

# 時系列データを扱った研究の動向調査

## Systematic Review of Studies on Time Serise Data

柴田 祐樹<sup>1\*</sup> 高見 玲<sup>1</sup> 菊池 圭祐<sup>1</sup> 武川 紘也<sup>1</sup> 白井 佑<sup>1</sup> 張 錦程<sup>1</sup>  
笹方 育也<sup>1</sup> 李 穎豪<sup>1</sup> 高間 康史<sup>1</sup>

<sup>1</sup> 首都大学東京 システムデザイン研究科

**Abstract:** 時系列データを扱った研究は未来を推測する枠組みを与え、季節の予測等生活に不可欠であることから古くより行われている。現在では、対象とする手法や問題は分野横断的となっているため、全体像の把握が難しくなっていることから、時系列データを扱った研究の動向調査を行い、その結果を報告する。近年医学系の分野で用いられる体系的調査を参考に、本調査に適した形式に改良した調査方法についても報告する。

## 1 研究背景

本稿では人工知能分野における時系列データを扱った研究の動向調査の結果報告と、本調査に適した体系的な調査方法 (Systematic Review) [2] の提案を行う。

時系列の解析に対する要求は、季節の予測など生活に直結することから古くから存在する。これら要求は現代でも同様であり、加えて近年では計算機を用いた数値解析手法の発達、時系列に対する汎用的な数理モデルの導入により [6]、貨幣価値の変動、機械の制御、解析可能な範囲は広がり続けている。この現状に対し、時系列データを扱った研究を体系的にまとめた文献が見当たらないため、全体像を俯瞰可能とする資料作成が、本調査の目的の一つである。

別の目的として、一般性の高い体系的な調査手法を構築し、様々な調査に対して適用可能な手法を構築しておくことは、今後においても価値があることである。体系的調査は医療分野ではすでに広く行われており、この分野での手法は確立されていると言えるが、医療分野における文献調査では人命に関わることから漏れが認められない一方、人工知能分野においては明確な基準があるわけでもなく、このように調査趣旨が異なるため、人工知能分野に適した、効率的な体系的調査手法を構築することも本調査の目的とする。

調査対象とする文献発行媒体として、本調査では、2016年から2019年までの間の日本人工知能学会全国大会予稿集を調査対象とした。本媒体を選んだ理由は、国内、特に人工知能分野での動向を幅広く知りたいため、また、文献あたりの容量がそれほど大きくなく、試行錯誤が行われる調査手法確立のための調査に適していると判断したためである。

\*首都大学東京システムデザイン研究科  
191-0065 東京都日野市旭ヶ丘 6-6  
E-mail: hshibata@tmu.ac.jp

## 2 関連研究

### 2.1 体系的調査

本調査で採用する体系的調査はもともと医療の分野において、網羅的な調査に基づき全体として優勢なものを明らかにする目的で行われるものである。典型的には以下の、2段階に分けて調査が行われる [2]。

- 1次選別: 要約や表題を参考にした網羅的に文献を収集
- 2次選別: 上記収集された文献の全文を確認し、関係する文献を選別

1次選別では、取りこぼしが無いように、少しでも疑わしい文献ならば収集される。2次選別では関係のない文献が除外される。どちらの作業も複数人で確認が行われる。手法や材料の出現頻度などを集計し、統計的に議論も行われる。

この体系的調査は、計算機科学など他分野でも利用されている [1,3,4]。基本的には [2] と同様に網羅的な取りこぼしの無い調査方法で行われるが、選別の基準に文献の特徴を使うなど、調査対象や目的に応じて幾らかの拡張が行われる [4]。文献の収集方法は重要であるが、使う検索エンジンや、選別の効率性に言及している文献は見当たらない。

得られた知見をまとめるために、分野の分類を作成し、体系的に論じる手法がしばしば用いられる [5]。ACMのページでは<sup>1</sup>、計算機科学の分野の分類を提供されている。広く知られるように、分野の分類は階層構造をもたせることで、様々な粒度で議論が可能となる。これに関し、文献 [5]、ACM どちらも、分類を階層的に定義している。

<sup>1</sup><https://dl.acm.org/ccs> [2020年3月閲覧]

## 2.2 時系列

時系列といえば、ある時刻  $t$  の値  $f(t)$  が  $\tau < t$  であるような  $f(\tau)$  に依存して決まる系列のことである。この系列を微分方程式として定式化し、未来の挙動を予測することは広く行われている。19世紀以降、ブラウン運動をはじめとする確率的な系列の研究が進み、確率過程として経済学、物理学をはじめとする様々な分野に適用可能な理論的枠組みが完成している [6]。

