

# 決定木学習を用いた Web トラスト形成支援

Supporting for Web trust formation by decision tree leaning

柳澤大祐\*  
Daisuke Yanagisawa

八槇博史†  
Hirofumi Yamaki

山口由紀子†  
Yukiko Yamaguchi

## 1 はじめに

Web サイトのプライバシーポリシーは、そのサイトが信頼に足るかを判断する手段の一つとなる。しかし、その読みづらさからほとんどの場合読まれることはない。そこで、Web サイトを信用できるかどうかを人間に代わり判断するエージェントを作成する研究が存在する [1]。

本研究では、エージェントが利用者の判断をどのように学習することで利用者がエージェントに判断基準を設定する手間を省くことができるかという考察および実際にその学習を用いたエージェントの開発を行った。

## 2 Web トラスト形成

利用者が Web サイトとのトラストを形成する際には、プライバシーポリシーを利用することができる。これを用いたトラスト形成では、(1)Web サイト管理者がプライバシーポリシーを自然言語で記述し、(2)利用者がプライバシーポリシーを閲覧・理解し、(3)利用者が Web サイトを信頼できるかどうか判断する、という手順を経ることとなる。

しかしながら、プライバシーポリシーは堅い文体で記述されているため理解しづらく、また文章自体も長いため利用者が理解しようと努めることはまれである。

W3C は、P3P(The Platform for Privacy Preferences) という規格を定めている [2]。この規格では、プライバシーポリシーを機械可読である P3P ポリシで記述するための構文および意味論を定義している。

また、この規格では P3P ユーザエージェント (以下 P3P UA) についても言及している。P3P UA とは、利用者の代わりに機械がプライバシーポリシーを読み、事前に設定された利用者選好と比較し、その Web サイトが信頼できるか否かを利用者へ通知するエージェントである。

しかしながら P3P UA にも利用者選好を設定しなければならないという問題点がある。またプライバシーポリシーが複雑であるために P3P ポリシも複雑とならざるをえない。よって、P3P UA に対する利用者選好の設定も簡易的なものにとどめ設定の手間をかけないようにするか、あるいは手間がかかることを前提として細かい設定項目を提示するかのどちらかとなる。

本研究では、利用者選好の設定に決定木学習を用いることで、利用者から設定の負担を大幅に軽減することを目的とした。

## 3 決定木学習による利用者選好の抽出

### 3.1 P3P ポリシの機械学習

利用者選好の抽出に教師あり学習を適用するためには、教師信号の判断基準が変化しない必要がある。利用者選好は Web サイトをまたいでも一定であると考えられることができるため、教師あり学習を用いることとした。

P3P ポリシは XML で表現されているため、それを機械学習させるためには木構造を入力することができる学習アルゴリズムを用いるのが最適である。しかしながら、そのような学習アルゴリズムは未だ確立されておらず、先端研究が存在するのみである [3]。

そこで、本研究においては広く用いられている学習アルゴリズムを用いることとし、その中より C4.5[4] を選択した。選択の理由は、判断根拠を決定木として明示できる点である。利用者のプライバシーに関わる判断を代行する P3P UA の場合、Web サイト以前にまず P3P UA が信頼できるものでなければならない。機械学習においては、誤判定は必ず発生する。その際に、判断根拠を明示することができる P3P UA はそうでない P3P UA に比べて利用者から信頼されやすくなると思われることができる。

### 3.2 学習のための調査

特徴空間を定めるための判断根拠として、調査を行った。この調査は、(1)Yahoo! Directory<sup>1</sup>の Business and Economy/Shopping and Services カテゴリ以下のリンクを抽出し、(2)各サイトの P3P ポリシを収集し、(3)入手できた P3P ポリシの各要素の平均個数などを計測するという方法で行った。

この調査により、(1)P3P ポリシの普及率は 0.5% (67,024 件中 381 件に存在)であったこと、(2)STATEMENT 要素 (後述) の平均個数は 2.18、分散は 2.575 であったこと、(3)DISPUTES 要素 (後述) の平均個数は 0.84、分散は 0.54 であったことなどが分かった。

また、この調査は Yahoo!カテゴリ<sup>2</sup>についても行った。その結果、普及率は 0.1% (55,138 件中 57 件に存在)であることなどがわかった。

