

センサで取得した人流情報に基づく異常検知システムに関する基礎的検討 Machine Learning System for Anomaly Detection of Pedestrian Flow

熊谷 兼太郎[†] 小野 憲司[‡]
Kentaro Kumagai Kenji Ono

1. 研究の背景と目的

公民館、体育館などの公共施設は、例えば災害発生直後などに通常と異った利用をされることがある。こうした施設を適切に管理するため、利用状況を常に把握し、異常が発生した場合には速やかに対処する必要がある。しかし、そのために人間が 24 時間監視するのは非効率的である。

1.1 既往の検討

近年、常時インターネットに接続した人流センサを用いて、人流を自動感知し、リアルタイムに情報を取得する技術の提供が進んでいる[1]。また、自動的処理を行うシステムを用いて、センサの観測結果に基づいて建物内などの滞在者の人数をリアルタイムに集計することが比較的容易に実現できる[2]。従って、このような技術の組み合わせにより、センサで取得した人流情報に基づく異常検知システムの構築は、十分に実現可能と考える。

センサで物体検知をするには、いくつかの方式がある[3]。そのうち例として赤外線を使用したセンサについて述べる。その仕組みは、発光部から受光部にむけて赤外線が断続的に発射されていて、その間を人などが通ると受光部に届くはずの赤外線が途切れるので、人流があったと判定されるものである[3]。発光部と受光部は数 m~10 m 程度離すことが可能なので[4]、建物の入口を横断するように設置できる。赤外線は目に見えない可視光外の電磁波であり、通過する人の行動にほとんど影響を与えない。また、単に人流の有無を判定しているだけで年齢、性別などの属性は収集できないというデメリットがあるものの、この同じ特性は、個人の特定に直接つながる情報を収集しないという意味でプライバシーをある程度保つことができるメリットとして解釈することもできる。そこで、センサの物体検知に赤外線を使用したシステムの構築が考えられる。

1.2 研究の目的

本研究では、人流センサ及び異常検知プログラムを組み合わせた異常検知システムを提案することを目的とした。

そのための基礎的検討として、人流センサ及び異常検知プログラムから構成される試行システムを構築するとともに、その検証 (verification) 及び妥当性確認 (validation) を行った。以下、2.1 節で試行システムの構築について述べ、2.2 節で同システムの検証・妥当性確認をした結果について述べる。3 章は、結論である。

2. 異常検知システム

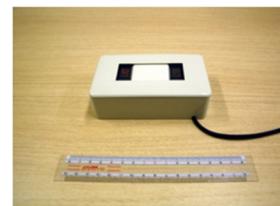
人流センサ及び異常検知プログラムを組み合わせたシステムを考えることとする。具体的には、同システムは赤外線センサによって人流をモニタリングし、測定結果をウェブ上のストレージに転送し、自動でリアルタイムに異常検知を行い、施設管理者の判断を補助する。

2.1 試行システムの構築

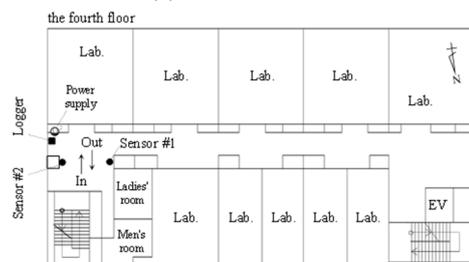
まず、建物への来訪者をモニタリングするために、人流センサを以下のとおり設置した。

センサの機材は、スキャンマチック販売株式会社の「iトレンド・ミニ」[4]を用いた。発光部と受光部は最大で 10 m 離すことが可能である。最も細かい時間解像度は 0.3 s である。すなわち、1 秒間に 3 人程度が等時間間隔で通過してもそれぞれ検知できる分解能があることになる。また、安全性については、LED 機器の光生物学的安全性に関する代表的規格の一つである EU EN62471 に基づいて Exempt (何らの光生物学的傷害も起こさない) と評価されている。従って、仮に通過する人が裸眼で発光部を覗き込んだとしても、安全性は十分に確保されていると考えられる。図-1(1)に、使用したセンサの写真を示す。

