

ユーザの振舞いを教師信号として学習する Bayesian Networkの電子メールエージェントへの適用

A Novel E-mail Agent: An Application of Bayesian Networks Learning from User's Behaviors

磯崎 隆司 堀内 一永 鹿志村 洋次
Takashi Isozaki Kazunaga Horiuchi Hirotsugu Kashimura

富士ゼロックス(株) 研究本部
Corporate Research Group, Fuji Xerox Co., Ltd.

New e-mail agent architecture with a Bayesian network (BN) was investigated in order to detect important e-mail for office users. The BN has nodes related to users' resultant behaviors during the e-mail operations, which enable the agent to adapt to users' intentions by implicit feedbacks, called semi-supervised learning. We have investigated performances of the agent for 5 examinees during 2 months and obtained an accuracy of as high as 0.937 (the F value) by semi-supervised learning, which is comparable with the accuracy obtained by full-supervised learning (0.924). It indicates that the nodes of resultant behaviors can be properly working in the implicit feedback cycles, as an alternative for users' questionnaires.

1. はじめに

我々は、オフィスワーカーに対する業務支援として、ユーザ個別にカスタマイズしたサービスの提供が重要だと考え、柔軟な適応性を学習によって得ることができる機械学習をユーザプロファイリングへ適用することを検討している。しかし、オフィスユーザの価値観や嗜好は業務内容の変化や自身の異動、組織の変化などによって動的に変化する可能性があるため、通常の教師付き学習では、こうした変化が起これば追加学習が必要になる場合が考えられ、その場合はユーザへの大きな負担が生じてしまう。

こうした課題に対して、特に Web のパーソナライゼーションの観点から、ユーザのアクセスログや閲覧時間、マウスやユーザの視線の動きなどから教師信号を生成し、暗黙的フィードバックとして価値観を学習するといった研究が行なわれている [土方 04]。ユーザのこうした振舞いは多様であると考えられるが、多くの研究では単一の振舞いからのフィードバックになっているので多数のユーザに精度よく対応することができない可能性がある。そこで我々は多様な振舞いから教師信号を生成することが必要と考えたが、この場合にもヒューリスティックなパラメータの調整はできるだけ少なく済むことが望ましい。またそうした振舞いにはノイズがあることや、複数の振舞い情報の関係やその他の情報との関係に条件付依存性があること、なども考えられる。我々はこうした不確実性を確率で表現し多様な情報とそれらの複雑な依存関係をヒューリスティックなパラメータ調整をほとんど必要とせずに対処ことができ、さらに確率(信念)の伝搬という形で定量的な情報を与える Bayesian Network が学習・推定器として相応しいと考えた。そこで我々は、ユーザの様々な振舞いを抽出し、その情報を統合して確率的な教師信号を生成することで明示的なフィードバックを減らし、ユーザをプロファイリングするアーキテクチャを提案する。

一方、オフィスワークで今や必須の情報ツールとも言える電子メールを対象として、その閲覧支援システムはすでに実用化されているスパムメールフィルタを始めとして、業務に関する

メール [Boone 98] や緊急のメール [Horvitz 99] などの特定のメールの抽出技術が、数多く研究されているが、ユーザにとっての重要なメールの判別という複雑なプロファイリングを要し、これを精度よく捉え、さらにダイナミックな追従も可能なシステムはほとんどない。そこで我々は電子メールを対象としてこのシステムを検討し、個々のユーザにとっての重要なメールを半教師付き学習 (Semi-supervised Learning) で抽出できるシステムを試作し、実験的に評価した。こうしたエージェントシステムが実現できれば、ユーザは重要なメールが到着したときだけ進行中の業務を中断すればよく、電子メールの到着情報を気にせずに遂行中の業務に集中することができる上、ユーザにとって重要な順からメールを読むことが容易になるので、忙しいときは重要なメールだけ読み、忙しくないときにそれ以外のメールを読む、といった効率的な時間の使い方が容易になり、その結果として業務効率の向上が期待できる。

本稿では、ユーザの振舞いから半教師付き学習する Bayesian Network を利用したエージェントアーキテクチャと、このシステムを用いて実際のオフィスで扱われた電子メールに対する重要度の推定実験の結果について報告する。

2. Bayesian Networks

Bayesian Network (BN) [Pearl 88] は確率分布のグラフィカルな表現形態であり、確率変数を表わすノードと有向辺とからなる非循環グラフである。確率変数は離散もしくは連続的な状態を有する。確率変数の組 $\{X_1, \dots, X_n\}$ に対して、 $\Pi(X_i)$ は一つのノード X_i の親ノード(集合)と定義される。ここで有向辺の向きは $\Pi(X_i)$ から X_i に向かう。そして結合確率分布を次の条件付確率分布の積に分解する:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \Pi(X_i)). \quad (1)$$

