

WWW 有害情報のフィルタリングのための画像判別手法

Image discriminant method for filtering web pages with potentially harmful information

I-82

武者 義則† 広池 敦† 森本 康嗣† 松田 純一†

Yoshinori Musha Atsushi Hiroike Yasutsugu Morimoto Jyunichi Matsuda

1. まえがき

近年、インターネットの普及に伴い、年々急速にホームページ数が増大している。また、ホームページの作成・公開が匿名で可能なため、悪意をもったユーザが公開した不適正な内容でさえ、子供でも容易にアクセスできてしまう。一方、フィルタリングシステムが言論の自由を不当に制限してはならないという問題がある。そこで、W3C は情報発信を制限せず、第三者のレーティング情報に基づいて受信者が受信内容をコントロールする枠組みとして PICS を提案した¹⁾。しかし、レーティングは人的負荷が高く、web ページ数が“.jp”ドメインだけで年々1500~2000 万のペースで増大する状況の下では、その人的負荷の軽減や web ページの自動分類の技術が望まれている。今日、キーワードやテキスト情報を用いた自動フィルタリングシステムが実際に運用されている²⁾。

我々は、テキスト情報と画像情報を用いて web ページを分類するシステムを開発した⁴⁾。本システムはレーティング情報のない有害ページを自動的にフィルタリングし、またオペレータによる web ページの格付け作業を効果的に支援することができる。本稿では、本トータルシステムの構成と、特に web ページのための画像分類手法について報告する。また、フィルタリングと格付け支援の両ケースについて、画像判別に基づいた実験結果を示す。

2. フィルタリングのためのトータルシステム

本トータルシステムは、URL ベースのフィルタリングシステム、内容ベースのフィルタリングシステム、レーティング支援システムの3つで構成されている。図1にデータフローを示した。小さい子供の親を含むユーザは、あらかじめカテゴリ毎に望むレベルを設定しておく。RSACi レーティング基準を元に日本で拡張された SafetyOnline レーティング基準に基づき、5つのカテゴリ、(n), (s), (v), (l), (e), および各カテゴリに対して5段階 (0~4) のレベル基準が用意されている³⁾。その基準において、数の小




図1 トータルシステム

いレベルは、厳しいフィルタリングで子供を含むすべてのユーザに受け入れられるコンテンツを意味し、数の大きいレベルは緩いフィルタリングを意味する。ユーザが web ページにアクセスした時、まず URL ベースのフィルタリングシステムがその URL をチェックし、その格付け情報がユーザの登録したレベルより低ければユーザはアクセスできる。それ以外であればアクセスは拒否される。ただし、格付け情報がなければ、内容ベースのフィルタリングシステムがテキストと画像をチェックし、ユーザが登録したレベルにおける適不適の判定を行う。その際の web ページは URL 格付けデータベースへ保存され、格付け推定システムで推定された結果が格付け作業員へ示される。格付け作業員は、格付け属性を web ページに付与してデータベースへ格納する。その属性情報は URL ベースのフィルタリングに使われると同時に、内容ベースフィルタリングや格付け推定の精度向上に使われる。

3. 画像判別によるフィルタリングおよびレーティング支援

画像判別による内容ベースのフィルタリングシステムおよび格付け推定システムの構成を図2、図3に示した。両者とも同じ4つの(n)カテゴリのレベル境界判別システムと4つの(s)カテゴリのレベル境界判別システムを備えている。それぞれの判別システムは200次元の画像特徴量を用い、入力画像の特徴量と辞書中のラベル付けされた特徴量を比較することによって判別を行う。図2のフィルタリングシステムにおいて、(1)HTML ファイルに貼付された画像のうち64x64以上のサイズのみ選別される。(2)次に、ユーザが指定したレベル境界判別システムで画像が判別され、(3)その全ての画像の判別結果が適正の場合のみ HTML 単位の判定が適正となるよう統合される。これにより、HTML 単位の適正フィルタリングの精度が画像単位の精度よりも高くなり、不適正の再現率も高くなることが期待される。一方、図3の格付け推定システムの場合、前述(1)のサイズで選別された全画像が、全てのレベル境界判別システムによって判別が行われ、ベイズ推定によ




