

Algorithme de recommandation adaptable pour la personnalisation d'un système mobile

Mathieu Petit
Laboratoire d'Informatique de
Grenoble
Bâtiment IMAG B
385, avenue de la Bibliothèque
38400 Saint Martin d'Hères
mathieu.petit @ imag.fr

Cyril Ray
Institut de Recherche de
l'Ecole Navale
BCRM de Brest, Ecole Navale
CC 600, 29240 Brest Cedex 9
cyril.ray @ ecole-navale.fr

Christophe Claramunt
Institut de Recherche de
l'Ecole Navale
BCRM de Brest, Ecole Navale
CC 600, 29240 Brest Cedex 9
christophe.claramunt @
ecole-navale.fr

RESUMÉ

Cet article présente un algorithme adaptable pour la construction de profils de préférences d'utilisateurs d'un système mobile et distribué. Ces profils sont produits implicitement par l'analyse conjointe des préférences d'utilisateurs selon leurs interactions et leurs comportements spatiaux. Appliqué à un assistant mobile de visite de campus, cet algorithme produit un ensemble de profils (personnels, de groupes ou mixtes) qui contraignent la présentation des informations des départements du campus. Une chaîne de simulation, implémentée en Java, autorise les concepteurs à paramétrer le modèle préalablement à son déploiement *in situ*.

Mots Clés

Systèmes mobiles et distribués, Adaptation contextuelle, Recommandations multi-utilisateurs.

ABSTRACT

This paper introduces a flexible algorithm to derive users' preferences in a mobile and distributed system. Such profiles are implicitly computed from users' spatial and interactive behaviours. A campus visit aid illustrates the benefits of such algorithm within unobtrusive recommender systems. Our approach provides a set of profiles (personal, group-based and hybrid) to adapt the presentation of campus services and suit users' immediate needs and interests. A Java-based simulation framework allows designers to customize the model before *in situ* validation.

Categories and Subject Descriptors

H.5.3 [Information Interfaces and Presentation]: Group and Organization Interfaces—*Collaborative computing*; I.2.6 [Artificial Intelligence]: Learning—*Knowledge acquisition*

General Terms

Algorithms, Human factors.

Keywords

Mobile and distributed systems, Contextual adaptation, Implicit profiling, Multi-user recommendations.

1. INTRODUCTION

La personnalisation des systèmes mobiles est motivée par l'utilisation croissante de nouveaux supports interactifs à la fois plus performants et plus autonomes. Le succès des dernières générations de "Smartphones", d'organiseurs ou de systèmes de navigation va de pair avec l'augmentation significative de la quantité d'information accessible à un utilisateur mobile. Contrastant avec cette richesse d'informations, les plates-formes mobiles deviennent plus petites et portables. Leurs capacités de traitement d'information s'accroissent, mais les interfaces et les surfaces d'affichage pour présenter ces informations restent contraintes par la taille des dispositifs [2].

Sur ces nouvelles plates-formes, il est souhaitable d'effectuer un filtrage des données présentées à l'utilisateur pour individualiser son expérience du système en fonction de ses besoins immédiats. Cette démarche a pour but d'éviter à l'utilisateur d'être inondé par des informations ou des fonctionnalités qui ne seraient pas pertinentes pour lui. Dans cette optique, de nombreuses propositions s'appuient sur la construction d'un profil d'expérience et/ou de préférences et proposent des recommandations de contenu ou de présentation en se basant sur les profils établis. Les profils d'utilisateurs sont construits soit par le *renseignement explicite* de la part des utilisateurs, soit par l'application de *profils pré-déterminés* décrits par les concepteurs, ou soit par un *renseignement implicite* des mesures du profil inférées à partir des actions des utilisateurs [7]. Cette dernière approche est plus souvent développée dans le cas des systèmes distribués et mobiles. Les bénéfices de cette méthode pour un utilisateur, éventuellement en déplacement, sont doubles :

- contrairement à l'application de profils pré-déterminés, la personnalisation du contenu et des fonctionnalités restent dynamiques à l'exécution ;
- par rapport au renseignement explicite du profil, la mesure implicite permet à l'utilisateur de rester concentré sur son action en cours sans avoir à fournir d'indications de préférences pour bénéficier d'adaptations contextuelles.

Dans la suite, quelques solutions pour la construction implicite de profils sont présentées. Un bilan de cet état de l'art permettra de justifier notre proposition d'algorithme, qui sera illustré par un exemple de cas d'application et de développement logiciel.

