Concernant le prétraitement, DS1 a été utilisé tel que fourni par les auteurs de l'étude source Satinet et al. (2024), qui y avaient préalablement appliqué un filtre *5-core* (ne conservant que les utilisateurs ayant interagi avec au moins 5 articles). DS2 a quant à lui fait l'objet d'un filtrage *12-core* itératif afin de garantir une densité suffisante des interactions, suivi d'un sous-échantillonnage aléatoire à 5 000 utilisateurs (*seed*=42) pour maintenir une taille comparable à DS1. Pour les deux *datasets*, les notes explicites ont été converties en interactions binaires (1

= interaction présente). Pour DS2 spécifiquement, contrairement à la binarisation originale des auteurs (1 si note = 5, 0 sinon) (Spillo et al., 2026), toute interaction a été conservée indépendamment de la note attribuée, afin de modéliser la présence d’un comportement d’achat plutôt que le niveau de satisfaction exprimé. Les distributions observées montrent que sur DS1, chaque utilisateur présente entre 5 et 172 interactions (moyenne : 15,87), tandis que sur DS2, ce nombre varie entre 12 et 169 interactions (moyenne : 16,35).

L’analyse de la distribution du score `Pred_EI` pour DS1 montre que le jeu de données est largement dominé par des articles non durables. Moins de 2 % des articles présentent un score $\text{Pred_EI} \leq 3$, ce qui signifie que l’offre est très largement non durable. Pour DS2, la distribution du `sustainability_score` est plus équilibrée : environ 33 % des articles sont considérés comme durables ($\text{co2e_kg} \leq 5,14$ kg, soit le 33^e percentile de la distribution).

Le Tableau 3.1 résume les caractéristiques clés de ces deux jeux de données, et met notamment en évidence la forte sparsité de la matrice d’interactions.

Table 3.1 – Synthèse et caractéristiques des jeux de données

Caractéristique	DS1 — Amazon Clothing, Shoes & Jewelry	DS2 — Amazon Clothing
Nombre d’utilisateurs	4 110	5 000
Nombre d’articles	6 723	7 600
Nombre d’interactions	65 230	81 744
Sparsité de la matrice	99,77 %	99,78 %
Interactions min / max / moy.	5 / 172 / 15,87	12 / 169 / 16,35
Métrique de durabilité	$\text{Pred_EI} \in \{1, \dots, 5\}$	$\text{sustainability_score} \in [0, 1]$
Seuil de durabilité	$\text{Pred_EI} \leq 3$	$\text{co2e_kg} \leq 5,14$ kg (P33)
Part d’articles durables	< 2 %	≈ 33 %

3.2.1 Définition d’un utilisateur durable

La notion d’utilisateur durable est définie de manière comportementale, sur la base de la proportion *d’items* durables dans l’historique d’interactions de chaque utilisateur :

$$\text{prop_sust_history}(u) = \frac{|\{i \in \mathcal{H}_u : i \text{ est durable}\}|}{|\mathcal{H}_u|} \quad (12)$$

où $\mathcal{H}_u$ désigne l’ensemble des *items* consommés par l’utilisateur u dans l’ensemble d’entraînement. Le seuil de classification est défini de manière relative à chaque *dataset* : sur DS1, où 96,4 % des utilisateurs n’ont jamais interagi avec un *item* durable, un utilisateur est considéré comme durable si $\text{prop_sust_history}(u) > 0$ (3,61 % des utilisateurs). Sur DS2, le seuil retenu est 0,33, correspondant à la proportion d’articles durables dans le catalogue (33 %), ce qui produit 45,6 % d’utilisateurs classés comme durables. Cette différence de seuil s’explique structurellement par la proportion *d’items* durables dans chaque catalogue (< 2 % pour DS1,

$\approx 33\%$ pour DS2); les deux *datasets* ne sont donc pas directement comparables, l'objectif étant d'observer la cohérence des tendances.

3.3 Implémentation des modèles et stratégies de post-processing

Afin d'évaluer les modèles de manière robuste, une validation croisée à 5 sous-ensembles (*5-fold cross-validation*) est appliquée. La stratification par utilisateur garantit que chaque sous-ensemble contient une proportion représentative des interactions de chaque utilisateur, évitant ainsi tout déséquilibre dans la répartition des données. Chaque utilisateur apparaît donc à la fois dans l'ensemble d'entraînement et dans l'ensemble de test à chaque itération, avec un ratio entraînement/test de 80 %/20 %. L'évaluation repose sur une approche de type *leave-some-interactions-out*, standard dans la littérature sur les systèmes de recommandation avec feedback implicite. Dans ce cadre, les notes explicites (1 à 5 étoiles) sont ignorées au profit d'une modélisation binaire de la présence ou absence d'interaction pour générer la matrice d'interactions initiale (Satinet et al., 2024).

Enfin, une normalisation min-max est appliquée par utilisateur sur les scores de pertinence produits par les modèles de base, juste avant l'étape de *post-processing*. Cette normalisation ramène les scores dans l'intervalle $[0, 1]$ selon la formule suivante :

Normalisation min-max

$$\hat{r}_{ui} = \frac{s_{ui} - \min_j s_{uj}}{\max_j s_{uj} - \min_j s_{uj}} \quad (13)$$

où $\hat{r}_{ui}$ est le score normalisé, s_{ui} est le score de pertinence brut initialement prédit par le modèle pour l'utilisateur u et l'article i , et $\min_j s_{uj}$ ainsi que $\max_j s_{uj}$ représentent respectivement les scores bruts minimal et maximal prédits pour cet utilisateur sur l'ensemble des articles j .

Contrairement à Satinet et al. (2024), une normalisation min-max est appliquée par utilisateur aux scores de pertinence bruts avant le post-processing, afin de garantir que le paramètre β contrôle effectivement l'arbitrage entre pertinence et durabilité, indépendamment de l'échelle des scores produits par chaque modèle.

3.3.1 Modèles de base

Ce mémoire s'appuie sur quatre modèles de recommandation utilisés comme baselines de pertinence. L'objectif n'est pas d'optimiser leur performance absolue, mais de mesurer le compromis précision/durabilité induit par le *post-processing*. Les hyperparamètres n'ont pas fait l'objet d'une optimisation formelle, les valeurs retenues correspondent à des valeurs standard de la littérature.

Les quatre modèles reposent sur une matrice binaire utilisateur-item ($m \times n$), où la valeur 1 indique qu'une interaction a eu lieu. Les notes explicites (1 à 5 étoiles) sont ignorées, seule la

présence ou l'absence d'interaction est prise en compte.

Avant de décrire chaque modèle, il convient de rappeler deux notions utilisées dans plusieurs d'entre eux. La similarité cosinus mesure la similarité entre deux vecteurs en calculant le cosinus de l'angle qui les sépare :

Similarité cosinus

$$\text{cossim}(x, y) = \frac{x \cdot y}{\|x\| \times \|y\|} = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (14)$$

où x et y représentent les deux vecteurs comparés, x_i et y_i sont les valeurs de ces vecteurs pour l'élément i , et n est la dimension totale des vecteurs (Kuanr & Mohapatra, 2021). Elle prend une valeur comprise entre 0 et 1, où 1 indique des vecteurs identiques et 0 des vecteurs sans aucune similarité. Cette mesure est bien adaptée aux données sparses, car elle ne tient compte que de l'orientation des vecteurs, et non de leur magnitude.

La méthode TF-IDF (*Term Frequency-Inverse Document Frequency*) est une technique de vectorisation textuelle qui attribue à chaque terme d'un document un poids reflétant à la fois sa fréquence dans ce document et sa rareté dans l'ensemble du corpus. Ainsi, les termes fréquents mais peu discriminants reçoivent un poids faible, tandis que les termes rares et informatifs sont davantage valorisés (Ko et al., 2022).

Ces deux notions étant posées, voici comment chacun des quatre modèles est implémenté.

- **User-kNN** : Le filtrage collaboratif basé sur les utilisateurs (*User-based CF*) calcule, pour chaque paire d'utilisateurs, une similarité cosinus à partir de leurs vecteurs d'interactions binaires. Pour chaque utilisateur u , les $k = 15$ voisins les plus similaires sont retenus. Les poids de similarité sont normalisés de sorte qu'ils somment à 1, puis le score d'un *item* i pour l'utilisateur u est calculé comme la somme pondérée des interactions des voisins avec cet *item* (Satinet et al., 2024).
- **Item-kNN** : Le filtrage collaboratif basé sur les *items* (*Item-based CF*) repose sur une logique symétrique par rapport à l'approche centrée sur les utilisateurs (Ko et al., 2022). La similarité cosinus est calculée entre les vecteurs-items, où chaque *item* est représenté par le vecteur binaire des utilisateurs qui l'ont consommé. Pour chaque *item* i , les $k = 15$ *items* les plus similaires sont retenus. Le score d'un *item* candidat i pour l'utilisateur u correspond à la somme des similarités entre i et chaque *item* j déjà consommé par u , pondérée par le rating binaire de u sur j . Autrement dit, plus u a consommé d'*items* similaires à i , plus le score de i est élevé.
- **SVD** : La factorisation matricielle repose sur une décomposition en valeurs singulières tronquée de la matrice binaire, c'est-à-dire limitée aux $K = 10$ facteurs latents capturant le plus d'information, plutôt que sur la décomposition complète. La matrice de scores est reconstruite par le produit des matrices de facteurs latents utilisateurs et *items*, pondérés par les valeurs singulières. Les valeurs négatives issues de la reconstruction sont

ramenées à zéro. Il s’agit d’une décomposition algébrique standard, sans régularisation ni optimisation par descente de gradient, ce qui en fait une baseline simple (Satinet et al., 2024).

