

岡田哲弘 後藤文太郎
北見工業大学 情報システム工学科

1 はじめに

現在、WWWには膨大な数のWebページが存在している。それらのWebページは、ユーザにとって有用な情報を含んでいるものばかりではない。WWWのような広大な情報源から、ユーザが必要な情報を含んでいるページを発見するのは困難である。このような状況では、ユーザのWWW利用を支援するシステムが重要である。

ユーザのWWW利用を支援するシステムとして、ユーザのWWWへのアクセスのデータを蓄積し、それらのデータの統計情報などをWebページのコンテンツと統合することで、WWW利用を支援するシステム^[1]がある。[1]では、ブラウザにユーザのWWWへのアクセスのデータを獲得可能なプロキシを設定することで、ユーザのWWWへのアクセス毎に、アクセス先URLやコンテンツ、アクセス時間等のデータ(以降、アクセスデータ)をデータベース(以降、DB)へ蓄積することを可能としている。

さらに、アクセスデータには、ユーザがWWWを利用する上での特徴が反映されるため、それらのデータの機械学習への利用^[2]も行われている。[2]では、学習アルゴリズムとしてC4.5^[3]を採用し、DB中の1つのアクセスデータから1つの訓練事例を作成することで作られた、訓練事例集合による学習の実験が報告されている。学習結果の利用としてインテリジェントブックマークを提案し、その有用性が示されている。また、[2]では、複数のアクセスデータを利用した1つの訓練事例の作成についても述べられており、そのような訓練事例集合を用いることによる、学習結果の有用性の向上が提案されていた。

そこで本研究では、ユーザのアクセス履歴、および、利用したWebページ間に存在するリンク構造などを利用し、1つの訓練事例とする複数アクセスデータの決定を行い、複数アクセスデータを単位とした学習実験を行うことにより、その有用性の確認を試みた。

2 アクセスデータからの訓練事例の作成

2.1 C4.5

学習技法は[2]と同様にC4.5^[3]を採用している。C4.5とは、決定木学習技法の1つであり、属性とその値の対によって特徴付けられた大量の分類データ(訓練事例集合)から、ノードが属性、枝が属性値、葉がクラスに対応する、木構造の分類モデル(決定木)を帰納的に生成する技法である。生成された決定木を用いることで、未分類のデータ(事例)のあるクラスへ分類することができる。

2.2 アクセスデータからの情報の取得

C4.5での学習には、あらかじめ訓練事例集合を用意する必要がある。データベース中のデータは、訓練事例ではないため、学習に利用するためにはデータベースから訓練事例集合を作成する必要がある。そのためには、アクセスデータから、様々な情報に関する値を求めることが必要である。以下にアクセスデータから獲得可能な情報の種類と、その値を求める関数を示す。

アクセスデータから取得可能な情報

(A) Webページそのものの情報

情報	説明
freq_word(Word)	コンテンツ中の語句Wordの頻度
presence_word(Word)	コンテンツ中の語句Wordの存否
url	コンテンツのURL
link	コンテンツに含まれるリンク先URLの集合

(B) ユーザのWebページの利用情報

情報	説明
stay_time	Webページでの滞在時間
access_count	Webページへのアクセス回数
access_time	Webページへアクセスした時刻
day_of_the_week	Webページへアクセスした曜日

情報の値を求めるための関数

関数	説明
value(d , info)	データ $d \in D$ の情報infoの値。infoは前述の(A),(B)の情報。DはDB中の全データの集合を示す。

2.3 訓練事例の作成

アクセスデータの情報の値を用いて、訓練事例の作成を行う。訓練事例を作成するためには、属性とクラスがあらかじめ定義されている必要がある。以降、属性および、クラスが、図1のように設定されているものとする。

属性 属性の集合を $A=\{a1, \dots, an\}$ とする。各 $a \in A$ は $att(info, type, op)$ と表し、 $info, type, op$ はそれぞれ、属性とする情報、その情報の取りうる値のタイプ、複数データに対する属性値の設定で用いるオペレータを表す。また、以下の関数により属性 a の $info, type, op$ を求められる。

$info(a)=info$ $value_type(a)=type$ $operator(a)=op$

クラス クラスの集合を $C=\{c1, \dots, cm\}$ とする。各 $c \in C$ は、 $class(ClassName, Conditions)$ と表され、 $ClassName, Conditions$ は、それぞれ、そのクラスのクラス名、事例をそのクラスに割り当てる条件の集合を示す。それらは、以下の関数により求められる。

$class_name(c)=ClassName$
 $class_conditions(c)=Conditions$

クラスの優先度 $priority(C)=ClassList$
 $ClassList$ はクラス名のリスト。リストの先頭のクラスが一番優先度が高い。優先度の順にクラスの割当が行われる

