

教師なし Random Forests を用いた 迷惑電話発信者分類法の検討

豊田 健太郎^{1,a)} 笹瀬 巖^{1,b)}

概要: IP 電話の普及に伴い、販売促進および宣伝といった迷惑電話の出現が問題視されている。着信側は電話に応答して初めてその電話が迷惑電話であるかを判定できるため、迷惑電話を着信前に判定することは、事前に内容を確認できる E メールのスパム判定より困難である。これまで、通話頻度、平均通話時間などの特徴量を用いて、迷惑電話を発信するアカウントを判別する方式が検討されてきた。しかしながら、迷惑電話発信者は複数アカウントを用いることにより、これらの判定方式を用いた場合の判定精度を低減できる。これは従来提案されてきたいずれの手法も単一の特徴量毎に判定を行っているため、各特徴量の閾値の設定が困難になるためである。そこで本論文では、多くのユーザが 1 つの SIP サーバを利用することに着目し、教師なし Random Forests に複数の特徴量を入力し、各ユーザの通話の特徴に関する類似度を基に迷惑電話を発信するアカウントを分類する方式を提案する。教師なし Random Forests を用い、複数の特徴量を用いて各ユーザ間の類似度から分類を行うことで、発信の特性が異なる迷惑電話発信者を、事前学習なしで分類することが可能となる。また、迷惑電話発信者が発信する相手は通話毎に異なり、その通話先から電話が掛け返される割合が低いことに着目し、これらの割合を顕著に表す特徴量を 2 つ提案する。実際の通話記録およびコンピュータによって生成された通話データを用い、本方式の有効性を示す。

キーワード: 迷惑電話発信者分類, Random Forests

SPIT Callers Detection with Unsupervised Random Forests Classifier

TOYODA KENTAROH^{1,a)} SASASE IWAO^{1,b)}

Abstract: As VoIP (Voice over IP) grows rapidly, it is expected to prevail tremendous unsolicited advertisement calls, referred to SPIT (SPam over Internet Telephony). SPIT detection is more difficult to execute than email SPAM detection since the callee or SPIT detection system does not tell whether it is SPIT or legitimate call until he/she actually takes a call. Recently, many SPIT detection techniques are proposed by finding outliers of call patterns. However, most of these techniques suffer from setting a threshold to distinguish that the caller is legitimate or not and this could cause high false negative rate or low true positive rate. It is because these techniques analyse call pattern by a single feature *e.g.* call frequency or average call duration. In this paper, we propose a multi-feature call pattern analysis with unsupervised Random Forests classifier, which is one of the excellent classification algorithms. By introducing unsupervised Random Forests, we calculate the proximity among users to be classified and detect several types of SPIT callers without a training data. We also propose two features that exploit the fact that a victim differs every call and few people call back to its SPIT caller. We show the effectiveness of Random Forests based classification without supervised training data and which features contribute to classification.

Keywords: SPIT caller detection, Random Forests

1. はじめに

近年、格安な料金体系で利用できる IP 電話 (VoIP : Voice over IP) が普及し始めている。格安で通話が容易になった一方、販売促進および宣伝といった迷惑電話 (SPIT : SPam over Internet Telephony) の出現が問題視されている [1]。電子メールにおける広告であるスパムの対策は、受信者がメールを受信する前にサーバ側でメールの内容を確認することで、そのメールがスパムであるかを判定することが可能である。しかしながら、電話の場合、受話者が実際に電話に出るまで内容を把握することができないため、その通話が迷惑電話であるかを判定することが困難である。そこで、発信者の通話の特徴から、その発信者が迷惑電話の発信者であるかを判別する方法が検討されている。例えば、Shin 等は通話の頻度に基づいて発信者を判別する方法を [2]、Waiting 等は迷惑電話発信者の通話時間の分布が正規分布に従わないという仮定のもと、Lilliefors 検定を用いる方法を提案している [3]。しかしながら、迷惑電話の発信者は検知されることを免れるため、これらの特徴量が突出しないように工夫することは容易である。例えば、複数のアカウントを使用することにより、1 アカウントあたりの通話の頻度を抑えることができる。また複数のアカウントと結託することで、架空の通話を確立させることで平均通話時間を伸ばすことも可能である。このように、迷惑電話の発信者もモデルは様々なタイプが考えられるため、これらの方法のように 1 つの特徴量に注目して発信者判別を行うことは高い誤検知率をもたらす問題がある。この問題を解決するためには、複数の特徴量を用いて分類を行う必要がある。そこで本論文では、教師なし Random Forests を用い、各ユーザ間の類似度を算出し、この類似度を PAM (Partitioning Around Medoids) クラスタリングによって 2 つのクラスに分類することにより迷惑電話発信者と正規の発信者を分類する方式を提案する。Random Forests は、サイズの大きなデータに対して効率良く動作し、事前に設定するパラメータが少なく、また複数の特徴量を扱え、非常に精度が高い学習手法である [4]。Random Forests は事前に訓練データを用いて学習を行う教師あり学習と訓練データを用いない教師なし学習がある。本提案では教師なし学習を用いる。これは、選択される訓練データによってはイベントなどの季節成分により通話の特性に影響するため、分類精度が変化する可能性があること、また事前に全ての種類の迷惑電話発信者の統計を把握することが困難なためである。そこで、1 つの SIP サーバは複数のユーザが利用することに着目し、ユーザ間の通話の特

