

人工知能はいかにして知識を獲得・表現・利用しているか？

Neural Symbolic × Learning Representation

井上 克巳



岡崎 孝太郎、ポア インジュン、マニアン モルガン、リベロ トニー、ブルニユ ゴヴァン、山口 順也、佐久間 純一、菊地 健介、勝俣 翔太、池田 光、ギヨム ロルトワール、ナン ジャン、テム リンタラ、中田聖也、戸塚悠太郎


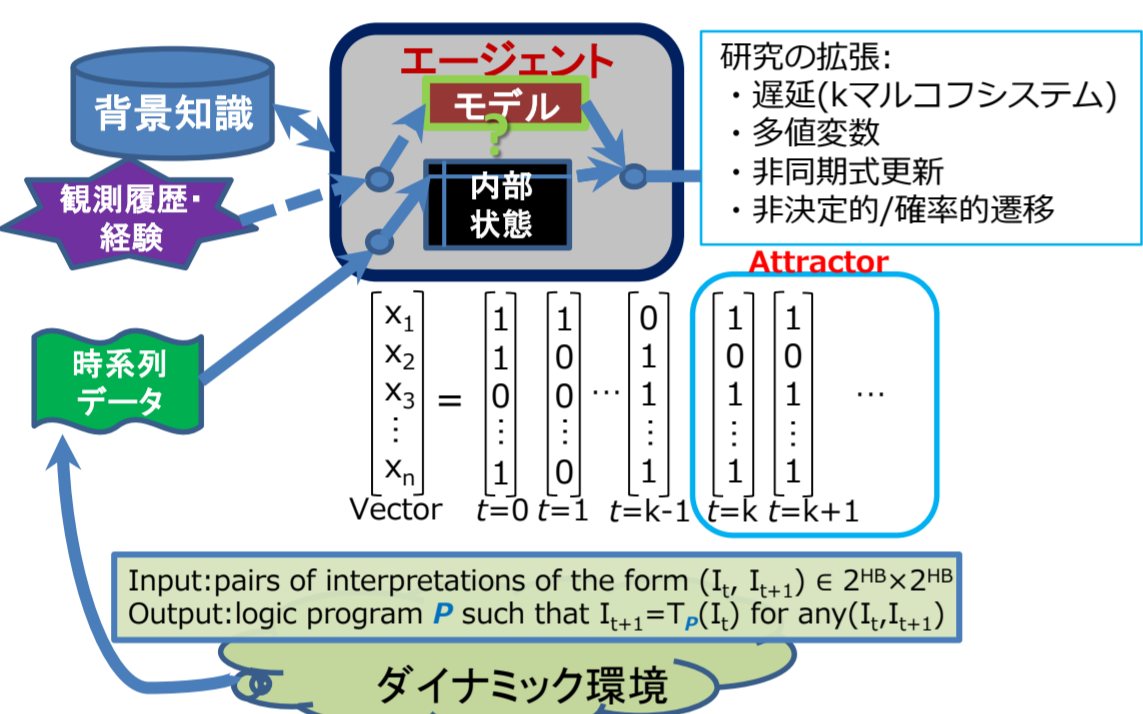
国立情報学研究所・総研大・東工大・SONAR・LS2N・LIP6・アールト大・アーヘン工科大

どんな研究？ 何がわかる？

昨今パターン認識を中心にした機械学習の研究成果が上がり始めていますが、知識の抽出・表現や推論といった高次処理とはまだ結びついていません。SATのような記号的推論とディープラーニング(深層学習)のようなパターン学習は対立しません。記号推論は認識・学習能力とは相補的であり、より強いAIの実現のためには必要です。本研究は、こうした**記号的AIを基礎とした知識表現**と、**ニューラルネット等の機械学習**との統合を目指します。

解釈遷移からの学習

LFIT(解釈遷移からの学習)は**状態遷移**からその背後で支配するルールを**学習**するための手法です。学習したルールは、**NLP(標準論理プログラム)**で表されます。NLPを用いて、各変数間の関係性を発見したり、予測にも使えます。LFITの実装方式として、論理的な手法とニューラルネットワークを用いた手法が提案されています。