2. CONSTRUCTION IMPLICITE DE PROFILS

Construire un profil utilisateur signifie rassembler un ensemble de propriétés contextuelles en relation avec l'utilisateur et servant à adapter le comportement du système. Ces informations caractérisent la dimension "utilisateur" du contexte d'usage (c-à-d. $\langle \text{utilisateur}, \text{plate-forme}, \text{environnement} \rangle$ [14]). Deux techniques de mesures sont couramment adoptées pour l'initialisation implicite d'un profil utilisateur [1]. La *construction par analyse de contenu* (content-based recommendation) considère les comportements passés d'un individu particulier comme des indicateurs de son comportement à venir. La *construction par analyse conjointe* (collaborative recommendation) considère que les comportements d'un ensemble d'individus groupés selon une valeur de proximité contextuelle révèlent les comportements à venir d'un utilisateur particulier du groupe.

Ces deux approches disposent d'avantages et d'inconvénients. L'approche par analyse de contenu permet une personnalisation au grain des individus, mais nécessite la collection implicite d'une quantité importante de données avant de pouvoir établir des profils. La notion de *démarrage à froid* [12] est caractéristique du passage d'un profil vide à un profil utilisable. En corollaire de ce problème, les profils générés souffrent d'une *inertie du contenu* liée à la difficulté de mesurer des changements de comportement par une analyse statistique [5]. L'approche par analyse conjointe est moins sensible à l'inertie de la génération des profils et élimine le problème du démarrage à froid en associant un profil de groupe à tout nouvel utilisateur s'y rattachant. Néanmoins, le regroupement d'utilisateurs pour la définition de profils personnels biaise la notion de personnalisation en créant des stéréotypes, qui satisfont les utilisateurs en général, mais aucun d'entre eux en particulier [11].

Les deux techniques de mesures s'opposent dans leurs avantages et inconvénients. Certaines méthodes hybrides tentent "d'associer les avantages de ces techniques de mesure [par analyse conjointe et analyse de contenu] sans hériter de leurs inconvénients" [1]. Ces propositions d'hybridation peuvent être classées en familles [3]. Par exemple, la famille des *profils pondérés* combine les valeurs obtenues par l'analyse conjointe et l'analyse de contenu [9]; dans la famille des *profils alternés*, les profils sont construits soit par analyse conjointe soit par analyse de contenu [15]; pour les méthodes de *profils cascades*, une technique de mesure sert à affiner les résultats de l'autre [8], etc. En l'absence d'expérimentations démontrant clairement l'avantage d'une approche sur une autre, l'utilisateur reste central pour choisir la technique de construction de profil [10]. Dans cette perspective, la notion d'*extra-IHM* [13], adaptée à la construction de profil, permettrait :

1. de choisir la source de mesure des profils (c-à-d. : par analyse de contenu, par analyse conjointe ou par une méthode hybride);

2. de comprendre le contenu des profils et l'origine des *indicateurs implicites d'intérêt* [4];
3. de contrôler la construction des profils en agissant sur les paramètres de mesure.

Dans la suite, l'algorithme développé initie une réponse à ces trois objectifs. Cette proposition constitue notre cadre de référence pour le développement de systèmes de recommandation dont les comportements sont observables par les utilisateurs.

3. PRINCIPE ALGORITHMIQUE

L'approche proposée pour la construction de systèmes de recommandation distingue trois niveaux de profils : les *profils utilisateur*, les *profils moyen* et les *profils de groupe*. Ces profils sont déterminés à l'exécution, à intervalles réguliers. Chacun d'eux regroupe les préférences d'un ensemble d'utilisateurs par rapport au contenu informationnel délivré par le système. Plus spécifiquement, un profil est un ensemble de paires (*score*, *element*) où la composante *score* quantifie l'intérêt des utilisateurs envers une information présente (composante *element*). Une composante *element* peut être un objet ou un ensemble d'objets numérique représentant une/des entité(s) de l'environnement de l'utilisateur. La composante *score* est constituée pour chaque *element* à partir d'une mesure instantanée et d'une mesure historique.