- **Filtrage basé sur le contenu (*Content-Based*)** : Le modèle content-based construit un profil textuel pour chaque utilisateur en concaténant les titres des *items* avec lesquels il a interagi dans l’ensemble d’entraînement. Ces profils, ainsi que les titres des *items* candidats, sont vectorisés conjointement à l’aide de la méthode TF-IDF, avec suppression des mots vides. Le score d’un *item* i pour un utilisateur u correspond à la similarité cosinus entre le profil textuel de l’utilisateur et le titre de $l’item$ (Satinet et al., 2024).

Le Tableau 3.2 présente une synthèse des caractéristiques des quatre modèles.

Table 3.2 – Caractéristiques des modèles de base				
	User-kNN	Item-kNN	SVD	Content-Based
Approche	Collaboratif	Collaboratif	Factorisation	Contenu
Distance/méthode	Cosinus	Cosinus	SVD tronquée	TF-IDF + cosinus
Features	Interactions	Interactions	Interactions	Item_title
	binaires	binaires	binaires	
Hyperparamètre	$k = 15$	$k = 15$	$K = 10$	—

3.3.2 Stratégies de post-processing

3.3.2.1 Ajustement linéaire des scores (Stratégie A)

La stratégie de *post-processing* retenue repose sur une combinaison linéaire entre le score de pertinence normalisé produit par le modèle de base et un score de durabilité associé à chaque *item*. Cette approche, introduite par Satinet et al. (2024), permet d’ajuster les recommandations initiales en intégrant un critère environnemental, sans modifier le modèle de base lui-même.

Le score de durabilité w_i est dérivé du score d’impact environnemental de $l’item$ selon la formule suivante, conformément à Satinet et al. (2024) :

Score de durabilité

$$w_i = e^{-s_i} \tag{15}$$

où s_i représente le score d’impact environnemental brut de $l’item$ i . Pour DS1, s_i correspond directement à $Pred_EI \in \{1, 2, 3, 4, 5\}$. Pour DS2, s_i est défini comme $1 - sustainability_score$ afin d’inverser l’échelle, un *item* très durable obtenant ainsi un poids w_i proche de 1.

Le score final utilisé pour le re-ranking est alors calculé comme suit. Dans le cas d’un paramètre β global, identique pour tous les utilisateurs :

Score final — β global

$$\text{score_final}_{ui} = (1 - \beta) \cdot \hat{r}_{ui} + \beta \cdot w_i \quad (16)$$

Dans le cas d'un paramètre personnalisé β_u , propre à chaque utilisateur :

Score final — β_u personnalisé

$$\text{score_final}_{ui} = (1 - \beta_u) \cdot \hat{r}_{ui} + \beta_u \cdot w_i \quad (17)$$

où $\hat{r}_{ui}$ désigne le score de pertinence normalisé, tel que décrit en section 3.3. Le paramètre β contrôle ainsi le compromis entre pertinence et durabilité : une valeur proche de 0 privilégie la pertinence, tandis qu'une valeur proche de 1 favorise les *items* les plus durables.

Pour chaque utilisateur, les *items* présents dans son historique d'entraînement sont exclus du re-ranking, afin de garantir que seuls des *items* non encore consommés sont recommandés. La liste finale est constituée des $N = 5$ *items* présentant les scores finaux les plus élevés.

Dans le cadre de ce mémoire, le β global est testé sur six valeurs uniformément réparties : $\beta \in \{0.0, 0.2, 0.4, 0.6, 0.8, 1.0\}$, suivant le protocole expérimental de Satinet et al. (2024). La valeur $\beta = 0.0$ correspond à une recommandation basée uniquement sur la pertinence et sert de baseline de référence, tandis que $\beta = 1.0$ produit des recommandations identiques pour tous les utilisateurs, fondées exclusivement sur le score de durabilité. Le β global constitue ainsi le point de comparaison contre lequel les stratégies d'estimation du paramètre personnalisé β_u sont évaluées.

3.3.2.2 Formation incrémentale avec calibration (Stratégie B)

La Stratégie B constitue une approche alternative de *post-processing*, utilisée dans ce mémoire comme analyse de validité externe. Contrairement à la Stratégie A qui calcule l'ensemble des scores finaux en une seule passe avant de sélectionner les N meilleurs *items*, la Stratégie B construit la liste de recommandations de manière itérative, en ajoutant un *item* à la fois (Satinet et al., 2024).

À chaque étape k ($k = 1$ à $N = 5$), le score dynamique de chaque *item* candidat i pour l'utilisateur u est calculé comme suit :

Score final

$$\text{score_final}_{ui} = (1 - \beta) \cdot \hat{r}_{ui} + \beta \cdot (1 - L(\Theta_C | RL_u)) \cdot e^{-s_i} \quad (18)$$

où $\hat{r}_{ui}$ désigne le score de pertinence normalisé, e^{-s_i} est le score de durabilité de l'*item* i selon une décroissance exponentielle, avec $s_i = \text{Pred_EI}(i)$ pour DS1 et $s_i = 1 - \text{sustainability_score}(i)$ pour DS2. $L(\Theta_C | RL_u)$ est la proportion d'*items* durables appartenant à l'ensemble cible Θ_C , défini comme l'ensemble des *items* avec $\text{Pred_EI} \leq 3$ pour DS1 et $\text{co2e_kg} \leq 5,14$ kg pour DS2, déjà présents dans la liste en construction RL_u à l'étape k .

Le terme $L(\Theta_C | RL_u)$ est mis à jour après chaque sélection selon la formule suivante :

Terme de calibration

$$L(\Theta_C | RL_u) = \frac{|RL_u \cap \Theta_C|}{|RL_u|} \quad (19)$$

Ce mécanisme de calibration constitue la différence fondamentale avec la Stratégie A. Si un *item* durable est sélectionné à l'étape k , la proportion L augmente, ce qui réduit le terme $(1 - L)$ et atténue le signal de durabilité à l'étape suivante. Le prochain *item* sélectionné est ainsi davantage guidé par la pertinence. Ce rééquilibrage automatique empêche la liste d'être saturée d'*items* durables consécutifs, produisant un compromis précision/durabilité intrinsèquement plus équilibré et moins vulnérable aux chutes soudaines de précision qu'avec la Stratégie A à même valeur de β (Satinet et al., 2024).

Les *items* déjà consommés par l'utilisateur dans l'ensemble d'entraînement sont exclus à chaque étape, garantissant que seuls des *items* non encore consommés peuvent être recommandés. Le paramètre β est testé sur les mêmes six valeurs que la Stratégie A : $\beta \in \{0.0, 0.2, 0.4, 0.6, 0.8, 1.0\}$, suivant le protocole de Satinet et al. (2024).

Les stratégies d'estimation du paramètre personnalisé β_u , présentées dans la section suivante, sont appliquées aussi bien à la Stratégie A qu'à la Stratégie B.

3.3.3 Estimation du paramètre β_u

L'objectif de cette section est de présenter les trois stratégies retenues pour estimer le paramètre β_u au niveau de chaque utilisateur. Ces stratégies constituent le cœur de la contribution de ce mémoire et sont comparées au β global présenté en section 3.3.2.1.

3.3.3.1 Approche comportementale (Stratégie 1)

La première stratégie repose sur l'exploitation de l'historique d'interactions de l'utilisateur. Le paramètre β_u est estimé comme la proportion d'*items* durables présents dans cet historique au sein de l'ensemble d'entraînement :

Approche comportementale

$$\beta_u = \frac{|I_{train}^u \cap \Theta_C|}{|I_{train}^u|} \quad (20)$$

où I_{train}^u représente l'ensemble des *items* avec lesquels l'utilisateur u a interagi dans les données d'entraînement, et Θ_C représente l'ensemble cible des *items* considérés comme durables, défini comme $Pred_EI \leq 3$ pour DS1 et $co2e_kg \leq 5,14$ kg pour DS2.

Cette approche repose sur l'hypothèse que les comportements passés de l'utilisateur reflètent son intérêt pour la durabilité. Un utilisateur ayant majoritairement interagi avec des *items* durables se verra attribuer un β_u élevé, ce qui renforcera le poids accordé à la durabilité dans ses recommandations. Par construction, $\beta_u \in [0, 1]$ et aucune normalisation supplémentaire n'est nécessaire. Cette stratégie ne comporte aucun hyperparamètre à optimiser.

Toutefois, cette approche présente une limite importante dans le contexte des jeux de données utilisés : si l'utilisateur n'a jamais interagi avec un *item* durable dans son historique, $\beta_u = 0$, ce qui revient à ignorer entièrement la durabilité dans ses recommandations. Cette vulnérabilité de la méthode face aux historiques ne contenant aucun *item* durable est d'ailleurs soulevée dans la littérature, ce qui conduit parfois à l'imposition d'un seuil minimum artificiel pour forcer la recommandation durable (Satinet et al., 2024). Dans le cadre de ce mémoire, nous conservons cette valeur stricte de 0, car c'est précisément cette limite qui motive les deux stratégies suivantes.

3.3.3.2 Approche sémantique (Stratégie 2)

La littérature récente souligne que la fusion des séquences comportementales avec les caractéristiques sémantiques textuelles permet de capturer des relations latentes et de pallier le manque d'interactions directes avec certains types d'articles (Zhao et al., 2025). La deuxième stratégie a pour objectif de dépasser la limite de l'approche comportementale en exploitant le contenu sémantique des titres des *items*.