### 3.3 決定木学習のクラスと特徴空間

クラスは good 及び bad の 2 つとした。good は P3P ポリシが利用者選好に受け入れられる場合であり、bad は受け入れられない場合である。

C4.5 は、事前に定められた表形式のデータを入力として用いる。ゆえに、木構造を持つ P3P ポリシから表形式へのマッピングを行う必要がある。また、判定精度の都

\*名古屋大学情報科学研究科 Graduate School of Information Science, Nagoya University

†名古屋大学情報連携基盤センター Information Technology Center, Nagoya University

<sup>1</sup><http://dir.yahoo.com/>

<sup>2</sup><http://dir.yahoo.co.jp/>




図1 採用した P3P の要素




図2 パターン数と正答率

合上利用者の判断にはあまり用いられないであろう要素および決定木学習が難しい要素を省略する必要がある。

第3.2節の調査結果より、図1の網掛けした要素のみを属性として用いることとした。ACCESS要素は利用者がWebサイトの持つ情報に対しどのようなアクセス手段を持つかを表現し、DISPUTES要素はプライバシーに関する紛争が発生した際にどのような解決を図るかを表現し、PURPOSE要素は情報の利用目的を表現し、RECIPIENT要素は情報を受け取る主体を表現し、RETENTION要素は情報の保持期間を表現するものである。

また、省略した要素とその理由は次の通りである。POLICY要素およびSTATEMENT要素は主に子要素のためのコンテナであり、決定木学習の点で有意な情報を有していないため省略した。ENTITY要素はWebサイト管理主体についての要素である。必須要素であることおよび主体の名称等は決定木学習にとって有意な差とならないので省略した。DATA-GROUP要素はどの情報を収集するかを表現する要素である。Webサイトがどのような情報を収集するかは、利用者がWebサイトを信頼するか否かに関わることであるため省略しないことが望ましい。しかし、(1)DATA-GROUP要素は複雑な木構造であるため表形式にマッピングすることが難しく、(2)調査の結果、P3PポリシーごとにDATA-GROUP要素の子要素数にかなりのばらつきがあり一律に決定木学習をすることが難しいために、省略することとした。

### 3.4 学習の評価

第3.3節で述べた学習の評価を行った。前提として、利用者のWebサイト訪問頻度はべき乗則に従うと仮定した。テストパターンとして第3.2節の調査で取得したP3Pポリシーのうち学習に適する298個を用いた。

シミュレーションは次の手順で行った。(1)テストパターンをランダムに10分割し、(2)個数の分布がべき乗になるように増幅し、(3)増幅したテストパターンをランダムに並び替え、(4)10個ずつ学習させるたびに元のテストパターンの正答率を計測した。

このシミュレーションを100回繰り返した結果、正答率が95%以上となるまでの学習したテストパターン数の平均値は30.7個、標準偏差は22.5であった。また99%以上となるまでの学習したテストパターン数の平均値は373.1個、標準偏差は185.5であった。

図2は100回の試行で得た正答率の平均値である。以上より、現実的な個数で学習が収束することがわかった。

## 4 Trustfox

以上の知見に基づき、TrustfoxというP3P UAを開発した。Trustfoxは、Firefoxのアドオンとして動作する。実装にはJavascriptを用いた。

先行研究としてInternet Explorer上で動作するPrivacy Bird[1]や、Firefox上で動作するPrivacy Fox[5]が存在する。他のP3P UAと異なる点は、利用者選好の設定を決定木学習によって行う点である。これにより、利用者の負荷を減らすことが可能となる。

## 5 おわりに

本研究では、決定木学習を用いてWebサイトのP3Pポリシーに関する利用者選好を学習する方法について考察・評価を行った。

決定木学習を用いた利用者選好の学習については、現実的な回数で学習が収束することがわかった。

また、決定木学習を用いて利用者のトラスト形成支援を行うP3P UAであるTrustfoxの開発を行った。既存P3P UAとの違いは、決定木学習により利用者選好の設定が不要となる点である。

今後の課題として木構造を扱うことができる学習アルゴリズムの適用やその都度ポリシーを読む余裕のないユビキタス環境への応用などが考えられる。

## 参考文献

- [1] L. F. Cranor et al. User interfaces for privacy agents. *ACM Trans. Comput.-Hum. Interact.*, Vol. 13, No. 2, pp. 135-178, 2006.
- [2] M. Marchiori. The platform for privacy preferences 1.0 specification. W3C Recommendation, 2002.
- [3] 鹿島久嗣他. 木構造データに対するカーネル関数の設計と解析. *人工知能学会論文誌*, Vol. 21, No. 7, pp. 113-121, 2006.
- [4] J. R. Quinlan. *C4.5: Programs for Machine Learning*. Morgan Kaufmann, 1993.
- [5] F. Arshad. Privacy fox - a javascript-based p3p agent for mozilla firefox. *Privacy Policy, Law, and Technology*, 2004.