

氏 名 PHUA Yin Jun

学位(専攻分野) 博士(情報学)

学位記番号 総研大甲第 2332 号

学位授与の日付 2022 年 3 月 24 日

学位授与の要件 複合科学研究科 情報学専攻
学位規則第6条第1項該当

学位論文題目 Learning Logic Programs from State Transitions Using
Neural Networks

論文審査委員 主 査 井上 克巳
情報学専攻 教授
高須 淳宏
情報学専攻 教授
杉山 磨人
情報学専攻 准教授
市瀬 龍太郎
情報学専攻 准教授
佐藤 泰介
国立情報学研究所 特別研究員／東京工業大学
名誉教授

(Form 3)

Summary of Doctoral Thesis

Name in full PHUA Yin Jun

Title Learning Logic Programs from State Transitions Using Neural Networks

Recent advancements in machine learning and deep learning have brought to the world an unprecedented level of artificial intelligence (AI) boom. At the same time, there are also tasks that are seemingly simple for humans but are exceedingly difficult for even state of the art AI techniques. A purely symbolic method, however, while being interpretable and thus possible to understand where a model might fail, suffer from the issue of robustness and are less applicable to real world usage. An emerging field, dubbed the Neural-Symbolic AI (NSAI) proposed a technique for combining symbolic AI method and neural networks in order to get the best of both worlds. This thesis proposes a method to advance the field of NSAI. While solving the entire interpretability issue is a scope beyond this thesis, this thesis attempts to tackle the problem in a much narrower sense, in hopes that the technique proposed here can lead to some breakthrough in the larger field.

Learning from Interpretation Transition (LFIT) is an unsupervised learning algorithm which learns the dynamics just by observing state transitions. Given a series of state transitions from the observed dynamic system, the LFIT algorithm outputs a normal logic program (NLP) which realizes the given state transitions. LFIT algorithms have mainly been implemented in the symbolic method, but they are not robust to noisy or missing data. To solve this, neural network methods have been introduced into the LFIT framework. Previous attempt utilizes an extraction technique. The issue with such a technique is that it is prone to overfitting, particularly when data is scarce. This technique is also unable to take advantage of advancements made in the neural network field. There are also many advancements in the symbolic LFIT side, such as delayed systems, general semantics and multi-valued systems that have not yet been implemented with the neural network method.

The first contribution in this thesis, in the form of ∂ LFIT, is described in chapter 3. ∂ LFIT departs from the usual NSAI techniques that produces symbolic knowledge. While most techniques utilize the extraction method, ∂ LFIT learns the general space of the problem and uses classification to output symbolic knowledge. To ensure that neural networks have the capability to classify logic programs, this thesis presents a second contribution that confirms neural networks' ability to classify logic programs. Compared to the previous attempt which must train a new neural network from scratch for different logic programs, ∂ LFIT only needs to train one neural network that can learn multiple different logic programs.

The third contribution in this thesis, is described in chapter 4, addresses various problems present in ∂ LFIT. In ∂ LFIT, due to the nature of symbolic logic, the neural network architecture suffers from a combinatorial explosion problem. ∂ LFIT also has a data inefficiency issue. ∂ LFIT takes a sequence of continuous transition as input, therefore any state transition that cannot be observed from the initial state, will never be observable by ∂ LFIT. Another issue is that different permutations of the input, that has the same meaning are treated as different inputs by ∂ LFIT. To solve these issues, ∂ LFIT+ introduced various improvements on top of ∂ LFIT. First, to solve the combinatorial explosion issue, a technique to reuse the output nodes is introduced. In this technique, instead of the one output node representing one logical rule in ∂ LFIT, one output node may now represent different logical rules depending on the input. To solve the data efficiency issue, ∂ LFIT+ takes a set of transitions as input instead of a continuous sequence. This allows ∂ LFIT+ to observe the full state transition, when it is available. Lastly, to solve the permutation problem, set transformer is introduced into the architecture in order to exploit the invariance that is present in the input. By applying these improvements, ∂ LFIT+ was able to scale up to 7 variables compared to 5 with ∂ LFIT.

The fourth contribution in this thesis extends ∂ LFIT+ to delayed systems and general semantics. By adding additional atoms for separate timesteps, ∂ LFIT+ is trivially extended to deal with delayed systems. The probabilistic nature of neural networks also made extending ∂ LFIT+ to general semantics simple.

Next, the thesis also performs a comprehensive survey and comparison with various related works currently ongoing in the field. Lastly, the contributions in this thesis are summarized and multiple possible paths that can be taken up in future research are discussed.

