

マルチユーザ嗜好属性を扱うユーザエージェントのユーザ嗜好学習方式

3H-7

柴田 弘 星合 隆成
NTT 未来ねっと研究所

1. はじめに

近年の WWW をベースとした放送技術、P2P 技術の発展により、誰もが容易にコンテンツ提供者になることができる。そのため、ネットワークに存在する膨大なコンテンツの中からユーザの嗜好に合致するコンテンツを選出し、カスタマイズして提案するサービスが注目されている。

このようなユーザ嗜好に対応したコンテンツ提案サービスとして、ユーザ嗜好に適応したカスタマイズが可能なインターネットラジオ[1]やマルチシナリオコンテンツ放送[2]等が実現されている。しかし、これらのサービスでは、ユーザとのインタラクションを行い、ユーザから入力された好み情報や選択内容を元にユーザに提供するコンテンツを決定していくため、コンテンツ鑑賞時にさまざまなデータ入力やメニュー選択をユーザが行わなければならないという問題がある。そこで、本報告では、ユーザ嗜好を学習するエージェントを用いて、ユーザの嗜好に応じた番組をユーザからの選択や入力操作なしで構築する、プログラマブルムービーサービスシステムを提案する。

2. システムアーキテクチャ

プログラマブルムービー(PM)および当該サービスを実現するシステム構成について説明する。PM とは、エンドユーザの興味、状況、環境等のマルチプルな属性(以後これらをユーザ嗜好属性と呼ぶ)を総合的に判断し、利用可能なビデオクリップのうち、現在鑑賞中のビデオクリップに関連が深く、エンドユーザに提供するに相応しいものを自動的につなぎ合わせて、1つの番組として提供される映像である。以後、PM の材料となる1つ1つのビデオクリップをコンテンツと呼ぶ。

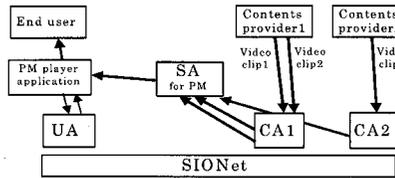


図 1 Programmable movie service system architecture.

図 1 に、本サービスを実現するシステム構成を示す。本システムは、コンテンツを提供するコンテンツプロバイダ(CP)、コンテンツを消費するエンドユーザ、CP の代理人として、CP が設定したコンテンツ属性すなわちコンテンツに登場する俳優名や映像シーンのタイプ(“ホラーシーン”、“コメディシーン”等)、R 指定等の条件、再生時間等を管理するコンテンツエージェント(CA)、エンドユーザの代理人として、エンドユーザのマルチプルなユーザ嗜好属性(俳優の好み、シーンの好み、時間の都合、使用端末、プロフィール等)を管理し、当該エンドユーザに相応しいコンテンツを特定するユーザエージェント(UA)、コンテンツに他のコンテンツ(前記コンテンツに続くコンテンツ等)をリンクさせ PM を作成しユーザに提供するサービスエージェント(SA)、エンドユーザの端末においてコンテンツを表示し、前記コンテンツ再生が終了するとともに続きのコンテンツに表示を切り替える PM 再生アプリケーションから成る。これらのコンポーネン

A learning method for personalized agents handling multiple user-preference attributes
Hiroshi Shibata and Takashige Hoshiai
NTT Network Innovation Laboratories

トは、不特定多数のコンポーネントの中から通信するに相応しい相手を選定可能な意味情報ネットワーク SIONet[3][4]上で動作することにより、各々が P2P でインタラクションを行うことが可能となる。

3. マルチエージェント

SA による PM 作成方法について述べる。PM を作成することとは、エンドユーザが鑑賞するコンテンツに、続きのコンテンツの参照先情報 (URI や CA のオブジェクトリファレンス等) をリンク情報として付与することである。SA はこの過程において、エンドユーザが鑑賞中のコンテンツのコンテンツキーワード (CK) を CA に対して要求する。このとき、CA はコンテンツ属性を CK に変換して提供する。CK とは、表 1 のような内容の元のコンテンツ属性を UA, CA, SA が共通に把握できるデータ形式に変換したものである。SA は取得した CK に合致するコンテンツを SIONet を用いて検出し、検出したコンテンツの参照先および CK をリンク情報とする。

表 1 Contents attributes

コンテンツ属性		
属性(大項目)	小項目	
Actor	Jennifer	70
	Rachel	50

Scene	Horror	80
	Comedy	30

Time	5 min.	/
...

