



HAL
open science

Modélisation du caractère séquentiel des repas pour améliorer la performance d'un système de recommandation alimentaire

Noémie Jacquet, Vincent Guigue, Cristina Manfredotti, Fatiha Saïs, Stéphane Dervaux, Paolo Viappiani

► To cite this version:

Noémie Jacquet, Vincent Guigue, Cristina Manfredotti, Fatiha Saïs, Stéphane Dervaux, et al.. Modélisation du caractère séquentiel des repas pour améliorer la performance d'un système de recommandation alimentaire. *Extraction et Gestion des Connaissances (EGC 2024)*, Jan 2024, Dijon, France. hal-04440140

HAL Id: hal-04440140

<https://hal.science/hal-04440140>

Submitted on 5 Feb 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Modélisation du caractère séquentiel des repas pour améliorer la performance d'un système de recommandation alimentaire

Noémie Jacquet*, Vincent Guigue*, Cristina Manfredotti*
Fatiha Saïs**, Stephane Dervaux*, Paolo Viappiani***

* AgroParisTech INRAE UMR MIA 518 Paris Saclay
22, place de l'Agronomie 91120 Palaiseau, France
prenom.nom@agroparistech.fr,
<https://mia-ps.inrae.fr/prenom-nom>

** Université Paris Saclay

Batiment 650, Campus Universitaire F-91190, Gif-sur-Yvette, France
Fatiha.Sais@lisn.fr
<https://www.lri.fr/sais/>

*** Université Paris Dauphine PSL

Place du Maréchal de Lattre de Tassigny 75775 PARIS Cedex 16 France
paolo.viappiani@lamsade.dauphine.fr
<https://www.lamsade.dauphine.fr/pviappiani/>

Résumé. L'adhésion de la population aux références nutritionnelles émises par les agences de santé est un enjeu majeur de santé publique et les systèmes de recommandation peuvent jouer un rôle essentiel à cet égard. L'enjeu est de construire un système capable de recommander non seulement des aliments, correspondant aux préférences des utilisateurs, mais aussi des menus, voire des séquences de menus, répondant à des contraintes diverses (e.g. régimes spécifiques, allergies, limites d'apports énergétiques). Nous proposons une approche, basée sur les réseaux de neurones récurrents, qui modélise la structure séquentielle d'un repas en même temps que les préférences des utilisateurs. Notre architecture est apprise sur les données INCA2, qui décrivent des consommations séquentielles d'individus à l'échelle de la semaine. L'approche présentée permet de répondre aux questions de recherche suivantes: (1) Comment se structurent les différents repas de la journée ? (2) Comment mêler modélisation séquentielle et préférences utilisateurs ? et (3) Comment évaluer la qualité des recommandations dans ce contexte ? Notre campagne d'expériences s'appuie sur différentes métriques pour démontrer que nous arrivons effectivement à modéliser cet aspect séquentiel conjointement aux préférences de l'utilisateur. Il s'agit d'une étape importante dans un projet plus global visant ensuite à travailler sur des données hétérogènes en entrée et à intégrer des contraintes de différentes natures sur les séquences générées.

1 Introduction

La plupart des maladies chroniques sont liées à de mauvaises habitudes alimentaires. Les agences de santé publique ont élaboré des recommandations destinées à l'ensemble de la population afin de l'inciter à adopter des habitudes alimentaires plus saines¹ : *mangez au moins 5 fruits ou légumes par jour, limitez votre consommation de sel*. Le respect de ces lignes directrices par le grand public est encore insuffisant, bien que la sensibilisation aux régimes alimentaires sains soit plutôt bonne. Les systèmes de recommandation alimentaire peuvent jouer un rôle essentiel à cet égard.

Du point de vue technique, les systèmes de recommandation sont des outils de plus en plus populaires pour aider l'utilisateur à trouver des suggestions de produits, de services et d'informations personnalisées (Adomavicius et Tuzhilin, 2010). Ils ont connu un grand succès dans divers domaines (films, achats, réseaux sociaux, portails d'emploi, etc.) et ont été déployés dans un grand nombre d'applications. Divers paradigmes ont été proposés puis combinés pour modéliser le contenu des items à recommander ou les traces de navigation des utilisateurs parmi ces items (Dong et al., 2017). Cependant, les problématiques ouvertes demeurent nombreuses, que ce soit autour de la diversité des suggestions, des explications associées aux suggestions (Ricci et al., 2015), de la transparence du système ou de son équité (Schnabel et al., 2016).