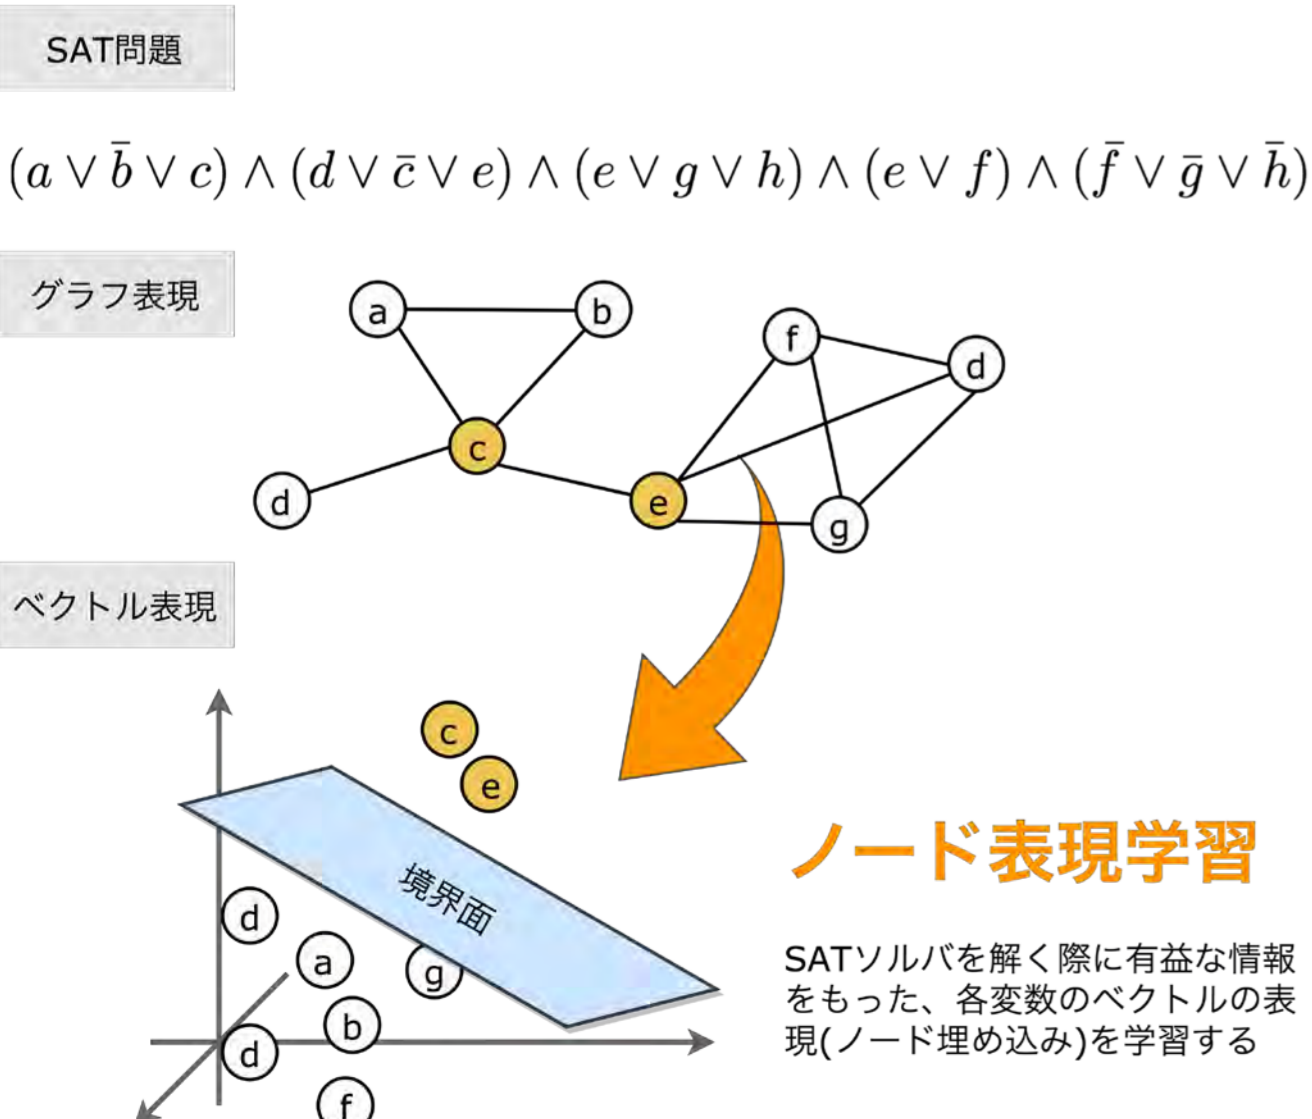
応用には、ロボットの**行動学習**、遺伝子制御ネットワークの**モデル化**や患者の症状の予測等があります。

この研究の拡張では、遅延のあるシステムの学習や連続値での学習、確率的システムの学習などがあります。

SATのグラフ表現からの学習

ある論理式に、充足する解(モデル)が存在するかを判定する問題を**SAT問題**と呼び、SAT問題を解くためのソフトウェアが**SATソルバ**です。SATソルバを用いることで、CPUなどのハードウェアが正常に動作するかを検証したり、Linuxで使われているライブラリ間の依存関係を解決できます。