この条件付確率分布を用いることによって、定量的な推論を実行することができる。ある証拠集合 E の下で、確率変数 X_i が、状態 x_i であるという推論結果を表わす確率(信念)は、 $P(x_i|E)$ として求められる。この信念の計算法は厳密解法である Junction Tree アルゴリズムと呼ばれるクラスタリングの一種や近似的解法である MCMC などの確率的なサンプリング手法などで計算される。

連絡先: 磯崎隆司, 富士ゼロックス(株) 研究本部, 〒259-0157
神奈川県足柄上郡中井町境 430 グリーンテックなかい, Tel:
0465-80-2141, E-mail: isoizaki.takashi@fujixerox.co.jp

条件付確率分布の学習 [Heckerman 96] は、通常 MAP 推定で行なわれ、その場合、完全データに対しては次式:

$$P(x_i^k | \pi_i^j) = \frac{\alpha_{ijk} + N_{ijk}}{\sum_{k'=1}^{r_i} (\alpha_{ijk'} + N_{ijk'})} \quad (2)$$

で表される。ここで、 i は X のインデックスであり、 j は親ノード集合の configuration を表す。 r_i はノード X_i の状態数を表し、 k と k' は X_i の状態 ($k, k' \leq r_i$)、 α_{ijk} は Dirichlet 分布のハイパーパラメータ、 N_{ijk} はデータセットにおける $X_i = x_i^k$ かつ、 $\Pi_i(X_i) = \pi_i^j$ となる頻度である。データが欠損を含む、もしくは潜在変数を含む場合には、EM アルゴリズムを使つての学習が可能であり、その場合、E ステップは次式:

$$E[N_{ijk}] = \sum_{l=1}^N P(x_i^k, \pi_i^j | y_l) \quad (3)$$

で表現される。ここで y_l はデータセットにおける l 番目のケース、 N はデータ数で $E[\dots]$ は "...” の期待値を示す。M ステップは式 (2) において、 N_{ijk} を $E[N_{ijk}]$ で置き換えた式を用いる。これらの E ステップと M ステップを必要に応じて繰り返して MAP 推定値を得る。

我々は EM アルゴリズムを用いたが、この学習においては推論アルゴリズムが必要であり、そのときの計算効率の観点から我々は Junction Tree アルゴリズム [Cowell 99] を実装して用いた。また今回の実験では図 1 に示すように PC に常駐して電子メールを重要度順にソートするエージェントプログラムを C++ で実装してテストしており、一度に 100 通程度のメールの重要度推定を行なった場合、Pentium 2.8GHz の CPU を用いて、10% 程度の CPU 占有率と 300msec 程度の演算時間で高速に実行できることを確認している。

3. アーキテクチャ

我々は学習により獲得したユーザのプロファイルを、エージェントがある判断をした原因と見做し、エージェントにより提供されたサービスに対するユーザの様々な振舞いをそのサービスの質に対する結果と見做した。この結果 (と原因) を証拠として BN の確率推論機能から正しいサービス内容を推定し、この情報を暗黙的フィードバックとしてプロファイル情報を更新する。重要な電子メールの推定においては、メールの内容やメールに関する履歴情報によってユーザのプロファイルが形成され、それによって新着メールの重要度を予測する。そしてユーザのメールに対する振舞いからプロファイル情報を更新するというサイクルになる。

3.1 素性選択: メールからの抽出情報

電子メールの重要度を推定・予測するにあたり、我々は、示唆的なキーワード群と、ユーザと送信者との間の人間関係を暗示する情報が重要であると仮定した。さらに具体的にユーザ個々の価値観を BN におけるノードとして表現するため、研究、開発、営業、コンサルタント、事務職など複数の職種におけるオフィスユーザへのアンケートを行ない、ノード (28 項目) の設定を行なった。キーワードとしては、会議、仕事の依頼、納期や約束に関する語をキーワードとして採用し、人間関係の暗示情報としては、各送信者に対しての過去の返信状況や、過去の重要度の平均値、同時受信者の数などを採用した。また、ユーザとメール送信者との人間関係は過去の履歴が重要な情報であるが、初めての送信者に対してはこの情報がない。