Cette approche repose sur le modèle all-MiniLM-L6-v2 (Hugging Face, 2022), un modèle de langage issu du traitement du langage naturel (NLP), construit sur le modèle MiniLM (Wang et al., 2020). Il s'agit d'un modèle pré-entraîné qui produit pour chaque titre d'*item* un vecteur de représentation (*embedding*) de 384 dimensions, optimisé pour la comparaison sémantique de phrases courtes via la similarité cosinus (Reimers & Gurevych, 2019), et entraîné sur plus d'un milliard de paires de phrases.

Dans un premier temps, un centroïde durable est calculé comme la moyenne des *embeddings* de l'ensemble des *items* durables du catalogue :

Centroïde durable

$$\vec{c} = \frac{1}{|\Theta_C|} \sum_{i \in \Theta_C} \vec{e}_i \quad (21)$$

où $\vec{c}$ représente le centroïde, Θ_C désigne l'ensemble cible des *items* considérés comme durables, défini comme $\text{Pred_EI} \leq 3$ pour DS1 et $\text{co2e_kg} \leq 5,14 \text{ kg}$ pour DS2, et $\vec{e}_i$ correspond au vecteur sémantique (*embedding*) du titre de l'*item* i . Ce centroïde représente le centre sémantique de la durabilité dans l'espace vectoriel.

Le score sémantique de chaque *item* est ensuite calculé comme la similarité cosinus entre son *embedding* et ce centroïde, puis ramené dans $[0, 1]$:

Score sémantique

$$\text{semantic_score}(i) = \frac{\text{cossim}(\vec{e}_i, \vec{c}) + 1}{2} \quad (22)$$

La fonction *cossim* renvoyant une valeur entre -1 et 1 , cette transformation permet de normaliser le score sur une échelle strictement positive et comparable.

Le paramètre β_u^{raw} est alors estimé comme la moyenne des scores sémantiques des *items* consom-

més par l'utilisateur dans l'ensemble d'entraînement :

Estimation de β_u^{raw}

$$\beta_u^{raw} = \frac{1}{|I_{train}^u|} \sum_{i \in I_{train}^u} \text{semantic_score}(i) \quad (23)$$

où I_{train}^u représente l'historique d'entraînement de l'utilisateur u , c'est-à-dire l'ensemble des *items* avec lesquels il a interagi.

Une normalisation min-max est enfin appliquée sur l'ensemble des utilisateurs afin de ramener les valeurs dans $[0, 1]$ et de les rendre comparables à celles de la Stratégie 1 :

Normalisation min-max

$$\beta_u^{semantic} = \frac{\beta_u^{raw} - \min_v \beta_v^{raw}}{\max_v \beta_v^{raw} - \min_v \beta_v^{raw}} \quad (24)$$

où v représente l'ensemble des utilisateurs de la base de données.

Contrairement à la Stratégie 1, cette approche permet de détecter une affinité implicite pour la durabilité même chez des utilisateurs n'ayant jamais interagi avec un *item* explicitement durable. En effet, un utilisateur peut ne jamais avoir consommé *d'item* considéré comme durable ($\text{Pred_EI} \leq 3$ pour DS1, $\text{co2e_kg} \leq 5,14$ kg pour DS2) tout en ayant interagi avec des produits dont les titres sont sémantiquement proches de la notion de durabilité. La Stratégie 2 capte cette affinité latente que la Stratégie 1 est incapable de détecter, offrant ainsi une représentation plus fine et complète des intérêts des utilisateurs (Zhao et al., 2025).

3.3.3.3 Approche hybride avec *shrinkage* (Stratégie 3)

La troisième stratégie combine les deux signaux précédents via un mécanisme de *shrinkage*, qui permet d'adapter automatiquement le poids accordé à chaque signal en fonction du volume d'interactions disponibles pour l'utilisateur. L'hybridation pondérée (*Weighted Hybridization*) est une méthode reconnue dans la littérature pour compenser les faiblesses d'une approche par les forces d'une autre (Ko et al., 2022). Dans ce contexte, le score combiné est calculé selon la formule suivante :

Approche hybride avec *shrinkage*

$$\beta_u = \left(\frac{n}{n + \lambda} \right) \beta_u^{behavioral} + \left(\frac{\lambda}{n + \lambda} \right) \beta_u^{semantic} \quad (25)$$

où n (qui correspond à $|I_{train}^u|$) désigne le nombre d'interactions de l'utilisateur dans l'ensemble d'entraînement, $\beta_u^{behavioral}$ et $\beta_u^{semantic}$ correspondent respectivement aux paramètres estimés lors des Stratégies 1 et 2, et λ est le paramètre de *shrinkage*. Lorsque n est faible, le poids accordé au signal sémantique est majoritaire, compensant ainsi le manque de données comportementales. À l'inverse, lorsque n est élevé, le signal comportemental domine. Pour $n = \lambda$, les deux signaux ont le même poids.

L’avantage de cette formulation concerne principalement les utilisateurs en situation de *cold-start* partiel, c’est-à-dire disposant de peu d’interactions mais d’un historique non vide. Dans ce cas, le signal comportemental est peu fiable car l’utilisateur n’a vraisemblablement pas encore interagi avec suffisamment d’*items* durables, et le signal sémantique compense en lui attribuant un β_u non nul. La littérature souligne en effet que ces approches hybrides sont particulièrement efficaces pour atténuer les problèmes liés à la sparsité des données ou au manque d’historique (Ko et al., 2022). En revanche, en *cold-start* total ($n = 0$), les trois stratégies produisent $\beta_u = 0$; ce cas est toutefois absent en pratique dans les deux jeux de données utilisés.

Le paramètre λ est testé sur trois valeurs : $\lambda \in \{5, 10, 20\}$. La valeur $\lambda = 10$ est retenue comme valeur de référence, car elle offre un équilibre intermédiaire entre les deux signaux, ni trop dominé par le comportemental ni trop dominé par le sémantique.

3.4 Cadre d’évaluation

L’évaluation repose sur un protocole hors ligne standard dans la littérature sur les systèmes de recommandation (Khadka & Sthapit, 2025). Pour chaque sous-ensemble de la validation croisée à 5 sous-ensembles, les modèles sont entraînés sur 80 % des interactions et évalués sur les 20 % restants. Pour chaque utilisateur, une liste de N *items* non encore consommés est générée par le système, puis comparée aux *items* présents dans son ensemble de test. Les métriques sont ensuite calculées sur cette comparaison et moyennées sur l’ensemble des utilisateurs et des 5 itérations.

Les expériences sont conduites sur deux jeux de données. Le jeu de données Amazon Clothing, Shoes & Jewelry (DS1) constitue le jeu de données principal. Le jeu de données Amazon Clothing (DS2) est utilisé comme jeu de données de validation, avec une métrique de durabilité différente (co2e_kg) et une distribution plus équilibrée (environ 33 % d’*items* durables).

3.4.1 Métriques de précision

Les métriques de précision utilisées dans ce mémoire sont le Recall@ N , la Precision@ N , le F1@ N et le NDCG@ N , dont les formules ont été présentées dans la revue de littérature (section 2.1.4.2). Ces métriques d’évaluation hors ligne sont aujourd’hui considérées comme incontournables pour mesurer l’exactitude des algorithmes (Khadka & Sthapit, 2025). Conformément à la méthodologie de Satinet et al. (2024), qui attribue une taille de liste fixe par *dataset*, les métriques sont calculées pour $N = 5$ pour les deux *datasets*.

Plusieurs spécificités d’implémentation méritent d’être précisées. Premièrement, la pertinence des *items* est traitée de manière binaire : un *item* est considéré pertinent s’il figure dans l’ensemble de test de l’utilisateur, indépendamment de la note attribuée. Deuxièmement, toutes les métriques sont calculées via une moyenne par utilisateur, c’est-à-dire que la métrique est d’abord

calculée individuellement pour chaque utilisateur, puis moyennée sur l'ensemble des utilisateurs (Satinet et al., 2024). Cette approche garantit que chaque utilisateur contribue de manière égale au résultat global, indépendamment du nombre d'interactions dans son ensemble de test. Enfin, pour le $\text{NDCG}@N$, l'IDCG est calculé sur la base du nombre réel d' items pertinents de l'utilisateur dans l'ensemble de test, plafonné à N .

3.4.2 Métriques de durabilité

Plusieurs métriques de durabilité sont utilisées pour évaluer l'intégration des critères environnementaux dans les recommandations. Le seuil de durabilité retenu est $\text{Pred_EI} \leq 3$ pour DS1 et $\text{co2e_kg} \leq 5,14$ kg pour DS2, conformément à la définition établie en section 3.2.

L'Impact Environnemental Moyen (AvgEI), présenté en section 2.4.1, mesure la moyenne des scores d'impact environnemental sur l'ensemble des *items* recommandés (Satinet et al., 2024). C'est une métrique à minimiser : plus elle est faible, plus les recommandations sont en moyenne durables. Pour DS1, cette métrique correspond à la moyenne des scores Pred_EI (échelle 1–5). Pour DS2, elle correspond à la moyenne des co2e_kg des *items* recommandés (en kg CO_2e). Ces deux valeurs ne sont pas directement comparables entre les deux *datasets*.

La proportion d' items durables recommandés ($\text{prop_sust_recom_items}$) mesure la part des emplacements de recommandation occupés par un *item* durable sur l'ensemble des $m \times N$ emplacements disponibles :

$$\text{prop_sust_recom_items} = \frac{|\{(u, i) : i \in RL_u \text{ et } i \in \Theta_C\}|}{m \times N} \quad (26)$$

où RL_u correspond à la liste des N recommandations générées pour l'utilisateur u , et m au nombre total d'utilisateurs, et Θ_C désigne l'ensemble des *items* durables ($\text{Pred_EI} \leq 3$ pour DS1, $\text{co2e_kg} \leq 5,14$ kg pour DS2).

