



## **Poursuite de cibles dans l'espace de recommandation - vers un nouveau système de recommandation basé sur le filtrage de Kalman**

Cédric Bernier, Samuel Nowakowski, Anne Boyer

### **► To cite this version:**

Cédric Bernier, Samuel Nowakowski, Anne Boyer. Poursuite de cibles dans l'espace de recommandation - vers un nouveau système de recommandation basé sur le filtrage de Kalman. Conférence en Recherche d'Information et Applications - CORIA 2011, Mar 2011, Avignon, France. pp 57-65. <hal-00579799>

**HAL Id: hal-00579799**

**<https://hal.science/hal-00579799v1>**

Submitted on 28 Mar 2011

**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.



HAL Authorization

---

# Poursuite de cibles dans l'espace de recommandation - vers un nouveau système de recommandation basé sur le filtrage de Kalman

Cédric Bernier <sup>\* \*\*</sup>, Samuel Nowakowski <sup>\*</sup>, Anne Boyer <sup>\*</sup>

<sup>\*</sup> LORIA-KIWI

Campus scientifique – BP239

F-54506 Vandœuvre-lès-Nancy Cedex

<sup>\*\*</sup> Alcatel-Lucent Bell Labs France

Route de Villarceaux

F-91600 Nozay

[cedric.bernier@loria.fr](mailto:cedric.bernier@loria.fr), [samuel.nowakowski@loria.fr](mailto:samuel.nowakowski@loria.fr), [anne.boyer@loria.fr](mailto:anne.boyer@loria.fr)

---

**RÉSUMÉ.** Dans cet article, nous proposons une nouvelle approche de système de recommandation basée sur la poursuite de cible à l'aide des filtres de Kalman. Nous supposons que les utilisateurs et leurs consommations de télévision (films, séries, émissions, etc.) sont représentés par des vecteurs dans l'espace multidimensionnel des genres des contenus (action, aventure, divertissement, etc.). Connaissant cet espace, nous proposons un algorithme basé sur les filtres de Kalman pour poursuivre le profil de l'utilisateur et prédire ses positions futures dans l'espace multidimensionnel des genres. A partir de cette prédiction, nous construisons une nouvelle stratégie de recommandation de contenus.

**ABSTRACT.** In this paper, we propose a new approach for recommender systems based on target tracking by Kalman filtering. We assume that users and their consumptions of television programs are vectors in the multidimensional space of the categories of the resources. Knowing this space, we propose an algorithm based on a Kalman filter to track the user's profile and to foresee the best prediction of their future position in the recommendation space. From this prediction, we build a recommendation of contents.

**MOTS-CLÉS :** système de recommandation, profil utilisateur, profil de groupe, filtre de Kalman, poursuite de cible.

**KEYWORDS:** recommender system, user profile, group profile, Kalman filter, target tracking.

---

## 1. Introduction

Dans cet article, nous proposons une nouvelle approche de système de recommandation basée sur la poursuite de cible à l'aide des filtres de Kalman. Nous nous plaçons dans un espace multidimensionnel dans lequel chaque dimension représente un genre de film. Chaque ressource est représentée par un vecteur la caractérisant, c'est-à-dire qu'à chaque dimension est associée une valeur (0 ou 1) correspondant à la présence ou non du genre dans la ressource. Chaque utilisateur est représenté par son profil qui est lui aussi un vecteur dans l'espace multidimensionnel des genres. La valeur de chaque genre (donc de chaque dimension) est comprise entre 0 et 1 et est proportionnelle à l'intérêt que l'utilisateur porte aux contenus contenant ce genre. Régulièrement, le profil utilisateur est mis à jour, il évolue donc dans l'espace des genres. Comme le profil utilisateur évolue dans cet espace, il suit alors une trajectoire et nous pouvons donc utiliser un modèle de poursuite afin d'anticiper ses prochains déplacements. Nous proposons d'utiliser les filtres de Kalman et plus particulièrement la poursuite de cible pour prédire le déplacement du profil utilisateur.

