

令和 5 年 6 月 18 日現在

機関番号：33919

研究種目：基盤研究(C)（一般）

研究期間：2020～2022

課題番号：20K11941

研究課題名（和文）人間本位の機械学習基盤としての識別パターン発見技術の開発

研究課題名（英文）Development of Discriminative Pattern Mining Techniques as a Foundation of Human-Centric Machine Learning

研究代表者

亀谷 由隆 (Kameya, Yoshitaka)

名城大学・情報工学部・准教授

研究者番号：60361789

交付決定額（研究期間全体）：（直接経費） 3,200,000 円

**研究成果の概要（和文）：**人間本位の機械学習の基盤技術として，識別パターン発見技術を確立することを目指した。具体的には，研究代表者が提案した識別パターン発見手法であるECHO法をベースとして，方法論上の改良・発展および医療分野における有用性の検証を行った。本研究では「医療データに対してECHO法が output したパターンに対する解釈・説明可能性の検証」「ECHO法における実行監視ツールの開発等」「ECHO法のメモリ共有型並列化」「ECHO法が output するパターンを利用した連関分類器の開発」の4つの副目標を設定し，各々で一定の研究成果を得た。また，説明可能AI分野のサービスを実施し，透明性の高い機械学習手法の重要性を確認した。

**研究成果の学術的意義や社会的意義**

近年の人工知能の中核を成す機械学習技術ではその不透明性，近似的な解，ハイパープラメータチューニングの必要性等，人間側が機械学習手法を確實・容易に理解・応用する上で障害となる問題点が残されている。本研究ではこれらの問題点をあらかじめ避けられる識別パターン発見手法であるECHO法に注目し，その方法論上の改良・発展および有用性の検証を行った。時間的な制約により，4つの副目標全てを完全に達成できた訳ではないが，これらの副目標の重要性が改めて確認でき，この方向で研究を進めていく意義を示すことができた。また，本研究を通じ，学術界・産業界で注目される説明可能AI分野に対する貢献ができたと考えている。

**研究成果の概要（英文）：**In this study, we aimed to establish discriminative pattern mining techniques as a foundation of human-centric machine learning. Specifically, we started with ECHO, a discriminative pattern mining method previously proposed by this study's principal investigator, and evolved it methodologically. We also examined the usefulness of ECHO mainly in medical domains. In this study, we achieved a certain progress in each of four sub-goals: evaluating the interpretability of ECHO-produced patterns in medical domains, development of a monitoring tool for ECHO, shared-memory parallelization of ECHO, and development of an associative classifier that uses ECHO-produced patterns. We also confirmed the importance of transparency in machine learning through an extensive survey of explainable AI.

研究分野：知能情報学

キーワード：識別パターン発見 機械学習 説明可能AI メモリ共有型並列 連関分類器

## 1. 研究開始当初の背景

従来の機械学習手法では (i) 不透明性, (ii) 近似的な解, (iii) ハイパーパラメータのチューニングの必要性等, 人間側が機械学習手法を確実・容易に理解・応用していく上で障害となる問題点を含んでおり, これらの問題点を解消・軽減する人間本位の機械学習の実現が望まれていた.

## 2. 研究の目的

人間本位の機械学習の基盤技術として, 識別パターン発見技術を確立することを目指す. 具体的には, 研究代表者が提案した識別パターン発見手法である ECHO (Exhaustive Covering in Hybrid dOmain) 法をベースとして, 方法論上の改良・発展および医療データへの応用を通じた有用性の検証を行う. ECHO 法はデータから厳密に識別パターン（興味ある事例群によく現れ, それ以外の事例群にはあまり現れない）を発見する手法であり, 我々は識別パターンから両群の違いを理解できる. また得られた識別パターンを用いる連関分類器 (associative classifier) は規則に基づく機械学習モデルの一種であり, 透明性が高い. ECHO 法では記号値と数値が混在するデータに対しても適用でき, 直観的な少數のハイパーパラメータを指定するだけでよい.