Afin d'évaluer si le système recommande des *items* durables de manière équitable entre les différents profils d'utilisateurs, deux métriques différenciées sont introduites. La proportion d' items durables recommandés aux utilisateurs durables ($\text{prop_sust_recom_durable}$) est définie comme suit :

$$\text{prop_sust_recom_durable} = \frac{|\{(u, i) : u \in \mathcal{U}^+, i \in RL_u \text{ et } i \in \Theta_C\}|}{|\mathcal{U}^+| \times N} \quad (27)$$

où $\mathcal{U}^+$ désigne l'ensemble des utilisateurs durables, tels que définis en section 3.2.

De manière symétrique, la proportion d' items durables recommandés aux utilisateurs non durables ($\text{prop_sust_recom_nondurable}$) est définie comme :

prop_sust_recom_nondurable

$$\text{prop_sust_recom_nondurable} = \frac{|\{(u, i) : u \in \mathcal{U}^-, i \in RL_u \text{ et } i \in \Theta_C\}|}{|\mathcal{U}^-| \times N} \quad (28)$$

où $\mathcal{U}^-$ désigne l'ensemble des utilisateurs non durables.

L'écart entre ces deux proportions (gap) mesure dans quelle mesure le système traite différemment les utilisateurs selon leur profil de durabilité :

gap

$$\text{gap} = \text{prop_sust_recom_durable} - \text{prop_sust_recom_nondurable} \quad (29)$$

Un gap élevé indique que le système favorise fortement les utilisateurs déjà durables, au détriment des autres. Un gap proche de zéro indique que le système recommande des *items* durables de manière équitable, indépendamment du profil de l'utilisateur.

Le nombre moyen d'*items* durables par liste (nbr_sust_items_list) est directement lié à la métrique précédente par la relation $\text{nbr_sust_items_list} = N \times \text{prop_sust_recom_items}$. Il exprime le même concept en termes absolus plutôt que relatifs.

La proportion d'utilisateurs recevant au moins un *item* durable (prop_sust_users) mesure la part des utilisateurs dont la liste de recommandations contient au moins un *item* durable :

prop_sust_users

$$\text{prop_sust_users} = \frac{|\{u : \exists i \in RL_u \text{ t.q. } i \in \Theta_C\}|}{m} \quad (30)$$

La couverture durable (sust_coverage) mesure la proportion du sous-catalogue durable effectivement exposée via les recommandations :

sust_coverage

$$\text{sust_coverage} = \frac{|\{i : i \in \Theta_C \text{ et } i \text{ recommandé à } \geq 1 \text{ utilisateur}\}|}{|\{i : i \in \Theta_C\}|} \quad (31)$$

Une valeur de 1 signifie que chaque *item* durable du catalogue a été recommandé à au moins un utilisateur. Cette métrique est complémentaire à prop_sust_recom_items : elle mesure la diversité de l'exposition aux *items* durables plutôt que leur fréquence.

Le coefficient de Spearman moyen (avg_spearman_coef) est la seule métrique sensible à l'ordre au sein de la liste. Il mesure la corrélation de rang entre la position d'un *item* dans la liste de recommandations et son score, soit Pred_EI pour DS1 et co2e_kg pour DS2 :

avg_spearman_coef

$$\text{avg_spearman_coef} = \frac{1}{m} \sum_u \text{Spearman}([1, 2, \dots, N], [\text{score_impact}_{\text{item}_1^u}, \dots, \text{score_impact}_{\text{item}_N^u}]) \quad (32)$$

Un coefficient négatif indique que les *items* les mieux classés tendent à avoir un impact environnemental plus faible, c'est-à-dire que les *items* les plus durables sont promus en tête de liste.

Un coefficient positif indique l'inverse.

3.4.3 Métrique de diversité

La couverture catalogue (*coverage*) mesure la proportion du catalogue total apparaissant dans au moins une liste de recommandations, afin d'évaluer la diversité globale (Satinet et al., 2024) :

$$\text{coverage} = \frac{|\{i : i \text{ recommandé à } \geq 1 \text{ utilisateur}\}|}{n} \quad (33)$$

où n représente le nombre total *d'items* dans le catalogue. Une valeur faible indique que le système se concentre sur un petit sous-ensemble *d'items* populaires, au détriment de la diversité des recommandations.

3.4.4 Protocole de comparaison

Pour chaque combinaison de modèle de base, de stratégie de *post-processing* et de mode β , les métriques sont calculées une fois par sous-ensemble, puis moyennées arithmétiquement sur les 5 sous-ensembles pour produire la valeur finale rapportée, conformément aux standards d'évaluation par validation croisée (Satinet et al., 2024).

La comparaison centrale du mémoire oppose le β global, testé sur six valeurs uniformément réparties $\beta \in \{0.0, 0.2, 0.4, 0.6, 0.8, 1.0\}$ (Satinet et al., 2024), aux trois stratégies d'estimation du paramètre personnalisé β_u (comportementale, sémantique et hybride avec $\lambda \in \{5, 10, 20\}$).

La valeur $\beta = 0.0$ constitue la baseline de référence, représentant un système focalisé exclusivement sur la précision, sans aucune intégration de la durabilité. L'objectif final est d'évaluer si un β_u personnalisé permet d'atteindre un meilleur compromis précision/durabilité qu'un β global optimal choisi *a posteriori*. Ainsi, ce mémoire répond à l'un des défis posés par la littérature récente : intégrer des critères de durabilité dans les systèmes de recommandation sans dégradation excessive de la pertinence pour l'utilisateur (Satinet et al., 2024).

Les métriques *prop_sust_recom_durable*, *prop_sust_recom_nondurable* et *gap* sont analysées séparément pour chaque stratégie de β , afin d'évaluer si le β_u adaptatif permet de réduire l'écart entre utilisateurs durables et non durables par rapport à un β global.

4. Analyse des résultats

4.1 Performances des modèles de base

Avant d’analyser l’effet du post-processing, il convient d’établir les performances de référence des quatre modèles sans aucune intervention sur les recommandations ($\beta = 0$).

Sur DS1, le modèle *Content-Based* affiche des performances nettement supérieures aux autres approches, avec un Recall@5 de 0,5505 et un NDCG@5 de 0,5963. SVD constitue le second meilleur modèle en termes de précision ($\text{Recall@5} = 0,1866$, $\text{NDCG@5} = 0,2140$), tandis que User-kNN et Item-kNN restent en retrait avec des valeurs de Recall@5 inférieures à 0,07.

Table 4.1 – Performances des modèles de base ($\beta = 0$, moyenne 5 folds)

Dataset	Modèle	Recall@5	NDCG@5	avg_EI	prop_sust
DS1	Content-Based	0,5505	0,5963	4,141	0,003
DS1	SVD	0,1866	0,2140	4,289	0,000
DS1	User-kNN	0,0666	0,0820	4,317	0,003
DS1	Item-kNN	0,0164	0,0156	4,265	0,043
DS2	User-kNN	0,0144	0,0152	15,070	0,275
DS2	SVD	0,0133	0,0121	14,199	0,224
DS2	Item-kNN	0,0082	0,0080	13,557	0,323
DS2	Content-Based	0,0010	0,0009	12,967	0,348

Note : valeurs en gras = meilleur modèle par dataset. avg_EI = Pred_EI pour DS1 (échelle 1–5) et co2e_kg pour DS2 (kg CO_2e).

Cette supériorité du modèle *Content-Based* sur DS1 s’explique par la cohérence des profils d’achat des utilisateurs : la similarité cosinus médiane entre les *items* achetés par un même utilisateur est de 0,723 sur DS1, ce qui signifie que les utilisateurs achètent des articles sémantiquement proches, rendant leur profil TF-IDF prédictif. Sur DS2 en revanche, cette similarité intra-utilisateur est quasi nulle (médiane = 0,013), les utilisateurs achetant des articles de catégories très hétérogènes, ce qui rend le profil TF-IDF inexploitable.

Concernant la durabilité naturelle des recommandations sur DS1, la proportion d’*items* durables recommandés est quasi nulle pour trois des quatre modèles (0,3%), ce qui est cohérent avec la composition du catalogue : moins de 2% des articles présentent un score $\text{Pred_EI} \leq 3$. Item-kNN constitue une exception notable avec une prop_sust de 4,3%, liée à la structure locale de ses recommandations. Pour SVD, la prop_sust est nulle : sans contrainte de durabilité, le modèle ne sélectionne que des *items* populaires, or ceux-ci sont quasi exclusivement non durables dans DS1.

Sur DS2, les performances en précision sont globalement plus faibles pour l’ensemble des modèles, ce qui reflète une différence structurelle avec DS1. Sur DS1, les interactions sont fortement concentrées sur quelques items populaires et les utilisateurs présentent des profils d’achat

cohérents, ce qui facilite la prédiction pour tous les algorithmes. Sur DS2, les interactions sont distribuées de façon plus uniforme sur l'ensemble du catalogue, sans clustering naturel exploitable, ce qui rend tous les modèles moins performants indépendamment de leur approche. User-kNN émerge comme le modèle le plus performant ($\text{Recall@5} = 0,0144$), suivi de SVD ($\text{Recall@5} = 0,0133$). La proportion naturelle d'*items* durables recommandés varie entre 22% et 35% selon les modèles, cohérente avec la proportion d'articles durables dans le catalogue (33% avec le seuil P33 retenu).