Si la recommandation de recettes s'apparente à un problème classique (Harvey et al., 2013), la suggestion de menus ouvre des perspectives associées à des défis techniques importants. Au niveau applicatif, recommander un ensemble cohérents d'aliments sur plusieurs repas permet d'introduire des contraintes diététiques pertinentes (Elsweiler et Harvey, 2015; Cholissodin et Dewi, 2017). Bien que l'aspect séquentiel des données a été déjà largement exploité au niveau des sessions, pour mieux modéliser les items (Guardia-Sebaoun et al., 2015; Grbovic et al., 2015), le problème est, ici, de construire un item complexe –en l'occurrence, une séquence d'aliments composant un menu– en incorporant des préférences utilisateurs et en maintenant la cohérence du repas (i.e. en évitant de proposer du chou-fleur en dessert). Un menu est un élément complexe composé de différents plats qui peuvent être décomposés en ingrédients. En plus de cette représentation hiérarchique, la séquence des menus est soumise à une dynamique particulière : les menus doivent être variés et leur équilibre est jugé sur une certaine période. La modélisation conjointe de cette hiérarchie et de la dynamique est critique; en effet, des contraintes peuvent s'appliquer aux ingrédients (allergies), aux méthodes de cuisson (friture), aux plats (préférence) ou à la séquence globale, à l'échelle de la journée ou de la semaine (respect des apports énergétiques).

Ainsi, l'application des approches séquentielles en recommandation pour la nutrition pose un certain nombre de questions de recherche, à la fois sur la modélisation des données en entrée du système, sur l'apprentissage des profils et sur la construction d'une sortie structurée :

- QR1 Comment caractériser la séquentialité des différents repas de la journée, du petit-déjeuner au dîner ?
- QR2 La modélisation séquentielle des menus permet-elle de capter les co-consommations (e.g. pain et beurre au petit déjeuner) ?
- QR3 Comment mêler modélisation séquentielle et préférences utilisateurs ?

1. <https://www.mangerbouger.fr/1-essentiel/les-recommandations-sur-1-alimentation-1-activite-physique-et-la-sedentarite>

QR4 Comment évaluer la qualité des recommandations dans un contexte séquentiel ?

QR5 Est-il possible de tirer parti efficacement de données hétérogènes (e.g. des données qualitatives et séquentielles comme des carnets de consommation et des données massives moins fiables comme des collections des recettes sur un site internet) ?

QR6 Comment mêler des préférences utilisateurs et des contraintes dures (allergies, enveloppes énergétiques globales, ...) dans un contexte de génération de séquences ?

Cet article applicatif se focalise sur les QR1, QR3 et QR4, marginalement QR2, les autres points étant évoqués en perspective. Les données INCA2 (ANSES, 2014) permettent d'accéder à des consommations séquentielles associées à des individus et de répondre à ces questions, elles sont décrites en section 2. Le système, combinant modélisation des séquences et apprentissage des profils utilisateurs, repose sur une architecture de réseau de neurones récurrents, il est décrit en détails et discuté dans la section 3. Un ensemble d'expériences illustre le fonctionnement de cette approche en considérant différentes ablations, résultats présentés en section 4

2 Analyse des données

Les données INCA2 Les données de consommations alimentaires utilisées dans cet article sont issues de l'enquête INCA2, un sondage national mené de 2006 à 2007 sur la consommation alimentaire individuelle des Français. L'enquête est constituée de journaux alimentaires recensant les consommations sur 7 jours de 4079 individus dont 2624 adultes sur plusieurs mois, en tenant compte de la saisonnalité possible des habitudes alimentaires. Nous avons exclu les consommations des enfants et adolescents de moins de 18 ans.


Une journée est composée de trois repas principaux : le petit-déjeuner, le déjeuner et le dîner. Les moments intermédiaires sont considérés comme des collations. Pour les repas principaux, le lieu (domicile, travail, école, extérieur) et l'accompagnateur (famille, amis, collègues, seul) sont enregistrés. Les 1280 entrées alimentaires sont organisées en 44 groupes et 110 sous-groupes d'aliments (cf Tab. 1).

