

クラウドセンシングによる突発的事象検出システムとその高速化

山本 泰史[†] 奥 健太^{††} 川越 恭二^{††}

[†] 立命館大学大学院情報理工学研究科 〒525-8577 滋賀県草津市野路東1丁目1-1

^{††} 立命館大学情報理工学部 〒525-8577 滋賀県草津市野路東1丁目1-1

E-mail: †is0145rp@ed.ritsumei.ac.jp, ††oku@fc.ritsumei.ac.jp, †††kawagoe@is.ritsumei.ac.jp

あらまし 近年、スマートフォンの普及により、スマートフォンを用いた事象検出に関する研究が活発に行われている。しかし、突発的に発生した事象を対象とした事象検出の研究は行われていない。そこで、著者らは、事件や事故などの突発的事象をクラウドセンシングを用いて検出するシステムである SQUED を提案した。スマートフォン搭載の各種センサから取得した情報を用いて、事象周囲の人々が自身のスマートフォンを事象発生位置に向けるだけで事象検出が行える。実験において、突発的事象の検出が可能であることを確認した。本論文では、SQUED をリアルタイムに突発的事象を検出可能なシステムとすることを目標とし、より効率的な事象検出手法を提案する。

キーワード イベント検出, スマートフォン, クラウドソーシング, GPS, センサーデータ

1. はじめに

近年、カメラやマイク等のセンサから取得した映像や音声からの事故や不審人物検出 [1] [2] の研究が行われている。特に設置式センサを用いた事象 (イベント) 検出手法がこれまでに多く提案されている。

しかし、設置式センサによる事象検出では、センサを予め設置しておく必要がある。また、センサが未設置の屋内外場所で発生した事象の検出はできない。さらに、高低差のある場所や見通しの悪い場所ではセンサの死角により事象検出精度が低下する問題があった。

しかし、端末自身にカメラやマイク、GPS のような様々なセンサが搭載されたスマートフォンの登場・普及により、特殊なセンサを必要とせず、場所に依存しない事象検出を行うことが可能となってきた。

スマートフォンを用いた事象検出の従来研究として、Robin Wentao ら [3] の iSee が存在する。iSee は、長期的に収集した GPS センサ、地磁気センサ及び人のスワイプの情報から、日常的によく起こる喫煙や落書き等の事象の検出を行う。しかし、iSee には長期的にデータを収集しないと事象が検出できない、人のスワイプにより誤差が含まれてしまうといった問題がある。

そこで本研究では、以前、突発的事象の検出に着目した、クラウドセンシングを用いた突発的事象検出システム (SQUED) を提案した。SQUED は、人々が日常生活で使用しているスマートフォンに搭載されている GPS センサ、地磁気センサを用いて、事故、事件等の様々な突発的事象をクラウドソーシングを用いて自動的に検出するシステムである。事象発生時、付近にいるユーザがスマートフォンを事象発生方向に向けるだけで事象の検出が可能となる。GPS センサから事象発生位置、地磁気センサからユーザから見た事象発生方向の検出を行う。以前行った評価実験により、突発的事象の検出が可能であることを確認した。

本論文では、リアルタイムに突発的事象を検出可能とするこ

とを目標とし、事象検出を高速化した事象検出手法を提案する。また、検出高速化を実現できたことを確認するため、擬似ユーザ生成器を作成した。擬似ユーザ生成器を用いることにより、静止しているユーザ・直進するユーザ・ランダムな動きをするユーザを擬似的に生成可能である。手法評価のために、既存のデータセットに擬似ユーザを追加し、現実環境に近いデータセットで評価を行った。既存手法の改良により検出高速化を実現できたことを示すとともに、突発的事象の検出をリアルタイムに可能とするシステムの実現に向けた研究の展望を示す。