性に関する類似度を用いて分類を行う。これにより、訓練データの季節成分の影響を抑え、かつ事前に迷惑電話発信者の統計を把握しなければならない問題を解決する。教師なし Random Forests と PAM クラスタリングを用いた分類手法は、医学の分野におけるバイオマーカーへの適用に提案されている [5]。しかしながら、現在のところ発信者の分類への適用例は見られない。また、迷惑電話は毎回異なる相手先に通話を行い、相手先から電話が掛け返される確率は非常に低いことに着目し、迷惑電話発信者が細工するのが困難である特徴量として BDR (Bi-Direction Ratio) および IOR (Incomings/Outgoings Ratio) を提案する。BDR は発信者が発信した相手先から着信した割合を、IOR はあるユーザが発信した相手先およびあるユーザに電話を掛けたユーザの和集合のうち、それらの積集合の割合をそれぞれ示す。例え迷惑電話発信者が複数のアカウントと結託し、BDR および IOR の低さを改善しようとしても、日々相手先の件数は増えるため、それに応じて日々多くの新規アカウントを用意しなければならない。提案方式の有効性を示すために、通話履歴の日数と TP (True Positive) 率および FP (False Positive) 率の関係、各特徴量がどの程度分類に貢献しているかを示す重要度を評価する。評価を行う上で、正規のユーザの通話統計として MIT Media Lab が収集した Reality Mining データセットによる実際の通話記録を用い、迷惑電話の発信として結託アカウントを使用した場合としない場合および 5 種類の通話の頻度を基にした計 10 種類の人口データを用いる。特性評価により、本シミュレーション環境において通話データの収集期間が 6 日程度で約 90% の TP 率および 0% の FP 率、14 日程度で約 96% の TP 率および 0% の FP 率を得ることができる。また 2 つの特徴量 BDR および IOR は評価日数が増えるに従い、重要度が増すことを示す。

以下 2 章ではこれまで研究されてきた発信者の通話の特徴を用いた発信者の判別方法、および迷惑電話発信者および正規の発信者の特徴量について述べた上でそれらの方式の問題点を挙げる。3 章では提案方式を説明する。4 章では特性評価を示し、5 章で結論をまとめる。

2. 関連研究

これまで、発信者の特徴量を用いて迷惑電話発信者を判別する方式として、以下の方式が検討されている。

Shin 等は、正規の発信者よりも迷惑電話発信者の通話頻度が高いことを仮定し、長期的な期間内の通話頻度と短期的な期間内の通話頻度に対してそれぞれ閾値を設け、スコアが閾値を越えた場合、発信を拒否する方式を提案している [2]。この方式では、通話頻度を基にしたスコアを用意し、通話がない場合は時間経過とともにスコアが低下するが、一度閾値を越えたアカウントに対してはスコアの減少の割合を低くすることにより、迷惑電話発信者が再び発信

¹ 慶應義塾大学 理工学部 情報工学科
Dept. of ICS, Information and Computer Sciences, Keio University
a) toyoda@sasase.ics.keio.ac.jp
b) sasase@ics.keio.ac.jp

表 1 迷惑電話発信者の特性

Table 1 Characteristic of SPIT callers.