Dans cet article, nous aborderons les principes de cette nouvelles méthodes et nous détaillerons la formulation des filtres de Kalman et leur utilisation. Nous poursuivrons par le détail de nos expérimentations que nous commenterons. Nous expliquerons alors comment utiliser cette prédiction pour construire une recommandation de contenus.

## 2. Les filtres de Kalman

Le filtre de Kalman est un estimateur optimal de l'état d'un système linéaire. Il permet de donner une estimation de l'état du système à partir d'une information *a priori* sur l'évolution de cet état (modèle) et de mesures réelles (Gevers *et al*, 2010).

### 2.1. Formulation générale du filtre.

On supposera que le système peut être représenté par un modèle d'état Gaussien Markovien de la forme suivante (Söderström, 1994) :

$$\begin{cases} X_{k+1} = AX_k + Bu_k + Gw_k & [1.a] \\ Z_k = HX_k + v_k & [1.b] \end{cases}$$

Où

$X_k \in \mathbb{R}^n$  est l'état du système

$Z_k \in \mathbb{R}^p$  est le vecteur des mesures effectuées sur le système

$u_k \in \mathbb{R}^m$  est l'entrée appliquée au système

$v_k \in \mathbb{R}^p$  et  $w_k \in \mathbb{R}^q$  sont des bruits blancs Gaussiens mutuellement indépendants.

où  $w_k$  est considéré comme un bruit agissant sur le processus, tandis que  $v_k$  est un bruit de mesure. Les matrices A, B, G, H sont supposées constantes.

Sur la base de cette représentation, nous obtenons les équations générales du filtre que nous détaillerons dans la partie suivante en les appliquant au cas étudié dans cet article.

## 2.2. La poursuite de cible dans le cyberspace

L'hypothèse que nous faisons est la suivante : l'utilisateur est une cible qui se déplace sur une trajectoire non connue a priori dans l'espace. L'objectif est alors de mettre en œuvre un filtre de Kalman pour poursuivre l'utilisateur-cible sur sa trajectoire et prédire sa position à des instants futurs. L'espace ainsi considéré est défini par n dimensions représentant les différentes catégories et les différents genres décrivant les ressources consultées. Cet espace que nous appellerons espace de recommandation, possède autant de dimensions que de genres.

## 2.2. La Formulation des filtres de Kalman

Comme nous nous mettons dans l'hypothèse de poursuivre un utilisateur-cible sur sa trajectoire dans l'espace de recommandation, nous allons définir l'état et adapter le modèle [1] en conséquence. Comment définit-on donc l'état d'une cible mouvante ?

Par sa position, sa vitesse et son accélération.

Nous allons donc exprimer le vecteur d'état de l'utilisateur-cible de la façon suivante :

$$X_k = \begin{bmatrix} x \\ \dot{x} \\ \ddot{x} \end{bmatrix}_k \in \mathbb{R}^{132}$$

Où :

$x \in \mathbb{R}^{44}$  est le vecteur contenant les coordonnées de la position dans l'espace de recommandation,

$\dot{x} \in \mathbb{R}^{44}$  est le vecteur contenant les informations de la vitesse,

$\ddot{x} \in \mathbb{R}^{44}$  est le vecteur contenant les informations de l'accélération.

Ce vecteur d'état permet d'obtenir l'ensemble des informations nécessaires à la description de la trajectoire de l'utilisateur-cible dans l'espace de recommandation. Connaissant ce vecteur, nous allons modifier le modèle [1] de la façon suivante :

C. Bernier, S. Nowakowski, A. Boyer

- le vecteur de mesure  $Z_k$  ne contiendra que la position de l'utilisateur-cible
- le système ne dispose pas de commande ; la matrice B est donc nulle.

