

環境・設備・人データに基づく居住空間の理解に関する研究

A Study towards Understanding Functionality of a Living Space based on Environment, Facility and Human Data

高井 勇志

Takeshi Takai

株式会社 竹中工務店 技術研究所

Takenaka Corporation

A hybrid system gives us a clue to understanding functionality or characteristic of a system from its time series. By integrating hybrid systems of environment, facility and human, we can understand functionality and characteristic of a whole space from which the system is obtained. This paper focuses on a hybrid system derived from human data, and shows that the system enables us to quantitatively notice changes of functionality of a living space.

1. はじめに

居住空間を構成する設備機器や環境, 人から得られた活動パターンについて, その要素が所属する「空間」という単位で統合すると, 空間全体の機能や活動が把握できるようになると考えられる (図 1). この枠組みを用いると, 個別の要素について単独で異常や故障を検出するのではなく, 空間全体としての機能や活動の変化を検出することが可能となり, 個々については異常がなくても空間機能として何か支障が出ていることがわかるといった, より高度なサービスへの応用が期待できる.

文献 [Takai 16] では, 離散的なモード変化と各モード内のダイナミクスを組み合わせたハイブリッドモデルを用いて時系列データを扱うと, その系列を出力した機器などの活動を表現・理解することができることを示し, この枠組みを用いて設備や環境由来データによる活動の表現や理解を試みた. 本稿では, 人由来データに対して本手法を適用してその活動把握についての検証を行い, 設備・環境・人由来データを組み合わせた空間機能や活動の理解についての可能性を探る.

ここで, 文献 [Takai 16] のモデル化法のうち, 単一のセンサから得られた時系列データからハイブリッドモデルを取得する流れをまとめておく (図 2).

1. 時系列データの区分化: X_i
2. 主成分分析を用いた区分化データの次元削減: X'_i
3. 混合ガウス分布を用いたクラスタリングによるモード推定: $q_j, N(\mu_j, \Sigma_j)$
4. モード遷移確率の取得: $P(q_k | q_j)$




図 1: 空間の機能と活動を表すグラフィカルモデル

2. 人由来データに対するモデル化

2.1 データ取得と再サンプリング

人由来データを取得するためのデバイスについては, 大きさや形状, ネットワーク接続の有無など様々な特徴を持ったものが市販され, 容易に手に入る状況となっている. 本研究では, 取得可能なデータの種類の種類, データ収集の利便性を考慮して, 常時ネットワークに接続可能な Apple Watch を用いた. 本研究で用いたデータを以下に示す.

- 活動量 (キロカロリー)
- 歩数 (歩)
- 心拍数 (1 分当たりの拍動数に換算された値)

これらのデータは, Apple Watch とペアリングしてある iPhone のストレージに適当なタイミングで保存されている. したがって, 取得したデータに対して, 以下のようにして再サンプリングを行った.

1. 1 日を適当な時間で区切る. 例えば 1 分で区切った場合, 1 日分の区分時系列データの次元数は 1440 となる.
2. それぞれの時間帯内に計測されたデータについて平均値を求め, これをその時間帯の値とする. ただし, 該当する時間帯にデータが存在しない場合は値を 0 とする.

2.2 結果

本研究に用いたデータは, 竹中工務店技術研究所に勤務する男性研究員 1 人を対象とし, 2015 年 10 月 1 日から 2016 年 9 月 30 日までの 12 ヶ月間, 休日も含めて毎日計測したものをを用いた. ただし, 計測の都合上, 朝 7 時から夜 7 時までのデータについて 3 分で区切ったものを分析に用いた. つまり, 1 日分の区分時系列データの次元数は 240 である. 図 3 に取得したデータ, 推定したモードのダイナミクス, 計測期間の各日のモードを示す.




図 2: 時系列データのモデル化

連絡先: takai.takeshi@takenaka.co.jp, 〒 270-1395 千葉県印西市大塚 1-5-1.

