

L-030

## ユーザのメール閲覧サイクルを考慮した遅延評価による迷惑メール検出率の調査 Analysis of spam Mail Detection Rate with Delay Evaluation on Cycle of Fetching Mail

奥村 慎太郎<sup>†</sup>  
Shintarou Okumura

鈴木 康介<sup>‡</sup>  
Kousuke Suzuki

松澤 智史<sup>†</sup>  
Tomofumi Matsuzawa

武田 正之<sup>†</sup>  
Masayuki Takeda

### 1. はじめに

近年、電子メールの快適な利用を妨げる問題として迷惑メールが挙げられる。symantec社による2008年5月の迷惑メールに関するレポート[1]によると、全世界のメールの80%以上が迷惑メールであるとされている。これらは社会への経済的被害[2]を与えている。迷惑メール被害の例として、正常なメールとの選別に消耗する時間が挙げられる。また同社の調査で、2006年の企業における迷惑メールの処理時間は従業員1人あたり平均4.4分/日であり、迷惑メール受信比率が30%を超える企業では平均11.2分/日かかることも判明している[2]。こういった迷惑メールを拒否するために、迷惑メールフィルタを用いたフィルタリングと呼ばれる手法が存在する。フィルタはサーバ側で行うものとクライアント側で行うものの2種類があり、サーバ側で行う代表的なものとして事例ベース型フィルタ、IPアドレスフィルタがある。しかしフィルタリングは、迷惑メールフィルタの種類によってはFalse Positive(正常なメールを迷惑メールだとする誤判定)が無視できない量で発生するという短所も存在する。よって迷惑メールフィルタは検出率が高く、かつFalse Positiveの発生確率が低くあることが望ましい。

### 2. 既存の迷惑メールフィルタ

#### 2.1 事例ベース型フィルタ

ある迷惑メールを受け取ったユーザが、迷惑メールに記載された URL などの特徴からチェックサムを計算してユーザ間で共有するデータベースに登録し、後に同じ迷惑メールを受信したユーザが、チェックサムを計算しデータベースに問い合わせることで迷惑メールをブロックする手法である。このフィルタリングはユーザが既知の迷惑メールを登録するという特性上、時間の経過によってデータベースが充実し、かつ False Positiveは無視できる程小さくなるという利点がある。しかし初見の迷惑メールには対応できないため、検出率は比較的低くなる。松浦らの研究[3]によれば、事例ベース型フィルタの1つである Pyzor を用いて実験した場合、False Positiveは0.0%であったが、検出率は67.8%と低い数値になったと報告されている。

#### 2.2 IP アドレスフィルタ

不当なメールの中継を許すサーバの、IPアドレスを列記したデータベース(ブラックリスト)をフィルタとして用いることで、迷惑メールを遮断する手法である。このようなデータベースはDNSBL(DNS Base Blackhole List)と称され、運用するサービスが世界中に存在していること、常に更新

<sup>†</sup> 東京理科大学 理工学部 情報科学科

Dept. of Information Sciences, Tokyo University of Science  
distinct@mt.is.noda.tus.ac.jp

<sup>‡</sup> 清水建設株式会社 SHIMIZU CORPORATION

され続けていること、DNSBLの組み合わせによって検出率の向上が見込めることが特徴である。迷惑メールの送信元IPアドレス4071件と、正常なメールサーバのIPアドレス186件を7種類のDNSBLに問い合わせた結果、1種類のDNSBLに検出された迷惑メールは全体の91.8%(False Positiveは6.4%)、2種類に検出されたメールは76.6%(0.5%)、3種類に検出されたメールは60.6%(0.0%)であった。しかしこの手法も事例ベース型フィルタと同様に、初見の迷惑メールには対応できないという欠点がある。

### 3. 遅延評価

事例ベース型フィルタとIPアドレスフィルタは、時間経過によってフィルタリングのデータベースが充実するという共通点を持つ。よってこれらの手法では、検出を行う時間を、メールがメールサーバに到着した時刻からユーザがメールをダウンロードする時刻へと遅延させることで検出率の向上が見込める。この手法は遅延評価と呼ばれ、漣らによる小規模の実験で報告されている[4]。

また松浦らの報告[3]によると、和歌山大学システム工学部のメールサーバで遅延評価を運用させたところ、148,206通の迷惑メールに対して、遅延評価を用いない場合は112,731通(76.1%)が検出できたが、用いた場合は8,604通(5.8%)多く検出できたとされている。

### 4. 本研究の目的

遅延評価はメールの到着時刻からユーザがメールをダウンロードするまでの待ち時間を利用するため、迷惑メール検出率はユーザのメール閲覧時刻や閲覧間隔に左右される。したがって検出率はユーザの環境やライフスタイルによって大きく変化すると考えられる。またユーザの環境やライフスタイルが検出率に影響を与えるのであれば、検出率の大小は、ユーザの属するユーザ群(例えば学生、社会人など)によって大別される可能性もある。ユーザ群毎に遅延評価が有効であるかどうかを知ることができれば、それを遅延評価システム導入時の指標と考えることが可能である。

### 5. 実験及びその評価

#### 5.1 実験環境及び実験手法

IPアドレスフィルタにおいて、各ユーザ及びユーザ群に対して遅延評価が有効に働くかどうかをシミュレートした。ユーザは本学教員18名と学生29名の計47名、ユーザ群は教員と学生の2つを対象とした。

実験を行うにあたって迷惑メールの到着分布が必要となるので、2008/5/27~2008/6/30に収集した迷惑メール3,314通の到着時刻を、1日を基準とした秒数(0秒から86,400秒)で抽出し、1日に3,314通全てが到着するものとして分布を作成した。また3,314通の迷惑メールを、それぞれ24時