Nous obtenons le modèle suivant :

$$\begin{cases} X_{k+1} = AX_k + w_k & [2.a] \\ Z_k = HX_k + v_k & [2.b] \end{cases}$$

Où la matrice A décrit la relation existant entre la position, la vitesse et l'accélération d'un mobile dans l'espace. Elle s'écrit dans de la façon suivante :

$$A = \begin{bmatrix} \alpha & T & \frac{1}{2}T^2 \\ 0 & \alpha & T \\ 0 & 0 & \alpha \end{bmatrix} \quad [3]$$

T peut être vue comme la moyenne des intervalles de temps entre deux positions dans l'espace. T vient de l'équation qui lie les positions à la vitesse et à l'accélération. Dans le cas qui nous intéresse, le temps n'étant pas défini par une horloge extérieure mais comme la suite des instants d'observation de la position de l'utilisateur-cible dans l'espace de recommandation, nous pouvons poser  $T = 1$ . Enfin, concernant les bruits de mesure et de processus, nous faisons les hypothèses suivantes :

- $w_k$  un vecteur aléatoire gaussien qui prend en compte des comportements non modélisés des utilisateurs cibles avec  $w_k \approx N(0, Q)$
- $v_k$  un vecteur aléatoire gaussien qui prend en compte les perturbations qui peuvent survenir sur les mesures,  $v_k \approx N(0, R)$

En conséquence des hypothèses faites ci-dessus, la matrice de mesure H aura la forme suivante :

$$\begin{array}{c} \text{3 * 44 columns} \\ \longleftrightarrow \longleftrightarrow \longleftrightarrow \\ \begin{array}{c} \updownarrow \\ \text{44 rows} \end{array} \begin{bmatrix} 1 & 0 & 00 & \dots & 00 & \dots & 0 \\ 0 & \dots & 0\dots & \dots & 00 & \dots & 0 \\ 0 & 0 & 10 & \dots & 00 & \dots & 0 \end{bmatrix} \end{array}$$

Nous pouvons détailler les équations du filtre de Kalman (pour plus de détails, voir également (Gevers *et al*, 2010)) :

La prédiction à l'instant k+1 connaissant k est donnée par :

$$\begin{cases} \hat{X}_{k+1/k} = \hat{X}_{k/k-1} + K_k (Z_k - H\hat{X}_{k/k-1}) \\ \quad = (A - K_k C)\hat{X}_{k/k-1} + K_k Z_k \end{cases} \quad [4]$$

Le gain du filtre est calculé de la façon suivante :

$$K_k = AP_{k/k-1}H^T(HP_{k/k-1}H^T + R)^{-1} \quad [5]$$

L'évolution de l'incertitude sur l'estimation de l'état est donnée par la relation suivante :

$$P_{k+1/k} = AP_{k/k-1}A^T - AP_{k/k-1}H^T(HP_{k/k-1}H^T + R)^{-1}HP_{k/k-1}A^T \quad [6]$$

### 3. Application

#### 3.1. Description de la base de données

Notre corpus de test est composé de données de consommation de télévision qui ont été récupérées de la base de données BARB (BARB). Ces données ont été enregistrées du 1<sup>er</sup> septembre 2008 au 28 février 2009. Elles ont été construites minute par minute par un ensemble d'utilisateurs représentatifs de l'audience de Grande-Bretagne. BARB contient trois types de données :

- des informations sur les utilisateurs (des données démographiques, etc.) et les foyers (composition du foyer, nombre de téléviseurs, etc.),
- les programmes regardés par les utilisateurs,
- la description des programmes de télévision (titre, genre(s), année, etc.) : à partir de la liste de ces genres (par exemple, « Talk Show », « Action » et « Adventure »), chaque programme est représenté par un vecteur de genres : les genres associés au programme prennent la valeur 1, les autres 0. Le corpus des consommations comporte 44 genres différents.

Le 1<sup>er</sup> septembre 2008, le panel BARB était composé de 14 731 utilisateurs formant 6 423 foyers. Sur une période de six mois, les utilisateurs ont généré environ 30 millions de logs. Un log contient la liste des utilisateurs regardant un programme sur le même téléviseur. La session se termine dès que le groupe d'utilisateurs regardant la télévision change et/ou que la chaîne change.