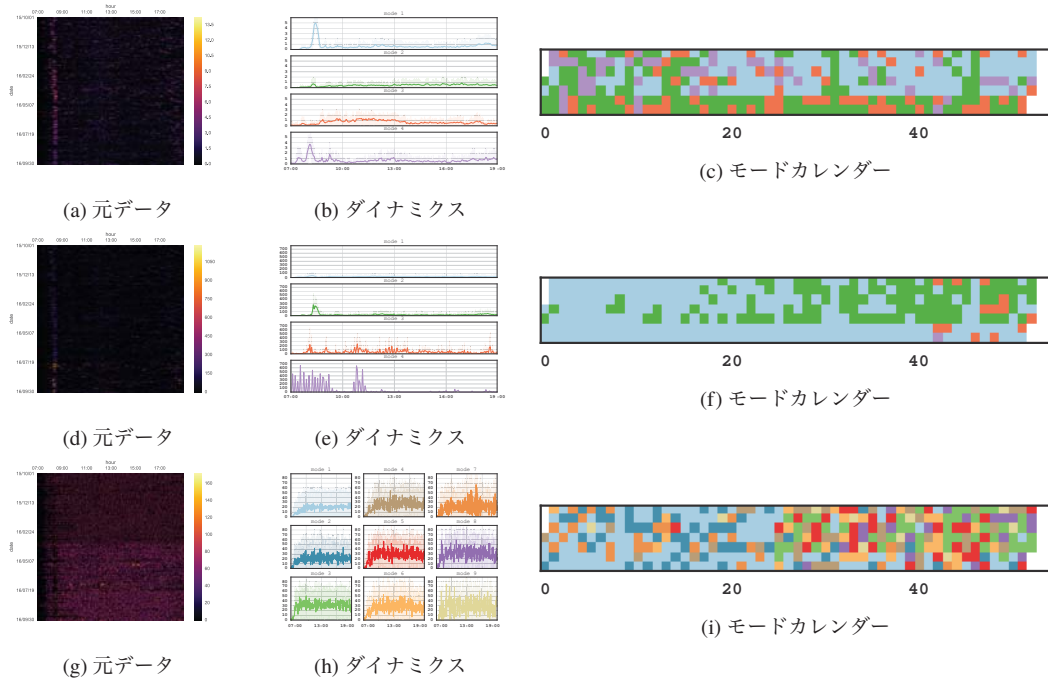


図3: 人由来データの12ヶ月分のデータとモデル化結果。“元データ”はセンサから得られた値を、“ダイナミクス”は学習したモードの μ と Σ を、“モードカレンダー”は各日のモードを可視化したものを示している。“元データ”の横軸は時刻、縦軸は日であり、明るい色ほど値が大きいことを示している。“ダイナミクス”の横軸は時刻、縦軸は値であり、それぞれ学習したモードのパラメータである μ と Σ を、実線とその上下範囲で示している。“モードカレンダー”の横軸は週番号、縦軸は曜日(月～日)であり、色は学習したモードに対応している。なお、(a)–(c)は活動量、(d)–(f)は歩数、(g)–(i)は心拍数のデータである。

2.3 考察

まずは、活動量の結果(図3(a)–(c))を見ていく。

元データ(a)を見ると、朝の8時頃に大きな値の列が見え、日々の通勤時の活動がほぼ一定の時刻であることがわかる。しかし、日中以降の活動量の大きさは日によってばらけており、特に一定の活動は見られない。

このデータを用いてモード推定をおこなった結果が(b)と(c)である。まず、このデータ収集期間における被験者の活動のモード数は4であることがわかる。ダイナミクス(b)を見ると、モード1や4では朝の通勤時の活動が表されていること、さらに、夕方以降には明確なピークは立っていないことがわかり、元データを可視化することで得られる結果と一致している。また、(a)から直観しづらいパターンとして、モード2と3が現れている。(c)を見ると、これらのモードは主に土日や休日に多く現れていることがわかり、モード3については午前中の活動がモード2より多いことがわかる。

次に、歩数の結果(図3(d)–(f))を見ると、朝にピークがあるといった、上記の活動量の結果と似た傾向にあることがわかる。元データ(d)を見ると、7月以降にそれ以前より大きな値が現れる傾向が見られるが、これは独立したモードとしては推定されていない。今回のデータ取得期間以降でもこの傾向が続いていれば、新たなモードとして認識される可能性が考えられる。モード4については、モードカレンダー(f)を見ると1日のみ出現していることから、この期間内では全く似た日がない特異日のモードであると考えられる。

最後に心拍数の結果(図3(g)–(i))からは興味深い結果が得られている。元データ(g)を見ると、3月末から4月にかけて明らかに傾向が二分されている。活動量や歩数についてはこの期間における変化が見られないことから、心拍数に大きな影

響を与える何らかの変化が起きたと考えられる。一つの可能性は、この時期に研究所のレイアウト変更があったことが挙げられる(図4)。つまり、このレイアウト変更によって働き方や環境などの変化があり、それが心拍数に影響を与えたと考えられる。この影響を与えた要因については、より詳細な分析やデータが必要となるが、人由来データから、空間機能の変化、或いは環境の変化を見出すことができると言えるだろう。

3. まとめ

本稿では、設備・環境由来データに対して行ったモデル化手法を人由来データに適用し、そのモードやダイナミクスをモデル化できること、また、得られたモデルからその人が滞在する環境や空間機能の変化を見出せる可能性を確認した。今後は、これらの設備・環境・人由来データを組み合わせ、空間としての機能の理解に関する研究を進めていく。

参考文献

[Takai 16] 高井 勇志. 建物活動プロフィール: 建物内活動のモデル化と学習. 2016年度人工知能学会全国大会(2016).



図4: ワークスタイル変更(左: 変更前, 右: 変更後)