2. 関連研究

本章では、本研究の関連研究について述べる。2.1 節で、動画像を対象とした研究について述べ、2.2 節でスマートフォンを用いた研究及び、本研究との差異を述べる。

2.1 動画像を対象とした研究

Du Tran ら [4] は、動画像において、効率よく物体の移動軌跡を認識可能なアルゴリズムを提案した。本アルゴリズムは、各フレーム間における物体の特徴点の交点を抽出するアルゴリズムであり、歩行や走行等の移動軌跡を既存の手法より効率よく認識可能である。本手法を用いることで、混雑した場面の映像やカメラ自身の動きがある映像を対象とした事象検出に対しても高い事象検出精度を出すことが可能である。Feng Wang ら [5] は、動画像からパレードやロッククライミングなどの事象を認識可能なアルゴリズムを提案した。これまでの手法では、カメラ自身の動きがある映像を対象とした事象検出は難しく、また、物体の移動軌跡を用いた事象検出手法が多かった。本アルゴリズムでは、人の目やタイヤなどの局所的な特徴を解析し、文字と対応付けしてあるデータベースを利用し、各フレームごとに生成したマップの差から事象を認識する。アルゴリズムは、カメラ自身の動きのある映像に対しても事象検出を行うことが可能であり、さらに、異なる物体やシーンの中から事象検出を行うことが可能である。

Tong Qin ら [6] は、クラウドソーシングによって収集した画

像群から、事象発生箇所とその概要を検出するシステムを提案した。本システムでは、スマートフォンを用いてユーザが撮影した事象の写真とその際のセンサ情報、ユーザが入力した事象の概要から、事象の発生箇所と概要を検出する。また、本システムは改ざんされた写真の検出も可能であり、信頼性の高い事象検出を可能とする。

2.2 スマートフォンを用いた研究

Robin Wentao ら [7] は、スマートフォンを用いた事象検出システムである iSee を提案した。iSee における事象検出では、2種類のセンサ (GPS, 地磁気) を用いる。ユーザは、事象を発見した際、その方向に向けて端末画面をスワイプする。iSee は、各センサ情報とスワイプ情報から、事象の発生箇所を検出する。

Robin Wentao らのアイデアは著者らが提案した SQUED に似ているが、iSee では、突発的事象に対応しておらず、しかもユーザがスワイプを行う必要がある。SQUED のユーザは、スマートフォンを事象発生方向に向けるだけでよい。その上、スワイプには他のセンサ同様、多くの誤差が含まれ、精度低下の要因となる。

3. SQUED

本章では、以前著者らが提案した、クラウドセンシングを用いた突発的事象検出システム (SQUED) について述べる。SQUED (Smart and Quick Unexpected-Event Detector) は、情報収集部、情報格納部、事象検出部の3つの要素によって構成されている。

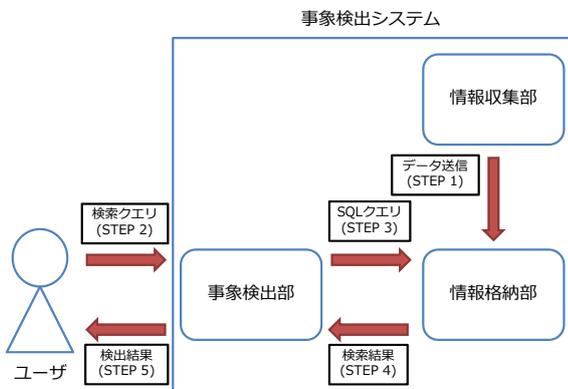


図 1: SQUED 概要図

3.1 情報収集部

情報収集部は、Android アプリとして実装しており、Android に搭載されている GPS センサ、地磁気センサからのデータ及び現在時刻を取得し、情報格納部にそれらのデータを送信する。

3.2 情報格納部

情報格納部は、情報収集部から送信されたデータをデータベースに格納する。まず、情報収集部から WebSocket を用いて送信されたデータを、nodeJS が受信し Redis に保存する。保存されたデータは一定時間ごとに Sinatra が取得し、データを事象検出に用いることが可能な形に整形した上で MySQL に

