

3 軸加速度計を用いた デスクワーク中の割り込み可能性の推定

卓 璐^{†1} 王 琛^{†1} 浅井 洋樹^{†1†2} 山名 早人^{†3†4}

^{†1} 早稲田大学 基幹理工学研究科 〒169-8555 東京都新宿大久保 3-4-1

^{†2} 早稲田大学 グローバルエデュケーションセンター 〒169-8050 東京都新宿区戸塚町 1-104

^{†3} 早稲田大学 理工学術院 〒169-8555 東京都新宿大久保 3-4-1

^{†4} 国立情報学研究所 〒101-8430 東京都千代田区一ツ橋 2-1-2

E-mail: {zhuolu,magaret1103,asai,yamana}@yama.info.waseda.ac.jp

あらまし スマートフォンやウェアラブルデバイスなどのモバイルデバイスの普及により、ユーザへのコンタクトが四六時中可能となった。しかし、ユーザの都合を考慮しない割り込みは、作業効率を下げたり、良い社会的コミュニケーションの妨げとなったりするため、迷惑である。このような背景のもと、ユーザへの割り込みの適切なタイミング、つまり割り込み可能性に関する研究が盛んに行われている。従来、スマートフォンを利用したユーザ割り込み可能性推定の研究が行われている。しかし、ユーザがスマートフォンをデスクに置いてしまえば、腕の動きを示す加速度データなど、推定に必要なデータを取得することができない。これに対して本研究では、リストバンド型センサの 3 軸加速度データを用いて、デスクワーク中のユーザ割り込み可能性を推定する手法を提案する。従来研究の割り込み可能性推定の適合率と再現率が 0.57 と 0.52 に対し、本研究では 0.717 と 0.712 の適合率と再現率を得た。

キーワード 割り込み可能性, デスクワーク, 3 軸加速度

1. はじめに

スマートフォンなどのモバイルデバイスは、ユーザ同士が時と場所を選ばずコンタクトを取り合う最も普遍的なデバイスである。世界の携帯電話販売台数は、2014 年で 20 億台を超え、世界中で 3 人に 1 人は携帯電話を持つ時代になった。その中で、スマートフォンが携帯電話市場を占める割合が急激に拡大している。ほとんどのユーザは、四六時中スマートフォンを携帯しているため、スマートフォンはユーザにつながる最も直接的なデバイスになってきている。しかし、ここ数年で普及が始まっているウェアラブルデバイスは、スマートフォンやタブレットの次世代デバイスとして注目されている。ウェアラブルデバイスは、操作が人間のアクティビティに合わせて改善されているため、より自然な動きで操作が可能である。また、ウェアラブルデバイスにはセンサが搭載され、ユーザの身体の様々な情報を取得できるため、健康管理やスケジュール管理など様々な用途がある。これらの画期的な特徴は、ウェアラブルデバイスが注目される理由と考えられている。

スマートフォンやウェアラブルデバイスが普及す

るユビキタス社会で、ユーザは四六時中、電話やメール、インスタントメッセージ(IM)や SNS、モバイルデバイスのアプリケーションから通知を受け取ることが可能である。その反面、タイミングの悪い通知による割り込みは、ユーザにとって迷惑である。Garrett ら[3]は、インスタントメッセージ(IM)はタスク関連の情報を即座に伝えてくれるため、仕事効率を高めると主張する。一方で、仕事に関係のない通知が届くと気が散る上、忙しいユーザに声をかけて気まずくなることもあるように、タイミングの悪い割り込みは作業効率を下げ、良い社会的コミュニケーションの形成を妨げる。そこで、ユーザへの割り込みの適切なタイミングを推測する研究が必要性を増している。

Pejovic ら[1]は、スマートフォンの時間、位置情報、加速度データを、拡張した機械学習モデルで学習させ、良い割り込みタイミングを提示するライブラリをデザイン、実装した。Pejovic らの研究で提示した割り込みのタイミングは、ユーザ満足度が高く、割り込みに対するユーザが返答するまでの時間が短

縮された。しかし、スマートフォンをデスクに置いてしまえば、ユーザの動きを示す加速度データなど、ユーザ割り込み可能性の推定に必要なデータを取得できない。そのため、デスクワーク中のユーザ割り込み可能性の推定精度は改善の余地があると考えられる。

