

# 強識別機を教師とした決定木の質問学習

高木 洋希<sup>1</sup> 坂野 鋭<sup>2</sup>

**概要:** 近年, 説明可能人工知能 (eXplainable AI, 以下 XAI) に関する研究が重要性を増している. 現在, 主流なのは深層学習等の説明不可能 AI について何らかの出力を用意して説明を求めるアプローチである. これに対して, 我々は, 現時点で存在する説明可能な人工知能である決定木に着目し, これを説明不可能人工知能を教師として高度化するアプローチを提案する.

## Decision tree query learning with support vector machine teacher

**Abstract:** In recent years, an eXplainable Artificial Intelligence is important issue of machine learning research. The mainstream approach to construct high accuracy XAI is explainablation of high accurate AI. In this paper, we propose opposite approach to construct one. Thus we employ existence XAI such as a decision tree. We use query learning to decision tree with support vector machine as teacher. The small scale preliminary experiment shows a possibility of proposed approach.

### 1. はじめに

本稿では, 説明可能人工知能 (eXplainable Artificial Intelligence, 以下, XAI) の実現方法として, 既存の XAI を高精度化するアプローチを提案する.

昨今, 人工知能 (Artificial Intelligence, 以下 AI) の発展は目覚ましく, 実用化も進んでいる. 実用上, 大きな問題と成っているのが, 多くの AI は識別結果をただ出力するだけで, 予測等の理由を説明する事が難しいと言う事である. このため, 行政等, 説明責任が大きな応用では AI の活用が進まないと言う現状がある.

このような課題に対し, XAI の研究が盛んになっている. 例えば, 2016 年に Defense Advanced Research Projects Agency(DARPA) が XAI プロジェクトを発足し [1], 同年, Local Interpretable Model-agnostic Explanations(LIME) という AI の決定を理解するための手法が発表された [2]. 国内では富士通が「Deep Tensor」を開発し, ナレッジグラフ構築技術と組み合わせて XAI を構築した [3].

現在の研究で主流となっている考え方は, 『現在説明能力を持たない AI をどのようにして XAI 化するか』である.

このアプローチでは現在高性能な学習機械を相手にするため, 高精度が保証される反面, そもそもどのようにすれば説明能力が得られるのかということから議論しなくてはならず, しかも, この議論に対する答えが合意出来ていない側面がある.

これに対し, 我々は既存の XAI, 例えば決定木を高精度化することにより, 高性能な XAI を実現するというアプローチを提案する.

決定木はその説明能力の高さから, コンサルタント業務等では不可欠の識別器であるが, 一般にその識別精度は説明能力の無い識別器に比して低く, 適用箇所が限定されるという問題があった.

以下, 我々が提案する枠組みを説明し, 評価結果を示す.

### 2. 提案手法

決定木に限らず, あらゆる識別器において有効な高精度化の手段の一つは学習サンプル数を増大する事である

その中でも質問学習 [4] の様な方法が利用出来る場合には, 効率よく学習が行われる事が知られている. Baum は線形識別機の識別面付近にデータを発生させ, 人間にその所属を解答させることで高速な学習が可能であることを理論的に示した.

Baum のアルゴリズムでは人間を教師役として想定していたが, 決定木の高制度化というタスクに特化して考え

<sup>1</sup> 島根大学 総合理工学部  
Shimane Univ. Interdisciplinary Faculty of Science and Engineering

<sup>2</sup> 島根大学大学院 自然科学研究科  
Shimane Univ. Graduate school of Natural Science

れば決定木より高精度な識別器, 例えば Support Vector Machine(以下, SVM) を教師として考える事には意味がある. この場合, 決定木の性能は SVM 程度まで高精度化する事が期待される事に成る.

すなわち, 今回提案するアイデアの中核は「識別精度の低い XAI」に「識別精度の高い説明不可能 AI」—今回は SVM, を教師として高精度化することはできないかということである.

### 3. 予備実験

提案手法の可能性を探るために小規模な実験を行った. 今回の実験では UCI Machine Learning Repository に提供されている「Blood Transfusion Service Center Data Set」という 4 次元, 2 クラス, 748 個のデータを用い, 200 個を初期の学習データ, 548 をテストデータとして用いた [5].

決定木と SVM の実装には python の機械学習ライブラリ scikit-learn[6] を用い, 決定木としては CART アルゴリズムを SVM では多項式カーネルを用いた.

Baum のアルゴリズムでは, 線形識別器の識別面付近に質問データを発生させる事に成っている. しかし, 決定木の識別プロセスは, 1 変数での識別の組み合わせである. つまり, Baum のアルゴリズムで指定された「識別面」と言う存在は必ずしも明確ではなく, 質問としてどのようなデータを発生させるべきかは自明ではない. そこで, 今回はランダムに質問を発生させる方法を用いた, この方法を以下, Random query と呼ぶ事にする.

テストデータに対する初期の識別率は, 決定木が 85.9%, SVM が 88.1%であった. Random query として 4800 個のデータを発生させ, SVM により得られた識別結果を質問正解ラベルとして決定木を再学習した. これにより決定木の識別精度は 86.4%に向上した.

### 4. まとめと今後の課題

本稿では, 高精度な XAI を構築するために低精度な AI を高精度化するというアプローチを提案し, 予備的な小規模実験で可能性を示した.

ただし, 今回の実験で示したのは, SVM による識別誤りを含むラベリングを行ったデータを学習に加える事で, 決定木の認識精度が向上する場合があると事である. このことをより正確に検証するためには, より多くのデータで, 実験的な検証を積み重ねる必要が有る. 特に, 決定木が破綻しがちな高次元のデータでの検証が不可欠である.

また, 今回の実験では可能性を示すことが目的であったために Random Query を用いたが, 本来の質問学習の思想的な観点から言えば, この方法が非効率であることは容易に考えられる. 今後は決定木のために有効な質問構成法を考案する必要が有る.

### 参考文献

- [1] DARPA: Explainable Artificial Intelligence(XAI), 入手先 (<https://www.darpa.mil/program/explainable-artificial-intelligence>), 最終閲覧日: 2020.1.23
- [2] Marco Tulio Ribeiro, "Why Should I Trust You?" *Explaining the Predictions of Any Classifier*, KDD2016 paper 573 Aug 2016
- [3] 富士通株式会社, *Deep Tensor* とナレッジグラフを融合した説明可能な AI, 雑誌 FUJITSU 2018-7 月号 (Vol.69, No.4) Jul 2018
- [4] E.B. Baum, *Nural net algorithms that learn polynomial time from example and queries*, IEEE Transactions on Neural Networks (Vol.2 No.1) Jan 1991
- [5] Blood Transfusion Service Center Data Set, UCI Machine Learning Repository, 入手先 (<https://archive.uci.edu/ml/datasets/Blood+Transfusion+Service+Center>), 最終閲覧日: 2020.1.30
- [6] scikit-learn: 1.10. Decision Trees—scikit-learn 0.22.1 documentation, 入手先 (<https://scikit-learn.org/stable/modules/tree.html>), 最終閲覧日: 2020.1.31