パラメータ	値
1日あたりの通話頻度	25, 50, 100, 500, 1000 回
通話時間	平均 15 秒の指数分布に従う
発信先から掛かってくる割合	10%
結託する人数	5 人
結託相手との平均通話時間	30~300 秒

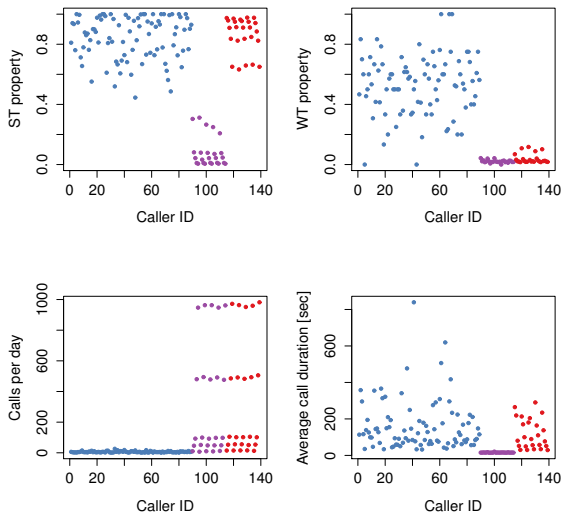


図 1 正規のユーザと迷惑電話発信者の 7 日分の通話履歴より算出された各特微量

Fig. 1 Each feature of legitimate callers and SPIT callers calculated from 7 days call data.

を行うのを困難にする。

Waiting 等は、正規の発信者の通話時間はガウス分布に従う一方、迷惑電話は正規の通話と比較して通話時間が短くなると仮定し、収集した発信者の通話時間のデータに対して Lillifors 検定を行い、その分布のあてはまりの良さを用いて発信者を判別する方式を提案している [3]。また彼等は迷惑電話の発信者の通話頻度が高いことを、FFT(Fast Fourier Transform) を用いて検出する方式も提案している。

Kusumoto 等は、迷惑電話発信者と正規の発信者では人間関係が異なることから、発信先との関係を数値化することにより発信者の判別を行うことを提案している [6]。この方式では、クラスタリング係数 (Clustering Coefficient) [7] を応用させ、発信先のユーザ間同士に発信があるかどうか、また発信の方向性、通話時間に重みを付けることにより、一方向の発信、発信先同士の繋がり、通話時間の短さに対してスコアが低くなるようにしている。

Bokharaei 等は、北米における実際の通話データセットより、正常な発信者と異常な発信者において 2 つの特微量が異なることを指摘している [8]。1 つ目は、正規の発信者の多くは全通話時間のうち 80% 以上を特定の 4~5 人との通話が占めており、この特性を ST (Strong Ties) property としている。2 つ目は、異常な発信者は平均 60 秒以上の通話を行う相手の割合が非常に低いことを挙げ、この特性を WT (Weak Ties) property としている。

2.1 迷惑電話発信者および正規ユーザの特徴

ここで、図 1 に正規のユーザと迷惑電話発信者の 7 日分の通話履歴より算出された各特微量を示す。図 1 において、

青色で示された点が正規ユーザ、紫色で示された点が迷惑電話発信者、赤色で示された点が複数アカウントおよび結託者を用いた迷惑電話発信者の各特微量を示している。ここで、正規ユーザとして、MIT (Massachusetts Institute of Technology) Media Lab が収集した計 94 名分の学生、スタッフおよびビジネススクールの学生の実際の通話履歴データセット Reality Mining のうち、7 日以上通話履歴を有する 89 名分を用いている。一方、現在のところ、迷惑電話発信者の通話履歴に関するデータセットは存在しないため、迷惑電話発信者の通話統計は表 1 に従って生成した 10 種類 (1 日あたりの通話頻度 5 種類に対して結託する場合およびしない場合)、各 5 アカウントずつの計 50 アカウント分の人口データを用いている。表 1 において、1 日あたりの通話頻度の上限および下限は以下の仮定から算出される。迷惑電話は当然着信側が電話を取れることを期待するため、電話を掛ける時間帯は 9 時~17 時とする。また 1 回のダイヤルに 30 秒要すると仮定すると、1 アカウントあたり最大約 1000 回の通話が考えられる。しかし、1 日 1000 通話を行うと頻度が高いため、例として 40 アカウントを有する迷惑電話発信者を仮定すると、1 アカウントあたり 25 回となる。また迷惑電話は多くの受け手にとって興味の薄いものであると考えられ、平均通話時間は正規のユーザの平均通話時間よりも短くしている。同様に発信先から電話が掛け直される割合も低いと考えられ、10%とした。ここで結託とは、迷惑電話発信者が迷惑電話を発信していない時間に低下した平均通話時間をより正規のユーザに近づける、もしくは上述の [8] にて提案されている ST property を細工するために行われる。結託する人数を 5 人としたのは、ST property が全通話時間のうち上位 5 人が占める通話時間の合計の割合が高いことを欺くためである。図 1 より、いずれの特微量も複数アカウントおよび結託者を用意することにより、各特微量による正規ユーザと迷惑電話発信者の判別を困難にすることが可能であり、これにより閾値を用いた判別法の精度が低減する問題がある。これは現在提案されている判別手法が、単一の特微量に着目しているためである。したがって、複数の特微量を用いた新しい迷惑電話発信者の識別方法の検討が必要である。