## 3. 研究の方法

本研究においては (1) 医療データに対して ECHO 法が出力する識別パターンに対する解釈・説明可能性の検証, (2) ECHO 法における動的優先付け探索の洗練と実行監視ツールの開発, (3) メニーコア CPU における ECHO 法のメモリ共有型並列化, (4) ECHO 法が出力する識別パターンを利用した高い予測性能を持つ連関分類器の開発, という 4 つの副目標を設定し, 各々の副目標について並列的に研究を進めた.

まず, 副目標 (1) では, 多剤服用 (polypharmacy) 患者の低血圧症の発症記録データ, 診療報酬明細書 (レセプト) および薬剤起因性老年症候群の発症の対応を記録したデータ, シスプラチン誘発性急性腎障害の発症記録データの 3 つを使用した. 前 2 つのデータは国立長寿医療研究センター, 最後のものは藤田医科大学より提供された. これらのデータに対し ECHO 法が出力する識別パターンが臨床的に有用か, 医療専門家と検証を行った.

副目標 (2) では, 実行時間が長くなりがちな ECHO 法の実行状況を監視するツールの開発を考えた. ECHO 法は識別パターンの動的優先付け探索を行い, anytime 性が期待できることから, 実行状況の監視により, 早期の探索打ち切りの実現が期待できる. 前段階として, ECHO 法のベースとなっている (記号値のみが扱える) 識別パターン発見手法 RP-Growth 法をターゲットとして, 深層学習ライブラリ TensorFlow の可視化・実行監視ツールである TensorBoard のような Web システムによる実行監視ツールを開発・評価した.

副目標 (3) では, ECHO 法のメモリ共有型並列化を目指して研究を進めた. 並列実装の開発は, 記号値のみが扱えるパターン発見手法から進めることとした. 具体的には, 頻出パターン発見を行う FP-Growth 法, 識別パターン発見を行う RP-Growth 法を順にターゲットとすることを考え, 最終的に ECHO 法に至ることを目指した. 並列化による探索速度向上の評価では, 64 コアを搭載したメニーコア CPU を積んだ計算機を購入し, 標準ベンチマークデータに対して並列化効果(並列化の前後における実行速度の比)を計測した. 本研究前の ECHO 法の実装言語は Java であったが, 並列実装においては Rust を採用した.

最後に, 副目標 (4) では, 標準ベンチマークデータや上述の医療データを対象として, 構築した連関分類器の予測性能の評価を行った. 標準ベンチマークデータでの評価は本研究以前の The 2019 Int'l Conf. on Technologies and Applications of Artificial Intelligence (TAAI 2019) にて発表の研究で実施したものよりも大規模なものと考えた. また, ECHO 法から得られる識別パターンを予測に利用するかについては自由度があり, より好ましい手法を模索した.

## 4. 研究成果

上記の副目標 (1)~(4) について並列的に研究を進めた結果, いずれの副目標においても一定の成果を得ることができた.

まず, 副目標 (1) では, 多剤服用患者の低血圧症の発症記録データから ECHO 法によって得られた識別パターンは臨床的に意味のあるものであるとの示唆があった (第 34 回人工知能学会全

国大会にて発表). 特に一部の識別パターンでは処方カスケード（ある薬剤の服用によって生じた有害事象に対して更に薬剤が処方され、結果的に重度の多剤服用となる現象）が起こっていることが示されており、臨床的な価値が高いとされた。シスプラチン誘発性急性腎障害の発症記録データから得られる識別パターンも同様に臨床的な説明がつくものであった（第 12 回日本医療情報学会「医用人工知能研究会」・人工知能学会「医用人工知能研究会」合同研究会にて発表）。一方、診療報酬明細書（レセプト）および薬剤起因性老年症候群の発症の対応を記録したデータから得られた原因薬と治療薬の因果の逆転が見られ（第 36 回人工知能学会全国大会で発表），改めて識別パターンを抽出したところ、実験で用いた患者データの時系列的な扱いに不備があることが判明した。識別パターンをこのようなデータの異常発見に用いることができるという貴重な知見を得られた。識別パターンは入力特徴量の条件式の連言として表現されるため、医療専門家にとっても理解しやすく、円滑にコミュニケーションすることが可能であった。