これに対して本研究では、リストバンド型センサの 3 軸加速度のデータを用いて、デスクワーク中のユーザ割り込み可能性を推定する手法を提案する。これらのデータを、オープンソース機械学習ツールの WEKA[6]を使って、割り込み可能性のモデルを構築する。

本論文では以下の構成をとる。まず第 2 章で関連研究をまとめ、第 3 章で本研究のデータ収集と提案手法について説明する。第 4 章では評価実験の方法と内容を紹介し、第 5 章でまとめを述べる。

2. 関連研究

割り込み可能性の研究は様々な角度からアプローチされている。我々の研究は、3 軸加速度センサデータを用いてデスクワーク中の割り込み可能性を推定する。2.1 節では、センサを利用して、オフィス環境においてのユーザの割り込み可能性を推定する研究を紹介し、2.2 節ではセンサを用いた生活環境下の割り込み可能性の研究を紹介する。2.3 節では関連研究をまとめる。

2.1. センサを用いたオフィス環境の割り込み可能性の推定

本節では、オフィス環境に限定した、センサを使用した割り込み可能性の推定の研究を紹介する。

2.1.1. シミュレートしたセンサを用いて割り込み可能性を推定する

Hudson ら[4]は、4 名の被験者がオフィス環境にいる時のビデオとオーディオ記録をそれぞれ取得した。そのビデオとオーディオ記録を人が観測し、それぞれの被験者のセンサで捉えられそうなアクティビティをコーディングした。つまり、Hudson らが用いたのはシミュレートしたセンサである。これらのセンサに基づいて、Hudson らは機械学習を用いて割り込み可能性モデルを構築し、予測した割り込み可能性をユーザセルフレポートと比較することで

評価を行った。

Hudson らは、センサに基づいた割り込み可能性の予測は可能と証明し、比較的シンプルなセンサでも、ほぼ確実に割り込み可能性を予測できると主張した。

Hudson らの研究の不足は、センサがシミュレートされたものである。実際のセンサが当時実現不可能だったこともあり、実際のセンサでも、割り込み可能性を予測できるか、将来研究で検証する必要があるとされた。

2.1.2. 机上圧力センサを用いて割り込み可能性を推定する

Tani ら[7]の研究では、机上圧力センサによってユーザのデスクワーク中の割り込み可能性を予測する手法を提案した。この研究の被験者は、タイピングタスクとマウス操作タスクを実行し、それぞれのタスクの最中に画面に割り込みのポップアップが表示される。この割り込みを受け入れるなら左足のスイッチを踏み、拒否するなら右足のスイッチを踏む。この受け入れと拒否のデータを、Tani らはオープンソース機械学習ツールの WEKA[6]を使って、SVM を含む異なる分類学習アルゴリズムで学習させた。また、10-分割交差検証でテストを行い、割り込み可能性の適合率を出した。SVM で学習させた時、適合率が最も高く、タイピングタスクの際に 76.8%、マウス操作タスクの際に 72%の適合率を得た。

しかし、Tani らの研究ではタイピングタスクとマウス操作タスクのみの割り込み可能性を推定でき、その他のデスクワーク中の割り込み可能性を推定できない。

2.2. センサを用いた生活環境の割り込み可能性を推定する研究

2.2.1. 3 軸加速度センサを用いて割り込み可能性を推定する

Ho ら[5]は、ワイヤレスの 3 軸加速度計を搭載したモバイルコンピューティングデバイスを構築した。このデバイスのシステムは、リアルタイムにユーザの体位と歩行状態（座る、立つ、歩く）の変化を検知できる。Ho らの研究では、身体アクティビティ変化があった時の割り込みと、ランダムな時刻の割

り込みに対してのユーザの許容度を比較した。

Ho らの研究の 1 つの結論は、身体アクティビティ変化がある時に送られる通知（割り込み）は、ランダムな時刻の通知よりユーザに積極的に捉えられる可能性があるということである。2 つ目の結論は、ユーザへの割り込みのタイミングを、身体的アクティビティ変化が始まった時にずらすことで、ユーザへの割り込みの負担を軽減できる可能性があるということである。