センサの設置場所は、京都大学吉田キャンパス北部構内 (京都府京都市左京区北白川追分町) の北部総合教育研究棟 4 階フロア入口である。図-1(2)に、同フロアの平面図を示す。図中の黒丸印の位置に、2 基で 1 組のセンサを配置した。センサ間は距離が 4.7 m で、2 測線の赤外線が平行に射出されている。ここで、フロア外からフロア内へむか



(1) 使用したセンサ



(2) 設置場所 (図中の黒丸印)

図-1 使用したセンサと設置場所

[†] 湘南工科大学工学部コンピュータ応用学科
Department of Applied Computer Sciences, Shonan Institute of Technology

[‡] 京都大学経営管理大学院 Graduate School of Management, Kyoto University

う方向を入場、その反対方向を出場と定義する。フロア外側測線で最初に物体を検知し、続いて内側測線で検知した場合は入場と判断する。反対に、内側測線で最初に検知し、続いて外側測線で検知した場合は出場と判断する。センサは床面から1 mの高さに設置した。これは、1人だけ通過したときに複数人と誤って検出する可能性を極力小さくするため、大人の腹から腰にかけての体幹部の高さにセットしたものである。

図-1(2)の黒四角印の位置に、ロガーを配置した。ロガーとセンサとはケーブルを用いて接続されている。データは、ロガーに内蔵されたSDカードに記録される。記録される項目はイベントの発生時刻及び入出場方向である。なお、最終的に目指しているシステムを実現するためには、測定データをリアルタイムに外部へ送信することが必要となる。ただし、今回は基礎的検討のため、SDカードにいったん記録しておいて検証・妥当性確認を行うこととした。

2.1.1 センサの設置期間

センサの設置期間は、2017年12月～2019年2月である。異常検知を行うためには、異常が発生していない平常時のデータが一定期間分必要である(以下、これを訓練データと呼ぶ)。そこで、2018年1月1日～12月31日のあいだ、訓練データを取得した。ただし、同年11月2日～5日は、建物において電源設備のメンテナンス作業がありシステムを停止したため、欠測期間である。すなわち、訓練データの日数 n は $n = 361$ である。また、一日の単位を午前6:00から翌日の午前5:59までと定義した(以下、特に断りの無い限りこの定義を用いる)。その理由は、センサの設置場所が大学内の研究棟であり深夜まで棟内に長時間留まっている人がいるので、未明から早朝にかけて発生するイベントのほとんどは前夜から留まっている人が行き来する行動であると考えたためである。

2.1.2 異常検知プログラム

次に、異常検知プログラムを開発した。図-2に、手順概要を示す。同プログラムは、訓練データの読み込み、訓練データの仕分けをする階層的クラスタ分析(以下、「クラスタリング」と言う。)、及び、統計的指標の計算を行う。続いて、リアルタイムで測定されているデータを逐次読み込んで異常検知を行う。

訓練データの読み込みのプログラムは、Intel Parallel Studio XE 2017 Update 2をMicrosoft Visual Studio Professional 2013に組み込んだ環境で作成した。元々の訓練データは、イベントが発生するたびに入出場方向及び時刻を記録したテキスト形式のファイルである。そのなかから入場だけを抽出し、累積入場者数(Cumulative number of Visitors, 以下CVと記す。)を午前6:00から翌日の午前5:59までの5分ごとに集計しなおし、行列データ X へと変換した。

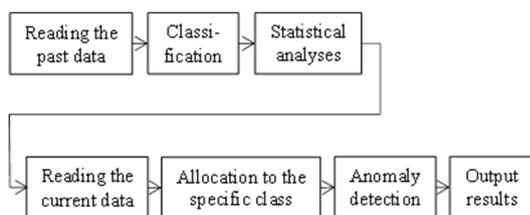


図-2 異常検知の手順概要

ここで、24時間×60÷5=288より $T = 288$ として、 X は、

$$X = \begin{pmatrix} x_{1,1} & \cdots & x_{n,1} \\ \vdots & \ddots & \vdots \\ x_{1,T} & \cdots & x_{n,T} \end{pmatrix} \quad (1)$$