図2 内容ベースのフィルタリングシステム

† (株) 日立製作所中央研究所
マルチメディアシステム研究部




図3 レイティング支援システム

で各レベルの出現確率が計算される。我々はその確率をそのレベルの信頼度として扱う。そして、その全ての画像の最も高いレベルをHTMLファイルのレベルとするように、HTMLファイル単位で結果が統合される。

4. フィルタリングとレイティング推定の評価

我々は、画像判別に基づいた(A)フィルタリングと(B)格付け推定の実験を行った。

(A) HTMLファイルに貼付された6,383像を用意し、(n)カテゴリについて5つのレベル³⁾を付与した。更に、画像をHTML単位で2セットに分け、一方を学習セット、他方を評価セットとして用いた。図4は画像単位とHTML単位の精度を、図5は再現率を示す。例えば、(n234)判別システムは、n0, n1レベルを適正とみなし、n2, n3, n4レベルを不適正とみなす。全ての判別において、適正検出の精度と不適正検出の再現率で、HTML単位の方が高くなった。

(B) HTMLファイルに貼付された6,531画像を用意し、(n)カテゴリについて5つのレベルを付与した。更に、画像をHTML単位




図4 画像判別における適正検出（精度）




図5 画像判別における不適正検出（再現率）

表2 格付け推定における精度

	画像単位		HTML単位		レベル候補の閾値
	精度(%)	アクセプト(%)	精度(%)	アクセプト(%)	
n0	83.49	12.8	92.33	12.73	0.811
n1	11.24	13.15	10.15	12.11	0.095
n2	21.98	15.19	19.01	10.27	0.22
n3	20.42	13.65	10.26	11.28	0.19
n4	32.28	14.54	35.67	25.74	0.093
all	33.15	Reject=30.68	35.04	Reject=0.00	---

で学習セット、ベイズ学習セット、評価セットの3つに分け、これらの組み合わせで6回実験を行った。また、格付け推定の際に、精度向上を期待してリジェクト機能を使用した。各レベルにおいて相対的に低い信頼度を持つレベル候補をリジェクトする。また、各レベルにおいてアクセプト率が16%以下となるようにリジェクトの閾値を設定した。実際には画像全体のリジェクト率は30.68%となった。全レベルの中ではn0が最も高い精度となった。また、HTML単位の精度の方が画像単位よりも高いことを期待していたが、レベルn0, n4のみでその傾向が見られた。ほかのn1, n2, n3において、HTML単位の精度が低くなった理由として、アクセプト率の低下が考えられる。

5. おわりに

我々は、web ページをフィルタリングするトータルプロトタイプシステムを開発した。そのシステムは、web ページをフィルタリングするとともに、格付け推定により、格付け作業者を支援することができる。また、フィルタリングシステムと格付け推定システムの両方に、同じレベル境界判別システムを用いているため、両者の精度を同時に向上させることができる。特に、本システムは、ユーザが一度アクセスしたweb ページに類似したページに関し精度が向上するシステム構成となっている。更に、我々は画像判別に基づいたフィルタリングと格付け推定の実験を行った。本システムでは、HTMLに貼付された画像群に関して、HTML単位で評価することにより適正検出の精度と不適正検出の再現率を向上させることができた。フィルタリングにおいて適正検出がよい傾向にあるのは子供などを有害情報に触れさせたくないというSafetyOnline レイティング基準の主旨と合致している。とりわけ、WWW上に大量に氾濫し子供へ直接影響を与えてしまう不適正な画像情報を、画像自体によってフィルタリングすることは非常に重要である。しかし、格付け支援を効果的に行うためには、更に精度向上を行う必要がある。なお、本研究は総務省の認可法人である通信・放送機構(TAO)の委託研究³⁾として行われた。

参考文献

- 1) Internet Content Rating Association: <http://www.icra.org/>
- 2) 井ノ上, 帆足, 橋本: 文章自動分類手法を用いた有害情報フィルタリングソフトの開発, 信学論 D-II, J84-D-II, No. 6, pp.1158-1166, 2001.
- 3) 財団法人ニューメディア開発協会: <http://www.nmda.or.jp/enc/rating/index.html>
- 4) 武者, 広池: WWW有害情報のレイティング支援のための画像判別手法, 信学会総合大会, D-12-33, p.209, 3月, 2002.
- 5) 松田, 本城: 情報通信不適正利用対策技術の研究開発, 通信放送機構(TAO)平成14年度研究発表会予稿集<席上発表編>, pp.45-49, 5月, 2002.