

ウェブニュース提供のための
ベイジアンネットワークと格フレームを用いたユーザの興味構造表現
User's Interest Structure Represented by a Bayesian Network and a Case Frame for Web News Providing

東原 智幸† 三吉 達夫† 市川 伸明‡ 渥美 雅保†
Tomoyuki Higashihara Tatsuo Miyoshi Nobuaki Ichikawa Masayasu Atsumi

1. まえがき

個人の興味にあった情報サービスを提供するシステムにおいては、その興味構造をいかに表現・利用・獲得するかが重要である。ユーザの興味や状態を表すユーザモデルを導入したシステムや手法についての研究が盛んに行われている。例えば、ダイナミックベイジアンネットワークにより記述されたユーザモデルを用いてユーザの要求を推論し、対話の制御を行う方法[1]や、決定木によりユーザのシステムへの習熟度、知識レベル、性急度を分類するユーザモデルを導入し、適応的な対話制御・応答生成を行うシステム[2]などが提案されている。また、記事の印象によって提供する音声を変更するニュース提供システム[3]や、ユーザの興味に適合可能な検索方法[4]についても研究されている。

本論では、個人の興味を反映したウェブニュース音声提供システム構築のため、ベイジアンネットワーク[6]と格フレームを用いた興味構造表現を提案する。そしてウェブから収集したニュースを用いた実験により、本興味構造の性能について評価する。

2. 興味構造の表現

ユーザの興味構造は、過去ユーザが興味を示した情報を格フレームを用いて記述した興味記述とそれに対するユーザの感性的興味の種類、応答により記述される。この記述を興味プロフィールと呼ぶ。ユーザの興味プロフィールの集合は、ベイジアンネットワークに変換され興味の推論に用いられる。このベイジアンネットワークを興味推論モデルと呼ぶ。推論された興味記述は、本論で提案するウェブニュース選択手法により類似度の高い新着ウェブニュースの選択に利用される。

2.1 興味プロフィール

興味プロフィール(表 1)は、ユーザにウェブニュースを提供したときに得られた応答、感性的興味(“喜”, “怒”, “悲”, “驚”, “その他”, “興味無し”の 6 種類), 興味記述, 日時とユーザ ID で構成される。

表 1 興味プロフィール構成

項目	説明
ユーザ ID	ウェブニュースを提供されたユーザの ID
興味記述	ウェブニュースのユーザが興味を持った部分を格構造で記述したデータ
応答	ウェブニュース提供後に取得した応答語を記述
感性的興味	ウェブニュース提供後に得られた感性的興味の種類を記述
日時	ウェブニュースが提供された日付, 時間を記述

†創価大学大学院工学研究科情報システム工学専攻
‡創価大学工学部情報システム学科

表 2 興味記述で使用する格の種類

格	格の意味
main	主体の動作
agent	動作の主体
object	動作・変化の影響を受ける対象
place	事象の成立する場所
scene	事象の成立する場面

興味記述は、表 2 の 5 種類の格を用いて表現される。例えば、文章“WHO は、スモーカーを雇用しない”に興味がある場合に、興味記述 I は、 $I = \{(\text{"main"}, \text{"雇用しない"}), (\text{"agent"}, \text{"WHO"}), (\text{"object"}, \text{"スモーカー"})\}$ と表現される。

一般的には、格を c_i 、その格の要素(単語または複合語)を w_i とするとき、 M 個の格を持つ興味記述 I は

$$I = \{(c_1, w_1^1) \dots (c_M, w_M^M)\} \quad (1)$$

と表現される。

2.2 興味推論モデル

興味推論モデル(図 1)は、ユーザ毎の興味プロフィール集合をベイジアンネットワークで表現したモデルであり、興味記述、時間帯による外部誘引がユーザの感性的興味に影響を与え、さらにその感性的興味がユーザの応答に影響を与える関係を記述したモデルである。この興味推論モデルを利用し、ユーザ応答からの感性的興味の種類の推論、感性的興味の種類からの興味記述の推論が可能となる。