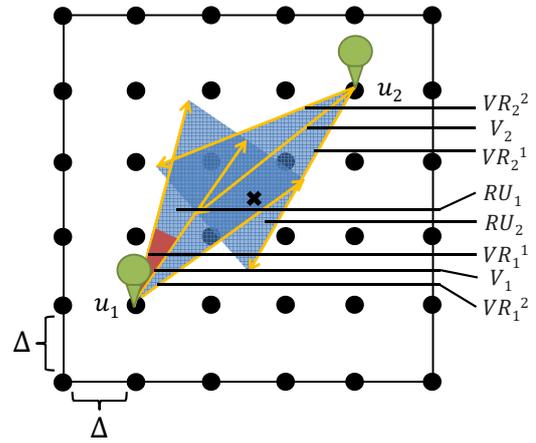


図 2: 既存手法概要図

格納する。具体的には、0.1 秒毎にデータをまとめたフレーム単位でデータを格納する。

3.3 事象検出部

事象検出部は、ユーザーからの検索クエリと情報格納部に格納されたデータを元に事象検出を行う。まずユーザーから、検出対象時間、検出対象範囲、検出対象データベース名、検出精度、視線長、視線範囲、最低視線重複人数の7つの内容を含む検索クエリを受け取る。検出対象時間、検出対象範囲、検出対象データベース名は、サーバである Sinatra に渡される。Sinatra はこれらの情報を元に SQL を生成し、情報格納部に問い合わせを行う。情報格納部から返ってきたデータと視線長、視線範囲、検出精度、最低視線重複人数の情報を用いて事象の検出を行う。

4. 既存手法

本章では、著者らが提案した、事象検出手法について述べる。

4.1 定義

検出対象範囲 R は、システムユーザが指定する検出精度 Δ と検出対象範囲となる基準点 (B_x, B_y) から生成した $(\Delta \times n_x) \times (\Delta \times n_y)$ の座標点により構成される長方形と定義する。

検出対象範囲内の事象検出に用いる座標点は、 $(n_x + 1) \times (n_y + 1)$ 個の $P_{ij} (i = 1 \dots (n_x + 1), j = 1 \dots (n_y + 1))$ の離散点とする。座標点は、図2に示すように、等しい間隔で、垂直水平方向に配置される。 Δ はシステムユーザが指定した、隣り合う座標点同士の間隔であり、事象検出の際の精度を表す。

さらに、クラウドソーシングのユーザを $U = \{U_k\}$ とする。 N_u 人のユーザ U_k の場所を UL_k 、ユーザの視線方向を V_k とする。あらかじめ与えられた視線範囲 θ を用い、 V_k を軸とした $-\theta/2$ から $\theta/2$ の角度ベクトルを VR_k^1, VR_k^2 とする。ここで、角度ベクトルの長さはシステムユーザが入力した視線長とする。そして R と UL_k から VR_k^1, VR_k^2 の共通範囲を RU_k とする。

4.2 手法

まず、 P_{ij} ごとの視線重複人数 DU_{ij} を求める。ここで、 $DU_{ij} = |U'_{ij}|$ where $U'_{ij} = \{U_l | P_{ij} \in RU_l, U_l \in U\}$ である。

次に、検出された事象の場所を E 、最低視線重複人数を $MU(= N_u)$ とすると、 $E = \{P_{ij} | DU_{ij} \geq MU\}$ を求める。 E が複数個存在した場合、 DU_{ij} の値が大きい順にソートし、値が大きい場所を事象発生箇所とする。図 2 は、クラウドソーシングのユーザが 2 人の場合の例である。

4.3 評価実験内容

7 名の被験者に、サーバに接続された Android 端末 (端末) を視線方向に向けて持ってもらう、地磁気センサの値と視線方向との差異がないか、GPS センサの誤差が許容値を下回っているかを確認してもらう。地磁気センサ、GPS センサの値の誤差が大きかった場合、キャリブレーションを行う。その後、被験者に指定した位置に立ってもらう。準備が整った後、サーバから任意の端末に向けて信号を送り、その端末から音を発生させる。被験者には、音が鳴った端末の方向を向いてもらい、音がなった被験者は向きを変えず静止してもらう。実験終了後、事象検出手法を用いて事象検出結果を確認する。この際、事象が発生した場所は、音が鳴った端末が位置する周囲 4 点の離散点とする。