## 3 調査方法

既存の調査手法に効率性へ言及したものが見あたらないが、限られた時間において調査を繰り返し行う為に効率性の高さは必要である。そこで、本稿では、次に示す調査全体を5段階に分けた調査方法を提案する。

- 事前調査: 媒体と文献の傾向を調査
- 一次選別: 文献を広範囲に網羅的に収集
- 二次選別: 大まかな内容確認による選別と分類
- 三次選別: 全文精読による選別
- 報告書作成

一次選別では、調査範囲の偏りを防ぐために、統計的かつ機械的手法を用いて文献を網羅的に収集することを目的とする。範囲を広くするために一文献あたりの作業量を減らす必要があり、調査方法は文献の表題のみの確認、特徴語による機械的検索などに限定したため、不適切な文献が結果に含まれることが想定される。

二次選別では、上述の不適切な文献を除外を行う。ここでは内容の確認を伴うが、同時に報告書の作成に必要な体系化なども行ったほうが効率的であり、かつ理解の助けにもなると考えるため、本調査では文献の分野分類や、当該分野における位置づけの把握も同時に行う。この時、効率と柔軟性を向上させるために、導入部のみを把握することで文献を選別する。医療系における症例把握目的など、内容の見逃しが許されない調査では二次選別の段階で全文を確認することが望ましいと考えるが、本調査は研究動向調査であり、網羅性だけでなく時間的負担を減らし結果として全体の質にかける余力を確保することが重要であるとの観点から、この方式とする。

三次選別では、全文を詳細に確認し、必要に応じて体系的にまとめ最終報告書作成のための準備を行う。不適切な文献は除外する。

上記大枠による作業は人でのみでも可能な範囲であるが、これに加え、本調査では近年利用可能である、検索エンジン、高い計算機性能を活用した調査とするた

めに、上述した事前調査、一次、二次、三次選別のそれぞれの間で、計算機による統計処理を行えるように全体の方式を設計する。以降の節でこれらの詳細について説明する。

### 3.1 事前調査

#### 3.1.1 調査媒体の予備的調査

調査媒体には様々な特徴がある。例えば、表題、引用、節の構成は各会議で異なり、論文が提供される媒体には複製防止策（コピープロテクト）が施されていたり、入手困難な文献が存在したりするため、本格的な調査を開始する前に事前調査を行い、調査方法の詳細を決定する。このために、本調査でははじめに、調査協力者全員に各自興味を持つ文献を報告してもらい<sup>2</sup>、その作業を通して媒体の特徴を把握してもらう。また、文献の内容を報告書にまとめてもらうことで、調査対象の分野への足がかりとなる知見の獲得を目指す。

報告書には当該文献中で時系列に関する研究分野で関連が深いと思われる特徴語を近傍語として記載してもらう。この時得られた近傍語を用いて文献の検索を行うことも考えられたが、本節の作業により選ばれた文献は恣意的であるため、次の節で説明する無作為な予備調査により得られる近傍語を、このような検索語拡張に用いる。

#### 3.1.2 一次選別のための無作為な予備調査

前節の作業により、調査媒体の仕様を確認したのち、検索エンジンを利用しより広範囲かつ無作為な文献の抽出を行う。さらに、調査範囲に対し網羅的な文献を検索結果として得られるように、次の手順により検索語を拡張する。二次選別以降の指針となるよう、同時に各研究の分類を木構造により行うことも試みる。

- 検索語「時系列」により文献を検索
- 得られた文献の導入部を読み、関連深いと考えられる単語を収集し、それらを近傍語と定義
- 簡単な分類を作成

### 3.2 一次選別

3.1.2節の作業で得られた近傍語に対し、調査協力者は検索語に相応しいどうか判定し、検索語を選別する。この具体的な手順を以降説明する。

<sup>2</sup>YAML形式の様式まとめて報告してもらい、後の解析を容易にした <https://yaml.org/spec/1.2/spec.html> [2019年12月閲覧]

評価者（調査協力者）の集合を  $U$ 、近傍語の集合を  $W_{\text{nbr}}$  とする。  $u \in U, w \in W_{\text{nbr}}$  に対し、  $k(u, w)$  は  $u$  が  $w$  を採用すべきと主張した時 1 を取り、そうでないとき 0 を取るものとする。以上の定義のもと、  $w$  の評価  $\tilde{s}(w)$  を式 (1) により計算する。

$$\tilde{s}(w) = \frac{\sum_{u \in U} k(u, w)}{\sum_{u \in U, w \in W_{\text{nbr}}} k(u, w)} \quad (1)$$