Seul le fait que les aliments aient été consommés ou non au cours d'un repas est considéré (nous ne considérons pas les quantités consommées). Ces données présentent l'avantage d'être structurées, de bonne qualité et de comporter des séquences de consommation réelles sur 7 jours, séquences qui sont nécessaires pour l'apprentissage et la recommandation de repas et non d'aliments isolés.

Dans cet article, les données de consommation de l'enquête INCA2 sont interprétées comme des préférences implicites des utilisateurs (Rendle et al., 2012) : cela revient à considérer une matrice d'interactions binaires "aliments"/"utilisateurs" constituées de 0 (non consommation de l'aliment par l'utilisateur) et de 1 (consommation de l'aliment par l'utilisateur). Globalement, nous distinguons, dans la suite, deux types de repas : (1) les petits déjeuners (repas caractérisés par des consommations plus "répétitives") et (2) les déjeuners et diners (repas plus complexes et caractérisés par une plus grande variété de consommations). Ces deux types de repas seront modélisés séparément. En considérant le 7ème jour comme un ensemble de test – l'étude n'est pas calée sur la semaine, ce jour peut être n'importe lequel –, il est très intéressant de constater que les utilisateurs consomment 11% de nouveaux aliments (c'est-à-dire que 11% des aliments n'ont pas été consommés dans les premiers 6 jours d'observation de l'utilisateur) au petit-déjeuner et 51% de nouveaux aliments sur les déjeuners et diners. Ces derniers repas représentent un défi très important, quasiment assimilable à du démarrage à froid.

Modélisation de la séquentialité des repas pour la recommandation alimentaire

Code Groupe	Nom du Groupe	Code Groupe	Nom du groupe
1	pain et panification sèche	24	pommes de terre et apparentés
2	céréales pour petit déjeuner	25	légumes secs
3	pâtes	26	fruits
4	riz et blé dur ou concassé	27	fruits secs et graines oléagineuses
5	autres céréales	28	glaces et desserts glacés
6	viennoiserie	29	chocolat
7	biscuits sucrés ou salés et barres	30	sucres et dérivés
8	pâtisseries et gâteaux	31	eaux
9	lait	32	boissons fraîches sans alcool
10	ultra-frais laitier	33	boissons alcoolisées
11	fromages	34	café
12	oeufs et dérivés	35	autres boissons chaudes
13	beurre	36	pizzas, quiches et pâtisseries salées
14	huile	37	sandwichs, casse-croûte
15	margarine	38	soupes et bouillons
16	autres graisses	39	plats composés
17	viande	41	entremets, crèmes desserts et laits gélifiés
18	volaille et gibier	42	compotes et fruits cuits
19	abats	43	condiments et sauces
20	charcuterie	44	aliments destinés à une alimentation particulière
21	poissons		
22	crustacés et mollusques		
23	légumes (hors pommes de terre)		



TAB. 1 – Nomenclature des 44 groupes d'aliments dans l'enquête INCA2 et distribution de ces catégories dans les repas.




FIG. 1 – Distribution temporelle des aliments pendant le déjeuner et le dîner. Les abscisses désignent les 44 catégories, l'ordonnée indique la période de consommation : la soupe, par exemple, est consommée au début du déjeuner/dîner (premier 20% du déroulement du repas). Par soucis de lisibilité, les catégories INCA2 du tableau 1 ont été réduites à leur premier mot.

Sequentialité dans les données INCA2 La notion de séquentialité est au cœur de cet article et nous savons, par la description des données INCA2, que les participants à l'étude ont saisi leurs consommations dans l'ordre. Notre hypothèse de travail est la suivante : le repas se structure autour d'un axe *entrée-plat-dessert*. En plus de cet axe, l'analyse rapide des données INCA2 montre qu'un certain nombre d'éléments transversaux (e.g. huiles, sucres, boissons) sont arbitrairement regroupés en fin de description.

Afin de mesurer la séquentialité des données, nous avons étudié la distribution des catégories INCA2 décrites en tableau 1 dans le temps. Chaque catégorie devient ainsi une distribution sur l'avancement du repas, qui est exprimé en pourcentage pour rendre comparables les séquences de longueurs différentes. La figure 1 illustre cette séquentialité sur les déjeuners-dîners : les catégories sont ordonnées selon leur moyenne et une tendance se dégage assez clairement. Il apparaît dans le même graphique que cet ordonnancement est néanmoins bruité comme en atteste les nombreuses anomalies aux extrêmes des distributions. Nos expériences préliminaires ont montré qu'une approche discrète de type Modèle de Markov Caché ne fonctionnait pas bien sur ces données, ce qui est directement lié à ce niveau de bruit. Cette figure montre également que dans l'hypothèse *entrée-plat-dessert*, la transition est très marquée entre *plat* et *dessert* et beaucoup moins entre *entrée* et *plat*, ce qui explique encore une fois la difficulté d'une modélisation discrète du phénomène. Ces analyses et expériences préliminaires nous poussent, donc, à envisager une modélisation séquentielle continue à base de réseaux de neurones récurrents telle que décrite dans la section suivante.