3. 提案方式

そこで、本論文では複数の特微量を Random Forests に

入力することで、各ユーザ間の類似度を算出し、PAM クラスタリングを用いて算出された類似度からクラスを2つに分類することで各ユーザが正規であるか迷惑電話発信者であるかを判別する方式を提案する。教師なし Random Forests を用いることによって、事前に学習が必要ないこと、比較的大きなサイズのデータに対しても動作すること、高い精度での分類が可能となる。Random Forests と PAM クラスタリングを使用した手法は医学の分野においてバイオマーカーへの適用を目的として提案されている [5]。しかしながら、発信者の分類に対する適用例は現在のところ存在しない。また Random Forests に入力する特徴量として、迷惑電話発信者が細工しづらい2つの特徴量 BDR および IOR を提案する。BDR は発信者が発信した相手先からの程度着信したかを表す値であり、IOR はあるユーザが発信した相手先およびそのユーザに電話を掛けたユーザの和集合の数のうち、それらの積集合の数がどの程度の割合いるのかをそれぞれ示す。これらの特徴量は、迷惑電話は同一の相手先に発信されることおよび相手先から折り返し電話が掛かる頻度が低いことを表すために用いられる。

以下、Random Forests の説明、提案方式において用いた特徴量および本提案方式の実装場所について述べる。

3.1 Random Forests

Random Forests は複数の決定木を用い、それぞれの決定木から得られる結果を組み合わせることにより識別、回帰を行うアンサンブル学習の一つである。元のデータから重複を許し N 個のデータをランダムにサンプリングし、 M 個の特徴量のうち、ランダムに M_{try} 個の特徴量を選択し、決定木を T 本、生成する。そして判別したいデータを生成した各決定木に入力し、各決定木が出力する確率が最も高いクラスに分類する。以下に Random Forests の特徴を示す。

- (1) サイズの大きいデータに対して効率的に動作する
- (2) 特徴量を削除することなく数千もの特徴量を扱える
- (3) どの特徴量がどの程度分類に貢献しているかを推定できる
- (4) クラス毎のデータ量が均一でなくても、クラス毎にエラー率を均一にできる
- (5) 入力したデータ間の類似度を計算できる

また、Random Forests は教師データの必要ない学習が可能であり、本研究では発信者の分類に教師なし Random Forests を用いる。仮に教師あり Random Forests を用いる場合、事前に発信者が正規であるか迷惑電話の発信者であるかがラベル付けされた教師データが必要である。これまで、迷惑電話発信者をおとりを用いて検知するシステムが提案されている [9] が、この手法ではあらかじめ発信者のリストを保持している発信者を特定することはできず、全ての迷惑電話発信者の通話特性を把握することができ

ない。また通話の終端時にフィードバック・メッセージを返すシステムを検討することも考えられるが、SIP のメッセージ・フォーマットを変更するため、SIP のサーバおよび端末の双方に変更を加える必要があり、導入が困難である。また通話の性質上、季節成分による変動も考えられるため、学習データ更新の必要もある。以上の点から、本研究では教師なし学習を用いる。教師なし学習を用いる場合、各ユーザ 1 人 1 人に対して正規であるかどうかを判定することは困難である。そこで本論文では、多くのユーザが1つの SIP サーバを利用することに着目し、そのサーバ内におけるユーザ間の通話の統計の類似度を計算し、この類似度からクラスを2つに分類することによりユーザが正規であるかを判別する。したがって、Random Forests において正規ユーザと迷惑電話発信者の類似度をより区別するために、迷惑電話発信者になるべく細工をしづらい特徴量を用いる必要がある。