事象発生位置からの被験者の距離、被験者の場所の偏り、事象発生箇所の事前通知の有無の 3 つの要素を変化させた次の 2 パターンを実施した。

パターン 1: 事象発生位置からの被験者の平均距離が 3 メートル、被験者の場所の偏りなし、事象発生箇所の事前通知あり

パターン 2: 事象発生位置からの被験者の平均距離が 6 メートル、被験者の場所の偏りあり、事象発生箇所の事前通知なし

4.4 評価実験結果

評価実験では、 α を 25 度 ~ 45 度の幅で変化させた時の検出精度、及び β を 0.33 ~ 1 の幅で変化させた時の検出精度について評価を行った。実験から、パターン 1 で α が 0.83 および 1.0 のときに事象が検出できなかった以外は、事象が検出できることを確認した。

4.5 問題点

既存手法では、検出対象範囲のスケールにおける点と、それに伴う複数箇所が発生した事象の検出における点の 2 点の課題が存在する。

まず、 Δ を 10 m、 n_x と n_y を 1000 とした場合を考える。このとき、座標点の数は 10000 個になる。SQUED は、それぞれの座標点に対し、ユーザの視線範囲との重複数をカウントする。ここで、ユーザの数や n_x 、 n_y の数が増えれば増えるほど、計算コストは大きくなる。そのため、検出対象範囲を増やすことが困難になる。

次に、5 km × 5 km の範囲でランダムに 10 件の事象が発生した場合を考える。もしシステムが、検出対象範囲のスケールにおける問題から、500 m × 500 m の範囲しか事象を検出できない場合、複数の事象を検出することは非常に困難になる。またこの場合、検出対象範囲を広げるほど、複数箇所が発生した事象の検出を行うことが難しくなる。

これらのような理由から、計算コストを削減し、事象検出の高速化を行う必要がある。

5. 改良手法 (RT-SQUED)

本章では、既存手法における計算コストの問題を解決するために著者らが提案した手法である、RT-SQUED (Real-Time Smart and Quick Unexpected-Event Detect method) について述べる。

5.1 基本的な考え方

既存手法における計算コストの問題を解決するため、RT-SQUED では、2 段階処理を用いて計算コストの削減を行う。図 3、図 4 に、荒い事象検出についての手順を、図 5 に細かい事象検出についての手順を示す。

荒い事象検出では、検出対象範囲を荒く区切ったグリッドと、それぞれのユーザの視線範囲である三角形を囲む最小の四角形との交差を検出する。各図に示す例では、検出対象範囲を 4 つのグリッドに区切る。図 3 は、左上のグリッドにおける交差検出を表す。図 4 は、4 つのグリッドの対し交差検出を行った結果である、各グリッドにおける交差数を示す。ここで、交差数のしきい値を 2 とすると、詳細に検出を行うべきグリッドは左上のグリッドのみとなる。このため、細かい事象検出は左上のグリッドに対してのみ行われる。

細かい事象検出では、既存手法を用いて事象検出を行う。図 5 における、赤い丸 (グレースケールでは白い丸) は、しきい値を 2 とした場合における、事象発生箇所を表す。RT-SQUED を適用することにより、計算コストの削減が可能となる。さらに、荒い事象検出を行う頻度を変化させることにより、精度と処理時間のバランスを調整可能で、状況に応じた事象検出を実現する。

5.2 RT-SQUED の簡易評価実験

RT-SQUED の効果を測定するため、簡易な評価実験を行った。評価実験では、既存手法における評価実験に使用したデータセットのうちの 1 つを用いた。RT-SQUED の評価結果を、表 1 に示す。なお、今回の評価では、荒い検出処理は 1 フレーム毎に行った。