3 Modélisation avec des réseaux de neurones récurrents

Les outils de modélisation séquentielle en recommandation sont nombreux, depuis les chaînes de Markov (Rendle et al., 2010) pour les séquences discrètes jusqu’au transformer qui permettent d’introduire une approche globale pour mieux capter les dépendances entre événements distants (Kang et McAuley, 2018). Dans notre application, nous souhaitons apprendre des représentations continues pour les utilisateurs et les aliments afin d’étudier, à terme, la topologie de la population d’une part et la similarité des aliments d’autre part. Les données sur lesquelles nous travaillons sont qualitatives mais peu nombreuses, (cf section 2), ce qui nous pousse à explorer des modèles parcimonieux en paramètres.

La flexibilité de l’architecture RNN –Recurrent Neural Network– et le fait que cette approche ait largement fait ses preuves sur les systèmes de recommandation nous pousse à l’étudier en détail. De plus les séquences de consommation sont assez courtes, marquées par des transitions franches (type entrée/plat/dessert pour les déjeuners et diners) et a priori peu propice à des dépendances longues.

Données séquentielles Nous sommes en présence de données contenant de menus m , chaque menu étant une séquence d’aliments a :

$$X = \{m_{d,r}^u\}, \quad m_{d,r}^u = [a_1, \dots, a_t, \dots, a_T] \quad (1)$$

Chaque menu est associé à une date d , un repas r (petit-déjeuner, diner, etc...) et un utilisateur u .

Apprentissage de représentation Par défaut, l’espace des aliments \mathcal{A} est discret. Suivant le paradigme de l’apprentissage de représentation (Bengio et al., 2013), nous projetons les aliments dans un espace vectoriel de dimension z :

$$a \in \mathcal{A} \mapsto \mathbf{a} \in \mathbb{R}^z \quad (2)$$

De la même manière, les utilisateurs sont projetés dans l’espace latent : $u \in \mathcal{U} \mapsto \mathbf{u} \in \mathbb{R}^z$. Ces représentations seront initialisées puis apprises par l’architecture récurrente décrite ci-dessous. Nous envisagerons différentes initialisations dans la partie expérimentale.

Cette approche, très générale, est la plus classique et la plus flexible pour encoder différentes informations –notamment les affinités– dans les profils des utilisateurs et des items. Depuis l’émergence des techniques de factorisation matricielle pour la recommandation (Lee et Seung, 2000) jusqu’aux variantes permettant de remporter le challenge Netflix (Koren, 2009), de la vague de modélisation des feedbacks implicites (Rendle et al., 2012) aux approches de deep-learning mêlant collaborative filtering et analyse du contenu (Zhang et al., 2019), toutes les avancées récentes sont basées sur l’apprentissage de représentation.

Réseau de neurones récurrents & séquentialité du repas Un RNN met à jour l’état caché au temps t ($\mathbf{h}_t \in \mathbb{R}^h$) en utilisant la fonction suivante :

$$\mathbf{h}_t = g(W \mathbf{a}_t + U \mathbf{h}_{t-1}), \quad W \in \mathbb{R}^{h \times z}, U \in \mathbb{R}^{h \times h} \quad (3)$$

Où g est une fonction tangente hyperbolique, $\mathbf{a}_t \in \mathbb{R}^z$ est la représentation de l'aliment en entrée de l'unité au temps t et \mathbf{h}_{t-1} est l'état caché au temps $t - 1$. Les paramètres des poids sont donnés par les matrices $W \in \mathbb{R}^{h \times z}$ et $U \in \mathbb{R}^{h \times h}$.