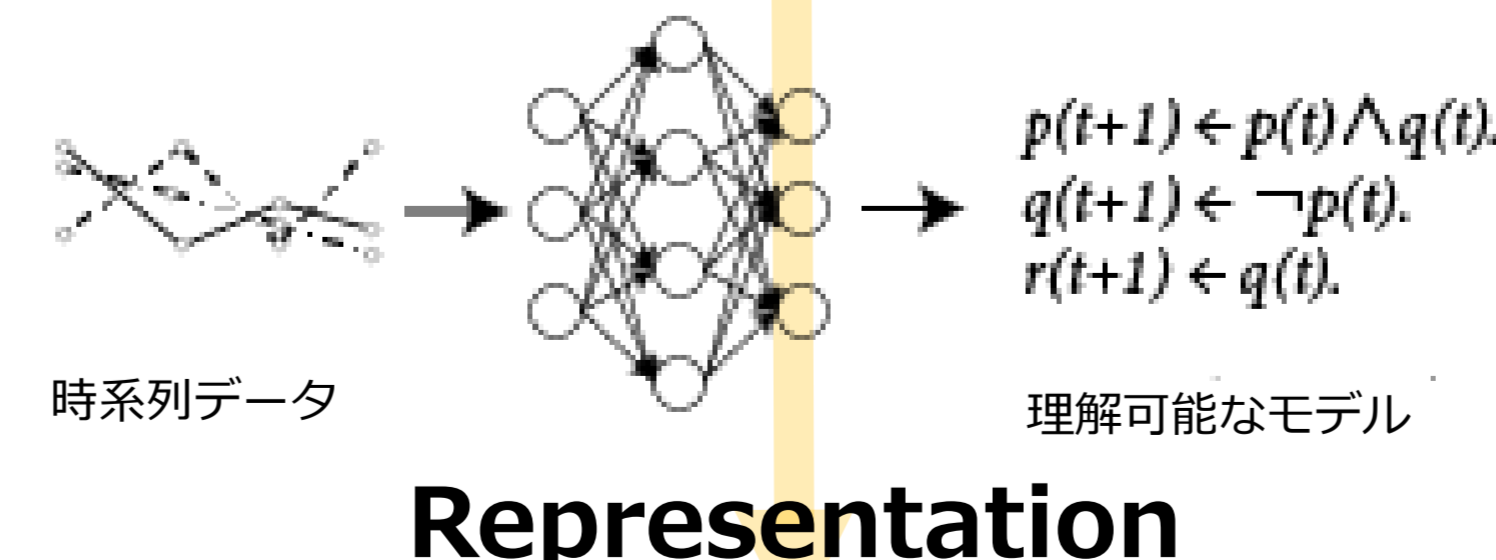
この研究の目的は、SATソルバに必要なテクニックである**変数選択ヒューリスティック**をより賢くすることです。SAT問題を**グラフ表現**することで、グラフの構造的な情報からSAT問題の特徴を学習し、SATソルバを高速化させます。