Ho らの研究の短所は、比較的少ない被験者で短期間に渡る実験を行ったため、より大人数で長期的に実験を実施しても、以上の結論が変わらないか確認されていないことである。また、Ho らは 3 軸加速センサーを使って体位と歩行状態の変化を検知したが、これらのアクティビティ変化がない、デスクワーク中のアクティビティを検知できないため、デスクワーク中の割り込み可能性を推定することができない。

2.2.2. スマートフォンを用いて割り込み可能性を推定する

我々の研究を最もインスパイアしたのが、Pejovic ら[1]の、スマートフォンセンサを活用した割り込み可能性の研究である。Pejovic らは、スマートフォンのセンシングで得られる時間、加速度、位置情報、Wi-Fi と Bluetooth 環境のセンサデータを用いて、機械学習を通して割り込み可能性をモデリングした。彼らは良い割り込みを定義し、この定義とユーザセルフレポートの内容を合わせて機械学習モデルを評価した。また、Pejovic らは適切な割り込みタイミングを提示するライブラリをデザイン、実装した。

データ収集では、ユーザはスマートフォンから一定時間ごとにランダムな通知を受ける。通知を受けると同時に、スマートフォンはセンサデータを記録する。通知が来ると、ユーザはスマートフォンの SampleMe というアプリケーションにて、セルフレポートに答えるよう指示される。ユーザセルフレポートの一部内容は以下になっている。

1. 割り込まれた時に独りでいたか、
2. 割り込まれた時の行動、

3. 返答時の感情

4. 割り込みを適切と感じる度合。

また、Pejovic らは通知時と返答時のコンテキスト情報と割り込み可能性の間の関係について、以下の仮説を立てた。

1. 通知時のコンテキスト情報は割り込み可能性を決定する。
2. 返答時のコンテキスト情報は割り込み可能性を決定する。
3. 通知時と返答時のコンテキスト情報の差は、割り込み可能性を決定する。
4. 通知時のコンテキスト情報（加速度）の変化は、割り込み可能性を決定する。

筆者らはまずオープンソースツールの WEKA[6]を用いて、Naïve Bayes を含む異なる分類器で、それぞれの仮説を証明した。通知時のコンテキスト情報は返答の有無を決定する仮説に対して、Naïve Bayes を使った適合率と再現率は 0.57 と 0.52 であり、通知時のコンテキスト情報は返答時の感情を決定する仮説に対して、適合率は 0.52 であった。返答時のコンテキスト情報は返答時の感情を決定する仮説に対して、割り込みを適切と感じる度合が 2（少し適切）、3（適切）、4（とても適切）の場合、適合率は順に下がるとわかった。

Pejovic らの研究の不足は、スマートフォンをデスクなどに置いてしまえば、割り込み可能性を予測するのに必要なデータ（加速度データなど）を得られないことから、割り込み可能性モデルの精度は改善の余地があることである。また、スマートフォンの加速度センサは一方向の加速度を取得することから、3 軸加速度計に比べ次元が少ない。

2.3. 関連研究のまとめ

シミュレートしたセンサで割り込み可能性を推定する研究では、シンプルなセンサでも割り込み可能性を推定できると証明したが、実際のセンサで実証していない。3 軸加速度データを用いた割り込み可能性の研究では、身体アクティビティに変化がある時割り込み可能性が高いと昭栄下が、デスクワーク中の割り込み可能性は推定できない。机上圧力セン

サを使った研究では、タイピング時とマウス操作時の割り込み可能性を推定できるが、これら以外の割り込み可能性を推定できない。スマートフォンのセンサを活用した研究では良い割り込み可能性を提示するライブラリを実装したが、スマートフォンをデスクに置いた時の加速度データなどを取得できない。また、加速度データが1次元のものであるという弱点がある。

3. デスクワーク中のユーザ割り込み可能性推定手法の提案

2.3 節で述べた関連研究の問題点を解決するために、我々の研究では、リストバンド型センサの3軸加速度データを用いて、デスクワーク中の割り込み可能性を推定する手法を提案する。

3.1. 割り込み可能性の定義と議論

本研究では、割り込み可能性を、ユーザを割り込む適切なタイミングと定義する。また、割り込みを評価するラベルは、“良い割り込み”と“悪い割り込み”の2つと置き、良い割り込み、つまり適切なタイミングの割り込みは、以下の条件1を満たすものとする。“良い割り込み”は“割り込み可能性が高い”と同等とし、“悪い割り込み”は“割り込み可能性が低い”とする。