また、近傍語の中に存在する同義語を一つにまとめるために、代表語を定義する。この代表語の集合を  $W_r$  と表し、  $w \in W_r$  に対して同義語の集合を  $W_{\text{id}}(w)$  とする。以上の定義から、代表語  $w$  のスコア  $s(w)$  を次式で計算する。

$$s(w) = \frac{\sum_{w' \in W_{\text{id}}(w)} \tilde{s}(w')}{\max_{w'} \tilde{s}(w')} \quad (2)$$

式 (2) では同義語の多い代表語が過大に評価される可能性があるため、近傍語への評価を行うとき、評価者には同義語に対してできるだけ重複した採用結果としない評価とするよう依頼し、重複による過大評価となる危険性を防ぐ<sup>3</sup>。  $s(w)$  の値が高い方から順に、幾らか選び、検索語とする。検索語の数は再現率を確保する必要性と検索の負担を考慮した上で決定する。

次に、検索語を用いて文献を選別する。本調査では検索語を J-Stage<sup>4</sup>が提供する検索エンジンへ一つづつ入力し、得られた文献を記録した後、検索語の評価値を合計し、文献に優先度を定義し、優先度の高い方から順に文献を選ぶ。選ぶ文献の数は先ほどと同様に再現率を確保する必要性と、二次選別の負担を考慮した上で決定する。

次に上述した文献の優先度の定義を具体的に述べる。文献の集合を  $D$  と表し、文献  $d \in D$  に含まれる単語の集合を  $W(d)$  とする。また、  $w \in W$  に対する文献  $d$  の検索結果を示す関数を  $I(w, d)$  とし、式 (3) で定義する。

$$\begin{aligned} [\exists w' \in W_{\text{id}}(w), w' \in W(d)] &\Rightarrow I(w, d) = 1 \\ [\nexists w' \in W_{\text{id}}(w), w' \in W(d)] &\Rightarrow I(w, d) = 0 \end{aligned} \quad (3)$$

この定義のもと、文献  $d$  の評価  $s_1(d)$  を式 (4) で定義する。

$$s_1(d) = \sum_{w \in W_r} I(w, d) s(w) \quad (4)$$

<sup>3</sup>同義語をまとめてから評価を行うべきであったが、今回の方式では同義語の選定と近傍語の評価を同時に行ったため、評価にあたりこのような煩雑な注意を与えている。本来は同義語のみを評価したほうが良い。

<sup>4</sup><https://www.jstage.jst.go.jp/browse/-char/ja> [2019 年 12 月閲覧]

### 3.3 二次選別

二次選別では人による評価を重視した選別方法とする。ここで、一次選別を通過した文献は単語による検索によってのみ選ばれたものであり、調査内容に対し不適切なものも多く含まれているため、これらを除外する必要がある。このために、まずは主に導入部のみ把握することで、大まかな選別を行う。また、導入部を把握することで得られる知見から、分類を作成する。分類の作成にあたり、3.1.2 節の結果や関連研究に上げた文献の分類を参考にする。

報告書では、動向を研究の分野、つまり手法などの分類毎に体系的に説明することが望ましいため、分類毎に評価者の担当をわけ、精読、つまり三次選別に望む方式が良いと考える。このときの担当分けの目安とするために、選別中、文献に対する自らの専門分野との関連性を 3 段階、「関連なし」、「少し関連有り」、「専門に該当」で記載してもらう。

#### 3.3.1 選別方法

一次選別の結果得られた文献の列  $d = d_1, d_2, \dots, d_n$  の各要素の全体を  $D_{1\text{st}}$  とする<sup>5</sup>。ただし  $n$  は文献の数で、  $|D_{1\text{st}}| = n$  ある。つぎに、評価者  $u (\in U)$  の  $d \in D_{1\text{st}}$  に対する評価を  $I(u, d)$  とし、  $u$  が  $d$  を参考にすべきと判断した場合、  $I(u, d) = 1$ 、参考にする必要がないと判断した場合  $I(u, d) = -1$  とする。また、これらいずれにすべきか判別できないもしくは評価を行っていない場合  $I(u, d) = 0$  であるとする。以上の定義において、式 (5) 中  $s_2$  の値が 1 以上の文献を採用し、その集合を  $D_{2\text{nd}}$  とする。

$$s_2(d) = \sum_{u \in U} I(u, d) \quad (5)$$

ただし、  $\sum_{u \in U} |I(u, d)| \leq 3$  を満たすものとする<sup>6</sup>。

#### 3.3.2 分類の作成

報告書を分類を目安にまとめることを想定しているが、このために、選ぶべき分類を定量的に議論する必要があるため、ここでは分類の定式化を行う。

分野の分類は階層構造を持つものと仮定する。分類全体の集合を  $V$  とし、  $v \in V$  に対し  $v$  の下位に属する分類の集合を  $f(v) (\subset V)$  と表す。また、  $v \in V, d \in D_{1\text{st}}$  に対し定義された分類を  $f'(d, v)$  と表す。ここで、3.3 節の報告書に記載された分類は断片的なものであるため、