Ces résultats établissent la baseline de référence à partir de laquelle toute stratégie de post-processing sera évaluée. Sur DS1, l'enjeu est d'introduire de la durabilité là où elle est quasi absente ; sur DS2, il s'agit plutôt de ne pas dégrader la durabilité naturelle des recommandations tout en maintenant un niveau de pertinence satisfaisant.

4.2 Distribution des paramètres β_u adaptatifs

Cette section analyse comment chaque stratégie adaptative distribue les β_u au niveau individuel, afin de comprendre comment elles traduisent l'hétérogénéité des préférences de durabilité.

4.2.1 Distribution globale des β_u

La Figure A.1 (voir Annexe A) présente les distributions des β_u pour les cinq variantes adaptatives (S1 Behavioral, S2 Semantic, S3 Hybrid $\lambda = 5, 10, 20$) sur DS1 et DS2, moyennées sur les cinq folds de validation croisée.

Sur DS1, les distributions diffèrent radicalement selon la stratégie. S1 Behavioral produit une distribution écrasée sur la valeur zéro : 96% des utilisateurs obtiennent un $\beta_u = 0$, ce qui s'explique directement par la composition du catalogue, moins de 2% des articles étant durables, presque aucun utilisateur n'a interagi avec un *item* durable dans son historique. S1 ne parvient donc pas à différencier les utilisateurs sur DS1, ce qui constitue précisément la limite motivant les deux stratégies suivantes. S2 Semantic contourne ce problème en exploitant le contenu sémantique des titres : sa distribution est centrée autour de $\mu = 0,525$ avec un étalement modéré ($\sigma = 0,076$), traduisant une affinité latente pour la durabilité détectée même chez des utilisateurs sans historique durable explicite. Les stratégies S3 Hybrid produisent des distributions intermédiaires dont la moyenne augmente avec λ ($\mu = 0,162$ pour $\lambda = 5$, $\mu = 0,244$ pour $\lambda = 10$, $\mu = 0,330$ pour $\lambda = 20$), reflétant le poids croissant accordé au signal sémantique à mesure que λ augmente.

Sur DS2, les trois stratégies produisent des distributions sensiblement différentes. S1 Behavioral produit une distribution centrée autour de $\mu = 0,312$ ($\sigma = 0,119$), avec une médiane à 0,309, très proche du seuil de classification des utilisateurs durables (0,33). S1 crée ainsi une vraie séparation nette de la population : environ la moitié des utilisateurs se situe en dessous du seuil,

l'autre au-dessus, ce qui rend le signal comportemental exploitable pour différencier les profils. S2 Semantic produit en revanche une distribution décalée vers des valeurs nettement plus élevées ($\mu = 0,579$, médiane = $0,584$), traduisant une affinité sémantique pour la durabilité détectée chez la quasi-totalité des utilisateurs. Ce résultat s'explique par l'homogénéité du catalogue DS2 : les titres des articles étant sémantiquement proches, le centroïde durable est voisin de presque tous les profils utilisateurs. Les stratégies S3 Hybrid produisent des distributions intermédiaires (μ entre $0,390$ et $0,476$), tirées vers S2 à mesure que λ augmente.

Sur DS1, le choix de la stratégie d'estimation de β_u est donc déterminant : S1 échoue à capturer l'hétérogénéité des utilisateurs, tandis que S2 et S3 y parviennent respectivement par le contenu sémantique et la combinaison hybride. Sur DS2, les trois stratégies produisent des profils distincts, S1 offrant la meilleure discrimination comportementale tandis que S2 surestime systématiquement l'affinité durable en raison de l'homogénéité sémantique du catalogue.

4.2.2 Distribution des β_u par profil d'utilisateur

La Figure A.2 (voir Annexe A) complète cette analyse en distinguant les β_u selon le profil d'utilisateur. Sur DS2, S1 Behavioral produit la séparation la plus nette ($\mu = 0,415$ pour les durables vs $0,225$ pour les non durables), confirmant que le signal comportemental assigne bien des β_u plus élevés aux utilisateurs durables lorsque l'historique est suffisamment riche. S2 Semantic ne discrimine en revanche pratiquement pas les deux groupes, assignant même des β_u légèrement plus élevés aux utilisateurs non durables ($\mu = 0,585$ vs $0,572$), en raison de l'homogénéité sémantique du catalogue. Les stratégies S3 Hybrid produisent une séparation intermédiaire ($\mu = 0,485$ vs $0,387$ pour $\lambda = 10$), cohérente avec leur combinaison des deux signaux.

Sur DS1, S1 Behavioral reste proche de zéro pour les deux groupes et S2 produit des distributions similaires ($\mu = 0,576$ vs $0,523$) ; seules les stratégies S3 montrent une séparation modérée ($\mu = 0,318$ vs $0,240$ pour $\lambda = 10$), grâce à la contribution du signal comportemental.

4.3 Compromis précision/durabilité : β global et β_u adaptatif

Les Figures A.3 et A.4 (voir Annexe A) présentent les frontières précision/durabilité pour les quatre modèles sur DS1 et DS2, respectivement pour la Stratégie A et la Stratégie B. Les points représentent les positions des stratégies β_u adaptatives. Le Tableau 4.2 détaille les valeurs numériques correspondantes.

Table 4.2 – Recall@5 et avg_EI par mode et stratégie (4 modèles agrégés, moyenne 5 folds)

Mode	DS1 Strat A Recall@5	DS1 Strat A avg_EI	DS1 Strat B Recall@5	DS1 Strat B avg_EI	DS2 Strat A Recall@5	DS2 Strat A avg_EI	DS2 Strat B Recall@5	DS2 Strat B avg_EI
Baseline	0,205	4,253	0,205	4,253	0,0092	13,948	0,0092	13,948
$\beta = 0,2$	0,196	3,441	0,204	3,604	0,0083	8,218	0,0090	10,058
$\beta = 0,4$	0,182	3,238	0,201	3,478	0,0066	4,478	0,0085	8,173
$\beta = 0,6$	0,169	3,046	0,186	3,325	0,0046	1,779	0,0078	6,463
$\beta = 0,8$	0,147	2,520	0,176	2,901	0,0023	0,157	0,0069	4,856
$\beta = 1,0$	0,000	1,800	0,000	2,400	0,0012	0,020	0,0010	1,396
S1 Behavioral	0,205	4,243	0,206	4,341	0,0073	6,297	0,0087	9,112
S2 Semantic	0,175	3,081	0,190	3,361	0,0048	2,171	0,0079	6,629
S3 Hybrid $\lambda = 10$	0,190	3,383	0,204	3,574	0,0062	4,133	0,0084	7,956

Stratégie A vs Stratégie B : Sur DS1, la Stratégie B préserve mieux la précision que la Stratégie A à niveau de durabilité comparable. S3 Hybrid $\lambda = 10$ illustre bien cet écart : avec la Stratégie B, il atteint avg_EI = 3,574 pour une perte de recall de seulement $-0,001$, alors qu’avec la Stratégie A le même mode atteint avg_EI = 3,383 mais au prix d’une perte de $-0,015$. Le mécanisme de calibration dynamique de la Stratégie B réduit le signal de durabilité dès qu’un *item* durable a été sélectionné, ce qui évite de trop pénaliser la pertinence des recommandations suivantes. Sur DS2, le même constat s’applique : chaque mode B perd moins de recall que son équivalent A pour un niveau d’EI comparable.

β global : Sur DS1, augmenter β réduit progressivement avg_EI, de 4,253 à la baseline jusqu’à 2,520 à $\beta = 0,8$ avec la Stratégie A, au prix d’une dégradation croissante du recall (Δ Recall = $-0,058$ à $\beta = 0,8$). La relation n’est pas linéaire : les premières hausses de β produisent des gains de durabilité importants pour un coût en précision modéré, tandis qu’au-delà de $\beta = 0,6$ la dégradation s’accélère nettement. Sur DS2, la même tendance apparaît mais de façon plus marquée : à $\beta = 0,8$, avg_EI chute à 0,157 kg CO₂ pour un recall résiduel de 0,0023, ce qui signifie que la durabilité est maximisée mais la précision est quasi nulle. À $\beta = 1,0$, cas limite théorique, le recall s’effondre à quasi zéro sur les deux *datasets* : tous les utilisateurs reçoivent les mêmes cinq items les plus durables du catalogue, indépendamment de leurs préférences.

β_u adaptatif vs β global : Sur DS1, les trois stratégies adaptatives se comportent très différemment. S1 Behavioral, dont 96% des β_u sont nuls, ne modifie pratiquement pas les recommandations par rapport à la baseline (avg_EI = 4,243, Δ Recall = 0,000), conformément à la distribution observée en section 4.2. S2 Semantic produit un compromis plus marqué (avg_EI = 3,081, Δ Recall = $-0,030$), proche de $\beta = 0,6$ global avec la Stratégie A. S3 Hybrid $\lambda = 10$ se situe entre les deux (avg_EI = 3,383, Δ Recall = $-0,015$), offrant un meilleur équilibre que S2.

Sur DS2, S1 Behavioral produit un compromis modéré (avg_EI = 6,297 kg CO₂, Δ Recall = $-0,0019$), comparable à $\beta = 0,2$ global en durabilité mais avec un meilleur recall. S2 Semantic pousse davantage vers la durabilité (avg_EI = 2,171, Δ Recall = $-0,0044$), proche de $\beta = 0,6$

global. S3 Hybrid $\lambda = 10$ offre le meilleur équilibre ($\text{avg_EI} = 4,133$, $\Delta\text{Recall} = -0,0030$), comparable à $\beta = 0,4$ global en durabilité mais avec un recall préservé.