1. 割り込み（モバイルデバイスの通知）に対して、ユーザの返答が有る。

3.2. データ収集

データ収集の被験者は、8名の大学生、大学院生で構成され、男女比は5対1である。被験者は、図1に示すSONYのSmartWatch 3というリストバンド型センサ（スマートウォッチ）を、1日中利き腕につけて通常の生活をした。デスクワークが開始する時、被験者はスマートウォッチのMy Applicationを立ち上げ、開始ボタンを押す。開始ボタンが押されると、1時間程のランダムな時間に、リストバンド型センサにブザー通知が与えられる。また、スマートウォッチは通知前の5分間の3軸加速度データを採取し、本体に保存する。通知と同時に、ユーザが暇（割り込み可能）かどうかを尋ねる操作画面が10秒現れ、暇（割り込み可能）ならボタン操作をす

る。ユーザによるボタン操作がない時は割り込み不可とする。

センサで採取する特徴量を以下の表1に示す。



図1 SONY SmartWatch 3

表1 収集するデータの種類

データの種類	特徴量
加速度	X 軸, Y 軸, Z 軸の加速度値

3.3. 割り込み可能性に関する仮説

Pejovic ら[1]の研究を比較の対象にするため、彼らが設定した割り込み可能性に関する仮説に習って、本研究での仮説を以下のように立てる。

1. 割り込み時の3軸加速度の変化が、割り込み可能性を決定する。

仮説1において、割り込みはブザー通知を指し、割り込み可能性を判断するには、ユーザによる返答があるか否かで判断する。返答があることは、ユーザによるボタン操作があることとする。

以上の仮説を、我々は機械学習の分類学習を用いて検証する。分類器の種類は、Pejovic らの研究で精度が最も高かったナイーブベイズ(Naïve Bayes)とベイズネット(BayesNet)を利用し、10クロスバリデーションによって学習、テストさせる。

3.4. 機械学習による割り込み可能性のモデリング

本研究では、収集したデータ（表1）で割り込み可能性をモデリングする。

Pejovic ら[1]の研究と比較をするため、機械学習によるモデリングと評価の方法を統一する。まず、以下の量を定義する。

i : 個々の通知（割り込み）のインスタンス

N : 表1に示す特徴量の総数。

$f_1^i, f_2^i, \dots, f_N^i$: 個々の割り込みインスタンスにおける 3 軸加速度値.

PO_i : 予測の割り込み可能性.

AO_i : 実際の割り込み可能性.

$\vec{f}^i = (f_1^i, \dots, f_M^i), M \leq N$ とする. M は機械学習に用いる特徴量数を表す.

$g(\vec{f}^i)$: 割り込み可能性の機械学習モデル. g は, 実際の分類器を表す.

予測の割り込み可能性は, $PO_i = g(\vec{f}^i)$ で求められる.

分類学習では, M 個のラベル付き特徴量を与え学習させる. ここでのラベルは, 割り込み可能(1)と割り込み不可(-1)の 2 値と定める. 特徴量は, 3 軸加速度の X 軸, Y 軸, Z 軸の値である. 分類学習によって, デスクワーク中のユーザへの割り込みが可能か不可かを分類する分類器が完成し, これが割り込み可能性のモデルである.

分類学習の目的は, 予測の割り込み可能性 PO_i を得ることを通して, 最終的に実際の割り込み可能性 AO_i を推定することである. 機械学習においては, オープンソース機械学習ツールキットの WEKA[6] を使用し, 10 クロスバリデーションで分類学習・テストする. 分類器において本研究では, Pejovic ら[1]の研究で結果が最もよかったナイーブベイズ (Naïve Bayes) と, ベイズネット (BayesNet) を活用する.

4. 実験と評価

4.1. 評価方法

本研究では, 4.4 節で構築した割り込み可能性モデルのパフォーマンスを, 10 クロスバリデーションを用いてテストする. 10 クロスバリデーションとは, データ収集で集めた特徴量とラベルのデータの 90% を分類学習に使い, 残りの 10% の特徴量データで分類器をテストし評価する学習法である.