<sup>5</sup> $\{d_1, d_2, \dots, d_n\} = D_{1\text{st}} \subset D$  である。

<sup>6</sup>つまり、1 か -1 の評価を行った評価者が 3 人となった時点で当該の文献にはそれ以上評価者を割り当てないものとする。また、  $|s_2(d)| = 2$  となった時点で、同様にこれ以上評価を行っても結果が変わらないため評価者の割り当てを停止するものとする。

これらを統合し分類体系を作るために、 $f(v)$  を式 (6) で定義する。

$$f(v) = \bigcup_{d \in D_{1st}} f'(d, v), v \in V, \quad (6)$$

また、文献  $d$  の評価  $s_2(d)$  を用い、分類  $v$  の評価  $s_d(v)$  を式 (7) で定義する。

$$s_d(v) = \ln \left( \sum_{d \in D_{1st}} s_2(d) \min(I(u, d), 0) \right), v \in V, \quad (7)$$

次に、得られた分類の構造と、分類それぞれの評価値から、着目すべき分類を抽出する方法を説明する。

式 (6) で分類を階層的に定義しているため、分類の数は階層が深くなるにつれ指数関数的に増加すると推測する。このため、式 (10) に示す指数分布から分類  $v$  が生成されるとモデル化すれば、分布をよく表現する統計量が得られると考える。

$$p(v) = \lambda \exp(-\lambda s_d(v)) \quad (8)$$

このとき、分類の集合  $V$  に対し、この分布に対する対数尤度関数は以下で定義される。

$$l = |V| \ln \lambda - \lambda \sum_{v \in V} s_d(v) \quad (9)$$

上記対数尤度の  $\lambda$  による偏微分が 0 となるときの  $\lambda$  を求めることで、最尤推定値  $\tilde{\lambda}$  は式 (10) により求めることができる。

$$\tilde{\lambda} = \frac{|V|}{\sum_{v \in V} s_d(v)} \quad (10)$$

この推定量  $\tilde{\lambda}$  を使い、着目すべき分類を推定することを以降考えるが、本調査では次の仮定を用いることとする。

1. 得られた分類は正しいものではなく、真の分類の一部を切り取ったものである。
2. 分類の階層関係は見かけの他に、調査の着目点に従い暗黙的に決定されている。

1 の仮定より、理想的な分布を仮定することが可能である。理想的な分布とは、どの階層でも対称性の高い議論が可能であることを要請すると考えるため、分類の階層構造がある一つの定数  $c (\in N)$  に対し、 $\forall v \in V, |f(v)| = c$  を満たすと仮定する。つまり、最上位分類から  $c$  ずつ均等に枝分かれしていくものとする。このとき、すべての階層間の要素数の比は  $c$  となるため、 $i$  番目の階層に属する要素の数  $n_i$  は次のように表される。

$$n_i = c^{i-1} \quad (11)$$

上記のような分類を行うことは一般に困難であるが、高度に統計的振る舞いをする系、つまり近年見られる高度に枝分かれした学術体系では潜在的に成り立っていると仮定することは妥当だと考える。

そして、2 の仮定より、得られた分類体系の最上位が「時系列」<sup>7</sup>でなくとも、時系列データの動向を調査するのに適切な文献から生成されたものであるため、「時系列」を最上位に持ってきた階層構造を構築可能な分類集合が得られていると考える。

以上の解釈に基づき、「時系列」以下の分類の数を  $c$  とすることを目標としたとき、式 (8) の分布の「時系列」を示す地点から、一様な階層構造を仮定した場合に、小分類が  $c$  となるまでの区間内に入る分類を、調査報告で着目する分類の候補とする。具体的には、 $v_{ts} (\in V)$  を「時系列」に対応する分類とし、区間  $[s_d(v_{ts}) - \Delta s_d, s_d(v_{ts})]$  中に入る分類を求める。このとき、 $\Delta s_2$  は次のように求める<sup>8</sup>。

$$\begin{aligned} c^{-1} &= \frac{\lambda \exp(-\lambda (s_d(v_{ts}) - \Delta s_d))}{\lambda \exp(-\lambda s_d(v_{ts}))} \\ &= \exp(-\lambda \Delta s_d) \end{aligned}$$

すなわち、式 (12) となる。

$$\Delta s_d = \frac{1}{\lambda} \ln c \quad (12)$$

$v_{ts}$  よりも評価<sup>9</sup>の低い分類を選ぶ理由は、 $v_{ts}$  よりも評価の高い分類は、多数ある子分類の親となっている、着目すべき分類としては粒度が大きすぎると考えるためである。