という T 行 n 列の行列である。行列の要素 x の添え字のうち1番目はデータ取得日を示す数値(1, 2, ..., n)である。2番目は、6:00～6:04が1、6:05～6:09が2、...という順に翌日5:55～5:59まで割り振られた、時間帯を示す数値である。

訓練データの仕分けをするクラスタリングのプログラムは、金[5]を参考に、汎用的な統計解析ソフトウェアであるR Ver. 3.5.2を用いて作成した。訓練データは、1日のCVも、1日のなかでの増加の様子も、日によって大きなばらつきがあった。例えば、1日のCVが100人超の日もあれば0人の日もあった。そのような状況で、訓練データの全部を用いて統計的指標(例えば、平均値)を計算すると、データが本来有している特徴が失われてしまう可能性がある。そこでCVの時系列データを、類似度に基づいて適当な数のグループに仕分けすることとした。まず、CVの時系列データ同士のユークリッド距離を求める。 i 日目のデータ $x_{i,t}$ ($t = 1, 2, \dots, T$) と j 日目のデータ $x_{j,t}$ とのユークリッド距離 $d_{i,j}$ は以下の式で算出した。

$$d_{i,j} = \sqrt{\sum_{t=1}^T (x_{i,t} - x_{j,t})^2} \quad (2)$$

続いて、クラスタリングを行った。ここで、 $d_{i,j}$ が小さいときに類似度が大きいと考え、個別のデータ同士をまず小グループにまとめ、次に小グループ同士をより大きなグループにまとめ、という手順を繰り返す。その際、個別のデータとグループとのユークリッド距離、あるいは、グループ同士のユークリッド距離の計算方法は複数の手法が提案されている。そして、そのうちのどの手法を用いるべきか、定まった評価方法が提案されているとは言えず、「探索的にさまざまな角度でデータを眺めて、総合的に判断することが必要」とされている[6]。そこで、主要6手法(群平均法、ワード法、重心法、最近隣法、メディアン法、最遠隣法)を用い、得られた結果を樹形図(デンドログラム)でそれぞれ描いた。デンドログラムは、逆にした木の構造に似たグラフである。ある高さのところまで直線を引いて切断することにより、元の大きな1つの木を複数の房に切り分けることが出来る。今回は、2つの比較的大きな房が形成される切り方のうちで樹形図の最も高い(木の根元に最も近い)位置で切り分けることとした。このような作業を、6つのデンドログラムについてそれぞれ行った。

統計的指標を計算するプログラムは、先述と同じプログラミング言語を用いて作成した。

また、リアルタイムで異常検知を行うプログラムは、先述と同じプログラミング言語を用いて作成した。井出[7]によると、ホテリング理論[8]により以下の定理が成立する。すなわち、1次元の観測データ $\{x_1, x_2, \dots, x_N\}$ がある正規分布に独立に従い、新たな観測値 x' も同じ分布に独立に従うとする。 $\hat{\sigma}$ は標本分散、 $\hat{\mu}$ は標本平均とし異常度 $a(x')$ を以下で定義したとき、

$$\alpha(x') \equiv \frac{1}{\hat{\sigma}^2} (x' - \hat{\mu})^2 = \left(\frac{x' - \hat{\mu}}{\hat{\sigma}} \right)^2 \quad (3)$$

$N \gg 1$ ならば $\alpha(x')$ は自由度 $k=1$ のカイ二乗分布に従う。

$$\alpha(x') - \chi^2(k|k=1) \quad (4)$$

この定理を参考に、それぞれの変数に添字 i をつけた次の式(3)及び(4)も成立すると考える。すなわち、今回の観測データは任意の時間帯 t について、ホテリングの理論による定理が成立すると考える。

$$\alpha(x'_i) \equiv \frac{1}{\hat{\sigma}_i^2} (x'_i - \hat{\mu}_i)^2 = \left(\frac{x'_i - \hat{\mu}_i}{\hat{\sigma}_i} \right)^2 \quad (3')$$

$$\alpha(x'_i) - \chi^2(k|k=1) \quad (4')$$

(4')のときのカイ二乗分布の確率密度関数 f は、

$$f(\alpha(x'_i) | k=1) = \frac{1}{2\Gamma\left(\frac{1}{2}\right)} \cdot \left(\frac{\alpha(x'_i)}{2}\right)^{-\frac{1}{2}} \exp\left(-\frac{\alpha(x'_i)}{2}\right) \quad (5)$$