Le réseau propose une prédiction de l'item suivant dans une séquence, toujours à un horizon temporel de 1, ce qui correspond à de l'apprentissage forcé *-teacher-forcing-* (Lamb et al., 2016). La prédiction de $P(a_{t+1}|a_t)$ est estimée classiquement par une fonction `softmax` :

$$\hat{p} = f(\mathbf{h}_t) = \text{softmax}(V \mathbf{h}_t) \in \mathbb{R}^{|\mathcal{A}|}, \quad \hat{a}_{t+1} = \arg \max \hat{p} \quad (4)$$

où la matrice $V \in \mathbb{R}^{|\mathcal{A}| \times h}$ rassemble les paramètres de prédiction. Le critère d'apprentissage du réseau est, classiquement, l'entropie croisée : $H(\hat{p}) = -\log \hat{p}(a_{t+1})$. Les échantillons sont regroupés en mini-batch pour économiser du temps de calcul, ce paramètre a très peu d'influence sur les performances.

Dans ce travail préliminaire, nous nous sommes concentrés sur les approches les plus robustes : les architectures LSTM (Hochreiter et Schmidhuber, 1996) ou GRU (Chung et al., 2015) nous ont semblées trop complexes par rapport à la faible longueur des séquences et aux peu de dépendances longues dans les données. Ces architectures seront testées ultérieurement.

Intégration des utilisateurs L'architecture précédente ne fait pas intervenir les utilisateurs, elle modélise simplement la séquentialité de l'ensemble des consommations. Deux solutions techniques simples permettent d'intégrer un profil d'utilisateur : (1) en jouant sur les conditions initiales ; (2) en concaténant le profil utilisateur à chacune des entrées.

Chaque début de repas est associé à un aliment spécial $\mathbf{a}_0 = DEB$, ce qui permet à l'architecture de prédire le premier élément de la séquence. L'idée est de remplacer \mathbf{a}_0 par \mathbf{u} afin de rendre les prédictions ultérieures dépendantes de l'utilisateur et d'apprendre le profil utilisateur en parallèle.

L'inconvénient principal de la précédente architecture réside dans le peu d'information de gradient qui sera transmise jusqu'au début de séquence. La solution à ce problème consiste à fournir à chaque pas de temps t l'entrée concaténée : $[\mathbf{a}_t, \mathbf{u}] \in \mathbb{R}^{2z}$.

Initialisation L'initialisation des représentations (*embeddings*) est habituellement aléatoire, l'apprentissage du prochain élément de la séquence permettant alors non seulement d'optimiser les poids U, V, W mais aussi les représentations d'aliments $\{\mathbf{a}_t\}$ et les profils d'utilisateur \mathbf{u} .

Cependant, le processus d'optimisation est non convexe et le peu de données disponible peut inciter à chercher des initialisations plus fines que l'aléatoire pour faciliter et stabiliser l'apprentissage. La solution la plus classique est de repartir du profil appris par factorisation matricielle robuste, par exemple en utilisant BPR -Bayesian Personalized Ranking- sur des *feedback* implicites (Rendle et al., 2012).

Evaluation L'évaluation est habituellement un des points les plus critiques sur les systèmes de recommandation (Said et Bellogín, 2014) : l'évaluation des notes prédites au sens des moindres-carrés a été la norme avant d'être totalement remise en question après 2010, les protocoles hors-ligne souffrant de différents biais (Castells et Moffat, 2022). Nous avons utilisé le MRR -*Mean Reciprocal Rank*- comme référence pour la factorisation matricielle.

Au niveau de la recommandation séquentielle, les métriques posent moins questions. Dans cet article, tous les résultats présentés sont des évaluations à horizon temporel 1 et nous utilisons simplement le taux de bonne classification sur la prédiction de l'aliment suivant, éventuellement relaxé en top-N (c'est à dire, sur les N prédictions les plus probables faites pour l'aliment suivant).

4 Expérimentations en recommandation nutritionnelle

Nos travaux ont d'abord porté sur des systèmes de recommandation plus classiques, respectivement orientés vers la modélisation des affinités des utilisateurs et la substituabilité des aliments. Ces expériences sont présentées et analysées avec leurs limites dans la première partie de cette section avant de présenter l'approche séquentielle.

La question critique est double : elle concerne l'usage et l'évaluation de tels systèmes. Notre objectif est de proposer un repas personnalisé à un utilisateur : ce repas doit (1) répondre aux préférences de l'utilisateur, (2) il doit être cohérent et (3) il devra rentrer dans un ensemble de contraintes strictes, qu'elles soient nutritionnelles, médicales et/ou religieuses.