得られた分類の候補を議論により、その数を  $c$  となるように統合するして調整する。

### 3.4 三次選別

二次選別時に記載してもらった関連度を元に、前節で得られた分類への最適割当を組み合わせ最適化法により決定する。その後、二次選別を通過した文献を各分類に割当て、分類担当者は精読を行い、必要に応じて除外や、他の分類に移すなどの対処を行う。ここで、報告書としてまとめるために、各研究における共通点などをまとめておく。

<sup>7</sup> 「時系列データ」の同義語として扱っているが、分類体系としてデータが付くことは妙なので、単に時系列としている。

<sup>8</sup> 本来比ではなく、 $c^{-1} = \int_{s_d(v_{ts}) - \Delta s_d}^{s_d(v_{ts})} \lambda \exp(-\lambda x) dx$  を求めるべきであるが、調査中の間違いにより、結果は式 (12) により出されている。しかし、今回の場合はどちらを用いても結果に影響はない。

<sup>9</sup>  $s_d(v)$  の値、つまり  $v$  の出現頻度と文献の評価の積の対数である。

表 1: 近傍語および重み

重み	近傍語
1.00	時系列データ (time series data)
0.78	市場動向予測 (market trends predicting)
0.67	行動分析 (behavior analysis)
0.67	トレンド予測 (trend prediction)
0.56	株価予測 (stock prices prediction)
0.56	セグメンテーション
0.56	時系列文節化
0.56	センサデータ (sensor data)
0.44	注文データ (pos data)
0.44	シーケンシャルパターンマイニング
0.44	時間的粒度
0.44	モーショントラック
0.44	隠れセミマルコフモデル




図 1: 検索語  $w$  に対する重み  $s(w)$  の頻度分布

## 4 調査結果

### 4.1 事前調査の結果

事前調査では、時系列データという語を含む文献は数 100 件以上と多数存在することを確認したため、効率的な選別方法の考案が必要であることを確認した。また、「時系列データ」の近傍語を選出した。選出された近傍語を元に得られた代表語と  $s(w)$  (式 (2)) の値の一覧を表 1 に示す。また、頻度分布を図 1 に示す。

網羅性と作業量の兼ね合いを考慮し、検索語は 16 程度が良いと判断した。また、重みの高い方から順に並べたとき、 $s(w_1) > s(w_2) > \dots > s(w_{12}) = s(w_{13}) > s(w_{14}) \dots$  であったため、13 番目までを検索語として採用した。また、13 番以降の単語のうち、特に含めるべきと判断した「強化学習」、「再帰的ニューラルネットワーク」、「クラスタリング」を検索語に含め、これら計 16 語を最終的な検索語とした。




図 2: 分類  $v$  に対する評価  $s_d(v)$  の頻度分布

### 4.2 1 次選別の結果

網羅性と作業量の兼ね合いから、上位 32 件程を二次選別の対象とすることに決定した。しかしながら、 $s_1(d_1) \geq s_1(d_2) \geq \dots$  となる  $d_1, d_2, \dots (\in D)$  の列に対し、 $s_1(d_{32}) = s_1(d_{33}) = s_1(d_{34}) \neq s_1(d_{35})$  であったため、 $d_{34}$  までを二次選別対象とした。検索語が一つでも該当する文献は 451 あったため、採択率は約 0.075% である。

### 4.3 二次選別の結果

二次選別の結果残った文献は 21 件で採択率は 61.8% であった。除外理由として、「時系列データに関係がない」、「内容の読み取りが困難である」などがあつた。この二次選別であるが、他の評価者の報告結果が見れる状態で行った。本来は評価の独立性を保つために、他人の結果を最後まで秘匿すべきであったが、円滑に行うために様式の記載方法、分類の情報共有をしたほうが良いとの判断から、秘匿せずに行った。

二次選別の結果得られた分類が、指数分布に従うという仮定の妥当性を検証するために、 $s_d(v)$  の頻度分布を計算したところ、図 2 に示す結果となった。これより仮定はある程度妥当であると考えられる。なお、分類の総数は 97 である。

分類の選択に使う式 (12) 中  $c$  の値について、本調査では調査員が 8 人であったため、各分類精査に複数人を割り当て可能な最大値である 4 とし、分類の候補区間を決定した。この区間  $[s_d(v_{ts}) - \Delta s_d, s_d(v_{ts})]$  に属する分類の一覧を表 2 に示す。また、この結果を議論によりまとめた結果を以下に示す。