図 1 興味推論モデル

興味推論モデルは、外部誘引(時間帯)ノード、興味記述ノード、感性的興味ノード、応答ノードから構成される。各ノードと取り扱う確率は、以下の通りである。

- ・ 興味記述ノード
提供したニュースに対するユーザ興味記述への参照を値とし、興味記述がウェブニュース選択に利用された頻度を事前確率とする。
- ・ 外部誘引(時間帯)ノード
情報提供の時間帯を朝・昼・夜の 3 つに分け、一様な事前確率とする。

表3 ニュースタグ

タグ	タグの示す内容
(1) <title>	主題を示すタグ
(2) <tag-title>	主題格記述を示すタグ
(3) <description>	ニュース本文を示すタグ
(4) <tag-description>	本文のすべてのセンテンス格記述を示すタグ
(5) <sentence no="X">	センテンスを示すタグ Xはセンテンス番号

表4 主題格記述, センテンス格記述で使用するタグ

タグ	タグの示す内容
<main>	主体の動作
<agent>	主体
<object>	動作・変化の影響を受ける対象
<modifier>	修飾関係
<implement>	動作における道具・手段
<purpose>	目的
<place>	事象の成立する場所
<time>	事象の起こる(起こった)時間
<scene>	事象の成立する場所
<number>	数値に関する内容

<?xml version="1.0" encoding="SHIFT-JIS" ?>	<tag-description>
<news>	<sentence no="1">
<title>	<main>決めた</main>
スモーカーは採用お断り=WHO	<agent>
</title>	<main>WHO</main>
<tag-title>	<noun>世界保健機関</noun>
<main>雇用しない</main>	</agent>
<agent>WHO</agent>	<purpose>
<object>スモーカー</object>	<main>守る</main>
</tag-title>	<object>
<description>	<main>信用</main>
<sentence no="1">	<modifier>国連保健機関</modifier>
世界保健機関(WHO)は1日、国連の保健機関としての信用を守るための方針を決めた。	</object>
</sentence>	</purpose>
(略)	<object>方針</object>
</description>	<time>1日</time>
	</sentence>
	(略)
	</tag-description>
	</news>

図2 ウェブニュースの記述例

・ 感性的興味ノード

ニュースに対するユーザの感性的興味を喜(うれしい)・怒(腹が立つ)・悲(悲しい)・驚(すごい)・その他(不安などその他の感性的興味)・興味無しに分類し、興味記述および時間帯との条件付確率を確率値とする。

・ 応答ノード

ユーザの感性的興味に応じた”へえー”, ”そう”などの感性的語や応答語を値とし、ユーザの感性的興味との条件付確率を確率値とする。

2.3 推論

本システムは、ユーザまたはシステムから得られたエビデンスをもとに興味推論モデルを使用し推論を行う。システムで使用している推論は、興味記述の推論と感性的興味の推論の2つに分類される。

・ 興味記述の推論

興味記述の推論を起動するエビデンスには、2つのタイプがある。1つは、システムから得られるエビデンスで、時間帯がこのタイプに対応する。時間帯がエビデンスとして与えられた場合、ベイジアンネットワークの原因間推論により、ユーザの興味記述を推論する。2つめのタ

イプは、ユーザから得られるエビデンスで、感性的興味に対応する。感性的興味がエビデンスとして与えられた場合には、診断的推論により興味記述を推論する。

・ 感性的興味の推論

ウェブニュースをユーザに提供した後、そのニュースの興味記述、時間帯、応答をエビデンスとして、混合型推論によりユーザの感性的興味を推論する。現システムでは、エビデンスと推論結果を履歴として残している。

3. ニュース表現形式と選択手法

本章では、本システムで使用するウェブニュースの構造と提供するウェブニュースを選択するための手法について説明する。

3.1 ニュース表現形式

ウェブニュースは、XML で表現され、主題、主題を格構造で表現した主題格記述、ニュース本文、ニュース本文をセンテンス毎に格構造で表現したセンテンス格記述から構成される。ウェブニュースの構成を記述するタグの一部を表3に掲載する。主題格記述、センテンス格記述で使用するタグの一部を表4に示す。図2にウェブニュースの例を掲載する。

