

特徴抽出によるフィルタ通過スパムメールの低減

Decrease of unfiltered spam mails by feature extraction

渡邊 隆志[†] 佐藤 直[†]

Takashi Watanabe Naoshi Sato

1. まえがき

スパムメールの特徴に着目し、非スパムメールとして誤判定されたスパムメール（以下通過スパムメールと呼ぶ）を削減することを提案する。通過スパムメールを調査したところ、件名と本文が類似している、本文の文字数が少ない、本文中に URL が含まれている、といった特徴があることがわかった。そこで、件名と本文の類似度、本文の文字数、URL の有無という 4 つの特徴量を機械学習し分類する手法を提案する。実際に受信した電子メールを対象に実験を行って提案の有効性を確認した。

2. 研究の背景、目的、関連研究

汎用的に使用されているメールクライアントソフトは、ベイジアンフィルタを搭載し、本文の内容（コンテンツ）を機械学習してスパムメールをフィルタリングする[1]。フィルタリングされたスパムメールは専用のフォルダに分類されることが多い。しかし、このコンテンツベースのフィルタリングには、単語の改変などにより容易にフィルタリングを通過できる、本文が短いスパムメールには対応できない、といった問題がある。実際、著者らの経験では、スパムメールを学習させたにもかかわらず、それらに類似した多くのスパムメールが通過スパムメールとして非スパムメールとともに受信箱に残ってしまうという現象が見られる。そこで、本研究は、スパムメールに関する本文の内容以外の特徴にも着目し、スパムメールの判定基準にすることで通過スパムメールを削減することを目的とする。

なお、関連研究として以下のような報告がある。すなわち、受信者の存在、送信者のドメイン、メールサイズ、URL の有無、同じ IP アドレスからの送信頻度、昼夜別の受信時刻といったスパムメールの行動の特徴からファジー決定木でスパム判定をする手法[2]、スパム／非スパムメール中で使用される単語の辞書をそれぞれ作成し、Jaro-Winkler 距離を使ってメール本文と辞書にある単語の距離を測定し同距離のマップを作成して判定する方法[3]、などがある。

しかし、本研究のように、通過スパムメールの低減に着目したフィルタリング手法の検討は見受けられない。そこで、以下では、従来の手法も参考に、特徴抽出による通過スパムメール低減法を検討する。

3. 電子メールの収集

著者の一人が使用している汎用 PC に搭載されているメールクライアントを利用して、約 10 ヶ月にわたって 21,128 件のメールを収集した。そのうち 5,000 件を非スパムメール、16,128 件をスパムメールと主観的に判定した。スパムメールのうち 15,594 件がメールクライアントに備わっているフィルタリング機能でフィルタリングされたスパムメール、534 件が通過スパムメールである。

4. 通過スパムメールの特徴

通過スパムメールを目視したところ、フィルタリングされたスパムメールとの件名と本文が類似しているものが多いことがわかった。また、本文中に URL が含まれていることや、本文の文字数が少ない、といった特徴があることも分かった。そこで、これらの特徴をスパム判定に用いることとする。件名や本文といった文字列の類似性を調べるアルゴリズムは、大きく文字ベースと単語ベースに分けられる[4]。単語ベースは形態素解析が必要になること、また、複数の区切り方がある場合や、未知語などが含まれている場合は解析精度が悪くなるため、ここでは文字ベースとする。文字ベースのアルゴリズムとしては、スパムメールの解析によく利用される Jaro-Winkler 距離を用いる。

5. 特徴量

収集された電子メールについて前述の 4 つの特徴量を調べた。以下代表的な結果を示す。

(1) 件名の類似度

Jaro-Winkler 距離を用いて件名の類似度を測った結果を図 1～図 3 に示す。




図1 通過スパムメールのみの件名の類似度




図2 通過スパムメールとフィルタリングされたスパムメールの件名の類似度







図3 通過スパムメールと非スパムメールの件名の類似度

[†] 情報セキュリティ大学院大学

図 1 は通過スパムメールのみのもので、類似度 95%以上のメールが大多数を占めていることがわかる。図 2 は通過スパムメールとフィルタリングされたスパムメールを合わせたもので、図 1 との比較から、フィルタリングされたスパムメールの類似度は 70%前後のものが多いことがわかる。図 3 は通過スパムメールと非スパムメールを合わせたもので、非スパムメールは通過スパムメールの 10 倍ほどあるため、同図から、非スパムメールの類似度は 55%前後のものが多いことが読み取れる。