1. 統計学と確率模型
2. 機械学習
3. マルチメディア処理
4. 人間主体型コンピューティング

表 2: 分類と評価値

$s_d(v)$	分類名
2.89	時系列
2.64	機械学習
2.48	確率過程
2.48	統計学
2.30	人文社会科学
2.08	センサとアクチュエータ
2.08	ロボット工学
1.79	教師なし学習
1.79	bayes モデル
1.39	マルチモーダル
1.39	自然言語処理
1.39	人間主体型コンピューティング
1.39	動作追跡
1.39	認知心理学

1, 2については上位からそのまま採択した. 3のマルチメディア処理についてだが, センサデータ, マルチモーダルは個別に扱われることが少なく, 近年では多数のセンサからのデータを複合することが一般的である, また, センサに限らず, 様々な媒体が複合的に用いられると考えることから, この分類とした. 最後に4であるが, 人文社会学, 認知心理学やロボット工学等が挙げられているが, これらは人を主体に置いた研究であると見受けられ, 人間主体型コンピューティングにまとめることが可能と判断した.

#### 4.4 三次選別の結果

調査報告作成のための担当分けに関し, 3.4節で述べたとおり組み合わせ最適化を試みたが, 関連度に8人中6人の評価者が「関連なし」とだけ記載していたため, 2人を除き無作為な組み合わせとなった. 除外すべきと判断された文献は特になかったが, 精読を行って行く中で, 統計学と確率モデルは数理模型としてまとめられると考え, 第一分類を数理模型に変更した. また, 各分類を特徴づける研究の内容について記録を残した.

#### 4.5 研究動向について

##### 4.5.1 数理模型

ここでは数理模型の観点から研究動向を把握する. 使われる手法は主に連続値を対象とする(連続模型)か, 離散値を対象とする(離散模型)かに分けられる. また, 実世界から得られる時系列データは, もともと連続値であるため, 本来は連続値を模擬可能な模型を

使うべきとも考えられるが, センサから得られるデータはサンプリング周期により離散化されていることから, 離散模型の適用も可能である.

連続模型を用いている文献は9件 [7,9,10,11,12,14,17,20], 離散模型のものを用いている文献は13件であった [8,13,15,16,18,19,21,22,23,24,25,26,27]. 市場や生活様式のような, 対象とする範囲が年単位に及ぶ文献は, すべてにおいて離散模型を用いていた. 連続模型は身体の動作など数分以内の規模においてのみ利用されていた. RNN は連続模型に用いられることはなく, この理由として, RNN は自然言語分野で特に発達している影響から, 連続値に対する適用事例が少なく, 応用がしづらいのではないかと考える.

時系列を分節化する研究が多く見られた. 時系列を分節に分けることは, 音声認識では文字と発音を対応付けるために一般的であるが, 人の生活活動や [10], 動作に意味付けを行う方法としても盛んに用いられていた [7,9,10,11]. 分節化を行う手法に関しては, 自然言語における形態素解析と同様に隠れ Markov 模型を使い潜在因子の系列を推定する方法と [7], 時系列の特徴量をクラスタリング (k-means 等) により分割することで推定する手法が見られた [16]. HMM と k-means 以外によく用いられていたのは DTW (Dynamic Time Wrapping) である. DTW は時系列の伸縮による相似性, 例えば歩く速度が異なってもその動作は概ね同じであること, を考慮し, 時系列データ間の類似度を測ることが可能な手法である. DTW を適用する参照用時系列を予め教師有り学習などで作成しておき, 適合する区間を特徴ある時系列区間として定義することが可能である [17].

##### 4.5.2 機械学習

多くの文献で機械学習手法が用いられていた. 特に, 隠れ Markov 模型が多く, Neural Network (NN) 系では, 畳み込み NN, 長短記憶を含む再帰的 NN が用いられていた.

用いられている模型はおもに確率的生成模型であった. 確率的生成模型としては Recurrent Neural Network (RNN), 隠れ Markov 模型が用いられていた [7]. トピックモデルも見られたが, 特徴抽出にトピックモデルを利用し, それらの時間的変化は RNN で捉えるという枠組みで利用されていた [18].

生成模型で, 実現値として時系列データが連続値であることを仮定している模型では回帰を用いており, これは当然といえるが, 時系列データの未来を予測する模型において, 回帰を用い外挿するのではなく, 変化を検知する2値識別模型とする文献がいくらかみられた [15,19,26]. この理由として, 文献 [26] は噴火予測で, ほかは市場動向予測であるが, 変化が起きるかど

うかわかることが最も重要であり、それ以降の対応はあまり考慮する必要のない問題を対象としているということが共通すると考える。

#### 4.5.3 マルチメディア処理

センサデータの中から知見を見出そうとする研究がいくつか見られた [10, 20, 21, 22, 23, 27]。これは、近年の IoT (Internet of Things) の普及により、センサから多量に時系列データを取得する下地が整ってきているためだと考える。