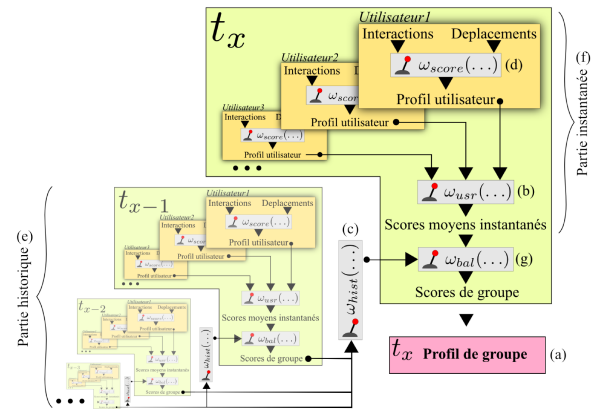


FIG. 1: Décomposition de l'algorithme de construction de profils

La *partie instantanée* représente les préférences d'utilisateurs partageant les mêmes tâches et un même contenu informationnel (Fig. 1f). Un profil personnel est défini pour chaque individu en mêlant des mesures implicites d'interaction et de déplacement du dernier intervalle d'exécution (c-à-d. entre t_{x-1} et t_x). L'agrégation des profils personnels construit le profil moyen instantané commun à tous les utilisateurs. La *partie historique* rapporte les valeurs des scores construits aux instants d'exécution précédents (c-à-d. entre l'instant d'initialisation t_0 et l'instant courant t_x). Un profil de groupe est issu de la combinaison des profils passés et du profil moyen instantané (Fig 1a).

Ce modèle est rendu observable par un ensemble de fonctions de pondération qui permettent aux utilisateurs de garder le

contrôle sur la construction des profils et l'application de recommandations :

- la fonction $\omega_{usr}(\dots)$ règle l'apport des utilisateurs dans la construction des scores moyens (Fig. 1b). Cette fonction rend observable l'hybridation de l'analyse de contenu et de l'analyse conjointe. Les utilisateurs règlent l'impact de leurs préférences dans le profil moyen ;
- la fonction $\omega_{hist}(\dots)$ définit quelle est l'importance de chacun des scores de groupe passés lors du calcul du score de groupe de l'instant courant (Fig. 1c). L'utilisateur peut renforcer certains profils passés, par exemple lorsqu'il avait accueilli favorablement les recommandations dérivées de ce profil ;
- fonction $\omega_{bal}(\dots)$ partage la part d'historique et la part d'instantané dans le calcul des scores de groupe (Fig. 1g). Cette fonction permet à l'utilisateur de régler l'inertie des profils, d'une variabilité faible reposant sur les profils passés à une variabilité forte reposant sur les profils moyens instantanés.

Dans un système mobile, la stratégie proposée pour quantifier les scores des éléments est de deux natures. Le *score d'environnement* est construit à partir des déplacements et des pauses des utilisateurs. Le *score d'interaction* se construit à partir d'indicateurs d'intérêt recoltés lors de la manipulation du service par l'utilisateur. Ces contributions au score d'un élément méritent d'être balancées. Il est possible que l'intérêt de certains utilisateurs très peu mobiles soit plutôt révélé par leurs interactions. Dans ce cas, le score d'environnement devrait être minimisé. À l'inverse, les utilisateurs très mobiles sont enclins à moins de manipulations sur leur client et fournissent un score d'interaction de moindre importance. La fonction $\omega_{score}(\dots)$ paramètre le réglage entre ces deux sources lors de l'identification d'intérêts implicites.

Le paramétrage du calcul des scores par les utilisateurs offre à la démarche de construction de profil la plasticité suffisante pour produire des recommandations par *analyse de contenu*, par *analyse conjointe* ou par un mélange de ces approches. Par exemple, dans le cas d'une fonction de pondération $\omega_{usr}(\dots)$ répercutant le profil d'un utilisateur unique en entrée des scores moyens, la chaîne de construction de profil de groupe devient équivalente à une construction par analyse de contenu. Dans la suite, l'algorithme proposé est appliqué à la personnalisation d'un assistant de visite.

4. ASSISTANT DE VISITE DE CAMPUS

L'assistant de visite de campus propose à des étudiants de découvrir leur université avec l'aide d'un système d'information géographique pour se repérer et s'informer. Selon le scénario de déploiement, l'assistant sera accessible dans des aires de service autour des bâtiments du campus. Un utilisateur, proche d'un bâtiment particulier, se servira de l'assistant pour se documenter sur l'historique et les fonctions du bâtiment, pour connaître les salles de cours et les laboratoires hébergés, ou pour identifier sa position par rapport aux accès à ce bâtiment.