(2) 本文の類似度

同様に本文の類似度を測った結果を図 4～図 6 に示す。図 4 は通過スパムメールのみのもので、類似度 95%以上のメールが殆どであることがわかる。図 5 は通過スパムメールとフィルタリングされたスパムメールを合わせたもので、図 4 との比較から、フィルタリングされたスパムメールの類似度は 60%前後のものが多いことがわかる。図 6 は通過スパムメールと非スパムメールを合わせたもので、(1)と同じ理由で、非スパムメールの類似度は 50%前後のものが多いことがわかる。



(3) 本文の文字数

本文の文字数を数えたところ、スパムメールは通過スパムメール、フィルタリングされたスパムメールともに最大 2000 字程度で 300 字未満のものが殆どを占めていることがわかった。一方、非スパムメールは最大 200000 字程度まで分布し、10000 字以内のものが多いことがわかった。

(4) URL の有無

本文中の URL の有無を調べたところ、スパムメールは

通過スパムメール、フィルタリングされたスパムメールともに URL を含む傾向が強いのにに対し、非スパムメールは URL を含まないものが多数を占めていることがわかった。

6. 機械学習による通過スパムメールの判別実験

以上の検討から、通過スパムメールと非スパムメールの間には、4 つの特徴量について違いのあることがわかった。そこで、同一の受信メールフォルダに収容されている両者を 4 つの特徴量を用いた機械学習で判別する。この機械学習には、2 種類の識別性能に優れているサポートベクターマシン SVM を用いる。具体的にはツール LIBSVM[5]を用いる。前述のように収集した通過スパムメールと非スパムメールをランダムに二分し訓練データとテストデータとする通過スパムメール判別実験を実施した。その結果、通過スパムメールの検出率 (正答率) は 95.1%, 非スパムメールの検出率は 99.8%であった。これは、現在の、コンテンツフィルタリングを経て受信メールフォルダに保存されるメールに本提案を適用することによって、非スパムメールとして誤判定され保存されるスパムメールの約 95%が低減可能であることを意味する。一方、本提案は非スパムメールの 0.2%をスパムメールとして誤判定するリスクがあることも分かった。

なお、本研究は、通過スパムメールの低減を図る目的で実施した。上記判別実験が比較的良好な結果を示したことから、参考のため、収集した全てのメールを対象に、コンテンツフィルタリングを経ずに、同様にスパムメール/非スパムメールの判別実験を行った。その結果、スパムメールの検出率は 99.6%, 非スパムメールの検出率は 99.8%, となり、本提案が従来のコンテンツベースのフィルタリングを代替できるという見通しを得た。

7. むすび

本研究は、通過スパムメールを削減することを目的に、件名と本文の類似度、本文の文字数、本文中の URL の有無という 4 つの特徴量を使用して機械学習でメールを分類する手法を提案した。実験の結果、既存のフィルタリング機能に提案手法を追加することによって、通過スパムメールを大幅に削減できることを確認した。また、提案手法が既存のフィルタリング機能を置換できる可能性を示した。

文 献

- [1]田端利宏: SPAM メールフィルタリング: ペイジアンフィルタの解説, 情報の科学と技術, Vol. 56, No. 10, pp. 464-468, 2006
- [2]W.Meizhen, L. Zhitang and Z. Sheng: Fuzzy Decision Tree Based Inference Technology for Spam Behavior Recognition, ISPA, pp. 463-468, 2009.
- [3]R.Ariaeinejad and A.Sadeghian: Spam detection system: A new approach based on interval type-2 fuzzy sets, Electrical and Computer Engineering, pp. 379-384, 2011.
- [4]W.Gomaa and A.Fahmy: A Survey of Text Similarity Approaches, International Journal of Computer Applications, Vol. 68, No. 13, pp. 13-18, 2013.
- [5]LIBSVM -- A Library for Support Vector Machines, <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>