文献 [21, 22, 24] では、得られたデータを解析する前段階として、センサから得られた時系列データを管理するシステムを提案している。これらは直接時系列データの解析手法を提案していないが、将来的にシステムへ蓄積されたデータを解析することを目標とする研究に位置づけられている。

文献 [20] はセンサデータに含まれる欠損に対処する手法を提案している。特に、工学系のセンサでは、欠損に瞬間的なものから長期的なものなど様々な種類があることを言及しており、それらを統一的に扱うことが可能なモデルを提案している。

文献 [27] は [20] とは別の観点で、センサデータ特有の問題である、雑音の影響を除去する手法に取り組んでいる。畳み込み NN と再帰的 NN を組み合わせることで、雑音に埋もれる信号を検出することに成功している。

文献 [8] は、複数センサを同時に使う場合に、それぞれのセンサ間で発生する時間遅れを考慮することの重要性を主張している。例えば同じ事象に起因する変化であっても、観測地点ごとにずれが生じる。このことを考慮しなければ、分節の境界が曖昧になるため、分節化が難しくなる。文献 [8] ではこれに対し時間遅れを考慮したモデルを提案し、考慮しない場合に比べ、分節化の精度が高くなる結果を示している。

#### 4.5.4 人間主体型コンピューティング

ヒューマン・コンピュータ・インタラクションやヒューマン・ロボット・インタラクションのような、人間が介在する研究領域においても時系列データに関する研究事例が複数確認される [11, 21, 24]。本節では、人間主体型コンピューティング (Human Centric Computing) と、関連分野における時系列データを対象とした研究事例を述べる。時系列データに対する当分類に該当する研究は教育学や動物行動学、ロボット工学 [11, 21] のような、学際的な研究として発表される傾向がある。

教育学における時系列データを対象とした研究事例として、鍵山らは学習内容の理解の補助を目指した可

視化システムの改善手法を提案している [24]。この手法では、学習者の理解内容を node-link ベースの可視化手法であるキットビルド概念マップにより可視化し、学習内容の時間的変化を複数のマップの重畳により表現する。学習者の知識の時間的変遷を外在化することで、教育者による指導方法の効果の理解を促進できると主張している。

上述の文献のように、人間主体型コンピューティングにおける時系列データを対象とした研究は、時系列データの量的な側面よりもマルチモーダルデータとしての質的な側面に焦点を当てている傾向がある。他説とは異なり、データの時間的粒度が大きい [24]、個人単位のデータを対象とした分析を行う [14]、データの巨視的な傾向把握を目的としている点が当該分類の研究において特徴的である。

## 5 まとめ

本稿では、人工知能分野における時系列データを扱った研究動向の調査結果を報告し、また、効率を重視した体系的調査手法を提案した。提案手法により、定量的に着目すべき観点の候補を推測し、4つの観点、「数理モデル」、「機械学習」、「マルチメディア処理」、「人間主体型コンピューティング」からみた動向をまとめた。

今後、同じ調査を別の媒体に行うことで、より洗練された知見が得られると考える。また、時系列データを扱った研究以外の動向調査を通じて、提案した調査手法の検証を行い、より一般性の高いものとする事ができると考える。

## 参考文献

- [1] Sacha, D., Kraus, M., Bernard, J., Behrisch, M., Schrech, T., Asano, Y., and Keim, D.: SOM-Flow: Guided Exploratory Cluster Analysis with Self-Organizing Maps and Analytic Provenance, IEEE Transactions on Visualization and Computer Graphics, Vol. 24, No. 1, 2018.
- [2] Waffenschmidt, S., Knelangen, M., Sieben, W., Buhn, S., and Pieper, D.: Single Screening Versus Conventional Double screening for Study Selection in Systematic Reviews: A Methodological Systematic Review, BMC Medical Research Methodology, Vol. 19, No. 132, 2019.
- [3] Vaidhehi, V., Suchithra, R.: A Systematic Review of Recommender Systems in Education, International Journal of Engineering & Technology, Vol. 7, No. 3.4, 2018.