Cet article se focalise sur les points (1) et (2) : nous voulons proposer un système proposant des aliments à la fois pertinents (qui plaisent à l'utilisateur) et cohérents (pas de chou-fleur en dessert).

4.1 Expériences préliminaires & limites

Factorisation Matricielle L'approche la plus classique en recommandation consiste à apprendre des profils d'utilisateurs et d'item pour prédire une affinité. En présence de *feedbacks* implicites, nous partons d'une solution éprouvée : BPR. La pertinence est évaluée sur les données d'un jour caché : le dernier jour n'est pas utilisé en apprentissage, il permet d'évaluer les performances au sens du MRR : $MRR_u = \frac{1}{n_u} * \left(\sum_{a \in A_u} \frac{1}{rang a} \right)$ Etant donné l'ordonnement des aliments selon les préférences de u , nous calculons le rang des aliments effectivement consommés A_u . Le MRR est la moyenne des inverses de ces rangs, il faut donc le maximiser.

Cet algorithme permet d'obtenir un MRR sur l'ensemble des utilisateurs de 0.161, le score idéal étant de 1 (inatteignable sur des ensembles d'items à recommander) et le score aléatoire de 0.019. Si les résultats quantitatifs sont très intéressants, les résultats qualitatifs discréditent malheureusement cette approche, les utilisateurs pouvant se voir recommander à la fois thé, café et jus d'orange mais parfois rien de pertinent à manger ou alors du beurre sans pain etc...

Modélisation des sessions et substituabilité Les repas s'apparentant à des sessions, nous avons utilisé l'algorithme prod2vec afin de mieux modéliser les profils d'aliments et potentiellement mieux identifier les éléments substituables (Akkoyunlu et al., 2017). Une étude qualitative des résultats montre que les proximités ont du sens et il est possible de catégoriser les aliments du petit-déjeuner... Mais ces profils ne sont pas robustes au bruit et l'application de cet algorithme sur les déjeuners et diners n'est pas concluant. L'exploitation des profils appris par prod2vec pour initialiser BPR ne conduit pas non plus à une amélioration des performances (ni quantitatives, ni qualitatives).

4.2 Expériences en modélisation séquentielle

Afin de gagner en consistance, nous avons travaillé avec l’architecture RNN décrite précédemment. La métrique d’évaluation retenue est le taux de reconnaissance de l’élément suivant, que nous avons aussi relaxé en top3² en exploitant la distribution softmax en sortie de réseau. Dans cet article, toutes les métriques sont à un horizon temporel de 1, nous ne considérons pas une prédiction à plus long terme. Il faut faire attention à ne pas comptabiliser les EOS (fin de repas) dans la métrique car celle-ci est facile à retrouver et fausse nettement les résultats.

Il est important de noter que l’entraînement des RNN est effectué de bout en bout. Nos expériences préliminaires nous ont permis de tester l’intérêt d’une initialisation des représentations d’aliment par prod2vec ou d’une initialisation des aliments + utilisateurs avec les représentations BPR. Ces deux expériences n’apportent rien : il est tout aussi efficace d’apprendre directement les profils à travers le RNN.

Métriques	Tx	Tx-Top3	Tx-CAT	Tx	Tx-Top3	Tx-CAT
Modèles		DEJ+DIN			PT-DEJ	
Sans utilisateur	0.11	0.25	0.20	0.38	0.60	0.47
Util. = h_0	0.13	0.27	0.24	0.66	0.78	0.73
Concat. Util.+Alim.	0.16	0.30	0.24	0.71	0.83	0.77
Aléatoire	0.003	0.01	0.023	0.018	0.055	0.023

TAB. 2 – Résultats en taux de bonne classification (Tx) sur la prédiction de l’aliment suivant dans le repas en test, Tx-Top3 le taux de reconnaissance en top3. Tx-Cat désigne le taux de reconnaissance de la catégorie INCA2.