3.2 ニュース選択手法

本システムでは、提供するニュースを選択する際に、興味推論モデルの推論により取得した興味記述と新着ニュースの類似度を計算し、類似度の一番高いニュースをユーザに提供する。類似度の計算手法を以下に示す。

3.2.1 単語間の類似度計算

単語間の類似度は、概念体系辞書[7]を用いて概念の深さを検索し、それらの値を用いて類似度を計算する。

単語 w_0, w_1 の概念体系の深さを d_0, d_1 、共通の深さを d_c とするとき、単語間の類似度は

$$sim(w_0, w_1) = \begin{cases} \frac{2 \times d_c}{d_0 + d_1} & \dots w_0, w_1 \text{ が登録されている} \\ 0 & \dots \text{それ以外} \end{cases} \quad (2)$$

で表される。

w_0, w_1 が辞書には登録されていないが、形態素要素に分割できる場合には、各形態素要素毎に類似度を計算し、それらの平均を $sim(w_0, w_1)$ とする。

3.2.2 類似度の計算

ウェブニュース n が、 J 個のセンテンス格記述

$$S_j = \{(c_l, w_l^{S_j}) \dots (c_i, w_i^{S_j}) \dots\}, j=0 \dots J \quad (3)$$

を持つとき、興味記述 I とウェブニュース n の類似度は、(I)~(V)の手順で計算される。

(I) 共通格集合 T_j の抽出

$$T_j = \{(c_l, w_l^{S_j}, w_l^I) \dots (c_L, w_L^{S_j}, w_L^I)\} \quad (4)$$

とする。このとき、 L は共通の格数である。

(II) main 格の単語間類似度 m の計算

S_j と I の main 格要素をそれぞれ $w_m^I, w_m^{S_j}$ として、式(5)により、 m を計算する。

$$m = sim(w_m^I, w_m^{S_j}) \quad (5)$$

(Ⅲ) S_j と I の類似度 $senSim(j)$ の計算

共通格集合 T_j 内の要素($w_i^{S_j}, w_i^I$)を用いて、式(6)により、類似度を計算する。

$$senSim(j) = m \times \frac{\sum_{i=1}^L sim(w_i^I, w_i^{S_j})}{L} \quad (6)$$

(Ⅳ) I と n の類似度 $sim(I, n)$ の計算

$sim(I, n)$ を式(7)により計算する。

$$sim(I, n) = \max_j senSim(j) \quad (7)$$

(Ⅴ) ニュースの選択

類似度 $sim(I, n)$ を最大とする n を選択する。

4. システム

4.1 構成と機能

システムの構成(図 3)について説明する。システムは、音声対話管理部、興味構造管理部、ニュース選択部の3つの部分から構成される。音声対話管理部は、ユーザからの音声入力、音声認識、ユーザへの音声によるウェブニュース提供を行う機構、興味構造管理部は、興味プロファイルの管理および興味推論モデルによる推論を行う機構、ニュース選択部は、新着ウェブニュースを選択し、音声対話管理部へ渡す機構である。