Neural Networkを用いた解釈遷移からの学習

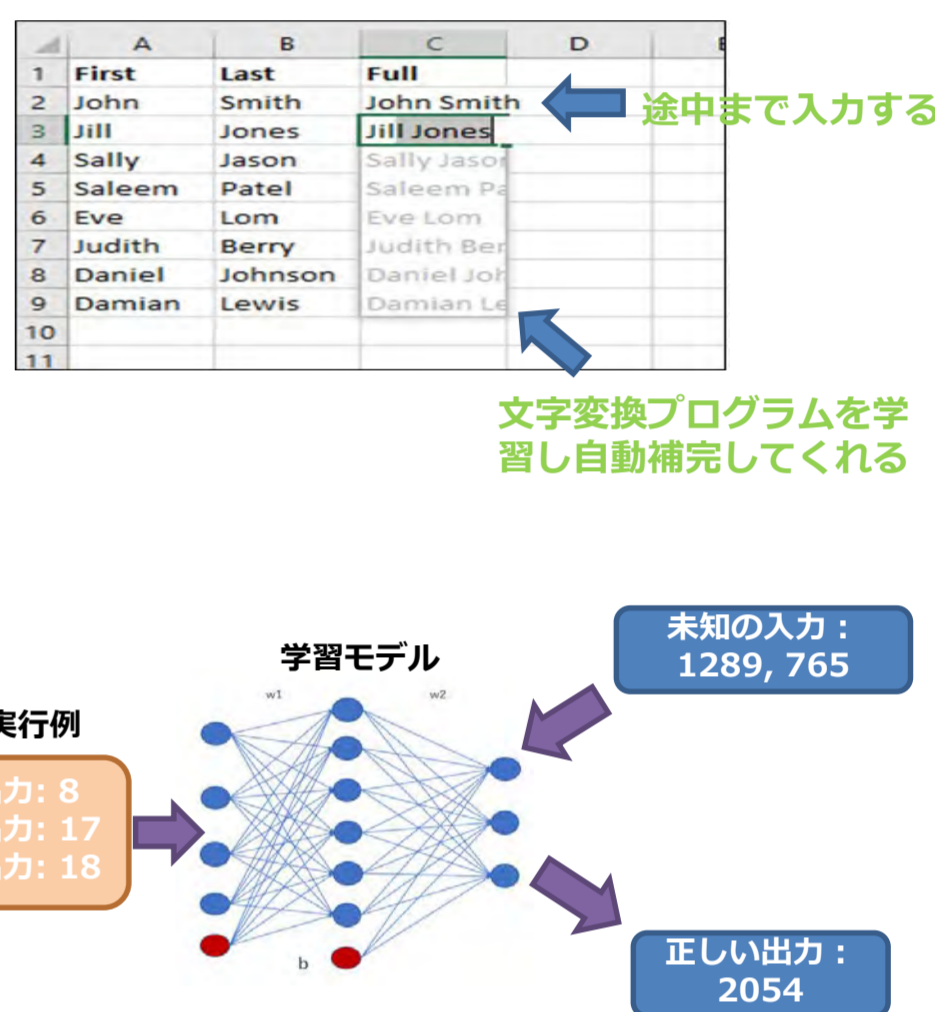
実世界のデータは、**ノイズや曖昧さ**を有していることがほとんどです。多くの**シンボリックな方法**ではそのようなデータを取り扱うことはできません。そのため、実世界のデータを扱うときには限界があります。シンボリックな手法では学習データに存在しないものに対して一般化することができません。したがって、生物学のような分野でそのような方法を適用することは非常に困難です。一方、**ニューラルネットワーク**は、データに存在する曖昧さやノイズに対して頑健であり、学習データに表れていないものに対して一般化することもできます。

本研究では、ニューラルネットワークを利用し、曖昧なデータに対してロバストであるだけでなく、トレーニングデータには含まれていないデータを一般化する手法の開発を目的としています。同時に、学習したモデルが**人間に読解可能で解釈可能**であることも目指します。



深層学習を用いた実行例からの学習

深層学習を用いることで**プログラムの実行例**から人工知能が**プログラムの実行方法**を学ぶ手法です。実行例をいくつか与えると、人工知能はそのプログラムを理解し、与えられた環境の中で**自動的に**そのプログラムを実行できるようになります。



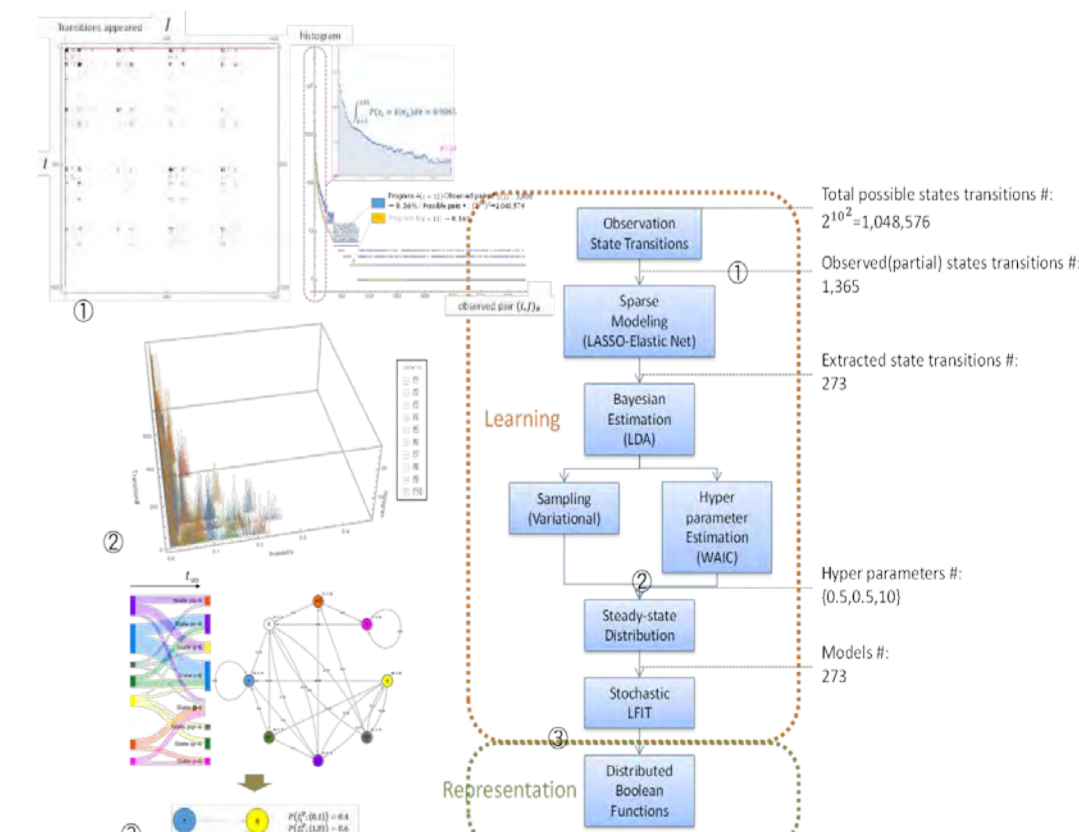
応用例としてはExcelの**Flash Fill**などがあります。これは、途中まで入力されたデータのペアが**どのようなルール(プログラム)**で入力されているのかを学習し、続きを**自動的に**入力してくれます。