ここで、 Γ はガンマ関数であり、

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

より、(5)は

$$f(\alpha(x'_i) | k=1) = \frac{1}{2\sqrt{\pi}} \cdot \left(\frac{\alpha(x'_i)}{2}\right)^{-\frac{1}{2}} \exp\left(-\frac{\alpha(x'_i)}{2}\right) \quad (5')$$

図-3 に、 $\alpha(x')$ と f の関係を描く。 A をある実数としたとき、 $\alpha(x') = A$ となる事象の発生確率 p は、図中で曲線、横軸 $f=0$ 及び直線 $\alpha(x') = A$ に囲まれた範囲の面積に相当する。最後に、求められた p と、あらかじめ決めておいた閾値とを比較して、前者が後者よりも小さければ異常と判定する。例えば、 p が 5% 以下となるのは $\alpha(x')$ が 3.8415 以上のときである。式(3)より

$$\begin{aligned} \left(\frac{x'_i - \hat{\mu}_i}{\hat{\sigma}_i} \right)^2 &\geq 3.8415 \\ \therefore \frac{x'_i - \hat{\mu}_i}{\hat{\sigma}_i} &\geq \pm 1.959... = \pm 2 \end{aligned} \quad (6)$$

となり、観測された値が より 2 以上大きいまたは小さいとき、通常では 5% 以下の確率でしか発生しないような異常が検知されたことになる。

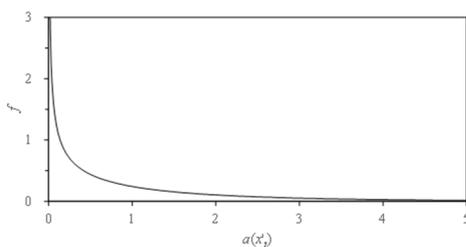


図-3 異常度と確率密度関数の関係

2.2 検証・妥当性確認

図-4 に、毎日の CV の時間変化を 5 分刻みの階段状グラフのかたちで示す。横軸は午前 6:00 から翌日午前 5:59 までの時刻をとり、縦軸は CV の値をとった。

1 日の CV は、最大 116 人で最少 0 人であり、日によってばらつきがあった。図によると、40 人程度を境に比較的多い日と少ない日とがある。1 日の CV が比較的多い日の日付を調べたところ、ほとんどが平日であった。また CV の変化は、ばらつきがあるものの 8:45 頃から大きくなり、朝から人流が活発になっている。CV の変化が大きい状態は 19 時頃まで続き、その前後の時間帯は小さい。すなわち、日中の時間帯の利用が中心と分かる。それに対し、1 日の CV が比較的小さい日は、CV の変化について明瞭な立ち上がりは見られない。

このように、訓練データは 2 つのグループで構成されている特徴をもったデータであった。

2.2.1 クラスタリングによる仕分け

主要 6 手法を用いてクラスタリングした。仕分け精度を評価するため、まず、京都大学の年間行事予定表などに基づいて、校休日及び平日のリストを作成した。校休日は、土曜・日曜・祝日に加えてお正月 (1/1~3)、創立記念日 (6/18)、お盆 (8/13~15) 及び年末 (12/31) で、欠測日 (11/3~4) を除外して 122 日である。平日はそれ以外で、欠測日 (11/2 及び 11/5) を除外して 239 日である。そして、クラスタリングの結果と比較することにより、本来は平日であるがクラスタリングの結果では校休日に仕分けされた日数 n_{e1} と、本来は校休日であるが平日に仕分けされた日数 n_{e2} とをそれぞれ求めたうえで、仕分けエラー率 r を算定した。

