

迷惑メール対策の現状と課題

2000MT034 泉澤 大資

指導教員 後藤 邦夫

1 はじめに

最近、PCや携帯電話に知らないアドレスからメールが来るが増えてきた。内容は、アダルトサイトやチェーンメールまで様々である。一日に数件程度ならよいが、何十件も来ると本来の有用なメールと区別しなければならず不便である。この迷惑メールの正体は「スパムメール」と言われる。現在のスパムの特徴として日に日に数が増えてきており、その種類も豊富になってきている。さらに英語のメールだけでなく日本語のメールも出始めている。本研究では、現在の対策から今後これらのスパムメールに有効となる対策について検討する。

2 スパムメールの現状

スパムの現状について述べる。

2.1 定義

『自分が望んでいない情報を一方的に送りつけてくるメール』のことをスパムメールという。

2.2 種類・目的

スパムは2種類に分類される。

1. UCE(Unsolicited Commercial Email):受信者に望まれない商業宣伝メール
2. UBE(Unsolicited Bulk Email):受信者に頼まれていない大量配信メール

スパムの目的を以下に示す。

1. アダルトホームページ宣伝
2. ねずみ講、マルチ商法
3. サイドビジネス勧誘
4. 商品の勧誘
5. 出会い系ホームページ勧誘

3 対策方法

スパムと非スパムを選別する「フィルタ」を用いた対策方法を検討する。

3.1 タイミング

メールの内容はユーザー毎に異なるため、その個人にあったユーザー独自のフィルタ作成が望ましい。そのため、MUAが受信した後に、フィルタリングする。

3.2 方法・手順

方法・手順を以下に示す。A Plan for Spam[1]、Better Bayesian Filtering[2]を使用した。

作成方法

メールの解析する対象を「ヘッダ、本文」とし、「バイナリの添付ファイル」は対象外とする。この対象情報から、ベイズの定理を用いてフィルタを作成する。確率が0でない事象AとBに対して、条件付き確率の定理より、次式が成り立つ。

$$P\{A|B\} = \frac{P\{A\}P\{B|A\}}{P\{B\}} \quad (1)$$

このベイズの定理より、 $B = (B \cap A) \cup (B \cap \bar{A})$ と $(B \cap \bar{A})$ は互いに素な事象であるから次式を得る。

$$P\{A|B\} = \frac{P\{A\}P\{B|A\}}{P\{A\}P\{B|A\} + P\{\bar{A}\}P\{B|\bar{A}\}} \quad (2)$$

計算の手順

1. 準備

大量のスパムメールと非スパムメールを用意し、それぞれに出現する単語の回数とメールを読み込んだ回数を数える。

ヘッダ内の単語は属性をつけて表す。例えば“Subject”に含まれる単語であれば“Subject*単語”とする。“o”を“O”、“a”を“@”等の類語は、別の単語として数える。

2. 単語のスパム確率 P を求める。

スパムメールに含まれる単語の割合と非スパムメールに含まれる単語の割合から判別したいメールの単語のスパム確率を計算する。

- 読み込んだ(学習)スパム数 ($snum$)
- 読み込んだ(学習)非スパム数 ($cnum$)
- 単語がスパムに現れた回数 (s)
- 単語が非スパムに現れた回数 (c)

誤検出を避けるために値を設定する。

- 非スパム中の単語の回数を2倍にする。
- 全体で5回以上出現していない単語は計算から外す。
- 一度も現れていない単語のスパム確率を0.4とする。

- 一方の集合にのみ現れる単語の確率はそれぞれ 0.001 と 0.999 とする。
- ベイズの定理 (2) 式を用いてスパム確率 P を求める。

$$P = \begin{cases} \frac{\min(1.0, \frac{s}{snum})}{\min(1.0, \frac{2c}{cnum}) + \min(1.0, \frac{s}{snum})} & (2c + s > 5) \\ 0.4 & (others) \end{cases} \quad (3)$$

3. 結合確率を求める。

メール中の 0.5 から最も離れている単語 (もっとも特徴的な単語) n 個のスパム確率を ($P_1 \sim P_n$) とし、以下のように結合確率を求める。

確率が 0 でなく互いに独立しており、かつ確率に対称性がある事象 P_1, P_2, \dots, n に対して次式が成り立つ。

$$\frac{P_1 * P_2 * \dots * P_n}{P_1 * P_2 * \dots * P_n + (1 - P_1) * (1 - P_2) * \dots * (1 - P_n)} \quad (4)$$

結合確率が 0.9 以上ならば、そのメールをスパムと判定する。

3.3 既存フィルタの手法と比較

- コンテンツ (ルールベースフィルタ)

あるルールに従ってメールに点数をつけて判定する。あらかじめ点数が決まっているため、計算が高速である。しかし、新たな種類のスパムに対応できない。ベイズ理論のフィルタはデータに応じて自己修正できる。
- ホワイトリスト・ブラックリスト

受信を許可、拒否するホストのリストを用いて判定する。他のフィルタと併用することで、計算を軽減することができる。

4 実装

日本語のスパムメールに対応するために日本語解析ツール「kakasi」を用いる。「kakasi」とは、漢字かなまじり文をひらがな文やローマ字文に変換し、単語毎に分割するツールである。

4.1 処理の流れ

学習 (データベースに保存)

- 大量のスパムメールと非スパムメールを用意する。(日本語メールに対して「kakasi」を用いて日本語解析する。)
- データベースを用意し、学習したメール数と単語の出現回数を保存する。
- 計算式 (3) からスパム確率 P を求め、値をデータベースに保存する。

判定 (スパムと非スパムを判定)

- 判別したいメールを単語毎に読み込む。
- それぞれの単語のスパム確率 P をデータベースから参照し、特徴的な単語 n 個を選び出す。
- 計算式 (4) から n 個の単語の確率を結合して判別する。
- 判定結果に基づき、データベースを更新する。
- スパムメールと非スパムメールを振り分ける。

5 評価

計算した単語のスパム確率 P の例を以下に示す。

| words | スパム確率P | | |
|-------|----------------|-------|----------------|
| 研究室 | 0.001 | ※ | 0.999 |
| 検出 | 0.001 | 販売 | 0.999 |
| 時間 | 0.162627052384 | こちらまで | 0.999 |
| 方法 | 0.071013845466 | 希望 | 0.890410958904 |
| 次回 | 0.132610508757 | ください | 0.871794871794 |

図 1 日本語の単語のスパム確率

| words | スパム確率P | | |
|-----------|-------------|-----------|-----------|
| perl | 0.001 | madam | 0.999 |
| scripting | 0.001 | promotion | 0.999 |
| describe | 0.001 | cgi | 0.9734398 |
| example | 0.033600237 | enter | 0.9075001 |
| I'm | 0.055427782 | quality | 0.8921298 |

図 2 英単語のスパム確率

6 おわりに

今後の改善策は、ベイズのフィルタは学習に応じて自己修正可能であり、より確実な確率を引き出せるということから、まず多くのメールを学習することである。また、計算中に設定した値の修正である。さらに、複数のフィルタを用いることによって、計算を軽減させることができる。このようにして、これから増えてくるであろう多種多様なスパムメールに対応できるのではないかと考える。

参考文献

- [1] Paul Graham, A Plan for Spam, <http://www.paulgraham.com/spam.html/>, 2002.
- [2] Paul Graham, Better Bayesian Filtering, <http://www.paulgraham.com/better.html/>, 2003.