表 1: RT-SQUED 評価結果

手法	検出精度 (F-measure)	処理時間 (sec)
既存手法	28.6%	31.67
RT-SQUED	28.6%	3.07

表 1 から、RT-SQUED によって、既存手法と比較し、処理時間を 1/10 に削減できたことがわかる。また、精度の低下は見られなかった。

5.3 考察

RT-SQUED における 2 段階処理により、計算コストを削減し、処理時間を削減することができた。また、処理時間を削減することにより、既存手法に比べ、より検出対象範囲を広げることが可能となり、複数箇所が発生した事象の検出にも対応できると考えられる。

しかし、使用したデータセットが限られているため、データセットを拡充した上で再実験を行い、より詳細な評価を取得す

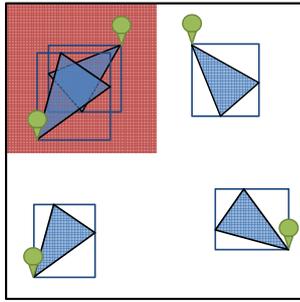


図 3: 荒い事象検出

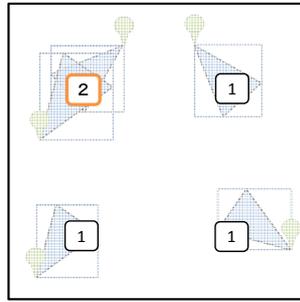


図 4: 荒い事象検出 2

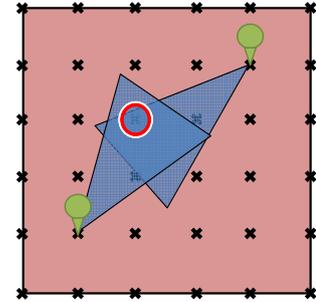


図 5: 細かい事象検出

る必要がある。

6. 擬似ユーザ生成器によるデータセットの拡張

本章では、既存手法と RT-SQUED の比較を詳細に行うために作成した擬似ユーザ生成器について述べる。擬似ユーザ生成器により、静止しているユーザ・直進するユーザ・ランダムな動きをするユーザを擬似的に生成可能である。

また、擬似ユーザ生成器を用いてデータセットに擬似ユーザを追加し、手法の再評価を行う。

6.1 定義

以前の実験で取得した既存のデータセットに含まれる、事象発生方向に端末を向けてくれるユーザの件数を U_e とする。また、このデータセットに擬似ユーザを加えたとき、擬似ユーザを含む全ユーザの件数に対し U_e が占める割合を p と定義する。擬似ユーザ生成器では、 $U_e * 1/p - U_e$ のユーザを擬似ユーザとして生成する。例えば、 $U_e = 6$ 、 $p = 0.1$ とすると、擬似ユーザ生成器が生成する擬似ユーザの総数 U_a は $U_a = 6 * 10 - 6 = 54$ 件となる。またこのとき、全ユーザの件数は 60 件であり、全ユーザに対する U_e の割合は 0.1 となる。

擬似ユーザを生成するとき、擬似ユーザ生成器は、静止しているユーザデータ・直進するユーザデータ・ランダムな動きをするユーザデータの 3 種類の擬似ユーザを、その合計数が算出された擬似ユーザの総数となるようランダムに生成する。また、擬似ユーザ生成器は、以下のパラメータにより、擬似ユーザを生成する。なお、 $PU_s + PU_w + PU_r = U_c * (1 - p) / p$ である。

静止しているユーザデータ (PU_s とする)

検出対象範囲内で、ユーザの座標をランダムに設定し、ユーザの視線方向を、 $0 \sim 360$ 度の間でランダムに設定する。

直進するユーザデータ (PU_w とする)

検出対象範囲内で、ランダムに選んだ始点・終点の座標を設定し、始点から終点方向に向けてユーザを直進させる。ここで、ユーザの速度は $0 \sim 8\text{km/h}$ の間でランダムに設定し、ユーザの視線方向は進行方向に設定する。

ランダムな動きをするユーザデータ (PU_r とする)