$$r = (n_{e1} + n_{e2}) / n \quad (7)$$

主要 6 手法のうちで仕分け精度が最も良かったのは群平均法及びワード法で、どちらも $r \approx 0.011$ であった。また、2 手法とも仕分けした結果に違いは無かった。ここからは、群平均法及びワード法の結果に限定して述べる。

n_{e1} または n_{e2} に該当した日を調べた。まず、8/16 (木) 及び 9/14 (金) はいずれも本来は平日であるが、校休日に仕分けされていた。その理由は、8/16 はお盆 (8/11~15) の直後で 1 日を通して来訪者が比較的小なかつたこと、夜に近隣で五山送り火の「大」の字の点火があつて、建物か

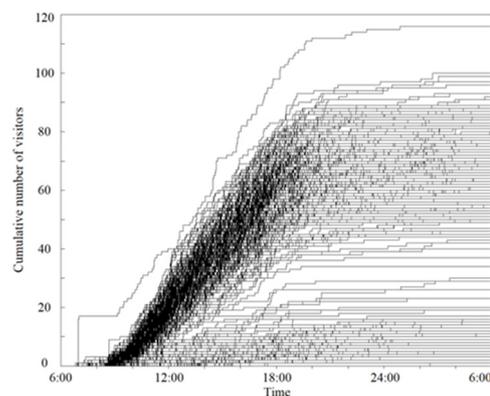


図-4 毎日の CV の時間変化

ら漏れる人工光の抑制のため建物利用を通常よりも控えたことが考えられる。また、9/14は連休(9/15~17)の直前であるため18時以降の来訪者が少なかったことが考えられる。

次に、7/21(土)及び10/27(土)はいずれも本来は校休日であるが、平日に仕分けされていた。その理由は、7/21は建物の1階会議室で開かれた会合、10/27は同じく1階ホールで開かれた講演会の影響がそれぞれ考えられる。

ここでは基礎的検討として、 r が最も小さかった群平均法及びウォード法を用いてクラスタリングした結果をそのまま、「平日」及び「校休日」として扱うことにした。

2.2.2 平均値と標準偏差

図-5に、例として、平日の訓練データについて、毎日のCVの19:00時点での度数分布を示す。図に描かれた分布は、一つの峰があり概ね左右へと対称に下る形状をしている。他の時刻についても同様である。そこで、データは正規分布に従っているとみなした。毎日のCVの平均値 μ 及び標準偏差 σ を5分刻みでそれぞれ求めた。図-6に、その時間変化を階段状グラフのかたちで示す。図中に実線で描いた μ は、8:45以前は1人未満であるが8:50に1.0人となり、その後は19:00ころまで概ね一定の傾きで増加する。そして、傾きは小さくなり翌日朝までに68.7人となった。また、点線で描いた σ は、6:55以前はゼロであったが7:00に1.0人となり、19:00ころまで概ね一定の傾きで増加する。そして、傾きは小さくなり翌日朝までに13.0人となった。

2.2.3 テストデータを用いた妥当性確認

2019年2月の第1月曜日である2月4日に、構築したシステムの妥当性確認を行うためのデータ(以下、これをテストデータと呼ぶ。)を取得した。

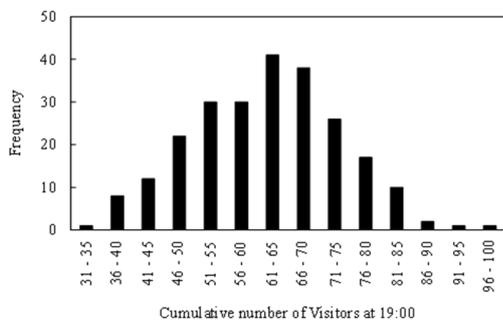


図-5 19:00時点のCVの度数分布

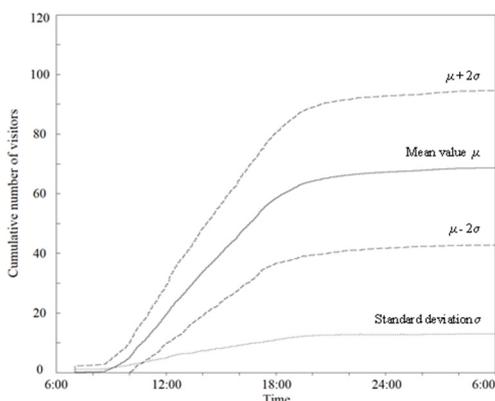


図-6 平均値及び標準偏差(訓練データ, 平日)