3.2 2つの特徴量

そこで本論文ではさらに、迷惑電話発信者が細工するのが困難な2つの特徴量 BDR および IOR を提案する。BDR は発信者が発信した相手先からの程度着信したかを表す値であり、IOR はあるユーザが発信した相手先およびそのユーザに電話を掛けたユーザの和集合の数のうち、それらの積集合の数がどの程度の割合いるのかをそれぞれ示す。これらの特徴量は、迷惑電話は同一の相手先に発信されることおよび相手先から折り返し電話が掛かる頻度が低いことを表すために用いられる。例えば迷惑電話発信者が複数のアカウントと結託し、BDR および IOR の低さを改善しようとしても、迷惑電話発信者が同一の相手先には掛けないという仮定のもとでは日々相手先の件数は増え続ける。したがって、迷惑電話発信者がこれらの特徴量を細工しようとした場合、日々多くの新規アカウントを用意しなければならず、これは迷惑電話発信者にとって負担となる。

3.3 提案方式の流れ

本節では本方式の流れを示す。本方式の実装場所は IMS (IP Multimedia Subsystem) におけるアプリケーション・サーバ上での動作を想定している。これは、IMS 上のアプリケーション・サーバは、その IMS の SIP サーバを利用しているユーザが例えばホーム・ネットワーク外に移動していたとしても通話を収集できるためである。アプリケーション・サーバは、そのアプリケーション・サーバを利用する発信者の全通話時間、発信先の SIP アドレス、その通話の確立が成功したかどうかを記録する。そして、あらかじめ定めた収集期間が経過した後、そのアプリケーション・サーバを利用している各ユーザの通話履歴から特徴量を求め、各ユーザ間の類似度を Random Forests を用いて算出する。本提案方式において用いた特徴量は BDR, IOR, [8]

にて提案されている ST property および WT property, 平均通話時間, 1日あたりの通話回数の6種類である. 他の特徴量として, 例えばどの程度通話の確立が失敗したかも考えられるが, 正規のユーザとそうでない場合で実際にどの程度の値になるのかを想定できなかったため, 今回は用いていない. そして求めた各ユーザ間の類似度を PAM クラスタリング手法に入力することにより, クラスを2つに分類する. 今回は PAM クラスタリングを用いたが, 他のクラスタリング・アルゴリズムでも分類可能である.

これまで迷惑電話の発信者の判定に単一の特徴量で判定されていたが, 提案方式により複数の特徴量を閾値を用いることなく判定することが可能となる. 教師なし学習を用いるため, 事前にラベル付きの学習データを用意する必要がなく, また事前の学習データに判別結果が左右される問題も解決できる. また, これまで各ユーザが正規のユーザであるかどうかを閾値によって判定する方式が多く検討されてきたが, この場合季節性もしくは特定のイベントなどにより通話の特徴が異なる場合に判定が困難になることが考えられる. 一方, 提案方式では, 発信者のある SIP サーバで管理されたユーザ間同士の類似度を基に判別を行うため, 季節性のあるイベントが背景で発生している場合, ユーザ全体もしくは一部として通話統計が変化することが予想されるため, 判別に与える影響を小さくすることができる. 本方式は通話の確立自体には影響を与えないため, 遅延を発生させない. そして, 提案方式は IMS のアプリケーション・サーバ上に判別システムを設置すればよいいため, 既存の SIP メッセージを変更する必要もない.

4. 特性評価

本方式の有効性を示すため, 計算機シミュレーションにより評価を行った. まず Random Forests のパラメータ設定として, 決定木を生成する際に用いる特徴量の数 M_{try} および決定木の本数 T を設定する. これらの M_{try} および T のうち, 最も良い値を以下の評価で用いる. 評価項目は, 通話履歴の収集期間に対する迷惑電話発信者の判定精度 TP 率および FP 率, 各特徴量がどの程度判別に貢献したかを示す重要度, そして通話履歴の収集日数に対する2つの特徴量 BDR および IOR の変化である.

4.1 シミュレーション環境

本シミュレーションでは, あるアプリケーション・サーバにおいて, 2.1 節で示した正規ユーザ 89 名および迷惑電話発信者 50 名分の通話履歴よりこれらの計 139 名を提案方式を用いて正規ユーザもしくは迷惑電話発信者であるかを分類する. シミュレーションに用いた言語は R 言語 (v.2.15.1) および Random Forests のパッケージとして randomForest[10] を, PAM クラスタリングとして R 言語に内蔵されている cluster パッケージを使用した.