ユーザの速度は $0 \sim 8\text{km/h}$ の間でランダムに設定し、ユーザの視線方向を、 $0 \sim 360$ 度の間でランダムに設定する。ユーザを視線方向に向けて直進させるとき、1 秒以上のランダムなタイミングで視線方向を変更することにより、ランダムな動きを実現する。

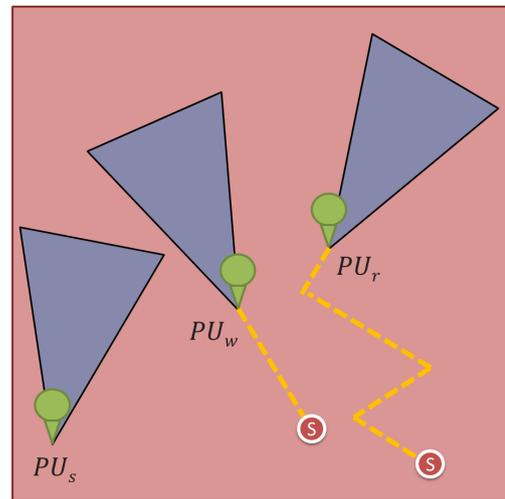


図 6: 擬似ユーザ概要図

擬似ユーザの概要を、図 6 に示す。図 6 は、赤い四角形で表現される検出対象範囲内で、 PU_s 、 PU_w 、 PU_r をそれぞれ 1 件ずつ出力し、初期位置から数フレーム経過した際の移動軌跡を示す。 PU_s は静止しているユーザデータであるため、初期位置から移動しない。 PU_w は直進するユーザデータであるため、中央に S と書かれた赤い丸 (グレースケールでは白い丸) から黄色の点線分移動している。 PU_r はランダムな動きをするユーザデータであるため、中央に S と書かれた赤い丸 (グレースケールでは白い丸) から黄色の点線分ランダムに移動している。

6.2 擬似ユーザを用いた評価実験

今回の評価実験では、RT-SQUED における評価実験と同様に、既存手法における評価実験に使用したデータセットのうちの 1 つを用いた。また、検出対象範囲は、以前のデータセットの $200\text{m} * 200\text{m}$ から拡大し、 $1.3\text{km} * 0.6\text{km}$ に設定した。このとき、既存のデータセットに対して、以下の 2 種類のパターン (パターン 1 とパターン 2) のように各種パラメータを変更するとともに、擬似ユーザの追加を行い、既存手法と改良手法における処理時間・精度比較を行った。さらに、複数箇所で事象が発生した状態を擬似的に生成し、同時に複数の事象が高速に検出できるのか確認を行った。

パターン 1 では、事象発生箇所が 1 つある場合を想定して、既存のデータセットに対し擬似ユーザを追加し、実験を行った。パターン 2 では、事象発生箇所が 2 つある場合を想定して、既存のデータセットに含まれるユーザ群を、検出対象範囲内に複



図 7: パターン 2 概要図

製した上で、擬似ユーザを追加し、実験を行った。図 7 に、パターン 2 におけるデータセットの概要図（一部掲載）を示す。青い枠内のユーザが既存のデータセットに含まれるユーザ群及びそのユーザ群を複製した擬似ユーザ群である。青い枠外のユーザは全て擬似ユーザである。

パターン 1: $U_e = 6, p = 0.1, U_a = 60, PU_s = 21, PU_w = 13, PU_r = 20$

パターン 2: $U_e = 12, p = 0.1, U_a = 120, PU_s = 31, PU_w = 28, PU_r = 49$

擬似ユーザを追加し実験を行った評価結果を、表 2 に示す。なお、今回の評価実験では、RT-SQUED の評価実験と同様に、荒い検出処理は 1 フレーム毎に行った。

表 2: 擬似ユーザを用いた評価結果

パターン・手法	処理時間 (sec)	1 フレームあたりの処理時間 (sec)
パターン 1・既存手法	1928.09	10.47
パターン 1・RT-SQUED	12.46	0.06
パターン 2・既存手法	4209.76	22.87
パターン 2・RT-SQUED	43.59	0.23