テストデータはリアルタイムに得られるデータを模擬している。従って、時刻 t_p ($t_p = 1, 2, \dots, T$)の時点では $1 \sim t_p$ の範囲のデータしか得られておらず、 $t_p \neq T$ であれば $t_p + 1 \sim T$ の範囲のデータは利用できないことになる。

そこで、まず $t_p = 1$ として、テストデータと平日の μ の時系列データのそれぞれ1番目のデータ(すなわち、6:00~6:04の5分間のデータ)だけを用いて、両者のユークリッド距離 d_w を求めた。また同様に、テストデータと校休日の μ のそれぞれ1番目のデータだけを用いて、両者のユークリッド距離 d_h を求めた。そのうえで、 d_w と d_h とを比較して、 d_w が小さければ平日と判定した。または、 d_h が小さければ校休日と判定した。

続いて、 $t_p = 2$ として、1番目と2番目のデータ(すなわち、6:00~6:04と6:05~6:10の10分間のデータ)だけを用いて d_w と d_h を計算し、平日か校休日かの判定を行った。以後、 $t_p = T = 288$ まで逐次的にこの過程を繰り返した。

このようにして、テストデータの取得日が平日か校休日かの逐次的な判定を行った。その結果、9:29 ($t_p = 41$)までは判定不能($d_w = d_h$)あるいは校休日と仕分けされていた。2月4日は平日であり特別に考慮すべき事情もなかったようであるから、本来は平日であるが誤って校休日とその時間帯は仕分けされる状態が発生したことになる。それ以降の時間帯は平日として正しく仕分けされていた。

3. 結論

公共施設の建物の入口などに設置したセンサで来訪者の行動を測定し、離れた場所からもリアルタイムでそうした情報を取得できるシステムを提案するとともに、機械学習の手法を用いて、毎日の建物入場者の人流を特徴に基づいて2群程度に分類し、未知の日についても類似度によってそのどちらかの群にリアルタイムに仕分けしたうえで、低い確率でしか発生しない異常な事象を検知するような実用的な手法を構築した。

謝辞

京都大学経営管理大学院の関係者の皆さんに、データ取得にあたりご協力を頂きました。ここに謝意を表します。

参考文献

- [1] 例えば、LiDARを使った人流計測サービス「スキア」、<https://www.nikkei-r.co.jp/service/lifestyle/lidar/>, 2021年6月1日確認。
- [2] 例えば、入退場者をカウントして混雑状況を表示するセンサー <https://xtech.nikkei.com/atcl/nxt/column/18/00120/00411/>, 2021年6月1日確認。
- [3] 例えば、動線計測ソリューション, <https://www.hitachi.co.jp/products/o-tracking/>, 2021年6月1日確認。
- [4] スキャンマチック販売株式会社: https://www.scanmatic.co.jp/itrend_mini/, 2021年6月1日確認。
- [5] 金明哲: Rによるデータサイエンス(第2版), 森北出版株式会社, pp.97-125, 2017.
- [6] Christensen L. and Ruch C. E.: The effect of social influence on response to hurricane warnings, *Disasters*, Vol. 4, No. 2, pp.205-210, Pergamon Press Ltd., 1980.
- [7] 井出剛: 入門 機械学習による異常検知-Rによる実践ガイド, コロナ社, pp.17-36, 2015.
- [8] Hotelling H.: The generalization of student's ratio, *Annals of Mathematical Statistics*, 2(3), pp. 360-378, 1931.