次に UA による PM 再生支援方法について述べる。PM では、エンドユーザが鑑賞中のコンテンツに続いて鑑賞するに相応しいコンテンツを、リンクされたコンテンツ群の中から1つに絞り込む必要がある。もし、エンドユーザからのインタラクションがなければ、最も合致するものを UA が自動的に選択しなければならない。ところが、リンクされたコンテンツ群のうち、あるコンテンツはエンドユーザの俳優好みとの合致度が高く、別のコンテンツはエンドユーザのシーンタイプ好みとの合致度が高い等の状況では、どちらのコンテンツを選択すれば良いのか判断するのが困難となる。このような場合、マルチプルなユーザ嗜好属性が、それぞれどの程度重要であるかという情報が必要である。すなわち、ユーザ嗜好属性とコンテンツ属性の合致度を定量的に表現するための、ユーザ嗜好の各属性への重み付けが必要となる。従って UA は、表 2 のように属性内の小項目の重み値だけでなく属性毎の重要度を表す重み値を用いて、各リンクコンテンツの CK との合致度得点を計算することが要求される。

表 2 User-preference attributes

ユーザ嗜好属性			
属性(大項目)	小項目		
Actor	63	Jennifer	81
		Jacky	36
	
Scene	22	Horror	74
		Action	48
	
Time limit	34	60 min.	/
...

4. 学習アルゴリズム

前節で UA, CA, SA の機能および UA が管理するユーザ嗜好属性について述べた。UA がマルチプルなユーザ嗜好属性

を扱い、個々の属性に対する重み値を設定することが必要である。このような重み値をエンドユーザに入力させるのではなく、UA がエンドユーザの行動等から学習する。本節では UA の属性に対する重み値および小項目の重み値の学習方法について述べる。

4.1 大項目の重み値学習方法

重み値を学習する方法として教師あり学習と教師なし学習に大別される。前者の学習方法は、正しい出力情報(すなわち適切な重み値)を与えて学習させる方法であり、UA の属性(大項目)に対する重み値学習方法には適さない。一方、後者の学習方法は、学習の指針が全く与えられないため、この方法も適さない。そこで、筆者らは属性に対する重み値学習には、両学習方法の中間にあたる強化学習[5]を用いる。強化学習方式とは、ある問題に対して UA が成功あるいは失敗したという経験により試行錯誤しながら適切な行動を学習していく方法であり、筆者らは次のような観点から以下の計算式で表される重み値学習アルゴリズムを考案した。

- ・ 学習が進むに従って、ある値付近に重み値が収束するが、エンドユーザの価値観が変わる等、失敗する場合が多くなると、重み値を発散させ再学習を行い、他の値へ収束させる。
- ・ 各属性(俳優好みやシエンタイプ好み等、ユーザ嗜好属性の1つ1つの項目)の重み値を、独立に学習する。

ユーザ嗜好属性 k (俳優好みやシエンタイプ好み等)の重み値を W_k , ($k=1,2,\dots$)と表し、重み値の範囲は $0 < W_k < 100$ とする。

学習回数を n 、エンドユーザおよびクライアントアプリケーション等の UA 使用時間(経過時間)を t 、試行錯誤において、重み値を変化させる際の単位時間当たりの変化量を ω_k とし、 W_k を以下のような関数で表される計算式で与える。

$$W_k(t, X_{kn}, Y_{kn}) = 50\{1 + \sin X_{kn} \sin Y_{kn} + (1 - \sin X_{kn}) \sin \omega_k t\} \quad (1)$$

ここで、 X_{kn} および Y_{kn} は次式のように学習が進むにつれて値が変動する。

$$X_{kn} = X_{k,n-1} + V_n \{1 - (1 - \sin X_{k,n-1}) |\sin T_{kn} - \sin Y_{k,n-1}|\} \quad (2)$$

$$Y_{kn} = Y_{k,n-1} + V_n (1 - \sin X_{k,n-1}) (T_{kn} - Y_{k,n-1}) \quad (3)$$

上式において、 V_n は、エンドユーザの挙動から抽出される評価値であり、表 3 のような対応関係とする。

表 3 Evaluation based on end user's action

エンドユーザの挙動	評価値 (V)
鑑賞中のコンテンツを巻き戻して再鑑賞	0.5
鑑賞中のコンテンツを最後まで見終える	0.1
鑑賞中のコンテンツを早送りまたはスキップして次のコンテンツへジャンプ	-0.5

また、 T_{kn} は前記エンドユーザの挙動の要因となったコンテンツを特定したときの t の値である t_n から、以下のように算出する。

$$T_{kn} = \sin^{-1} \omega_k t_n \quad (4)$$

上記評価をフィードバックすることにより、重み値 W_k を算出する関数のパラメータ X_{kn} および Y_{kn} が更新される。ただし、それぞれ $0 < X_{kn} < \frac{\pi}{2}$, $-\frac{\pi}{2} < Y_{kn} < \frac{\pi}{2}$ とする。値域を越えた場合は以下のように修正する。

$$\begin{aligned} X_{kn} < 0 &\Rightarrow X_{kn} = 0, & X_{kn} > \frac{\pi}{2} &\Rightarrow X_{kn} = \frac{\pi}{2}, \\ Y_{kn} < -\frac{\pi}{2} &\Rightarrow Y_{kn} = -\frac{\pi}{2}, & Y_{kn} > \frac{\pi}{2} &\Rightarrow Y_{kn} = \frac{\pi}{2} \end{aligned} \quad (5)$$