この研究は将来的には文字列操作にとどまらず、プログラマーが実際に書くような、より**高レベルなプログラム**を学習することが期待されています。

部分観測からの状態遷移確率モデルと学習

実世界での問題を解決するためにはモデル化が役に立ちます。しかし、モデル化に必要な十分な従属変数が予め判っていることは稀です。うつろいやすい実世界のどこをどれだけ捉えれば、学習するに値する観測値が得られるのでしょうか? そしてそこからどのようにして知識を抽出すればよいのでしょうか?

本研究では、**動的なビッグデータからの部分観測値**から前処理としてスパースモデリングとベイジアン推定によって、**状態遷移の変数削減と完全観測化**を実現します。マルコフ性の特質により状態遷移の定常分布から、確率測度付きの論理プログラムを背景知識として抽出することを目指しています。



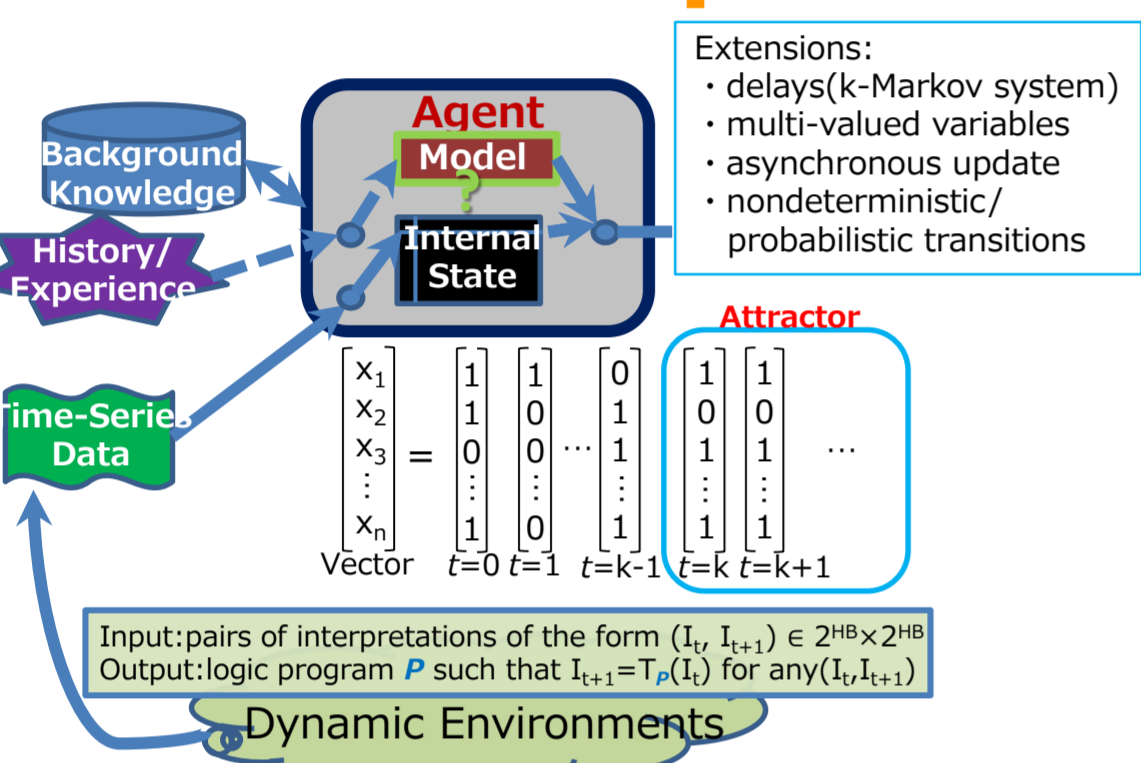
Neural Symbolic × Learning Representation