Pejovic ら[1]の実験では, 20 名の被験者に対し, 合計で 2334 個の通知を送り, 返答があった数は 906 であった. 彼らの研究で, 通知時のコンテキスト情報 (複数のセンサデータ) はユーザ返答の有無を決

定するという仮説に対して, Naive Bayse を分類器として使用した結果, 割り込み可能性のモデルの適合率は 0.57 で, 再現率は 0.52 であった. 本研究の評価においても, 通知時の 3 軸加速度データを用いて分類学習 (Naïve Bayse) を行い, Pejovic らが得た適合率と再現率を比較する. つまり, 通知時のコンテキスト情報 (3 軸加速度データ) がユーザ返答の有無を決定するという仮説に対する適合率を 0.57 と, 再現率を 0.52 と比較検証する.

適合率 (Precision) と再現率 (Recall) の計算法は以下の表 2, 表 3 に示す. また, 本研究においての TP (True Positive), FP (False Positive), TN (True Negative), FN (False Negative) と Precision, Recall が指す内容を表 4 に示す.

表 2 予測結果と真の結果

		真の結果	
		正	負
予測結果	正	TP	FP
	負	FN	TN

表 3 適合率と再現率

$Precision = \frac{TP}{TP + FP}$
$Recall = \frac{TP}{TP + FN}$

表 4 本研究での適合率と再現率

TP	割り込み可能と予測し, 実際も 割り込み可能だった通知の数
FP	割り込み可能と予測し, 実際は

	割り込み不可だった通知の数
<i>TN</i>	割り込み不可と予測し、実際も 割り込み不可だった通知の数
<i>FN</i>	割り込み不可と予測し、実際は 割り込み可能だった通知の数
<i>Precision</i>	割り込み可能と予測した 通知の内、実際に 割り込み可能だった通知の割合
<i>Recall</i>	実際に割り込み可能だった 通知の内、割り込み可能と 予測した通知の割合

3.4 節で構築した機械学習モデルを評価するため、本研究の仮説（3.3 節）を証明する．機械学習の評価にはナイーブベイズ(Naïve Bayse)とベイズネット(BayesNet)という分類器(*g*)を利用した．

Pejovic ら[1]の研究では、割り込み時の加速度を、割り込みの前後 5 分間採取し続けた．本研究では、割り込み可能性を推定する特徴量として、通知時の 3 軸加速度データのみを利用するため、割り込み前の 5 分間のデータを取得する．

ここで、3.1 節で紹介した、良い割り込みの基準について振り返る．私たちは、割り込みを“良い”と“悪い”のバイナリーラベルで評価する．出力関数(*g*) が割り込みに対しての返答の有無の場合、返答があれば“良い”割り込みであり、その逆なら“悪い”割り込みと定義した．

4.2. データセット

実験では 8 名の被験者に、リストバンド型センサ

を利き腕につけてもらい、約 1 時間毎の通知に対して、通知前の 5 分間の 3 軸加速度データを取得した．各通知に対して、割り込み可能(ラベルが 1)か不可(ラベルが-1)のラベルを、ボタン操作の有か無で判断してもらった．1 個の通知を 1 つのインスタンスと見なし、1 つのインスタンスに対する、5 分間の 3 軸加速度データ(X 軸, Y 軸, Z 軸, X 軸, ...)をカンマ区切りで記録し、最右端にラベル値を示す．以下の表 5 は、実験で集めたデータセットの分類を示す．合計 132 個の通知の内、49 個に対しユーザの返答があった．

表 5 データセットの分類

被験者	割り込み 可の数	割り込み 不可の数	合計の 通知数
A	5	16	21
B	1	5	6
C	13	3	16
D	12	17	29
E	4	3	7
F	13	33	46
G	1	1	2
H	0	5	5
全員	49	83	132

4.3. 提案手法の評価

我々の実験では、通知前の 5 分間の 3 軸加速度データを通知毎に収集した．しかし、技術的な課題があり、加速度値に変化がある時のみ、0.2 秒間隔で 3 軸加速度データを取得できるが、3 軸加速度値に変化がない場合、データを収集できない．しかし、異なる特徴量を機械学習ツール WEKA で学習させることができないため、ヒストグラムの考え方をういて特徴量を変換した．