図 1: 重要なメールの順にソートする常駐プログラム

その場合には、電子メールの文面などからユーザのカテゴリを推定し、過去における同様のカテゴリに属すると推定された送信者に対するユーザの価値観を利用する。カテゴリは、上司や同僚、取引先、ニュースやメールマガジンなどである。これらのカテゴリに対して証拠は得られないのでこの送信者のカテゴリ情報は潜在変数となる。これらの情報を以下原因因子 (CF: Causal Factors) もしくはメール情報と呼ぶ。

3.2 素性選択: メールに対するユーザの振舞い情報

ユーザの電子メールに対する振舞いは多様であり、事前の聞き取り調査では、メールの種類に限らず一定時間後にすべて削除するというユーザもいた。また閲覧時間は文書量にも関係し、重要なメールでも非常に短い時間しか閲覧時間を要さない場合もあるなど、素性の条件付依存性も予想された。我々が採用した振舞いの情報としては閲覧時間や閲覧回数、削除、返信、転送、印刷、添付文書の閲覧・保存、マウスの移動速度、PC にログオンしてからメールを読み始めるまでの時間、など 32 項目である。こうした情報の符号化は、得られたデータをソートして 5 分割で決定している。これらの情報を以下結果因子 (RF: Resultant Factors) もしくは振舞い情報と呼ぶ。

3.3 BN の構造設計

上記の考えから BN の構造を設計した。しかし、電子メールからの抽出情報を一律に「原因」とした場合、パラメータの増大から条件付確率の学習が困難になるので「原因」情報を互いに独立したものと仮定してから相互作用を導入する Naive Bayes Classifier を拡張した形式とした。ノード間のリンクは事前知識から想定される条件付依存性を考慮して設計した。この中には CF と RF とが直接リンクしているものや、メールの重要度と直接リンクしていないノードなども存在する。こうして設計したネットワークの一部を図 2 に示す。

4. 実験結果と考察

実験は、当社研究本部に属する複数の研究領域の研究者とマネージャー、計 5 人に対して、およそ 2ヶ月弱の間に彼らが実際に受け取った電子メールが被験者にとって重要であったか否かを推定するタスクとして行なった。被験者がこの期間に受け取った電子メールは 401 通から 977 通 (平均 641 通) であった。また我々は重要な電子メールを、すぐに読みたい (処理したい) メール、読み忘れたくないメール、覚えておきたいメールのいずれかと定義した。推定精度を調べるため全メールに対してこの基準で被験者に判断してもらい、その結果、被験者が判定した重要なメールの割合は 25.2% から 63.4% (平均 40.5%) の分布であった。以下の実験では、個人ごとに電子メールデータを時系列順に並べた後に 2 つに分け、先に受信した 250 通を学習用データとし、後から受信した 150 通をテスト用データとしている。以下では被験者をユーザとも呼ぶことがある。

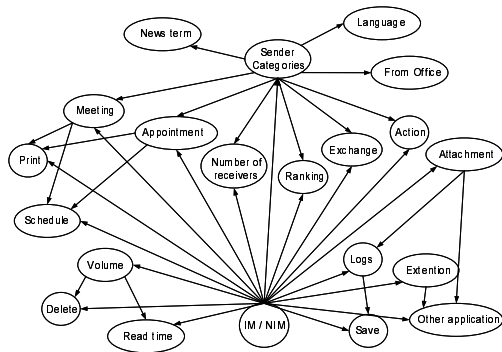


図 2: 重要なメール (IM) か否か (NIM) を推定するための BN の部分構造

4.1 原因及び結果からの教師付き学習による推定精度

本節では CF 及び RF それぞれの、教師付き学習による推定精度の実験について述べる。BN の構造は CF と RF を含む単一のネットワークとした。CF を学習し、CF からの推定精度をテストするときには RF の条件付確率を一律確率にし、影響を排除した。RF の学習及びテストのときも同様に CF の影響を排除した。ユーザにとっての全てのメールに対する精度 (F 値) はユーザ平均で CF に関して 0.916、RF に関して 0.873 であった。重要なメールに関しての詳細結果を表 1 に示す。重要なメールの F 値の平均は CF/RF とともに全体での値より下がり、重要なメールの推定精度が非重要なメールの推定精度より劣ることがわかる。この理由としては、非重要なメールは時間があるときにしか読まないニュースやメールマガジン、あるいは、一方向的な告知メールなど、比較的単純な素性のメールが多いからだと考えられ、一方で重要なメールは、重要度が内容やユーザの状況に大きく依存し、より複雑な推定が必要だと思われる。