副目標（2）では、ECHO 法のベースとなっている識別パターン発見手法 RP-Growth 法に対する実行監視ツールを設計・試作した（令和 2 年度電気・電子・情報関係学会東海支部連合大会、情報処理学会第 83 回全国大会にて発表）。実行監視ツールは Web クライアント・サーバの形態を取り、サーバでは RP-Growth 法を実行しつつ、RP-Growth 法の実行状況をクライアントに送信する。クライアントでは HTML5, CSS, JavaScript (jQuery) で実装された動的 Web ページである。通信プロトコルとしてサーバ側からのプッシュが可能な WebSocket を用いた。実行監視ツールを実際に動作させたところ、（ECHO 法と同様に）動的優先付け探索を行う RP-Growth 法では初期に有用な識別パターンが発見され、一定時間を経過した後には有用なパターンは発見されにくくなることが観察された。ECHO 法でも同様の傾向となることが予想され、実行監視ツールによる早期停止は有効であるという感触を得た。

副目標（3）では、まず頻出パターン発見を行う FP-Growth 法に対するメモリ共有型並列化を行った（第 18 回情報学ワークショップ、第 35 回人工知能学会全国大会、The 12th Int'l Workshop on Computational Intelligence and Application (IWCIA 2021) にて発表）。従来のメモリ共有型並列手法は探索木の浅いところでタスクを分割し、その後は各タスクを並列に実行するという方式であったが、我々が提案した手法は work stealing という方式に基づく動的なタスク割り当てを行うため、既存手法よりも高い並列化効果を実現した。更に、上位  $k$  パターン制約と最良カバー制約を別々に導入した RP-Growth に対するメモリ共有型並列化を行った（第 15 回データ工学と情報マネジメントに関するフォーラム (DEIM 2023) にて発表）。上位  $k$  パターン制約と最良カバー制約のいずれもパターン間の制約であり、並列化においてはそれまでに発見された候補パターン群を管理するためにスレッド間の同期が追加が必要となるが、候補パターン群の更新タイミングの工夫によりスレッド間の同期を最小限に抑えて、並列化効果を向上させた。研究期間の上限により ECHO 法の並列実装には至らなかったが、本研究の過程でメモリ共有型並列化における知見を数多く得ており、ECHO 法の並列化への道筋は付けられたと考えている。また、実装言語として用いた Rust はガーベッジコレクションを持たないコンパイル型言語であり、実行時のメモリ消費が抑えられるため、共有メモリ型並列処理に向いていることが確認できた。また、Rust のメモリ安全性によりスレッド間のデータ競合を適切に回避でき、メモリ関連のバグの削減に大きく貢献することが分かった。将来の ECHO 法の並列実装も Rust で行うことが望ましいと考えられる。

最後に、副目標（4）では、まず本研究以前 (TAAI 2019) に提案した ECHO 法に基づく連関分類器を TAAI 2019 発表時よりも大規模な標準ベンチマークデータで評価した（未発表）。構築した連関分類器は、（予測精度は高いが透明性の低い）ランダムフォレストには予測精度の観点で劣るもの、他の透明性の高い機械学習モデルより良好な予測性能を示した。また、ランダムフォレストに着想を得て、ランダムに属性選択を行いながらアンサンブル予測を行う連関分類器を提案する等の改良を試みた（令和 2 年度電気・電子・情報関係学会東海支部連合大会にて発表）。現在、ECHO 法の連関分類器の出力を確率化するなど、更なる予測精度の向上を模索している。

