

# 環境認識ライフログからの行動パターン解析による類似性・イベント検出

富山県立大学 工学部 電子・情報工学科  
1415048 福嶋瑞希

指導教員：奥原浩之

## 1 はじめに

自身の研究テーマは中間発表前まで「Google の VisionAPI を用いた AR 教育コンテンツの作成と学習評価に関する考察」であった。しかし研究室に沿った研究内容でないと卒業論文として認められない危険性から、急ぎ奥原研究室の内容に沿った研究をすることとなった。このことより卒業研究を行う意味、つまりモチベーションについて再度考え直す必要と新たな分野の勉強が必要となった。

## 2 ライフログ

### 2.1 現在のライフログ

「ライフログ (lifelog)」とは、「人間の活動 (life)」の「記録 (log)」である。センサーなどで個人の活動に関するログを取得する行為が、元来のライフログの語源と考えられている。この個人の活動に関するログから、個人を特定できる場合、個人情報取り扱いに伴う義務が生じ、プライバシーの侵害という問題を引き起こす [1]。

スマートフォンから得られる位置情報履歴や写真撮影履歴を使用したライフログから行動特徴抽出とイベント検出を行う研究が行われている [2]。ライフログを収集する上で、手間がかからず無意識に残っていることが重要である。自動でライフログを残すことを可能にすることにより、誰でも負担のないライフログの収集を可能とする。

### 2.2 ライフログ取得アプリケーションの作成

現状の拡張現実を組み合わせたアプリケーションではデバイスに負荷がかかり、長時間の動作は難しい、またライフログとして定期的なデータの取得が難しい。よって拡張現実を組み合わせたアプリケーションではなく、ただ「スマートグラスのカメラ画像を定期的に取得し、その画像を画像認識 API へ送信し、返答される JSON データをテキストファイルに保存する。」というアプリケーションをつくる。将来的に拡張現実の負荷に耐えられるデバイスが販売されたり、プログラム内で負荷を少しでも減らしていくことで今までの研究は生かすことができると考えているため拡張現実を含めたアプリケーションでのライフログ取得は今後の課題としたい。

スマートグラスは EPSON MOVERIO BT-300 を使用し、画像認識 API は Microsoft 社が提供している API の一つである Computer Vision API を使用する。使用する理由として、今までの研究から Google Cloud Vision API と比較して、タグの性能差は大きくないが、精度の高いキャプションを出力できるため、キャプションからライフログ解析を行うことも視野に入れるためである。

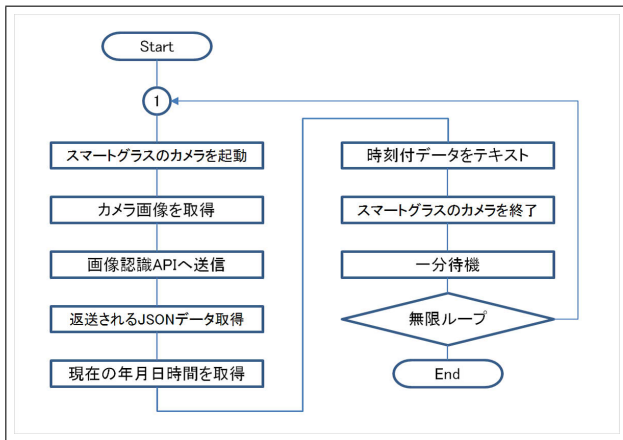


図 1: アプリケーションのフローチャート

図 1 はライフログ取得アプリケーションのフローチャートである。起動した際画面は真っ暗であり、カメラを起動しても画面に表示を行わないようにしている。EPSON MOVERIO BT-300 は黒い画面は透過する性質があるため、視界を妨げずにライフログ取得を行うことができる。また、カメラを起動させたままだと二時間程度で充電がなくなってしまったため、カメラの起動・終了にかかるバッテリー消費よりも連続起

動の方がバッテリー消費が大きいと考えデータ取得後カメラを終了させている。

## 3 データ取得と KHcoder

### 3.1 データ取得

テストデータとして 2018 年 1 月 6 日自宅にて 9 時 46 分から 19 時 46 分まで約 10 時間データを取得した。データは Microsoft Computer Vision API を使用して一分おきに取得を行い、タグとキャプションについて取得し、タグは confidence の高い順に 5 個保存した。しかし、一分おきに取得を行ったが、データの取得や保存に時間がかかり 1 分 10 秒～20 秒ごとの取得になり、10 時間取得を行い 8 時間分のデータしか取得できなかった。休止時間を 50 秒程度にしての取得か 2 分ごとの取得に変更するなど検討が必要である可能性がある。また、この日は一日自宅で卒論執筆などを行っていた。

### 3.2 自己組織化マップ

本研究では自己組織化マップ (SOM) の解析を行う。SOM は、ヘルシンキ大学のコホーネン教授により 1981 年頃に発表された、教師なし学習を行なうニューラルネットワークの代表例と言える解析手法である [3]。

ニューラルネットワークとは、脳機能に見られるいくつかの特性を計算機上のシミュレーションによって表現することを目指した数学モデルである。つまり、人間が無意識にやっていることを機械にやらせるということである。




図 2: 入力層と競合層

自己組織化マップは図 2 に示すように入力層と競合層の 2 つに分かれて競合学習を行う [4]。今、入力層から競合層への入力を  $x$  と定義する。 $x$  は入力データベクトルと呼ばれ、1 以上の次元を持つ。図 2 には、入力層のニューロンが複数個あるが、各々のニューロンがそれぞれの次元に対応した出力を行っていると考えられる。