図 3 には学習データ数に対する全メールの推定結果のユーザ平均を示す。この図からわかるように、振舞い情報による推定精度はメールから抽出できるメール情報による推定精度には常に及ばないものの、学習データに対して比較的安定した結果を示している。図中に示した各ユーザ毎の Over 95 という指標は、振舞いデータによる推定精度が 250 通学習時における推定精度の 95% を初めて超えたときの学習データ数を示し、どれほど少ないデータで学習ができるかの一つの指標と考えられる。この結果より 150 通程度で振舞いの教師付き学習の精度がほぼ飽和していると考えられる。

4.2 代用教師信号としての振舞い情報の評価

本節では、振舞い情報と BN による確率推論機能との組み合わせから生成される確率的な教師信号が、ユーザの明示的な教師信号の代用となりうるかを検証する。具体的には RF のみを学習し、RF を使って生成される教師信号を用いて全く学習していない CF を学習させ、CF からの推定精度がどの程度まで向上するかを検証した。この結果を図 4 に示す。RF を学習するのに要した教師付き学習データ数をパラメータとして、横軸は学習を終えた RF を用いて学習した CF の学習データ数とし、縦軸はテストデータに対して推定した精度 (F 値のユーザ平均) を示す。BN のグラフ構造は CF と RF を含む単一のネットワークとし、教師なし学習では、EM アルゴリズムを用いて CF に関する条件付確率表のみを更新した。テストを実行する際には、CF のノードのみに証拠を与えて確率推論を実行

表 1: 重要メールに対するメール情報と振舞い情報からの推定精度

| User | CF | | | RF | | |
|------|-------|--------|---------|-------|--------|---------|
| | Prec. | Recall | F Value | Prec. | Recall | F Value |
| U1 | 0.787 | 0.923 | 0.850 | 0.776 | 0.731 | 0.753 |
| U2 | 0.825 | 0.971 | 0.892 | 0.931 | 0.794 | 0.857 |
| U3 | 0.973 | 0.750 | 0.847 | 0.940 | 0.813 | 0.872 |
| U4 | 0.986 | 1.000 | 0.993 | 0.969 | 0.861 | 0.912 |
| U5 | 0.756 | 0.838 | 0.795 | 0.615 | 0.649 | 0.632 |
| Ave. | 0.865 | 0.896 | 0.875 | 0.846 | 0.769 | 0.805 |




図 3: 教師付き学習による、学習データに対する推定精度結果 (F 値のユーザ平均)

した。結果を見ると、この実験では、アンケートからの CF の学習 (“Supervised” で図示) にはいずれも及ばないことがわかるが、150 通の振舞いの学習で 0.9 に近い精度を得ている。また 25 通程度で飽和しており、これはアンケートより速いことがわかる。アンケートに精度で及ばないこと理由は振舞い学習の精度がまだ十分ではないことだと考えられるが、その差は 5% に満たない程度である。また、25 通程度あればユーザの価値観をゼロからある程度学習できることが確認でき、このことはシステムが RF と BN の確率推論によりプロファイルの急激な変化に対してもダイナミックに追従する能力を有することを示している。

4.3 半教師付き学習と教師付き学習の比較

前節での結果より、振舞いからの暗黙的フィードバックがユーザの明示的なアンケートの代用になり得ると考えられる結果を得た。そこで本節では、実際の利用を考慮した半教師付き学習を検証する。具体的には振舞い情報からの暗黙的フィードバックによってユーザのプロファイルが維持できるかどうかを、完全な教師付き学習と半教師付き学習との比較実験によって調べた。前々節及び前節の結果から、振舞いからメールの重要度を推定するには、150 通程度の教師付き学習が必要であることがわかったので、次の 3 条件での比較を行なった。s を教師付き学習による学習データ数、u を教師なし学習による学習データ数、t をテストデータ数とし、学習データを以下

- ・SU0: $[s, u] = [250, 0]$
- ・SU1: $[s, u] = [100, 150]$
- ・SU2: $[s, u] = [150, 100]$

のように分割し、SU1 と SU2 はいずれも教師付き学習の後に教師なし学習を行なう。ここで、t は共通に 150 である。BN の構造と学習、推定の方法は前節と同様である。重要メールに関しての、学習データ (s+u) に対するテストデータにおける推




図 4: 振舞いのみの学習後におけるプロフィール獲得特性




図 5: 学習方式の違いによる重要電子メールの推定精度の比較

定精度 (F 値のユーザ平均) を図 5 に示す。この図から、SU1 では 225 通の学習を経た後に推定精度が劣化したことがわかる。これは SU1 の条件である 100 通の教師付き学習では振舞いが十分に学習できておらず、その結果正確な教師信号を生成できず、推定精度が劣化したと考えられる。それに対して SU2 では完全な教師付き学習である SU0 と同等の推定精度を維持できている。前節との結果と異なり SU2 で SU0 と同等の精度が維持できていることは、BN の構造に CF と RF とのリンクがあるため、教師付き学習において、CF と RF のノードを同時に学習することで、より正確に適應できたのではないかと考えられる。このことは条件付依存性をモデルに容易に組み込める BN の特徴が現れた結果ではないかと我々は考えている。