- [4] Dutt, A., Ismail, M., Herawan, Tutut.: A Systematic Review on Educational Data Mining, IEEE Access, Vol. 5, 2017.
- [5] 山口昌哉, 佐和隆光, 坂本賢三, 富永茂樹: 学問の現在, 1989.
- [6] 伊藤清: 確率過程, 岩波書店, 第2版, 2007.
- [7] 長野匡隼, 中村友昭, 長井隆行, 持橋大地, 小林一郎, 高野渉: HVGH: 高次元時系列データの深層圧縮と教師なし分節化, 2019年度人工知能学会全国大会(第33回), 1L3-J-11-01, 2019.
- [8] 真矢滋, 山口晃広, 稲木達哉, 植野研: 多変量時系列データの柔軟な分割方法の提案, 2019年度人工知能学会全国大会(第33回), 114-K-2-05, 2019.
- [9] 長野匡隼, 中村友昭, 長井隆行, 持橋大地, 小林一郎, 金子正秀: ノンパラメトリックベイズ法に基づく時系列データの分節化, 2018年度人工知能学会全国大会(第32回), 2G4-04, 2018.
- [10] 岩田健輔, 池田成満, 青木達哉, 西原成, 中村友昭, 長井隆行: 動作の分節化に基づく家事タスクにおける行動の構造化, 2016年度人工知能学会全国大会(第30回), 1O2-4, 2016.
- [11] 布川遼太郎, 宮澤和貴, 中村友昭, 長井隆行, 金子正秀: 時系列マルチモーダル情報の分節・分類に基づく物体と動作の統合概念学習, 2018年度人工知能学会全国大会(第32回), 1G3-05, 2018.
- [12] 中村友昭, M., Attamimi, 長井隆行, 持橋大地, 小林一郎, 麻生英樹, 金子正秀: ガウス過程の隠れセミマルコフモデルに基づく身体動作の分節化, 2016年度人工知能学会全国大会(第30回), 1O3-5, 2016.
- [13] 野中尚輝, 中山浩太郎, 松尾豊: RNN を利用したコンテンツ産業の消費トレンド予測, 2016年度人工知能学会全国大会(第30回), 1D2-2, 2016.
- [14] 三村喬生, 中村友昭, 松本惇平, 西条寿夫, 須原哲也, 持橋大地, 南本敬史: 霊長類における身体動作時系列の分節推移構造推定, 2019年度人工知能学会全国大会(第33回), 1C4-J-3-01, 2019.
- [15] 松井藤五郎, 和泉潔: 新聞記事の時系列テキスト分析による株式市場の動向予測, 2016年度人工知能学会全国大会(第30回), 3L3-OS-16a-6, 2016.
- [16] 中塚祐喜, 白山晋: 外生変数を伴う長期予測における主要因子推定法, 2019年度人工知能学会全国大会(第33回), 114-J-2-03, 2019.
- [17] 中村凌子, 鈴木浩子, 渡部勇, 高木友博: Shapelets による時系列特徴抽出とオンラインサンプルでの問題行動の予測, 2019年度人工知能学会全国大会(第33回), 4A2-J-3-04, 2019.
- [18] 内田脩斗, 吉川大弘, 古橋武: FKC コーパスを用いたトピック遷移分析手法に関する検討, 2019年度人工知能学会全国大会(第33回), 4A2-J-3-03, 2019.
- [19] 和田裕貴, 長尾智晴: Deep Neural Network を用いた株式売買戦略の構築, 2016年度人工知能学会全国大会(第30回), 4G4-1, 2016.
- [20] 武石直也, 矢入健久: 工学システムの間欠的センサーデータのための動的混合モデル, 2016年度人工知能学会全国大会(第30回), 4M1-2, 2016.
- [21] 稲邑哲也: 大規模なマルチモーダル対話経験からの概念獲得を支援するクラウド型VRのアーキテクチャ, 2016年度人工知能学会全国大会(第30回), 1O3-1, 2016.
- [22] 川進也, 今田兼太, 神谷直輝, 石川翔吾, 竹林洋一: 認知症ケア改善のためのマルチモーダル映像センシング解析基盤の検討, 2016年度人工知能学会全国大会(第30回), 2H3-NFC-03a-4in2, 2016.
- [23] 浅野秀平, 切通恵介, 泉谷知範: 特徴アテンションを用いた時系列データのアトリビュション抽出, 2019年度人工知能学会全国大会(第33回), 2H3-J-2-05, 2019.
- [24] 鍵山貴一郎, 林雄介, 平嶋宗: 学習者集団および個人についての理解状態とその遷移の可視化の試み, 2016年度人工知能学会全国大会(第30回), 1C5-OS-13b-3, 2016.
- [25] 中川慧, 今村光良, 吉田健一: 時系列勾配ブースティング木による分類学習, 2016年度人工知能学会全国大会(第30回), 2J2-03, 2018.
- [26] 村田剛志, L., Heip, 井口 正人: Stacked Recurrent Neural Network による桜島噴火予測, 2018年度人工知能学会全国大会(第32回), 2A1-02, 2018.
- [27] 茂木貴弘, 中澤友哉, 田原鉄也: 1d CNN-LSTM による調節弁内部の異常検知, 2018年度人工知能学会全国大会(第32回), 3Pin1-44, 2018.