Au final, les stratégies adaptatives n'écrasent pas le β global sur la frontière de Pareto, mais elles produisent des compromis raisonnables sans supposer de connaissance préalable du β optimal, ce qui constitue leur principal intérêt dans un contexte réel.

4.4 Analyse par profil d'utilisateur

Les Figures A.5 et A.6 (voir Annexe A) présentent la proportion *d'items* durables recommandés aux utilisateurs durables et non durables selon chaque mode, ainsi que le gap correspondant, pour DS1 et DS2.

Il convient de rappeler qu'un utilisateur est ici considéré comme durable sur la base de son historique comportemental : la proportion d'*items* durables consommés dans l'ensemble d'entraînement. Un utilisateur classé non durable peut donc tout à fait recevoir des recommandations durables, notamment via S2 Semantic : si les titres des produits qu'il a consommés sont sémantiquement proches du centroïde durable, un β_u élevé lui sera assigné indépendamment de son profil comportemental.

Sur DS1, S1 Behavioral est la seule stratégie adaptative à produire un gap positif (+0,10 avec Strat A, +0,09 avec Strat B) : les utilisateurs ayant historiquement consommé des *items* durables reçoivent effectivement plus de recommandations durables que les autres. Toutefois, la prop_non durable reste quasi nulle (0,012 avec Strat A), ce qui signifie que les utilisateurs non durables reçoivent presque aucun *item* durable dans leurs recommandations. S2 Semantic et S3 Hybrid produisent des gaps négatifs (respectivement $-0,11$ et $-0,17$ avec Strat A), similaires à ceux du β global, mais avec des prop_non durable nettement plus élevées (0,471 et 0,348 avec Strat A).

Sur DS2, les résultats diffèrent. S1 Behavioral produit le gap positif le plus élevé (+0,237 avec Strat A, +0,131 avec Strat B), tout en maintenant une prop_non durable élevée (0,537 avec Strat A), ce qui contraste avec son comportement sur DS1. La composition du catalogue DS2 permet au signal comportemental d'être plus informatif, ce qui se traduit par une meilleure différenciation entre profils sans sacrifier l'exposition des utilisateurs non durables. S2 Semantic produit un gap quasi nul avec Strat A (0,000) et légèrement positif avec Strat B (+0,010). S3 Hybrid $\lambda = 10$ maintient un gap positif modéré (+0,126 avec Strat A, +0,081 avec Strat B).

Sur DS1, le choix de la stratégie influe donc fortement sur la répartition des recommandations durables entre profils : S1 concentre les *items* durables chez les utilisateurs déjà durables, tandis que S2 et S3 les distribuent plus largement, y compris aux utilisateurs non durables. Sur DS2, cette tension s'inverse : les trois stratégies produisent des gaps positifs, S1 offrant la meilleure différenciation entre profils (+0,237 avec Strat A) tandis que S2 et S3 maintiennent

des *prop_nondurable* élevées, assurant une large exposition des utilisateurs non durables aux *items* durables.

4.5 Impact sur la diversité

Le Tableau 4.3 présente les métriques de couverture catalogue (*coverage*) et de couverture durable (*sust_coverage*) pour chaque mode et stratégie, sur DS1 et DS2.

Table 4.3 – Coverage et *sust_coverage* par mode et stratégie (4 modèles agrégés, moyenne 5 folds)

Mode	DS1 Strat A coverage	DS1 Strat A sust_cov	DS1 Strat B coverage	DS1 Strat B sust_cov	DS2 Strat A coverage	DS2 Strat A sust_cov	DS2 Strat B coverage	DS2 Strat B sust_cov
Baseline	0,256	0,199	0,256	0,199	0,476	0,473	0,476	0,473
$\beta = 0,2$	0,249	0,392	0,241	0,280	0,415	0,559	0,439	0,546
$\beta = 0,4$	0,228	0,434	0,230	0,310	0,313	0,532	0,412	0,555
$\beta = 0,6$	0,191	0,434	0,211	0,353	0,175	0,415	0,372	0,539
$\beta = 0,8$	0,112	0,411	0,170	0,370	0,053	0,161	0,307	0,459
$\beta = 1,0$	0,006	0,305	0,001	0,038	0,001	0,003	0,001	0,002
S1 Behavioral	0,258	0,316	0,244	0,232	0,377	0,550	0,427	0,552
S2 Semantic	0,196	0,426	0,212	0,344	0,223	0,443	0,377	0,537
S3 Hybrid $\lambda = 10$	0,240	0,422	0,235	0,297	0,304	0,519	0,408	0,554

Note : *sust_cov* = *sust_coverage*.

Sur DS1, augmenter β avec la Stratégie A réduit fortement la *coverage* générale (de 0,256 à la baseline jusqu'à 0,112 à $\beta = 0,8$), tandis que la *sust_coverage* plafonne autour de 0,43 dès $\beta = 0,4$. La Stratégie B préserve mieux la *coverage* (0,170 à $\beta = 0,8$) mais produit une *sust_coverage* plus faible (0,370). Parmi les stratégies adaptatives, S1 Behavioral offre le meilleur compromis en termes de diversité sur DS1 : elle conserve une *coverage* proche de la baseline (0,258) tout en doublant la *sust_coverage* (0,316 contre 0,199). S2 Semantic et S3 Hybrid atteignent des *sust_coverage* plus élevées (0,426 et 0,422 avec Strat A) au prix d'une réduction de la *coverage* générale, plus marquée pour S2 (0,196) que pour S3 (0,240).

Sur DS2, la Stratégie A montre un comportement préoccupant : la *sust_coverage* atteint son pic dès $\beta = 0,2$ (0,559) avant de chuter rapidement, tandis que la *coverage* s'effondre à 0,053 à $\beta = 0,8$. Au-delà d'un certain seuil, la pression de durabilité réduit tellement l'espace de recommandation que même la couverture durable se dégrade. La Stratégie B est nettement plus stable sur DS2 : *coverage* et *sust_coverage* restent élevées sur toute la plage β , sans effondrement. Parmi les modes adaptatifs sur DS2, S1 Behavioral et S3 Hybrid $\lambda = 10$ offrent les meilleurs compromis avec Strat B : S1 présente la *coverage* la plus élevée (0,427) tandis que S3 atteint la *sust_coverage* la plus haute (0,554), pour des valeurs globalement très proches.

Ces résultats confirment un risque identifié dans la littérature : pousser trop fortement la durabilité via un β global élevé finit par concentrer les recommandations sur un petit sous-ensemble *d'items*, réduisant à la fois la diversité et l'utilité du système. Les stratégies adaptatives, en modulant β_u selon le profil de chaque utilisateur, limitent partiellement ce risque : sur DS1, S1

Behavioral conserve une coverage proche de la baseline ; sur DS2, S1 et S3 offrent les meilleurs compromis entre coverage et `sust_coverage`.

4.6 Synthèse

Les analyses menées dans ce chapitre font ressortir plusieurs tendances consistantes sur les deux *datasets*.

Sur le compromis précision/durabilité, la Stratégie B se révèle globalement plus conservative que la Stratégie A : à niveau de durabilité comparable, elle préserve mieux le recall grâce à son mécanisme de calibration dynamique. Cette tendance est observable indépendamment de la composition du catalogue et des profils utilisateurs, aussi bien pour le β global que pour les modes adaptatifs.

Parmi les stratégies adaptatives, l'efficacité de chaque approche dépend fortement de la proportion d'utilisateurs ayant interagi avec des *items* durables dans leur historique. Lorsque cette proportion est faible, comme sur DS1 où seulement 3,6% des utilisateurs ont un historique durable, S1 Behavioral devient inopérante : 96% des β_u sont nuls, ce qui se traduit par une absence d'effet sur la durabilité des recommandations. Dans ce contexte, S2 Semantic et S3 Hybrid contournent ce problème en exploitant le signal sémantique, produisant des compromis précision/durabilité comparables au β global. En revanche, lorsque la proportion d'utilisateurs durables est plus élevée, comme sur DS2 où elle atteint 45,6%, S1 Behavioral retrouve une efficacité notable sur DS2 : pour une perte de recall comparable à $\beta = 0,4$ global ($\Delta\text{Recall} \approx -0,002$), il atteint une durabilité intermédiaire ($\text{avg_EI} = 6,297$). L'analyse par profil confirme la cohérence interne de cette stratégie : les utilisateurs durables reçoivent effectivement des β_u nettement plus élevés que les non durables ($\mu = 0,415$ vs $0,225$), ce qui valide que S1 capture bien l'hétérogénéité des préférences lorsque le signal comportemental est suffisamment riche.

Sur la répartition des recommandations durables entre profils, le même contraste s'observe. Avec peu d'utilisateurs durables dans l'historique, S1 Behavioral produit un gap positif mais n'expose quasi aucun *item* durable aux utilisateurs non durables ($\text{prop_nondurable} = 0,012$ sur DS1 avec Strat A), tandis que S2 et S3 maintiennent des prop_nondurable élevées (0,471 et 0,348) au prix de gaps négatifs. Avec davantage d'utilisateurs durables, cette tension disparaît : les trois stratégies produisent des gaps positifs et maintiennent des prop_nondurable élevées, S1 offrant la meilleure différenciation entre profils (+0,237 avec Strat A sur DS2).