L'interface proposée est découpée en deux volets (Fig. 2). Sur la gauche, le panneau des informations géographiques détaille un plan du campus et localise l'utilisateur et les



FIG. 2: *Projet d'interface utilisateur pour l'assistant de visite*

différents bâtiments à propos desquels il peut se documenter. Sur la droite, le panneau des informations textuelles présente un ensemble de fiches d'identité des bâtiments. Ces fiches sont organisées dans une colonne d'onglets.

Constituant l'environnement des utilisateurs et représentés numériquement sur leurs clients, les bâtiments sont assimilés à la composante *element* de l'algorithme de construction de profils. Il est possible de leur associer des scores d'intérêt pour constituer des profils de préférences. D'autre part, la notion d'*aire de service* constitue une métrique d'association des utilisateurs pour la constitution des profils en groupe. Les utilisateurs au sein d'une aire de service reçoivent des informations portant sur les mêmes groupes de bâtiments et disposent des mêmes outils de manipulation de ces données. Les profils personnels qu'ils génèrent peuvent être comparés et combinés [6].

Un outil de simulation, implémenté en Java, permet de vérifier la constitution des trois niveaux de profils en imaginant des parcours d'utilisateurs et en simulant leurs interactions avec leur client. Dans la simulation illustrée en figure 3, deux utilisateurs (*Jim* et *Joe*) effectuent entre t_0 et t_5 un parcours dans l'aire de service des départements non-scientifiques. Leurs pauses et localisations sont enregistrées sur cet intervalle et sont jugées révélatrices d'un intérêt pour les départements proches (Fig. 3a). Similairement, les

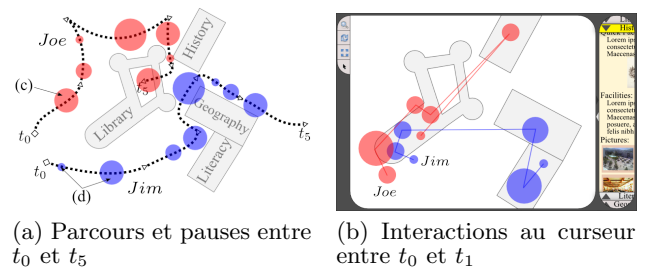


FIG. 3: *Simulation des indicateurs implicites d'intérêt*

interactions de ces utilisateurs sont simulées pour chacune des sessions d'utilisation, lors de leurs pauses (Fig. 3b). Par exemple, entre t_0 et t_1 , les sélections, les arrêts et les parcours du curseur lors des pauses de *Jim* et *Joe* (Fig 3c,d) révèlent l'intérêt de *Joe* pour la bibliothèque ("Library").

Les scores des différents bâtiments de l'environnement sont quantifiés à partir des indicateurs implicites et sont combinés pour former les profils personnels des utilisateurs (Tab. 1).

TAB. 1: Profils personnels à l'instant t_1 classés par rang d'intérêt (1^{er}, 2^{ème}, 3^{ème} et 4^{ème})

	Library	History	Literacy	Geography
Jim	28.9%	10.7%	32.3%	28.1%
Joe	43.3%	31.5%	12.3%	12.8%

Par exemple, le profil de *Jim*, calculé à t_1 , quantifie un point d'intérêt à propos du département "Literacy" alors que le département "History" semble moins mobilisateur d'attention (Tab. 1 - 1^{ère} ligne).

Construits à partir des profils personnels, les profils moyens instantanés et les profils de groupe représentent un consensus entre les utilisateurs d'une même aire de service. Dans l'interface de simulation, les concepteurs et/ou les futurs utilisateurs peuvent régler les leviers d'adaptation de l'algorithme en surchargeant les fonctions de pondération. Après chaque réglage, les profils sont re-générés et des indicateurs statistiques sont retournés. Ils permettent de contrôler la variabilité des profils et l'adéquation entre les profils personnels et les profils communs.