Nous avons adapté ces données à notre expérience en prenant en compte le fait que nous avons besoin d'une estimation de l'intérêt de l'utilisateur pour chaque genre de programme regardé. Nous allons ainsi commencer par construire leur profil (Aghasaryan *et al*, 2008) (Senot *et al*, 2010). Puis les logs regroupant les mêmes utilisateurs pour les mêmes programmes ont été agrégés pour former un nouveau log. Ensuite, pour supprimer du bruit dans le corpus, les logs ont été filtrés en fonction de leur durée.

Ainsi, nous calculons une estimation de l'intérêt porté par chaque utilisateur pour chaque programme regardé en fonction de la façon dont ces programmes ont été regardés. La mise à jour du profil utilisateur est effectuée tous les jours.

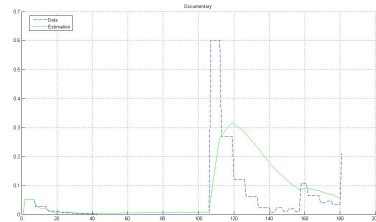
### 3.2. Description de l'expérimentation

Notre expérimentation se base sur les profils des utilisateurs. A partir du profil utilisateur, nous appliquons le filtre de Kalman. Dans un premier temps, nous initialisons le profil utilisateur avec le profil observé après le premier jour de consommation de télévision. A partir de là, nous calculons une prédiction du profil pour le deuxième jour et calculons aussi le profil. Cette opération est répétée pour les six mois de données du corpus (180 itérations).

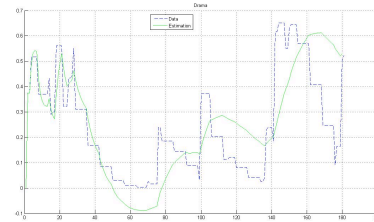
### 3.3. Résultat de l'expérimentation

Les résultats obtenus peuvent être analysés de la manière suivante : le filtre de Kalman prédit l'intérêt d'un utilisateur spécifique pour un genre connaissant son passé.

Dans les figures suivantes, nous pouvons voir l'estimation / la prédiction fournie par le filtre de Kalman pour quatre genres spécifiques. Les courbes pointillées montrent l'évolution des valeurs réelles. Les courbes continues montrent la prédiction obtenue à chaque instant.

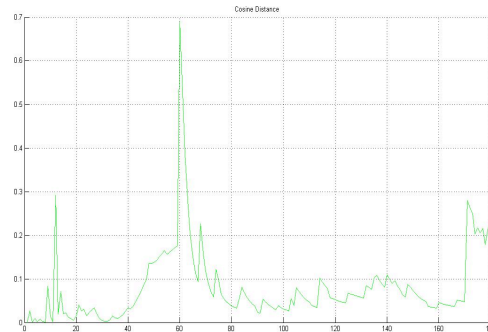


**Figure 1.** Valeurs réelles et prédictions du genre "Documentary"



**Figure 2.** Valeurs réelles et prédictions du genre "Drama"

Les Figures 1 et 2 montrent que les prédictions sont cohérentes avec les valeurs réelles. La Figure 3 montre la distance « cosinus » calculée entre les valeurs réelles et les prédictions. La plupart des estimations sont correctes, avec une distance inférieure à 0,10. Le pic au temps 60 correspond à un changement brusque du type de consommation du téléspectateur.