Katsumi Inoue Kotaro Okazaki; Yin Jun Phua; Morgan Magnin; Tony Ribeiro; Gauthier Bourgne; Junya Yamaguchi; Junichi Sakuma; Kensuke Kikuchi; Shota Katsumata; Hikaru Ikeda; Guillaume Lorthioir; Nan Jiang; Teemu J Rintala; Seiya Nakata; Yutaro Totsuka
 NII, SOKENDAI, Tokyo Tech, SONAR, LS2N, LIP6, Aalto U., RWTH Aachen


Research Topic and Target

There have been major breakthroughs in the machine learning research field, particularly around pattern recognition. However higher level tasks such as knowledge extraction and representation, logical inference have not been advancing as much. Symbolic reasoning such as SAT and deep learning techniques such as those used in pattern recognition can be integrated together. Symbolic reasoning is complementary to recognition and learning, and is essential towards realizing strong AI. In our research, we attempt to combine **symbolic AI techniques such as knowledge representation**, with **machine learning techniques such as neural networks**.

Learning from Interpretation Transition



LFIT is a technique for learning transition rules just by observing the environment. A normal logic program is constructed to explain the behavior of the environment. This normal logic program can then be used to explain the relationship between the variables, or can be used to perform predictions. Multiple approaches have been developed, including logical methods and neural networks.

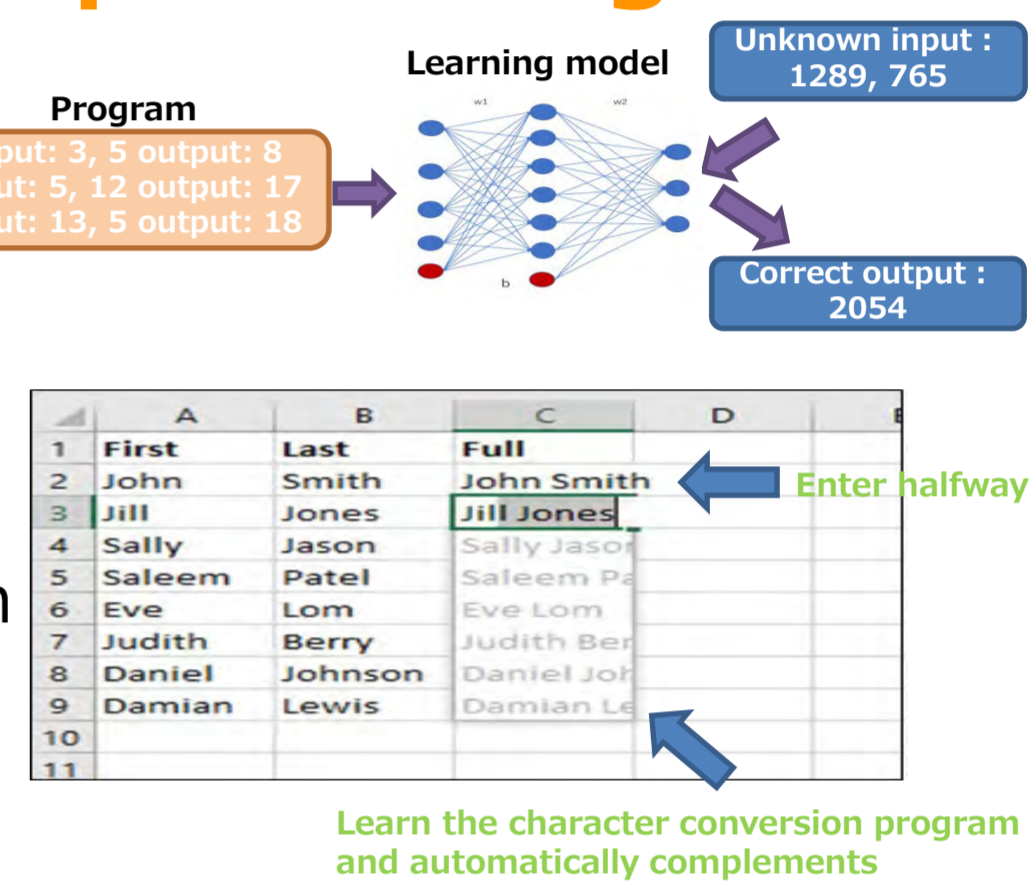


Such techniques can be applied to **motion learning** for robots, **modelling** gene regulatory networks, and also **predicting** if a patient will become sick if exposed to certain viruses.