まず、加速度値を-9～9 を 18 等分し、-9 以下、9 以上の値を合わせて 20 の区間を用意する．加速度値がこれら区間に属するデータ数の累積を特徴量とする．1 つのインスタンスにおいて、X 軸, Y 軸, Z 軸それぞれ 20 の区間が存在するため、計 60 区間存在する．このように、機械学習させる特徴量を 60

に統一することができた。分類学習の結果、3 軸加速度データを用いて割り込み可能性を推定する適合率と再現率が、Naïve Bayes の場合、それぞれ 0.538 と 0.568 であり、BayesNet を用いた場合、適合率と再現率は 0.717 と 0.712 であった。

4.4. 考察

Naïve Bayes では適合率が既存研究を下回った原因として考えられるのは、ヒストグラムの区間の設定が最適でないことである。実験データは、-9 以下のデータが圧倒的に多いため、ヒストグラムにおいて負の区間を増やすべきと考えられる。

一方で、BayesNet を用いた学習では、適合率と再現率が 0.717 と 0.712 であり、既存研究の 0.57 と 0.52 を大きく超えた点から、提案手法では割り込み可能性推定の精度を上げることができたと考えられる。BayesNet を用いた学習で精度が上がった理由として考えられるのは、BayesNet は特徴量数が多い分類を得意とすることである。

5. おわりに

本稿では、リストバンド型センサより得た時間と 3 軸加速度データを用いて、ユーザのデスクワーク中の割り込み可能性を推定する手法を提案した。従来の 3 軸加速度計を用いた割り込み可能性の研究[5]は、ユーザの体位と歩行状態の変化を検知し、このような変化がある時にユーザは割り込み可能性が高いと証明したが、体位と歩行状態の変化がないデスクワーク中の割り込み可能性を推定できない。スマートフォンの加速度センサなどを使ってユーザ割り込み可能性を推定する研究[1]では、使用した加速度データが 1 次元のものであり、更にスマートフォンをデスクに置いた時に有効な加速度データを取得できない問題があった。提案手法では、リストバンド型センサの 3 軸加速度データを用いることで、デスクワーク中にも 3 次元の加速度データを取得できた。

実験の結果、スマートフォンセンサデータで割り込み可能性を推定した研究の適合率と再現率が 0.57 と 0.52 だったのに対し、提案手法では 0.717 と 0.712 の適合率と再現率を得ることに成功した。

一方で、データ収集の際、等間隔に加速度データ

を収集できないという問題があった。我々は機械学習の際に、特徴量をヒストグラムに直す方法を活用した。将来研究としては、スマートウォッチの 3 軸加速度の変化がない場合は、0 の値を示すことで等間隔にデータを取得することの実現を期待する。また、ヒストグラムの横軸の範囲を様々なものに変えて学習することで、精度が挙げられると考えられる。これらの問題以外にも、実験期間が短いという問題が考えられるため、長期的な評価実験が必要と考えられる。

参考文献

- [1] V. Pejovic and M. Musolesi, “InterruptMe: Designing Intelligent Prompting Mechanisms for Pervasive Applications”, Proc. of UBICOMP '14, pp. 897-908 (2014).
- [2] 総務省, 政策, 白書, 24 年版, スマートフォンなどの急速な普及と端末市場の変化, 第 1 部, 第 2 節, 1, (1) スマートフォン等の急速な普及と端末市場の変化.
<http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h24/html/nc122110.html> (2014.12.7 22:50 アクセス).
- [3] R. K. Garrett and J. N. Danziger, “Instant messaging and disruption in the workplace.” Journal of Computer-Mediated Communication, Vol.13, No.1, pp.23-42 (2007).
- [4] S. E. Hudson, J. Fogarty et al. “Predicting Human Interruptibility with Sensors: A Wizard of Oz Feasibility Study.” Proc. of CHI '03, pp. 257-264 (2003).
- [5] J. Ho and S.S. Intille, “Using Context-Aware Computing to Reduce the Perceived Burden of Interruptions from Mobile Devices.” Proc. of CHI '05, pp. 909-918 (2005).

- [6] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witter. The WEKA data mining software: an update. ACM SIGKDD Explorations Newsletter, Vol.11, No.1, pp.10-18 (2009).
- [7] T. Tani and S. Yamada “Estimating User Interruptibility by Measuring Table-top Pressure,” Proc. of CHI EA’13, pp. 1707-1712 (2013).