Petit-déjeuner Il est important de distinguer les performances sur les données du petit-déjeuner de celles des repas plus longs (déjeuners/diners); en effet, la régularité des utilisateurs et le peu d’aliments en jeu rendent la prédiction bien plus simple pour le repas du matin. La séquentialité du petit-déjeuner n’était pas une évidence a priori (par rapport à la structure *entrée-plat-dessert* du déjeuner/diner); force est de constater qu’elle est très présente dans les données : il est possible de prédire l’élément suivant dans une séquence à 60% en top-3 sans même prendre en compte l’utilisateur (cf Tableau 2). Cette performance est directement liée à la présence de nombreuses associations récurrentes qui sont bien prédites par le RNN. L’apport de la modélisation utilisateur est très net, de même que la supériorité de l’architecture répétitive où le profil utilisateur est présenté à chaque pas de temps pour éviter les problèmes de mémorisation des préférences sur la fin de repas (+23% de bonne prédiction en top3).

Déjeuner/diner L’expérience est beaucoup plus intéressante sur les repas longs lorsqu’on rappelle que les approches BPR/prod2vec se sont complètement effondrées dans ce cadre plus variable et bruyé. Bien que les performances soit nettement en dessous du petit-déjeuner, 11% de bonne prédiction représente déjà une base exploitable. Ce taux monte à 30% en intégrant l’utilisateur et en relaxant la métrique en top-3. La figure 2 illustre aussi le fait que le RNN respecte bien la séquentialité générale du repas, même si l’horizon de prédiction à 1 limite les conclusions sur ce point.

2. ce-ci est une metrique en topN avec N=3.

L'impact du profil utilisateur sur les performances est significatif mais néanmoins décevant. Ce point est pour nous directement lié à la variabilité des données : les données de test des utilisateurs (=7ème jour de l'étude) contiennent 51% d'aliments nouveaux (contre 11% pour le petit-déjeuner). Il s'agit d'un contexte, s'apparentant à du démarrage à froid, où l'extraction d'un profil est particulièrement délicat.




FIG. 2 – Distribution temporelle des aliments dans les prédictions faites par RNN pour les déjeuners et les diners.

5 Conclusion et perspectives

Cet article constitue une étape préliminaire importante vers la construction d'un système de recommandation dans le domaine de la nutrition. Nous avons démontré les faiblesses des approches traditionnelles, y compris en modélisation par session, pour l'apprentissage de profils et la prédiction lorsque les conditions sont difficiles (déjeuner et dîner). En parallèle, nous avons comparé plusieurs approches à base de RNN pour la prise en compte de la séquentialité et des préférences utilisateurs : cette base technique est intéressante et demande maintenant à être optimisée puis exploitée.

Ainsi, les perspectives de ce travail sont nombreuses. En terme d'amélioration des performances, nous sommes convaincus que l'exploitation de plus de données utilisateurs -notamment à travers les avis des sites de type *marmiton*- permettra de densifier puis fiabiliser l'espace de représentation des utilisateurs. L'exploitation des RNN pour la génération d'un repas est assez trivial, le principal enjeu réside dans la métrique d'évaluation d'un tel système. De nouveau, il va falloir plus de données pour mieux modéliser la substituabilité et être en mesure d'évaluer les propositions au niveau sémantique, à la manière d'un BERT-score dans le domaine du TAL. Sur le plan architectural, le défi consiste à construire un modèle neuronal hybride intégrant des contraintes dures issues des bases de connaissances nutritionnelles lors de la génération d'une séquence d'aliments respectant aussi les préférences utilisateurs.

Remerciements : Ce travail a été en partie financé par l’institut DATA-IA, Paris-Saclay.