Recent extensions has also been made to deal with systems with continuous values, systems that contains delays or even systems that are asynchronous.

Programming By Example Using Deep Learning

This work involves learning how to generate and execute a program based only on execution trace. By providing several example execution traces, the AI will learn about the program that generated the execution traces, and it can execute the same program on different inputs within the same environment.



An example of such application is Excel's Flash Fill. Given a semi-completed data, the program that describes the pattern of the input data can be learned. That program is then used to automatically complete the rest of the missing data.

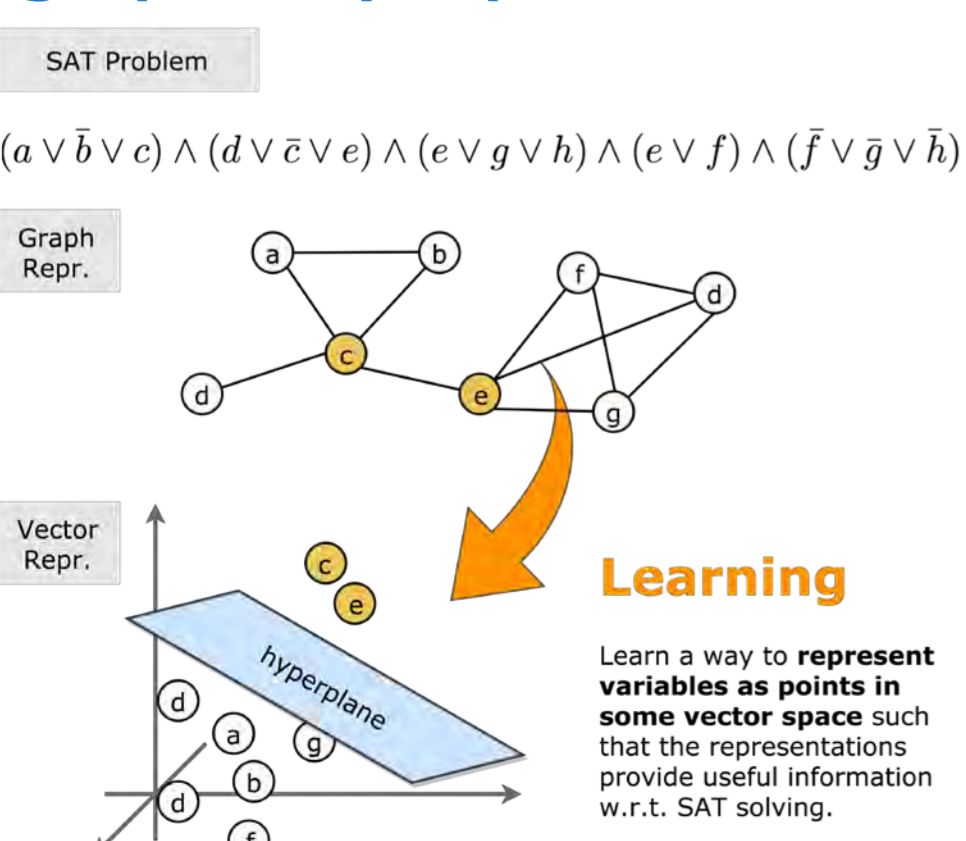
In the future, this research is expected not only to manipulate strings but also to learn higher level programs like that a programmer actually writes.

Symbolic

Learning from Graph Representation of SAT

A problem of determining whether a given Boolean formula has a satisfying assignment is called "SAT" problem. SAT solvers allow us to verify that a hardware (e.g. CPU) correctly implements its specification or resolve the dependencies between libraries in Linux.


The aim of this research is to devise a novel **branching heuristic**, which is a heuristic incorporated in modern SAT solvers, that could solve SAT problem faster. It tries to learn beneficial features from the structural information of **graphically represented** SAT problems.



Learning from Interpretation Transition Using Neural Network

Real world data are often noisy and fuzzy. Most symbolic methods cannot deal with such data, which often limit their application to real world data. Symbolic methods also have a problem of being unable to generalize beyond the training dataset. As such, it is very difficult to apply such methods in fields like biology where data is rare and fuzzy. On the other hand, neural networks are robust to fuzzy data and can generalize very well, but they are not human-readable and interpretable.