博士論文審査結果

Name in Full 氏名 PHUA Yin Jun
ボア イン ジュン

論文題目 Learning Logic Programs from State Transitions Using Neural Networks

本学位論文は、「ニューラルネットワークによる解釈遷移からの論理プログラム学習」（論文和題目）と題し、系の状態遷移列を入力としてその背後にあるダイナミクスを論理プログラムの形式で学習する方式において、ニューラルネットワークを利用することにより、汎化性能を高めノイズに対して頑健であるような新たな手法を確立した研究について述べている。本学位論文は英語で執筆されており全 7 章から構成されている。

第 1 章では、研究の背景としてニューラルネットワークと記号処理を融合した人工知能であるニューラル・シンボリック AI について紹介し、状態遷移を観測とし系のダイナミクスを学習する研究の背景が述べられている。状態の変化を論理プログラムとして表現し、そのような論理プログラムを学習することで、時間の経過とともにある状態からどのような状態に遷移するかを予測することが可能となる。代表的な応用としては、遺伝子制御を表現するブーリアンネットワークや物理系のセルオートマトンの学習、ロボットの行動履歴からの行動規則学習などがある。本研究ではこうした論理プログラムを近年急速に発展している深層学習を用いて学習するためのニューラル・シンボリック学習を提案している。

第 2 章では本論文で必要となる基礎知識として、論理プログラミングの基礎、状態遷移を入力とし遷移規則を表現する論理プログラムを学習する「状態遷移からの学習 (Learning from Interpretation Transition (LFIT))」方式、さらに本研究で用いている LSTM やアテンション等の深層学習における関連技術について説明している。

第 3 章は本研究の基本的アイデアとなる、LFIT をニューラルネットワーク上で実現するための ∂ LFIT と呼ばれる新たな手法を提案している。従来のニューラルネットワークによる論理プログラム学習では、入力が状態であり出力が次状態となるようなネットワークをモデルとして学習し、学習したネットワークからプログラムを抽出するものが多かった。これに対し、 ∂ LFIT では、状態遷移列を入力とし、同遷移を実現するような論理プログラムを直接出力するようなモデルを深層学習により構築する。このため、従来の学習方式が一回の学習で一つのプログラムしか学習できないのとは異なり、 ∂ LFIT ではプログラムのクラスを学習できる。ただしこの設定においては、入力と出力のサイズが爆発的に増えてしまうという計算量的問題を有していることが解析的に述べられている。

このため第 4 章において、 ∂ LFIT に対して多くの効率化手法を施した学習方式として ∂ LFIT+ を提案している。効率化手法には、同一の意味を持つ異なる記号列に対して重複する学習を削減することを目的とした Set Transformer の利用や入力時系列データのエンコーディング、出力するルール数の削減、入力ラベルのバランス化等が含まれる。 ∂ LFIT+ の実現手法の詳細と各効率化技術による計算量削減に関する解析が述べられた後、各効率化手法を検証するための実験を行い、各手法の有効性を詳細に分析している。

第5章では θ LFIT+の拡張として、次状態が現在の状態のみならず過去の状態にも依存するようなメモリをもつ系や、変数の非同期更新に基づく遷移を許した意味論に基づく論理プログラムの学習手法を提案し、実験により各学習法の効率性を検証している。

第6章ではニューラル・シンボリック学習を含む関連研究について詳細にまとめており、第7章に本論文の成果をまとめ今後の課題について述べている。

公開発表会では博士論文の章立てに従って発表が行われ、その後に行われた論文審査会及び口述試験では、審査員からの質疑に対して適切に回答がなされた。質疑応答後に審査委員会では、出願者は情報学分野の十分な知識と研究能力を持つと認められ、博士研究はニューラル・シンボリック学習において十分なレベルの新規性を有しており、学術的に重要な貢献をなしていることが評価された。

以上を要するに本学位論文は、観測される状態遷移列から系のダイナミクスを論理プログラムの形式で学習する際に、深層学習を用いて状態遷移列を入力とし論理プログラムを直接出力するという画期的な学習方式を提案し、可能な限りの効率改善を試みることで、高い汎化性能を有するようなニューラル・シンボリック学習の新たな可能性を示したものである。また、本学位論文の成果は、学術雑誌論文1件、フルペーパー査読付き国際会議論文2件として発表され、学術的な貢献も認められる。以上の理由により、審査委員会は、本学位論文が学位の授与に値すると判断した。