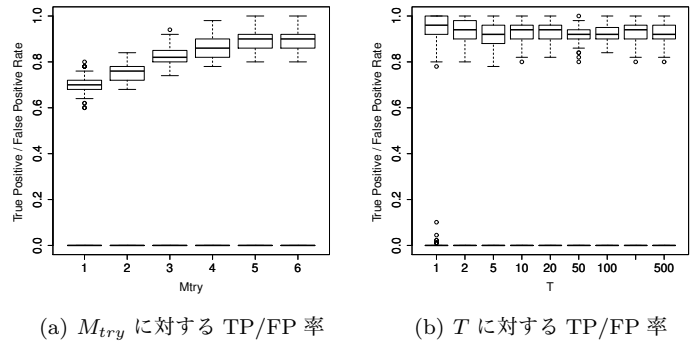


図 2 M_{try} および T に対する分類精度

Fig. 2 Classification accuracy versus M_{try} and T .




図 3 収集期間に対する判別精度

Fig. 3 Classification accuracy versus collection period.

4.2 パラメータ設定

提案方式の有効性を最大限得るために, まず決定木を生成する際に用いる特徴量の数 M_{try} および決定木の本数 T を設定する. 図 2(a) に $T = 25$, 収集期間 7 日とした場合の M_{try} に対する分類精度を示す. 提案方式において用意した特徴量は 6 つあるため, 横軸は 1 から 6 としている. また [4] では, $T = 20 \sim 30$ の値を用いて M_{try} を調節するよう主張しているため, ここでは $T = 25$ としている. 図 2(a) より, $M_{try} = 6$ において分類精度が最も良いため, 以下では $M_{try} = 6$ を使用する. 次に T を設定する. 図 2(b) に $M_{try} = 25$, 収集期間 7 日とした場合の T に対する分類精度を示す. 図 2(b) より, T を大きくしても TP 率は上がらず, また $T > 2$ とした場合は FP 率は 0 であることがわかる. したがって以下のシミュレーションでは $T = 25$ を使用する.

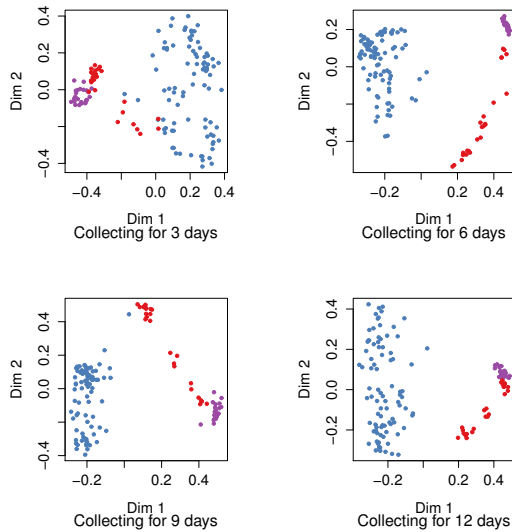


図 4 収集期間に対する MDS プロットの変化
 Fig. 4 MDS plot versus collection period.

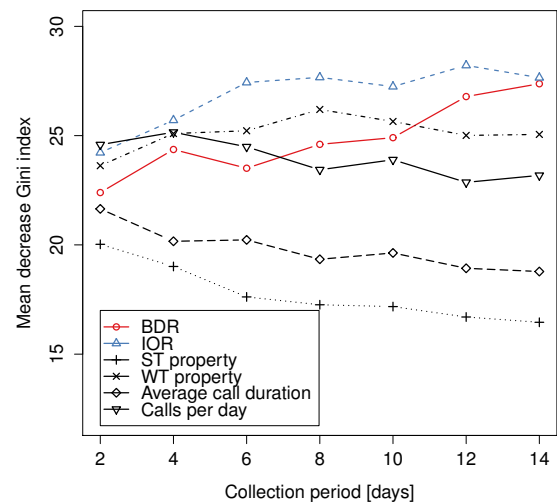


図 6 収集期間に対する各特微量の減少 Gini 係数の変化
 Fig. 6 Mean decrease Gini index versus collection period.