4.2 音声対話管理部

音声対話管理部は、ユーザとの対話管理、Julian[5]による音声認識、TTS(TextToSpeech)を介したユーザへのウェブニュース音声提供を行う。

ユーザから入力された音声は、Julianサーバクライアントを介して認識処理を行う。その結果からユーザの要求を解析し、興味構造管理部へユーザの要求を渡す。

また、ニュース選択部からの渡されたニュースを解析し、TTSによりウェブニュースを音声にて提供する。提供後、ユーザの応答を取得し、興味管理部へその応答を渡す。

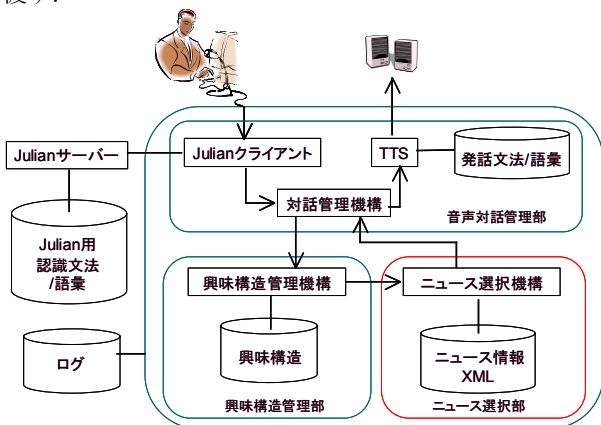


図 3 システム構成

4.3 興味構造管理部

興味構造管理部では、音声対話管理部から受け取ったユーザ要求を解析し、ユーザの興味記述を興味推論モデルにより推論する。推論された興味記述は、ニュース選択部に渡される。

また、ウェブニュース提供後のユーザの応答を受け取り、感性的興味推論の実行と興味プロファイルの更新を行う。

4.4 ニュース選択部

推論された興味記述と新着ウェブニュースの類似度を3.2節のニュース選択手法にて計算し、選択したニュースを音声対話管理部に渡す。

5 実験

5.1 実験環境

2005年12月2日~13日のgooニュース100件を使用し、ユーザ4人に対してアンケートを行い、興味プロファイルと興味推論モデルの条件付確率表の初期値を作成した。また、新しいニュースへの適応性評価のため、2007年3月14日~3月18日のgooニュース20件も用意した。ニュースに対するタグ付けは、手作業で行った。

5.2 実験内容

試作したシステムをユーザ4人が使用し、システムについての評価を行った。本システムで認識できる音声要求は、VD1~VD3の3つのタイプである。

VD1: △について教えて(△は、提供したニュース中の単語)

VD2: 何かニュースはありますか

VD3: {感性的興味の代表語}ニュースはありますか

感性的興味と代表語は、表5のように対応する。

表 5 代表語

	感性的興味の種類	代表語
1	喜	嬉しい
2	怒	腹が立つ
3	悲	悲しい
4	驚	すごい
5	その他	他に
6	興味なし	つまらない

例えば、“喜”のニュースを聞きたい場合には、ユーザは、“うれしいニュースはありますか”と要求する。

評価の前に、VD1~VD3を使用して、ユーザ毎に20回の対話を行い、興味推論モデルの個人適応を行った。その後、興味推論モデルの評価を次の評価I、評価IIの手順により行った。

[評価 I]

自分の興味推論モデルを使用して、評価を(a)~(c)の手順で行う。音声要求は、VD3の中から5種類(表5の1~5)の代表語について行った。

- (a) 音声要求
- (b) 推論した興味記述を持つニュースを提供
- (c) 提供したニュースの感性的興味と一致するかどうかを5段階[1(低)~5(高)]で評価

また、他人A、他人Bの興味推論モデルを使用して同様の評価を行った。

[評価 II]

評価を(a)~(c)の手順で、すべての興味プロファイルについて行った。

- (a) 興味プロファイルを選択

- (b) 興味プロフィール中の興味記述と新着ウェブニュースとの類似度を計算し、類似度の高いニュースをユーザに提供
- (c) 提供したニュースに対して、どのような感性的興味が得られたか確認

表 6 要求に対する一致度

	自分	A	B
喜	3.5	2.5	1.5
怒	4.25	2.75	3.75
悲	4.25	2.25	2.25
驚	3.75	2.5	2.5
その他	3.75	2.75	2.3333
平均	3.9	2.55	2.4667

表 7 ユーザの要求に対する感性的興味の一致の割合

ユーザ	興味一致	興味あり
1	0.08696	0.41304
2	0.03125	0.28125
3	0.125	0.60938
4	0.13636	0.77273
平均	0.09489	0.5191

表 8 要求-提供の感性的興味の割合

		要求				
		喜	怒	悲	驚	他
提供	喜	0.137	0.081	0.125	0.144	0.086
	怒	0.094	0.028	0	0.044	0.023
	悲	0.078	0.056	0.142	0.226	0.247
	驚	0.118	0.279	0.185	0.157	0.176
	他	0	0	0	0	0
合計		0.426	0.444	0.452	0.572	0.532