Références

- Adomavicius, G. et A. Tuzhilin (2010). Context-aware recommender systems. In *Recommender systems handbook*, pp. 217–253. Springer.
- Akkoyunlu, S., C. Manfredotti, A. Cornuéjols, N. Darcel, et F. Delaere (2017). Investigating substitutability of food items in consumption data. In *Workshop on Health Recommender Systems, ACM RecSys*, Volume 5.
- ANSES (2014). Données de consommations et habitudes alimentaires de l’étude inca 2, <https://www.data.gouv.fr/fr/datasets/donnees-de-consommations-et-habitudes-alimentaires-de-letude-inca-2-3/>.
- Bengio, Y., A. Courville, et P. Vincent (2013). Representation learning : A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence* 35(8), 1798–1828.
- Castells, P. et A. Moffat (2022). Offline recommender system evaluation : Challenges and new directions. *AI Magazine* 43(2), 225–238.
- Cholissodin, I. et R. K. Dewi (2017). Optimization of healthy diet menu variation using pso-sa. *Journal of Information Technology and Computer Science* 2(1), 28–40.
- Chung, J., C. Gulcehre, K. Cho, et Y. Bengio (2015). Gated feedback recurrent neural networks. In *International conference on machine learning*, pp. 2067–2075. PMLR.
- Dong, X., L. Yu, Z. Wu, Y. Sun, L. Yuan, et F. Zhang (2017). A hybrid collaborative filtering model with deep structure for recommender systems. In *AAAI Conference on artificial intelligence*, Volume 31.
- Elsweiler, D. et M. Harvey (2015). Towards automatic meal plan recommendations for balanced nutrition. In H. Werthner, M. Zanker, J. Golbeck, et G. Semeraro (Eds.), *ACM RecSys*, pp. 313–316. ACM.
- Grbovic, M., V. Radosavljevic, N. Djuric, N. Bhamidipati, J. Savla, V. Bhagwan, et D. Sharp (2015). E-commerce in your inbox : Product recommendations at scale. In *ACM SIGKDD*, pp. 1809–1818.
- Guàrdia-Sebaoun, E., V. Guigue, et P. Gallinari (2015). Latent trajectory modeling : A light and efficient way to introduce time in recommender systems. In *ACM RecSys*, pp. 281–284.
- Harvey, M., B. Ludwig, et D. Elsweiler (2013). You are what you eat : Learning user tastes for rating prediction. In *SPIRE*, Volume 8214 of *Lecture Notes in Computer Science*, pp. 153–164. Springer.
- Hochreiter, S. et J. Schmidhuber (1996). Lstm can solve hard long time lag problems. *Advances in neural information processing systems* 9.
- Kang, W.-C. et J. McAuley (2018). Self-attentive sequential recommendation. In *2018 IEEE international conference on data mining (ICDM)*, pp. 197–206. IEEE.
- Koren, Y. (2009). The bellkor solution to the netflix grand prize. *Netflix prize documentation* 81(2009), 1–10.

- Lamb, A. M., G. Anirudh, Y. Zhang, S. Zhang, A. C. Courville, et Y. Bengio (2016). Professor forcing : A new algorithm for training recurrent networks. In *Advances in neural information processing systems*, Volume 29.
- Lee, D. et H. S. Seung (2000). Algorithms for non-negative matrix factorization. *Advances in neural information processing systems 13*.
- Rendle, S., C. Freudenthaler, Z. Gantner, et L. Schmidt-Thieme (2012). Bpr : Bayesian personalized ranking from implicit feedback. *arXiv preprint arXiv :1205.2618*.
- Rendle, S., C. Freudenthaler, et L. Schmidt-Thieme (2010). Factorizing personalized markov chains for next-basket recommendation. In *Proceedings of the 19th international conference on World wide web*, pp. 811–820.
- Ricci, F., L. Rokach, et B. Shapira (2015). Recommender systems : introduction and challenges. *Recommender systems handbook*, 1–34.
- Said, A. et A. Bellogín (2014). Comparative recommender system evaluation : benchmarking recommendation frameworks. In *Proceedings of the 8th ACM Conference on Recommender systems*, pp. 129–136.
- Schnabel, T., A. Swaminathan, A. Singh, N. Chandak, et T. Joachims (2016). Recommendations as treatments : Debiasing learning and evaluation. In *international conference on machine learning*, pp. 1670–1679. PMLR.
- Zhang, S., L. Yao, A. Sun, et Y. Tay (2019). Deep learning based recommender system : A survey and new perspectives. *ACM computing surveys (CSUR) 52*(1), 1–38.

Summary

The compliance by the general public to the nutritional guidelines issued by health authorities is relatively low and this represents a significant health concern. A solution to this problem could be to develop a nutritional recommender system. The challenge is to develop a system capable of suggesting not only foods that align with users’ tastes but also menus, or even sequences of menus, that meet diverse restrictions such as particular diets, allergies, or calorie thresholds. We present a method based on recurrent neural networks that simultaneously model the sequential structure of meals and individual tastes. Our architecture is learned on the INCA2 dataset, which describes daily individuals’ consumptions over a week. Our approach tackles the following research questions: (1) How meals are structured during the day? (2) How can we consider both sequential modelling and user preferences? and (3) How can we evaluate the performance of the recommendation in this context? Our experimental campaign employs several metrics to illustrate the successful incorporation of sequential aspects and user preferences in our models. This marks a crucial milestone in a larger project that aims to work with diverse input data and integrate various sequence constraints.