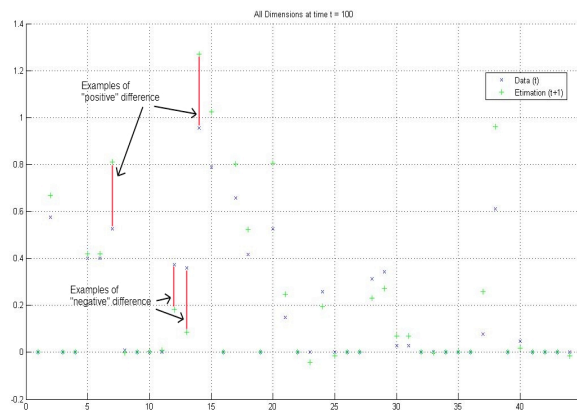


**Figure 3.** Distance entre les valeurs réelles et la prédiction

#### 4. La recommandation

A partir du profil utilisateur représenté dans l'espace multidimensionnel des genres, le filtre de Kalman calcule une nouvelle position du profil dans l'espace. Une fois la prédiction calculée, nous connaissons alors les genres qui devraient évoluer. Le profil utilisateur étant mis à jour tous les jours, la prédiction prend en compte toutes les ressources qui seront consommées dans cette journée. Les genres qui vont diminuer (notés « negative difference » dans la Figure 4) nous indiquent ce qui n'intéressera pas l'utilisateur pour la période suivante. Parallèlement, les genres qui vont augmenter (notés « positive difference » dans la Figure 4) nous indiquent ce qui intéressera l'utilisateur. Le système de recommandation évitera donc les genres « négatifs » et se concentrera sur les genres « positifs ». Les genres avec peu de différence ne sont pas pris en compte. Ensuite, une étude du programme de télévision nous permet de sélectionner les ressources qui semblent les plus pertinentes.

De plus, au fur et à mesure de la journée et donc des consommations de ressources par l'utilisateur, le système de recommandation s'affinera car certains genres seront déjà consommés. Par exemple, un utilisateur dont les genres « Talk Show », « Action » et « Adventure » augmentent dans la prédiction, si cet utilisateur vient de regarder un talk show, la nouvelle recommandation devra surtout prendre en compte les deux autres genres, « Action » et « Adventure ».



**Figure 4.** Analyse de l'évolution d'une prédiction pour construire une recommandation

Contrairement aux méthodes existantes qui recommandent des ressources précises à un utilisateur donné, notre méthode prend en compte l'état d'esprit de l'utilisateur et s'appuie sur l'évolution du profil sur une période équivalente à plusieurs ressources. Notre système de recommandation travaille à un niveau macroscopique : nous cherchons avant tout le genre que l'utilisateur souhaite consommer puis cherchons les ressources adéquates.

## 5. Conclusion

Dans cet article, l'idée principale est de prendre en compte le fait que le profil utilisateur « bouge » et suit une trajectoire dans l'espace de recommandation. Cet espace de recommandation est vu comme un espace de 44 dimensions basé sur les genres décrivant les ressources. La position de la cible est mesurée par la valeur de l'intérêt pour chaque genre. Alors, connaissant les positions passées du profil utilisateur le long des différents axes de l'espace à 44 dimensions et à l'aide du filtre de Kalman, un modèle de poursuite de cible permet de prédire la prochaine position de cette cible (le profil utilisateur) dans l'espace de recommandation.

Le système de recommandation basé sur les filtres de Kalman construira la recommandation de la manière suivante : si la prédiction propose trois dimensions « positives »  $x$ ,  $y$  et  $z$  et que l'utilisateur a déjà regardé des ressources du genre  $x$  et  $y$ , alors la recommandation se concentrera essentiellement sur le genre  $z$ .

La force de notre approche est dans sa capacité de construire la recommandation à un haut niveau prenant en compte les habitudes de l'utilisateur car il suit une trajectoire globale et ne se focalise pas sur un contenu spécifiquement.

## 6. Bibliographie

- Aghasaryan A., Betgé-Brezetz S., Senot C., Toms Y., « A profiling engine for converged service delivery », *Bell Labs technical journal*, vol. 13, 2008, p. 93-103
- BARB: Broadcaster Audience Research Board, DOI=<http://www.barb.co.uk/>
- Bernier C., Brun A., Aghasaryan A., Bouzid M., Picault J., Senot C., Boyer A., « Topology of communities for the collaborative recommendations to groups », *SIIE 2010 conference*, Sousse, Tunisia, February 17 – 19, 2010
- Gevers M., Vandendorpe L., « Processus stochastiques, estimation et prédiction », DOI=<http://www.tele.ucl.ac.be/EDU/INMA2731/>
- Senot C., Kostadinov D., Bouzid M., Picault J., Aghasaryan A., Bernier C., « Analysis of strategies for building group profiles », *User Modeling, Adaptation and Personalization*, 2010
- Söderström T., « Discrete-time stochastic systems: estimation and control », *Prentice Hall International*, 1994