表 2 は全体のメールに関するユーザごとの、 $s + u = 250$ での F 値を示すものである。全体のメールにおいてもやはり SU1 では全被験者で SU0 や SU2 と比較して精度が劣っている。一方で 150 通の教師付き学習と組み合わせた半教師付き学習である SU2 では 0.937 と F 値での高い精度を達成している。興味深い結果として挙げられるのは、半教師付き学習である SU2 が完全な教師付き学習である SU0 を被験者 5 人のうち前々節での振舞い精度が 0.75 以上の 4 人で同等か上回っているという点である (例外は振舞いからの推定精度が 0.63 と大きく劣っている被験者 U5 1 人である)。この理由としては二つのことが考えられる。一つには、アンケートではユーザが判断に迷うケースもあり、全てのデータに対して完全に一貫性のある答えを出すことが難しいが、振舞いは無意識の動作であるために、一貫性を保つことが可能だということが挙げられる。もう一つには、アンケートは重要か非重要かのどちらかに分類するため重要度の信念の強さというアナログ的な情報が欠落してしまうのに対して、振舞いからの教師信号は確率 (信念) という連続値を伝搬させるため、より豊富な情報を学習に反映させることができるということが考えられる。実験結果とこれらの理由から、振舞いが精度よく学習できれば、ユーザのアンケートによる教師付き学習よりも振舞いからの暗黙的なフィードバックからの方が高い精度での適應的学習が可能かもしれないと我々は考えている。

5. むすび

我々は、ユーザ個々の価値観を半教師付き学習する Bayesian Network によって学習するアーキテクチャを考案し、ユーザにとっての重要な電子メールを推定するタスクに適用した結果、150 通の教師付き学習の後、100 通の暗黙的フィードバックからの学習により、5 人の被験者における F 値の平均値で

表 2: 教師付き学習と半教師付き学習での推定精度 (F 値) の比較

| User | SU0 | SU1 | SU2 |
|--------|-------------|-------------|-------------|
| U1 | 0.875 | 0.864 | 0.930 |
| U2 | 0.950 | 0.915 | 0.973 |
| U3 | 0.897 | 0.837 | 0.911 |
| U4 | 0.993 | 0.947 | 0.993 |
| U5 | 0.903 | 0.845 | 0.876 |
| Ave.±σ | 0.924±0.042 | 0.882±0.043 | 0.937±0.042 |

0.937 (93.7%) の推定精度を達成した。また、この方式でユーザの価値観の急激な変化にも 25 通程度で追従できる可能性を示した。今後はさらに被験者を増やして、必要なノードの追加などの改良をしていく予定である。また、今回の実験から特に振舞いの学習精度は改善の余地があると考えている。振舞いの学習が、高い精度で速く飽和すれば、それだけ教師付き学習に必要なデータも少なくできるので、動的な特性の向上とともにユーザへの負荷も減少させることができることができ重要な課題である。そのために Bayesian Network Classifier の構造学習や連続値の離散化処理の改良などを導入することで改善を図っていく予定である。また、別のアプリケーションへの適用も検討課題である。

参考文献

- [Horvitz 99] Horvitz, E., Jacobs, J. and Hovel, D.: Attention-Sensitive Alerting, *Proceedings of Uncertainty in Artificial Intelligence*, pp. 305-313 (1999).
- [Boone 98] Boone, G.: Concept Features in Re:Agent, an Intelligent Email Agent, *Proceedings of International Conference on Autonomous Agents*, pp. 141-148 (1998).
- [Pearl 88] Pearl, J.: *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*, Morgan Kaufmann (1988).
- [Cowell 99] Cowell, R. G., Dawid, A. P., Lauritzen, S. L. and Spiegelhalter, D. J.: *Probabilistic Networks and Expert Systems*, Springer-Verlag (1999).
- [土方 04] 土方嘉徳: 情報推薦・情報フィルタリングのためのユーザプロフィール技術, 人工知能学会誌, Vol. 19, No.3, pp. 365-372, (2004).
- [Heckerman 96] Heckerman, D.: A Tutorial on Learning with Bayesian Networks, Technical Report MSR-TR-95-06, Microsoft Research, 1995, revised June (1996).