クラスオペレータ $operator(C)=op$
複数データから事例を生成する際のオペレータ op を求める関数

図1 属性とクラス

このとき、訓練事例の作成は、図2の $\text{example}(Ds, A)$ により属性値を求められ、クラスは $\text{class}(Ds, C)$ により求められる。

```

Ds={d1,...,dk,...,dn} 任意のデータの集合

example(Ds, A)
E←{}, i←1
i≤nの間、以下を繰り返す
    vi←decide_value(Ds, ai)
    Eにai/viを追加, i←i++
return E

decide_value(Ds, a)
V←{}, k←1, in=info(a), op=operator(a)
全てのdk∈Dsに対し、以下を実行
    vk←value(dk, in) (1つのデータに対する値の計算)
    Vにvkを追加
return value_operator(V, op)

decide_class(Ds, C)
Cs←{}, op=operator(C)
全てのdk∈Dsに対し、以下を実行
    ck←class(dk, C) (1つのデータに対するクラスの計算)
    Csにckを追加
return value_operator(Cs, op)

value_operator(V, op)
op(sum, mean, max, min, major, minor)に従い、値の集合Vから、
総和、平均、最大値、最小値、最も頻度の高いもの、低いものの算出

```

図2 データ集合からの訓練事例の生成

2.4 複数データの集合の生成

複数データの集合の生成は、図3の $\text{traverse}(d, R)$ 関数により行う。全ての $d \in D$ に対し、 $\text{traverse}(d, R)$ を行うことで、訓練事例集合が生成される。

```

traverse(d, R)
R=r(R1, N, R2, R3, R4)
Ds←{}, u←value(d, url)
D1, D2, D3, D4, D5, D6←{}
D1←traverse_time(u, R1)
if N>0 {
    D2←S(D1, R2)
    全てのd∈D1に対し繰り返す
        D3←
            D3∪traverse(d, r(null, N, R2, R3, R4))
    D4←traverse_link(d, R3)
    D5←S(D4, R4)
    全てのd∈D5に対し繰り返す
        D6←
            D6∪traverse(d, r(null, N-1, R2, R3, R4))
}
return d∪D1∪D3∪D4∪D6

traverse_time(URL, R)=S(D, url=URL)∩S(D, R)

traverse_link(d, R)
Ds←{}, L←value(d, link)
全てのl∈Lに対し
    Ds←Ds∪traverse_time(l, R)
return Ds

S(D, t(P, A, B))={d∈D | value(d, access_time)>(P-A)
    ∧value(d, access_time)<(P+B)}
S(D, url=URL)={d∈D | value(d, url)=URL}
S(D, all)=D
S(D, null)={}

```

図3 複数データの集合の生成

3 実験

●データ

単一ユーザによる1ヶ月間のブラウジングにより蓄積された、438のデータ。

●属性とクラスの設定

実験では、属性として、全Webページにおける総出現頻度の上位1000語の各Webページ中の頻度を用い、クラスの設定には、Webページの滞在時間を用いた。滞在時間の長いページがユーザにとって有用であるものと考え、滞在時間60秒以上、30秒以上60秒未満、30秒未満の3つのクラスに分類した。なお、起点は、全Webページとした。

複数ページに対する属性値は、各Webページの属性値の平均とし、クラスは、複数Webページにおいて、最も頻度の高いクラスとした。

●実験結果

いくつかの設定による実験の結果を表1に示す。

設定	R1	N	R2	R3	R4
S1	null	1	n(near(self),1)	null	n(near(self),1)
S2	n(near(self),3)	1	n(near(self),3)	null	n(near(self),1)
S3	n(near(self),3)	2	n(near(self),3)	null	n(near(self),1)
S4	n(near(self),3)	0	null	null	null

設定	誤り	推定誤り率
S1	76(17.4%)	31.7%
S2	70(16.0%)	30.2%
S3	63(14.4%)	29.3%
S4	57(13.0%)	25.1%

表1 実験結果

●考察

複数データから1つの訓練事例を作成することで、誤りが少し減少している。しかし、複数ページ単位による学習の有効性を評価するためには、実験結果を詳しく解析する必要がある。

4 おわりに

本稿では、ユーザのWWWへのアクセス履歴、および、利用したWebページ間に存在するリンク構造などを用いた、複数データ単位の学習による学習結果の向上を試みた。

参考文献

- [1] 石川雅弘, 後藤文太郎, "WWWアクセス活動とWebコンテンツの情報統合", 第60回情報処理学会全国大会講演論文集(3), pp.157-158, 2000
- [2] 渥美尚絨, 後藤文太郎, "SPIRALへのC4.5による学習モジュールの統合", 北見工業大学大学院工学研究科修士論文, 2000
- [3] J.R.Quinlan著, 古川康一監訳, "AIによるデータ解析", トッパン, 1995