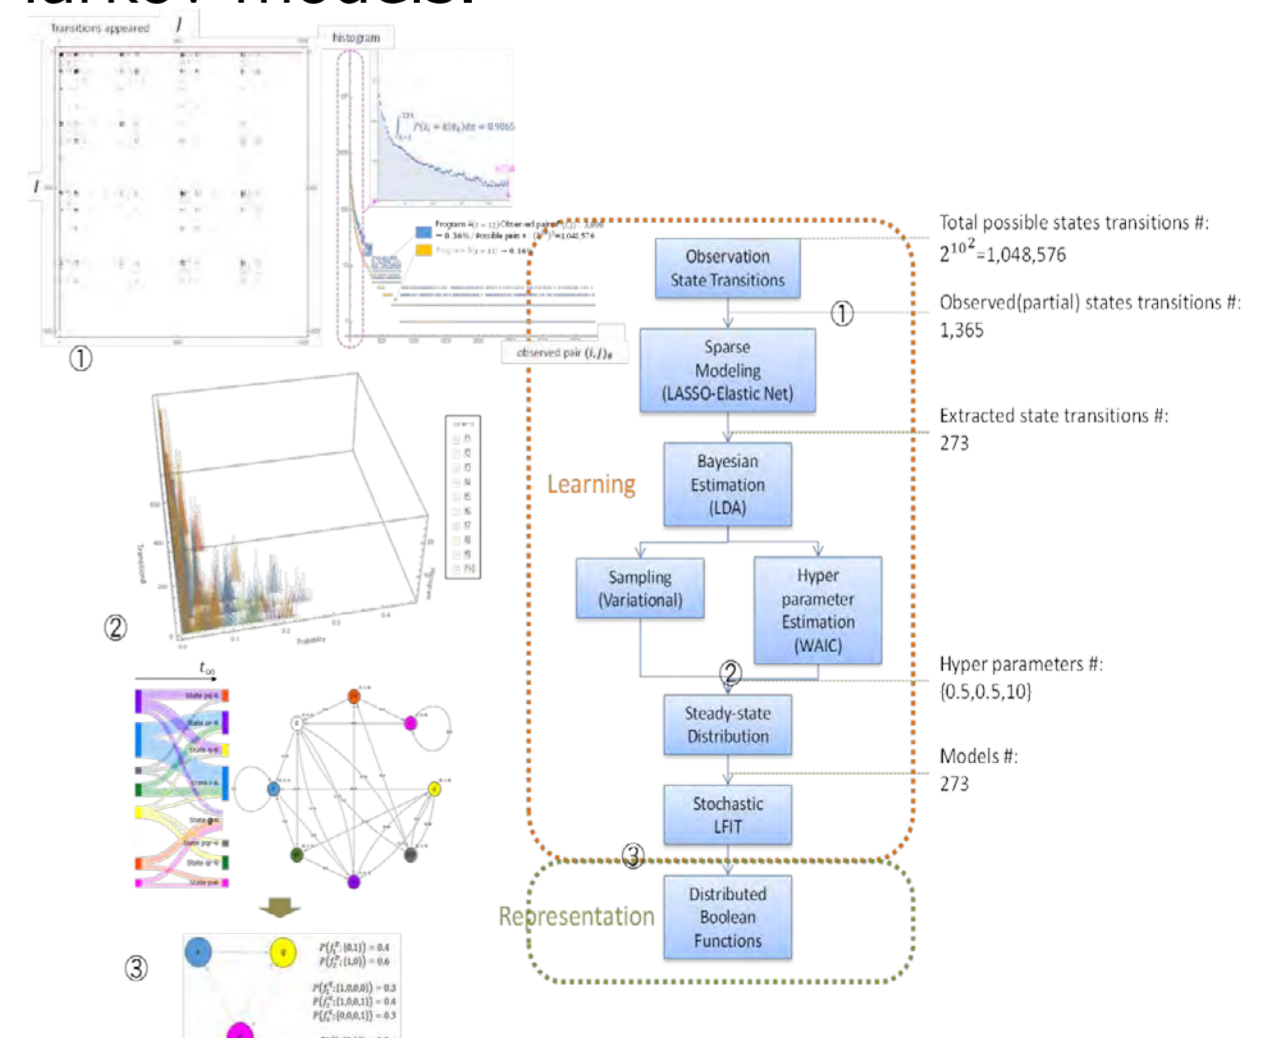
In this work, we propose a method utilizing neural networks, that is not only robust to fuzzy data, but also generalizes to data that are not in the training data. At the same time, the model it learns is also human-readable and interpretable.



Representation

Learning Probabilistic Transition Models from Partial Observation

Modeling is good way to solve the problem in real world. However it is hard to know sufficient numbers of variables in advance. Can unstable real world provide us enough observations? And how we can extract **robust knowledge in partial observations**? Our challenge is to **complete observations** by sparse modeling and Bayesian estimation, and to induce NLP with probabilistic measure from **steady-state distribution** under Markov models.



Neural