4.2 小項目の重み値学習方法

次に小項目(属性のさらに詳細な項目)毎の重み値の学習方法を示す。小項目の例として、俳優好み属性の小項目

を挙げると“ジェニファー”、“ジャッキー”、“レイチェル”等のように区別され、それぞれの好み度を示す重み値が必要である。この項目は、あらかじめ決めておくことが困難であるため、この重み値の学習方法として、正しい出力を与える方法や試行錯誤しながら決定する方法は適さない。したがってエンドユーザの PM 鑑賞履歴等から、各項目の重み値を自己組織化させる方法すなわち教師なし学習方法が適している。そこで、次のような観点から以下の式で重み値を決定することにした。

- ・ エンドユーザの挙動から抽出される評価値を反映する。
- ・ エンドユーザの最近の興味(新しい履歴)を重視する。
- ・ 履歴情報の増加により、エンドユーザの嗜好解析処理負荷が増加するなどの問題を生じない。

以下の式では、ユーザの俳優好み属性の小項目“Actor- m ”に関する重み値を $Au_n(\text{Actor}-m)$ 、鑑賞したコンテンツに付与された CK における“Actor- m ”の重み値を $Ac(\text{Actor}-m)$ とし、 n および V_n は前節と同様とする。小項目重み値は、エンドユーザが表 1 のようなアクションを起こした時に更新する。

$$Au_n(\text{Actor}-m) = Au_{n-1}(\text{Actor}-m) + \mu Ac(\text{Actor}-m) V_n \quad (6)$$

ここで μ は、過去の履歴と現在のエンドユーザの嗜好との重要度の比を示し、エンドユーザがしばらく PM を利用していなかった場合には、 μ を大きくして過去の履歴を更改していく。PM を頻繁に利用している場合は、 μ を小さくして過去の履歴のウェイトを大きくする。エンドユーザの最近一ヶ月間の PM 鑑賞回数を γ 回として μ を以下の式で与える。

$$\mu = 1/(\gamma + 1) \quad (7)$$

また、重み値の範囲を $0 < Au_n(\text{Actor}-m) < 100$ とし、最大値を越えた場合以下のように超過分 $\Delta Au_n(\text{Actor}-m)$ を算出する。

$$\begin{aligned} Au_n(\text{Actor}-m) &> 100 \\ &\Rightarrow \Delta Au_n(\text{Actor}-m) = Au_n(\text{Actor}-m) - 100 \end{aligned} \quad (8)$$

この超過分を、各俳優に対する重み値毎に算出し、その最大値 ΔA_n 分だけ、全俳優に対する重み値から減算する。

$$\Delta A_n = \max\{\Delta Au_n(\text{Actor}-m); \forall \text{Actor}-m\} \quad (9)$$

$$Au_n(\text{Actor}-m) \leftarrow Au_n(\text{Actor}-m) - \Delta A_n \quad (10)$$

なお、重み値が最小値を下回った場合は 0 とする。

$$Au_n(\text{Actor}-m) < 0 \Rightarrow Au_n(\text{Actor}-m) = 0 \quad (11)$$

以上の計算式を使用した学習方式により、エンドユーザが自身のユーザ嗜好属性のさまざまな重み値等を意識しなくても、エンドユーザの PM 鑑賞や鑑賞時の挙動から、それらの値が UA によって自動的に学習され設定される。

5. まとめ

本報告では、エンドユーザの嗜好に従って自動的にビデオクリップ等のコンテンツを組み合わせた番組を提供するプログラムブルービーサービスの実現システムについて述べ、本システムを実現する上で重要な UA のユーザ嗜好学習方法を提案した。本提案方式により、UA はマルチプルなユーザ嗜好属性を扱い、エンドユーザがこのような属性を意識しなくても、UA がそれらを学習して設定可能となる。今後はシミュレーションや実験により、本提案方式の妥当性を検証していく予定である。

参考文献

- [1] <http://www.riaa.com/>
- [2] <http://www.mpt.go.jp/policyreports/japanese/group/housou/>
- [3] 星合, 小柳, スクパターナル, 久保田, 柴田, 酒井: 意味情報ネットワークアーキテクチャ, IEICE vol. J84-B No.3 pp.411-424, 2001.
- [4] <http://www.onlab.ntt.co.jp/jp/ni/preference/index.html>
- [5] R. S. Sutton and A. G. Barto: Reinforcement Learning - An Introduction, MIT Press, 1998.