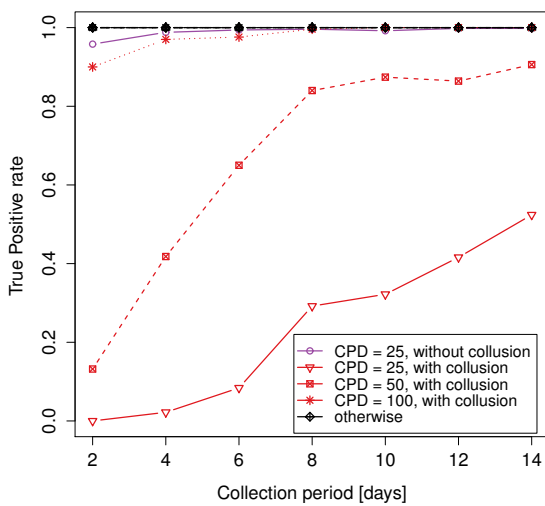


図 5 収集期間に対する迷惑電話発信者の種類別分類精度
 Fig. 5 Classification accuracy of each SPIT caller versus collection period.

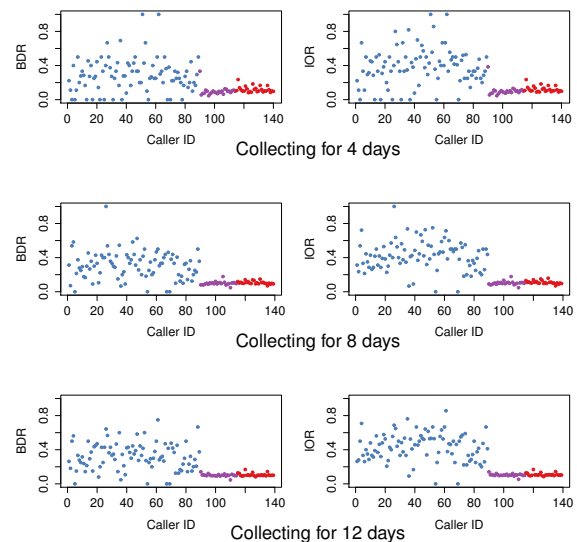


図 7 収集期間に対する BDR および IOR の変化
 Fig. 7 Collection period versus BDR and IOR of each caller.

4.3 収集期間に対する判別精度

図 3 に収集期間に対する発信者の分類精度を示す。図 3 より、当該環境下においていずれの収集期間においても FP 率は 0 であり、収集日数が 6 日程度で TP 率が 90%、14 日程度で TP 率が 96% となることがわかる。また図 4 に収集期間に対する MDS(Multi-Dimensional Scaling) プロットを示す。MDS プロットとは、各ユーザ間の類似度を 2 次元もしくは 3 次元といった低次元空間上に射影したものである。図 4 において各点群は 1 と同一の色でプロットしている。図 4 より、いずれの収集日数に対しても結託を行っていない迷惑電話発信者群(紫色)は正規ユーザ群(青色)とはっきりと区別されているが、結託を行う迷惑電話発信

者群(赤色)と正規ユーザ群は区別をすることが難しいことがわかる。図 5 に収集日数に対する迷惑電話発信者の種類別の分類精度を示す。図 5 より、結託を行い、1 日の平均通話回数が 25 回および 50 回のアカウントに対する分類結果が分類精度の低下の原因となっていることがわかる。

4.4 各特微量の重要度

次に各特微量の重要度について評価を行う。図 6 に各特微量が分類にどの程度貢献しているかを表す減少 Gini 係数の変化を示す。Gini 係数とは、その特微量を用いずに Random Forests の決定木を生成した場合に、その特微量を用いた場合と比較してどの程度分類精度が低くなったか

を示す指標である。すなわち、Gini 係数の減少量が大きい程、分類に貢献しているといえ、重要度としてみることが出来る。図6より、収集日数が長くなるにつれ、ST property の重要度は低下している。これは本シミュレーションにおいて想定した5人の結託者により、迷惑電話発信者と正規ユーザ間の ST property の差が縮まっているためである。その一方で、WT property, BDR および IOR の重要度は増加していることがわかる。これは迷惑発信者は通話毎に異なる相手先を選択するという仮定のため、これらの特徴量の分母は迷惑電話を発信する度に増大する。一方、[8]でも指摘されている通り、正規ユーザはある程度親密なユーザと多くの通話を行う傾向にあるため、正規ユーザの ST property, BDR および IOR の値は迷惑電話発信者と比較して高くなっていることがわかる。これは、図7に示す、収集期間に対する BDR および IOR の変化からはっきりとわかる。1に示した通り、本シミュレーションにおいては、迷惑電話の発信先から何らかの理由により通話をし返す確率を10%としている。図7より、BDR および IOR のいずれに対しても、結託を行った場合も行わない場合も値に差があまり生じず、収集日数が長くなるにつれて、正規ユーザと迷惑電話発信者が区別しやすくなることがわかる。特に、図6からもわかる通り、BDR よりも IOR の方が優れた特徴量であることがわかる。これは BDR と IOR の相違点は、そのユーザに他者がどの程度発信を行うかであり、他者からの着信の程度を考慮したためである。