また、競合層のニューロンと入力層のそれぞれのニューロンとの結合強度は総称して参照ベクトルと呼ばれ、 $m_i$  で表される。添え字である  $i$  は、競合層のニューロンの番号である。ここで、入力ベクトルと各ニューロンの参照ベクトルとのユークリッド距離で競合層のニューロンを競合させる。勝者ニューロンを  $c$  とすると、式 1 で表される。 $\operatorname{argmin}_i(x)$  は  $f(x)$  を最小にする  $x$  の集合であり、下側に変数がとる値の範囲を書くことが多い。

$$c = \operatorname{argmin}_i \{ \|x - m_i\| \} \quad (1)$$

勝者ニューロンは自らの参照ベクトルと入力ベクトルを近づける学習を行う。また、勝者ニューロンに近いニューロンについても、同じ入力から何かを学習しようと活性化するため、参照ベクトルを同様に更新させる (式 2)。

$$m_i(t+1) = m_i(t) + h_{ci}(t) \cdot \{x(t) - m_i(t)\} \quad (2)$$

また、 $h_{ci}$  は勝者ニューロンとの距離によりガウス関数で減衰する係数であり、式 3 で定義される。

$$h_{ci} = \alpha(t) \cdot \exp \frac{-\|r_c - r_i\|^2}{2\sigma^2(t)} \quad (3)$$

ここで、 $r_i$  は  $i$  番目のニューロンの競合層上での位置、 $r_c$  は勝者ニューロンの競合層上での位置を示す。また、 $\alpha(t)$  は学習率係数、 $\sigma^2(t)$  は学習半径という。ともに学習を収束させるため学習回数  $t$  で減衰する係数である。

3.3 解析方法ツール

自己組織化マップを作成するツールとして KH coder を使用していたが、卒業論文には使用不可能ということから紹介のみ記述する。KH Coder とは、テキスト型データの計量的な内容分析、もしくはテキストマイニングのためのフリーソフトウェアである。すべての機能をマウス操作で利用することができ、どんな言葉が多く出現していたのかを頻度表から見ることであったり、自己組織化マップ、共起ネットワーク等の解析を行える。KH Coder を用いて行われた研究としては、アンケートの自由回答項目・新聞記事・インタビューデータなど様々なデータを解析した事例がある [5]。

KH coder を使用した SOM の作成には、まず対象のテキストファイル（もしくはエクセルファイル）を読み込ませ、前処理ボタンおすと、POS Tagger を使用して形態素解析を行う。そして、自己組織化マップというボタンを押すだけで SOM が出力される。この時、SOM の学習に用いているのは、各文書に、それぞれの語が何度出現していたのかという集計表である「文書×抽出語」表（図 3）を使用している。また、自己組織化マップ作成過程ではユークリッド距離を利用している。文書の長さのばらつきに左右されない形で計算を行うために、文書中における語の出現回数をそのまま使うのではなく、1,000 語あたりの出現回数に調整したものを計算に使用する。また、実行時に距離が 0 となる語の組み合わせがあった場合、自動的にそのうち片方の語が分析から除外される。

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	h1	h2	h3	h4	h5	dan	bun	id	length_c	length_w	computer	laptop	table	desk	screen
2	0	0	0	0	1	0	0	1	0	0	0	0	0	0	0
3	0	0	0	0	1	1	1	2	17.5	8	1	1	1	0	0
4	0	0	0	0	2	0	0	3	0	0	0	0	0	0	0
5	0	0	0	0	2	1	1	4	17.5	8	1	1	1	0	0
6	0	0	0	0	3	0	0	5	0	0	0	0	0	0	0

図 3: 文書×抽出語表の例

KHcoder ではないツールで自己組織化マップを作成するために R を使用する。R は、多機能フリーデータ分析ソフトウェアである。

3.3 KHcoder での解析結果

取得したデータから R で SOM を作成した。使用したデータはキャプションデータである。




図 4: R で作成した SOM

4 今後の展開

自己組織化マップについての理解が追い付いていない状態であり、解析を行いながら理解を深めるべきである。また、データ量をより増やし解析を行ったり、自己組織化マップの比較など行い類似性・イベント検出を行うべきである。さらに SOM だけでなく共起ネットワークについて解析することが求められたため、同じように内容理解と解析が必要である。解析には KHcoder ではなく R を使用することとなったが、詳細なプログラムなどがないため勉強が必要である。そして、卒業論文をある程度書き上げる必要がある。

参考文献

[1] 新保史生. ライフログの定義と法的責任 個人の行動履歴を営利目的で利用することの妥当性. 情報管理, Vol. 53, No. 6, pp. 295–310, 2010.

[2] 宏貴角田, Hiroki SUMIDA. ライフログ分析による行動特徴抽出及びイベント検出. 法政大学大学院紀要（情報科学研究科編）, Vol. 9, pp. 119–124, mar 2014.

[3] T. KOHONEN. Self-organized formation of topologically correct feature map. *Biol. Cybern.*, Vol. 43, pp. 59–69, 1982.

[4] 自己組織化マップを用いた気象要素の分類と予測. <http://www.gifu-nct.ac.jp/elec/deguchi/sotsuron/oka/oka.html>, 2011. 閲覧日 2018,1,7.

[5] Kh coder を用いた研究事例のリスト. <http://khc.sourceforge.net/bib.html>, 2017. 閲覧日 2018,1,7.