Sur la diversité, augmenter β avec la Stratégie A concentre les recommandations sur un sous-ensemble restreint d'*items* durables au détriment de la coverage, tandis que la Stratégie B maintient une coverage plus stable. Parmi les modes adaptatifs, S1 Behavioral conserve la meilleure coverage lorsque le signal comportemental est faible, tandis que S3 Hybrid offre le meilleur compromis entre coverage et `sust_coverage` lorsqu'il est plus riche.

5. Discussion

5.1 Réponse aux questions de recherche

RQ1 — L'utilisation d'un paramètre β_u adaptatif permet-elle d'améliorer le compromis entre précision et durabilité des recommandations, par rapport à une approche basée sur un paramètre β global ?

La réponse est nuancée et dépend fortement du contexte dans lequel les stratégies sont appliquées. Sur DS1, S2 Semantic et S3 Hybrid $\lambda = 10$ produisent des compromis précision/durabilité comparables à ceux du β global. Sur DS2, S1 Behavioral produit un compromis comparable au β global, se situant entre $\beta = 0,2$ et $\beta = 0,4$ en termes de durabilité et de recall.

Par ailleurs, contrairement au β global qui applique la même pression de durabilité à tous les utilisateurs, les stratégies adaptatives modulent cette pression selon le profil utilisateur. L'effet sur chaque groupe dépend de la stratégie choisie et de la proportion d'utilisateurs ayant un historique durable : lorsque celle-ci est faible, S1 Behavioral favorise les utilisateurs déjà durables tandis que S2 et S3 exposent davantage d'*items* durables aux utilisateurs non durables ; lorsqu'elle est plus élevée, les trois stratégies recommandent proportionnellement plus d'*items* durables aux utilisateurs durables tout en maintenant une exposition élevée pour les utilisateurs non durables.

Les stratégies adaptatives ne dominent donc pas systématiquement le β global sur la frontière de Pareto. Leur avantage réside ailleurs : elles produisent un compromis raisonnable sans supposer de connaissance préalable du β optimal, ce qui constitue un atout pratique important dans un contexte réel où ce paramètre est difficile à calibrer.

RQ2 — Quelles stratégies d'estimation du paramètre β_u au niveau utilisateur offrent les meilleurs compromis entre précision et durabilité ?

Aucune stratégie ne domine sur toutes les dimensions simultanément, et le choix dépend de l'objectif prioritaire.

Sur le compromis précision/durabilité, S3 Hybrid $\lambda = 10$ offre le meilleur équilibre sur DS1 ($\text{avg_EI} = 3,383$, $\Delta\text{Recall} = -0,015$ avec Strat A), en combinant les signaux comportemental et sémantique. Sur DS2, S1 Behavioral se révèle plus compétitif que les autres stratégies adaptatives, bénéficiant d'un signal comportemental plus riche grâce à la proportion élevée d'utilisateurs ayant interagi avec des *items* durables (45,6%). L'analyse par profil (section 4.2.2) confirme cette cohérence : les utilisateurs durables reçoivent effectivement des β_u nettement plus élevés que les non durables ($\mu = 0,415$ vs $0,225$).

Sur la répartition des recommandations durables entre profils, la situation diffère selon le contexte. Lorsque peu d'utilisateurs ont un historique durable, aucune stratégie ne satisfait simultanément un gap positif et une prop_non durable élevée : S1 Behavioral produit un gap positif mais ex-

pose quasi aucun *item* durable aux utilisateurs non durables, tandis que S2 et S3 font l'inverse. Lorsque la proportion d'utilisateurs durables est plus élevée, cette tension disparaît et les trois stratégies maintiennent simultanément un gap positif et des *prop_nondurable* élevées.

Sur la diversité des recommandations, S1 Behavioral conserve la meilleure coverage parmi les modes adaptatifs, limitant la concentration des recommandations sur un sous-ensemble restreint d'*items* durables.

Sur l'ensemble de ces dimensions, S3 Hybrid $\lambda = 10$ offre le compromis le plus équilibré lorsque le signal comportemental est faible : une durabilité comparable au β global, une perte de précision modérée, une *prop_nondurable* acceptable et une bonne conservation de la diversité. Lorsque le signal comportemental est plus riche, S1 Behavioral se distingue sur la plupart des dimensions.

5.2 Mise en perspective avec la littérature

Les résultats obtenus s'inscrivent dans la continuité des travaux de Satinet et al. (2024) dont ce mémoire reprend le cadre méthodologique. Satinet et al. observent également une dégradation non linéaire de la précision quand β augmente, avec un point de rupture qui varie selon le *dataset* et la stratégie utilisée. Cette tendance est confirmée dans nos résultats : sur DS1, la dégradation du recall s'accélère nettement au-delà de $\beta = 0,6$ avec la Stratégie A, tandis que la Stratégie B maintient une précision plus stable sur toute la plage.

Satinet et al. concluent que la Stratégie B est légèrement préférable à la Stratégie A, car elle produit des compromis plus équilibrés et évite les chutes brutales de précision. Nos résultats confirment cette conclusion : sur les deux *datasets*, la Stratégie B préserve mieux le recall à niveau de durabilité comparable, et maintient une *coverage* catalogue plus stable.

La principale différence entre les deux travaux réside dans l'introduction du paramètre β_u adaptatif. Satinet et al. utilisent exclusivement un β global identique pour tous les utilisateurs, ce qui constitue précisément la limite que ce mémoire cherche à dépasser. Nos résultats montrent que l'efficacité des stratégies adaptatives dépend du contexte : sur DS1, S2 Semantic et S3 Hybrid permettent d'atteindre des compromis comparables au β global, tandis que sur DS2, c'est S1 Behavioral qui se révèle la plus compétitive. Ces résultats représentent un apport méthodologique par rapport au cadre initial en identifiant les conditions sous lesquelles l'individualisation du paramètre est bénéfique.

Un résultat notable de ce mémoire est la forte dépendance des performances à la proportion d'utilisateurs ayant un historique d'interactions avec des *items* durables. Sur DS1, où seulement 3,6% des utilisateurs ont interagi avec un *item* durable, S1 Behavioral est rendu inopérant par l'absence de signal comportemental exploitable. Cela souligne une spécificité du critère de durabilité : lorsque peu d'utilisateurs ont un historique durable, les approches purement compor-

tements sont insuffisantes et doivent être complétées par des signaux alternatifs comme le contenu sémantique, ce que S2 et S3 permettent de faire.

5.3 Limites

Plusieurs limites méritent d’être mentionnées pour contextualiser les résultats présentés.

Les deux *datasets* utilisés proviennent du même domaine, à savoir la mode et le textile, ce qui limite la généralisation des résultats à d’autres contextes de recommandation. Par ailleurs, le score d’impact environnemental de DS1 (Pred_EI) est un score prédit par un modèle de machine learning et non une mesure directe de l’empreinte environnementale réelle des produits. Sur DS2, l’empreinte carbone co2e_kg a été estimée par un grand modèle de langage à partir des titres de produits, ce qui introduit une incertitude sur la fiabilité de cette estimation.

Les hyperparamètres des modèles de base n’ont pas fait l’objet d’une optimisation formelle, les valeurs retenues correspondant à des valeurs standard de la littérature. De meilleures performances baseline auraient pu produire des listes de recommandations de meilleure qualité, ce qui aurait pu influencer marginalement les résultats du *post-processing*. Ce choix est cependant justifié par l’objectif du mémoire, qui porte sur les stratégies de post-processing et non sur l’optimisation des modèles de base.

La stratégie sémantique repose sur des *embeddings* de titres de produits, qui capturent peu d’information sur l’impact environnemental réel des articles. Sur DS2, la similarité cosinus entre le centroïde des items durables et celui des items non durables est élevée (0,793), ce qui signifie que les deux groupes sont sémantiquement très proches. Cela explique pourquoi S2 Semantic assigne des β_u élevés à la quasi-totalité des utilisateurs sur DS2, indépendamment de leur profil comportemental réel.

Enfin, le seuil de durabilité retenu pour DS2 est le 33^e percentile global du co2e_kg , sans distinction par catégorie de produits, ce qui peut introduire des biais dans la classification des articles appartenant à des catégories très hétérogènes en termes d’empreinte carbone (Li et al., 2025).

5.4 Pistes futures

Plusieurs pistes pourraient prolonger ce travail.

Enrichissement du signal de durabilité : La stratégie sémantique est contrainte par le fait que les titres de produits ne reflètent pas l’impact environnemental des articles. Intégrer des attributs plus informatifs comme les matières utilisées ou le pays de fabrication (Li et al., 2025), ainsi que la présence de labels environnementaux (Satinet & Fouss, 2022), dans la construction des *embeddings* renforcerait le pouvoir discriminant de β_u sémantique et réduirait sa dépendance à

un score prédit par un modèle externe.

Optimisation du paramètre λ : Le paramètre λ de S3 Hybrid a été testé sur trois valeurs fixes. Une piste serait de l’adapter au niveau utilisateur en fonction du volume d’interactions disponibles : un λ faible pour les utilisateurs avec peu d’historique, favorisant le signal sémantique, et un λ plus élevé pour les utilisateurs mieux documentés. Cela prolongerait la logique de personnalisation déjà à l’œuvre dans les stratégies β_u .

Extension à d’autres domaines : Les deux *datasets* utilisés appartiennent au secteur de la mode et du textile. Tester les mêmes stratégies sur des domaines comme l’alimentation, l’électronique ou le tourisme permettrait de vérifier si les tendances observées tiennent au-delà de ce contexte spécifique.

Évaluation en ligne : Ce mémoire repose sur une évaluation hors ligne par validation croisée. Une évaluation en ligne, mesurant l’impact réel des recommandations durables sur les comportements d’achat des utilisateurs, permettrait de valider si les gains de durabilité observés se traduisent effectivement par des choix plus responsables.