5.3 実験結果

5.3.1 評価Ⅰ

表 6は、自分、他人 A、他人 Bの興味推論モデルを使用した際の、要求と提供されたニュースの感性的興味間一致度の平均(ユーザ 4人)である。

結果から明らかなように、自分の興味推論モデルを使用した場合に、どの要求に対しても、推論した興味記述の一致度が高いことがわかる。

5.3.2 評価Ⅱ

表 7は、興味プロフィール中の感性的興味と提供されたニュースに対する感性的興味が一致した割合(興味一致)と、提供されたニュースに対して何らかの感性的興味が得られた割合(興味あり)をユーザ毎に示した結果である。“興味あり”の平均は、約 0.519 となっているが、“興味一致”の平均は、約 0.09 と低い結果となっている。

表 8は、興味プロフィール中の各感性的興味に対する提供されたニュースの各種感性的興味の割合をユーザ 4人に対して求め、それらを平均したものである。“驚”の感性的興味を持つ興味記述を選択した場合に、ユーザが提供されるニュースになんらかの感性的興味を示す割合が、0.572 と一番高い。

5.4 検討・考察

評価Ⅰの結果から、推論された興味記述は、個人に適應していることがわかった。また、評価Ⅱの結果では、ある興味記述に感性的興味が一致するニュースを提供する割合は低い、なんらかの感性的興味を示すニュースを提供できる割合が 50%以上であることがわかった。

一致度が低くなる理由として、興味記述をウェブニュース主題から作成したため、実際にユーザが興味を示している部分との差異があること、実験で用いたウェブニュースの数が少ないことがあげられる。また、アンケートにおいて、提供されたニュースに対して、感性的興味から 1つを選択させているため、“悲”と“驚”等の 2つの感性的興味が得られるニュースに対して正確な評価が得られないことが考えられる。

また、表 8 において、“驚”が一番高い割合を示した理由として、“驚”は、その他の感性的興味を包含している場合もあると考えられる。

今後の課題として、上記の考察に加え、ウェブニュースの自動タグ生成、“その他”でまとめた感性的興味の細分化、ユーザが興味を示した部分への興味の強さの測定、時間経過による興味記述の削除または統合、新たに提供したニュースからの興味記述の取得などがあげられる。

6 むすび

本論では、ユーザの興味構造の表現方法と、ニュース選択手法についての提案を行い、それらについて評価実験を行った。興味推論モデルについては、個人への適應が確認できた。新たなニュース提供については、完全に一致はしないが、ある程度興味あるニュースを提供することが確認できた。

参考文献

- [1] 松本,麻生,他:インタラクティブエージェント用ユーザモデル構築のための対話実験,2004年度人工知能学会全国大会(第18回)論文集,2E1-07,2004.
- [2] 上野,駒谷,河原,奥乃:京都市バス運行情報案内システムの試験評価とユーザモデルの導入,2003年度人工知能学会全国大会(第17回)論文集,2C2-03,2003.
- [3] 熊本,灘本,田中:記事の印象を伝達するニュース番組生成システム wEE の設計と評価,電子情報通信学会誌,Vol. J90-D No2,pp.185-195,2007.
- [4] 野美山,紺谷,渡辺他:個人適応型情報検索システム一人の興味を学習する階層記憶モデルとその協調的フィルタリングへの適用一,情報学基礎研究会報告,Vol. 96, No70, pp. 49-56, 1996.
- [5] 河原,李:連続音声認識ソフトウェア Julius,人工知能学会誌,vol. 20, No. 1, pp. 41-49, 2005.
- [6] Korb,K.B. and Nicholson, A.E.: Bayesian Artificial Intelligence, Chapman and Hall/CRC Press UK, 2004.
- [7] 日本電子化辞書研究所,EDR 電子化辞書(第2版)仕様説明書,TR2-006(改),2001.