表 2 から、擬似ユーザを増加させて実験した際にも、RT-SQUED は既存手法に比べ大幅に処理時間を削減可能であることがわかる。また、ユーザの数が増えた場合や、同時に複数の事象が起きた際にも、最長で 1 フレームあたり 0.23 秒と高速に事象を検出できることがわかった。なお、既存手法と RT-SQUED との精度の差を目視で確認、比較したが、精度の低下は見られなかった。

6.3 考 察

擬似ユーザ生成器により、データセットの拡充を行い、2 つの手法について詳細な評価を行った結果、RT-SQUED を使用することにより、精度を維持したまま大幅に処理時間を削減できることがわかった。また、既存手法に比べ、検出範囲を広げた場合やユーザを増やした場合でも高速に事象検出を行うことが可能であり、複数箇所で発生した事象の検出にも対応可能であることを示した。

しかし、パターン 1 とパターン 2 において、既存手法及び RT-SQUED の処理時間の比は、順に約 2 倍、約 4 倍と、RT-SQUED の方がデータセットを増やした際の処理時間の比が大きいたことが確認できる。このため、データセットの拡充を行った上で再評価を行い、原因を特定した上で、手法の改良を行う必要があると考えられる。

さらに、ユーザの位置から遠い場所で起きた事象の検出や、ユーザの位置の偏りが事象検出精度に与える影響測定等、実験及び評価に不十分な点があるため、これらを今後の課題とする。

7. おわりに

本論文では、リアルタイムに突発的事象を検出可能とすることを目標として、事象検出を高速化した事象検出手法である RT-SQUED を提案した。また、検出高速化を実現できたことを確認するため、擬似ユーザ生成器を作成した。擬似ユーザ生成器を使用し、既存のデータセットに擬似ユーザを追加した上で手法の評価を行った結果、検出高速化を実現でき、複数箇所で発生した事象の検出にも対応可能であることを示すことができた。今後は、擬似ユーザ生成器の改良に取り組んだ上で、データセットを一層拡充し、手法の評価を行う。また、さらなる事象検出の高速化を目指し、手法の改良を行う予定である。

謝 辞

本研究の一部は、文部科学省科学研究費補助金 (24300039) の助成を受けたものである。関係各位に感謝する。

文 献

- [1] Alan F. Smeaton and Mike McHugh. Towards event detection in an audio-based sensor network. In *ACM, VSSN '05*, pp. 87–94, 2005.
- [2] A. Harma, M.F. McKinney, and J. Skowronek. Automatic surveillance of the acoustic activity in our living environment. In *IEEE ICME 2005*, pp. 4 pp.6–8, July 2005.
- [3] T. Yamamoto, K. Oku, Hung-Hsuan Huang, and K. Kawagoe. Squed: A novel crowd-sourced system for detection and localization of unexpected events from smartphone-sensor data. In *IEEE/ACIS ICIS 2015*, pp. 383–386, June 2015.
- [4] Du Tran, Junsong Yuan, and D. Forsyth. Video event detection: From subvolume localization to spatiotemporal path search. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 36, No. 2, pp. 404–416, 2014.
- [5] Feng Wang, Zhanhu Sun, Yu-Gang Jiang, and Chong-Wah Ngo. Video event detection using motion relativity and feature selection. *Multimedia, IEEE Transactions on*, Vol. 16, No. 5, pp. 1303–1315, 2014.
- [6] Tong Qin, Huadong Ma, Dong Zhao, Tianyuan Li, and Jianwei Chen. Crowdsourcing based event reporting system using smartphones with accurate localization and photo tamper detection. In *Big Data Computing and Communications*, Vol. 9196 of *Lecture Notes in Computer Science*, pp. 141–151. 2015.
- [7] Robin Wentao Ouyang, et al. If you see something, swipe towards it: Crowdsourced event localization using smartphones. In *ACM, UbiComp '13*, pp. 23–32, 2013.