Seuil de durabilité par catégorie : Le seuil global retenu pour DS2 ne tient pas compte de l’hétérogénéité des empreintes carbone entre catégories de produits. Une approche par seuil propre à chaque catégorie permettrait une classification plus fine, en comparant les articles au sein de leur catégorie plutôt qu’à l’ensemble du catalogue.

6. Conclusion

Ce mémoire s'est intéressé à l'intégration de critères de durabilité environnementale dans les systèmes de recommandation, via des approches de post-processing basées sur un paramètre de pondération β . L'objectif principal était d'évaluer si l'adaptation de ce paramètre au niveau utilisateur, plutôt que l'utilisation d'une valeur globale identique pour tous, permettait d'améliorer le compromis entre précision des recommandations et durabilité des *items* suggérés.

Trois stratégies d'estimation du paramètre β_u ont été proposées et évaluées : une approche comportementale basée sur l'historique d'interactions de l'utilisateur, une approche sémantique exploitant la similarité entre les titres des *items* consommés et un centroïde durable, et une approche hybride combinant les deux signaux via un mécanisme de shrinkage. Ces stratégies ont été comparées à un β global de référence sur deux *datasets* issus du domaine de la mode, en utilisant quatre modèles de base représentatifs des grandes familles de filtrage collaboratif et de filtrage basé sur le contenu.

Les résultats montrent que les stratégies adaptatives ne dominent pas systématiquement le β global sur la frontière précision/durabilité, mais qu'elles présentent un intérêt pratique réel : elles produisent des compromis raisonnables sans nécessiter de calibration explicite du paramètre β . Sur DS1, où seulement 3,6% des utilisateurs ont un historique durable, S1 Behavioral est rendu inopérant par l'absence de signal comportemental exploitable. S2 Semantic et S3 Hybrid sont les seules stratégies à produire un effet de durabilité notable. Sur DS2, où 45,6% des utilisateurs ont un historique durable, S1 Behavioral retrouve une efficacité notable et produit un compromis comparable au β global.

Au-delà du compromis précision/durabilité, l'analyse par profil d'utilisateur révèle que le choix de la stratégie influe fortement sur la répartition des recommandations durables entre utilisateurs. Sur DS1, S1 Behavioral concentre les *items* durables chez les utilisateurs déjà sensibilisés, tandis que S2 et S3 les distribuent plus largement à l'ensemble des utilisateurs, y compris non durables. Sur la diversité, la Stratégie B de post-processing se révèle globalement préférable à la Stratégie A, préservant mieux la coverage catalogue tout en atteignant des niveaux de durabilité comparables.

Les systèmes de recommandation occupent une place croissante dans les décisions d'achat quotidiennes, et la question de leur impact environnemental mérite d'être posée. Intégrer la durabilité comme critère explicite dans ces systèmes constitue une piste concrète pour contribuer à une consommation plus responsable, à condition de trouver le bon équilibre entre pertinence pour l'utilisateur et impact environnemental des *items* recommandés. Les pistes futures identifiées, notamment l'enrichissement du signal sémantique et l'extension à d'autres domaines, ouvrent des perspectives prometteuses pour aller plus loin dans cette direction.

Bibliographie

- Hou, Y., Li, J., Fu, X., He, Z., Yan, A., Chen, X., & McAuley, J. (2024). Bridging Language and Items for Retrieval and Recommendation : Benchmarking LLMs as Semantic Encoders [arXiv :2403.03952]. <https://doi.org/10.48550/arXiv.2403.03952>
- Hugging Face. (2022). sentence-transformers/all-MiniLM-L6-v2 [Consulté le 27 mai 2026]. <https://huggingface.co/sentence-transformers/all-MiniLM-L6-v2>
- Khadka, A., & Sthapit, S. (2025). A Review on Scholarly Publication Recommender Systems. *Informatics*, 12, 108. <https://doi.org/10.3390/informatics12040108>
- Kim, J., Choi, I., & Li, Q. (2021). Customer Satisfaction of Recommender System : Examining Accuracy and Diversity in Several Types of Recommendation Approaches. *Sustainability*, 13, 6165. <https://doi.org/10.3390/su13116165>
- Ko, H., Lee, S., Park, Y., & Choi, A. (2022). A Survey of Recommendation Systems : Recommendation Models, Techniques, and Application Fields. *Electronics*, 11, 141. <https://doi.org/10.3390/electronics11010141>
- Kuanr, M., & Mohapatra, P. (2021). Assessment Methods for Evaluation of Recommender Systems : A Survey. *Foundations of Computing and Decision Sciences*, 46, 393-421. <https://doi.org/10.2478/fcds-2021-0023>
- Li, X., Zhang, K., Gao, Z., & Xu, J. (2025). Influencing Factors and Prediction Model for the Carbon Footprint of Textile Finishing Production : Case Study of 672 Textile Products. *Sustainability*, 17(22), 10350. <https://doi.org/10.3390/su172210350>
- Ma, X., Li, M., & Liu, X. (2025). Advancements in recommender systems : a comprehensive analysis based on data, algorithms, and evaluation. 6.
- Mo, Y., & Wang, H. (2025). Session-Based Recommendation Method Using Popularity-Stratified Preference Modeling. *Mathematics*, 13, 960. <https://doi.org/10.3390/math13060960>
- Muhammad, M., Gunardi, G., Danardono, D., & Rosadi, D. (2025). Optimization hybrid weighted switching filtering (OHWSF) using SVD and SVD++ for addressing data sparsity. *International Journal of Advances in Intelligent Informatics*, 11, 533. <https://doi.org/10.26555/ijain.v11i3.1796>
- Ni, J., Li, J., & McAuley, J. (2019). Justifying Recommendations using Distantly-Labeled Reviews and Fine-Grained Aspects. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, 188-197. <https://doi.org/10.18653/v1/D19-1018>
- Ragain, S., Peysakhovich, A., & Ugander, J. (2018). Improving pairwise comparison models using Empirical Bayes shrinkage. <https://doi.org/10.48550/arXiv.1807.09236>
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT : Sentence Embeddings using Siamese BERT-Networks [arXiv :1908.10084]. <https://doi.org/10.48550/arXiv.1908.10084>

- Satinet, C., & Fouss, F. (2022). A Supervised Machine Learning Classification Framework for Clothing Products' Sustainability. *Sustainability*, 14(3), 1334. <https://doi.org/10.3390/su14031334>
- Satinet, C., Fouss, F., Saerens, M., & Leleux, P. (2024). In-processing and post-processing strategies for balancing accuracy and sustainability in product recommendations. *Electronic Commerce Research and Applications*, 67, 101433. <https://doi.org/10.1016/j.elerap.2024.101433>
- Spillo, G., Di Filippo, A., Musto, C., Milano, M., & Semeraro, G. (2026). Eco-Amazon : Enriching E-commerce Datasets with Product Carbon Footprint for Sustainable Recommendations. <https://doi.org/10.48550/arXiv.2602.15508>
- Wang, W., Wei, F., Dong, L., Bao, H., Yang, N., & Zhou, M. (2020). MiniLM : Deep Self-Attention Distillation for Task-Agnostic Compression of Pre-Trained Transformers. <https://arxiv.org/abs/2002.10957>
- Wei, P., Shu, H., Gan, J., Deng, X., Liu, Y., Sun, W., Chen, T., Hu, C., Hu, Z., Deng, Y., Qin, W., & Li, Z. (2025). Sequential Recommendation System Based on Deep Learning : A Survey. *Electronics*, 14, 2134. <https://doi.org/10.3390/electronics14112134>
- Zhang, L., Lian, Y., Wu, H., Song, C., & Yuan, X. (2025). An Exploratory Study on Information Cocoon in Recommender Systems. *Data Science and Engineering*, 10, 495-514. <https://doi.org/10.1007/s41019-025-00288-9>
- Zhao, W., Zhao, L., & Liu, Z. (2025). Research on an MOOC Recommendation Method Based on the Fusion of Behavioral Sequences and Textual Semantics. *Applied Sciences*, 15, 10024. <https://doi.org/10.3390/app151810024>
- Zhou, X., Zhang, L., Zhang, H., Zhang, Y., Zhang, X., Zhang, J., & Shen, Z. (2024). Advancing Sustainability via Recommender Systems : A Survey. <https://doi.org/10.48550/arXiv.2411.07658>

A. Annexes

A — Distribution des β_u adaptatifs




Figure A.1 – Distribution des β_u adaptatifs — DS1 (haut) et DS2 (bas).




Figure A.2 – Distribution des β_u adaptatifs par profil d'utilisateur — DS1 (haut) et DS2 (bas).

B — Frontières Précision/Durabilité




Figure A.3 – Frontière Précision/Durabilité — Stratégie A, DS1 et DS2.




Figure A.4 – Frontière Précision/Durabilité — Stratégie B, DS1 et DS2.

C — Analyse par profil d'utilisateur



Figure A.5 — Analyse gap utilisateurs durables/non durables — Stratégie A, DS1 (haut) et DS2 (bas).




Figure A.6 – Analyse gap utilisateurs durables/non durables — Stratégie B, DS1 (haut) et DS2 (bas).

D — Code source

Le code source, les données et les résultats utilisés dans ce mémoire sont disponibles sur le repository GitHub suivant :

<https://github.com/Charlesmolle/molle-charles-memoire>

Ce repository contient le notebook principal d'expérimentation, les jeux de données DS1 et DS2, ainsi que les résultats des expérimentations sous forme de fichiers CSV.