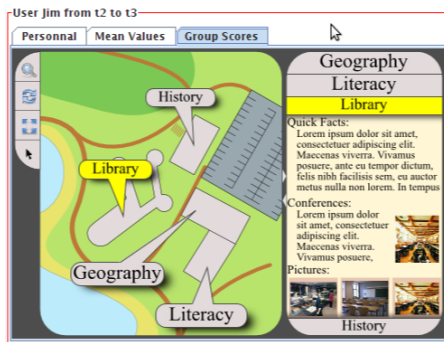


FIG. 4: Explorateur d'interfaces adaptées selon les profils

En sortie de la chaîne de simulation, les profils *personnels*, *moyens* ou *de groupe* permettent différentes adaptations de la présentation des éléments (Fig. 4). Dans les interfaces générées, la taille des labels de la carte ou de la liste est directement indexée sur les scores des éléments. L'ordre des fiches de renseignements dans le panel d'information est donné par le rang des scores d'éléments.

5. CONCLUSION

Le modèle de personnalisation détaillé dans cet article propose de construire différents "styles" de profils pour adapter le contenu informationnel d'un système mobile. En paramétrant l'algorithme de génération à la volée, les utilisateurs accordent le contenu des profils selon leurs intentions. Par la responsabilisation des utilisateurs, les concepteurs contournent les problèmes d'inertie de contenu ou de recommandations stéréotypées. L'algorithme de construction mis en oeuvre s'exécute pour l'instant en environnement simulé, contrôlé par les concepteurs. Avant de déployer un prototype distribué, l'observabilité des réglages devra être améliorée et testée auprès des futurs usagers du système. D'autre part, les indicateurs d'intérêt implicites devront être validés et éventuellement complétés par d'autres sources de mesures.

6. REFERENCES

- [1] M. Balabanović and Y. Shoham. Fab: content-based, collaborative recommendation. *Communications of the ACM*, 40(3):66–72, 1997.
- [2] M. Banâtre, C. Bryce, P. Couderc, and F. Weis. *Informatique diffuse: des concepts à la réalité*, chapter Emergence de l'informatique diffuse, pages 35–48. Hermes-Lavoisier, 2007.
- [3] R. Burke. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4):331–370, 2002.
- [4] D. Kelly and J. Teevan. Implicit feedback for inferring user preference: a bibliography. *SIGIR Forum*, 37(2):18–28, 2003.
- [5] W. Lam, S. Mukhopadhyay, J. Mostafa, and M. Palakal. Detection of shifts in user interests for personalized information filtering. In *SIGIR'96: Proc. of the 19th Int. Conference on Research and development in information retrieval*, pages 317–325. ACM, Aug. 1996.
- [6] E. Mac Aoidh, G. McArdle, M. Petit, C. Ray, M. Bertolotto, C. Claramunt, and D. Wilson. Personalization in adaptive and interactive gis. *Annals of GIS*, 11(1):23–33, June 2009.
- [7] L. Montaner, B. López, and J. De la Rosa. A taxonomy of recommender agents on the internet. *Artificial Intelligence Review*, 19(4):285–330, Oct. 2003.
- [8] R. Mooney and L. Roy. Content-based book recommending using learning for text categorization. In *DL'00: Proc. of the 5th ACM conference on Digital libraries*, pages 195–204. ACM, June 2000.
- [9] M. Pazzani. A framework for collaborative, content-based and demographic filtering. *Artificial Intelligence Review*, 13(5):393–408, 1999.
- [10] M. Petit. *A spatial approach to execution-context modeling in ubiquitous information systems*, chapter Systèmes d'information sensibles au contexte, pages 35–71. Ensam-ParisTech, June 2010. submitted.
- [11] E. Rich. Users are individuals: individualizing user models. *Int. journal of man-machine studies*, 18(3):199–214, 1983.
- [12] A. Schein, A. Popescul, and L. Ungar. Methods and metrics for cold-start recommendations. In *SIGIR'02: Proc. of the 25th Int. Conference on Research and development in information retrieval*, pages 253–260. ACM, Aug. 2002.
- [13] J.-S. Sottet, G. Calvary, J.-M. Favre, and J. Coutaz. *Human-Centered Software Engineering*, chapter Megamodeling and Metamodel-Driven Engineering for Plastic User Interfaces: MEGA-UI, pages 173–200. Springer, June 2009.
- [14] D. Thévenin. From the workstation to the mobile phone: multi-target interface design. In *IHM'2003: Proc. of the 15th French-speaking conference on human-computer interaction*, pages 166–173. ACM, Nov. 2003.
- [15] T. Tran and R. Cohen. Hybrid recommender systems for electronic commerce. In *Proc. from the AAAI Workshop on Knowledge-Based Electronic Markets*, volume 4 of *IAAA Technical Reports*, pages 78–83. IAAA Press, 2000.