また、4 つの副目標と並行して、本研究を包含する研究分野である説明可能 (explainable) AI 分野について包括的なサーベイを行った（電子情報通信学会スマートインフォメディアシステム研究会、電子情報通信学会基礎・境界ソサイエティ Fundamentals Review にて発表）。このサーベイを通じて分かったことの一つとして、解釈・説明可能性を特に重視する場合は、不透明な機械学習モデルを後付け (post-hoc) で説明するのではなく、初めから透明性を持つ機械学習モデルを利用することが望ましく、またそれが近年好まれる傾向にあるということである。本研究で発展させた識別パターン発見技術を更に追求することが説明可能 AI 分野にも寄与するものと考える。

## 5. 主な発表論文等

[雑誌論文] 計0件

[学会発表] 計12件 (うち招待講演 0件 / うち国際学会 1件)

1. 発表者名

櫻井健太朗, 亀谷由隆

2. 発表標題

動的負荷分散を用いた関連パターン発見手法の共有メモリ型並列化

3. 学会等名

第15回データ工学と情報マネジメントに関するフォーラム

4. 発表年

2023年

1. 発表者名

西澤達哉, 亀谷由隆, 薮武志, 溝神文博

2. 発表標題

レセプトデータを用いた老年症候群の発症予測モデルの構築・評価

3. 学会等名

第36回人工知能学会全国大会

4. 発表年

2022年

1. 発表者名

亀谷由隆

2. 発表標題

説明可能 AI 技術のこれまでとこれから

3. 学会等名

電子情報通信学会基礎・境界ソサイエティ Fundamentals Review

4. 発表年

2022年

1. 発表者名

Kentaro Sakurai and Yoshitaka Kameya

2. 発表標題

Shared-Memory Parallelization of FP-growth with Dynamic Load Estimation and Balancing

3. 学会等名

The 12th International Workshop on Computational Intelligence and Applications (IWCIA-2021) (国際学会)

4. 発表年

2021年

1 . 発表者名 亀谷由隆
2 . 発表標題 説明可能 AI 技術のこれまでとこれから
3 . 学会等名 電子情報通信学会スマートインフォメディアシステム研究会 (SIS)
4 . 発表年 2021年

1 . 発表者名 英彰悟, 亀谷由隆, 水野智博
2 . 発表標題 シスプラチニン誘発性急性腎障害の発症を予測する機械学習モデルの構築と予測根拠の分析
3 . 学会等名 第12回日本医療情報学会「医用人工知能研究会」・人工知能学会「医用人工知能研究会」合同研究会
4 . 発表年 2022年

1 . 発表者名 池田武史, 亀谷由隆, 水野智博, 溝神文博
2 . 発表標題 ポリファーマシーによる薬物有害事象（低血圧症）の発生を予測する規則分類器の評価
3 . 学会等名 第34回人工知能学会全国大会
4 . 発表年 2020年

1 . 発表者名 中山智仁, 亀谷由隆
2 . 発表標題 識別パターンの探索状況を示すモニタリングシステムの構築
3 . 学会等名 令和2年度電気・電子・情報関係学会東海支部連合大会
4 . 発表年 2020年

1 . 発表者名 池田武史 , 亀谷由隆 , 水野智博 , 溝神文博
2 . 発表標題 ランダム属性選択に基づく連関分類器の予測精度向上の検討
3 . 学会等名 令和2年度電気・電子・情報関係学会東海支部連合大会
4 . 発表年 2020年

1 . 発表者名 櫻井健太朗 , 亀谷由隆
2 . 発表標題 FP-growth 法の Rust による実装とその並列化に向けて
3 . 学会等名 第18回情報学ワークショップ
4 . 発表年 2020年

1 . 発表者名 中山智仁 , 亀谷由隆
2 . 発表標題 識別パターンの探索状況を示すモニタリングシステムの表示方法の改良
3 . 学会等名 情報処理学会第83回全国大会
4 . 発表年 2021年

1 . 発表者名 櫻井健太朗 , 亀谷由隆
2 . 発表標題 動的なタスク量推定と負荷分散を備えた FP-growth 法の共有メモリ型並列化
3 . 学会等名 第35回人工知能学会全国大会
4 . 発表年 2021年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-  
6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関