5. 結論

本論文では、教師なし Random Forests を用いることにより複数の特徴量を考慮した迷惑電話発信者判別を行う方法を提案した。教師なし Random Forests を用いて、各サーバを利用するユーザ間の各特徴量から類似度を算出し、PAM クラスタリングを用いてそれらを2つのクラスに分類することで正規のユーザと迷惑電話発信者を分類する。これにより、従来考慮されていなかった複数の特徴量を用いることができ、結託アカウントおよび複数アカウントを用いた迷惑電話発信者を判別することが可能となる。また特徴量として新たに2つの BDR および IOR を提案した。BDR および IOR は迷惑電話発信者が発信先の数および電話を掛けてくる発信者数を考慮している。したがって、迷惑電話発信者が通話毎に異なる発信先に発信を行うという仮定では、迷惑電話発信者のこれらの特徴量は0に近づく。迷惑電話発信者がこれらの特徴量を細工するには、日々複数の新規アカウントを作る必要があるが、これは負担が大きく、現実的でないことを示した。また Reality Mining データセットおよび人口的に生成した迷惑電話発信者の通話データを用いて本方式の分類精度、各特徴量の重要度を明らかにした。当該環境下において、通話データの収集期間が6日の場合に TP 率 90% および FP 率 0%、14日の場

合で TP 率 96%、FP 率 0% の分類精度を得た。また提案した2つの特徴量 BDR および IOR は収集期間が増える程、分類に重要な影響を与えることを示し、また分類に際し、IOR は BDR と比較してより優れた特徴量であることを示した。

謝辞 本研究の一部は、「科研費 基盤研究 (C)23560465 高効率セキュアアドホックネットワークに関する研究」の助成により行われた。関係者各位に深謝する。

参考文献

- [1] 山崎洋一：特集 2 噂は本当だった！ IP 電話狙うスパム「SPIT」出現、芽を摘むのは今だ、*Nikkei communications*, No. 439, pp. 50–58 (オンライン), 入手先 (<http://ci.nii.ac.jp/naid/40006711631/en/>) (2005).
- [2] Shin, D., Ahn, J. and Shim, C.: Progressive Multi Gray-leveling: A Voice Spam Protection Algorithm, *Network, IEEE*, Vol. 20, No. 5, pp. 18–24 (online), DOI: 10.1109/MNET.2006.1705879 (2006).
- [3] Waiting, D. and Ventura, N.: A Multilayered Architecture for Preventing Automated Spam in the IP Multimedia Subsystem, *Global Telecommunications Conference, 2007. GLOBECOM'07. IEEE*, pp. 2140–2145 (2007).
- [4] Breiman, L.: Random Forests, *Machine learning*, Vol. 45, No. 1, pp. 5–32 (2001).
- [5] Shi, T. and Horvath, S.: Unsupervised Learning with Random Forest Predictors, *Journal of Computational and Graphical Statistics*, Vol. 15, No. 1, pp. 118–138 (2006).
- [6] Kusumoto, T., Chen, E. and Itoh, M.: Using Call Patterns to Detect Unwanted Communication Callers, *Applications and the Internet, 2009. SAINT'09. Ninth Annual International Symposium on*, pp. 64–70 (2009).
- [7] Albert, R. and Barabási, A.: Statistical mechanics of complex networks, *Reviews of modern physics*, Vol. 74, No. 1, p. 47 (2002).
- [8] Bokharaei, H., Sahraei, A., Ganjali, Y., Keralapura, R. and Nucci, A.: You Can SPIT, But You Can't Hide: Spammer Identification in Telephony Networks, *INFOCOM, 2011 Proceedings IEEE*, pp. 41–45 (2011).
- [9] Salehin, S. and Ventura, N.: Blocking Unsolicited Voice Calls Using Decoys for the IMS, *Communications, 2007. ICC'07. IEEE International Conference on*, pp. 1961–1966 (2007).
- [10] Liaw, A. and Wiener, M.: Classification and Regression by randomForest, *R News*, Vol. 2, No. 3, pp. 18–22 (online), available from (<http://CRAN.R-project.org/doc/Rnews/>) (2002).