ビッグデータからいかに重要な知識を抜き出し推論するか？

知識表現と学習

井上 克巳

ソフィ・トゥレ、岡崎　孝太郎、マキシム・クレモン、アブドゥラマン・チャバニ、アレクシ・ロブ、グエン・ディン・ヒエン、小俣　仁美、山口　順也、インジュン・ポア、菊池　健介、佐久間　淳一、佐藤　泰介、沖本　天太 、ニコラ・シュウィンド、坂間　千秋、リベロ・トニー、モルガン・マグナン

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。

GPUを用いた高速並列計算

GPUの並列計算能力を用いることで、論理推論やアブダクション、**SAT（充足可能性問題）**など、人工知能の「**思考**」を高速化することができます。こうすることで、モデル検査、プランニング、スケジューリングなどの現実世界問題を早く解決することにつながります。

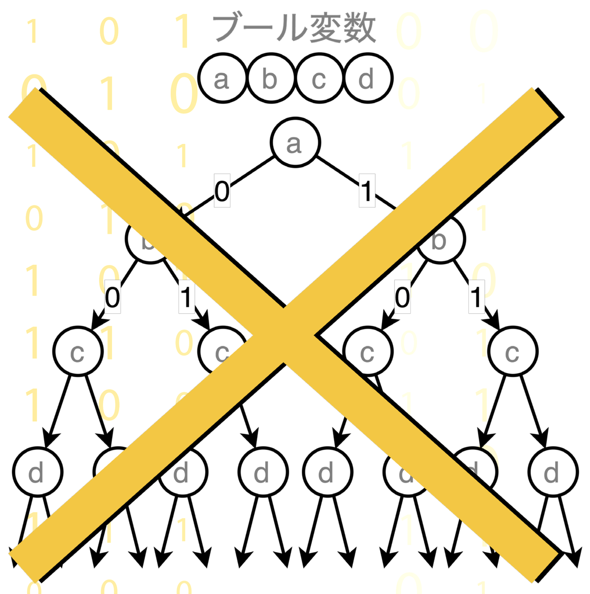

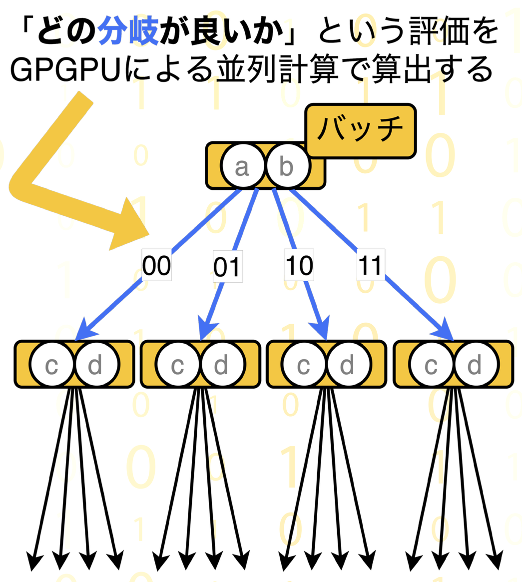

本研究では、並列でSAT問題を解くアルゴリズムを開発しました。このアルゴリズムに基づくSATソルバ、**BatSAT**を実装しました。BatSATはGPU上で動く重み付き部分**MaxSATソルバ**を用います。このMaxSATソルバはGPGPUを使うことによって、最新のMaxSATソルバより、**速く解く**ことができます。分岐の評価をこの高速MaxSATソルバで評価し、効率よくSAT問題を解きます。

多目的制約最適化

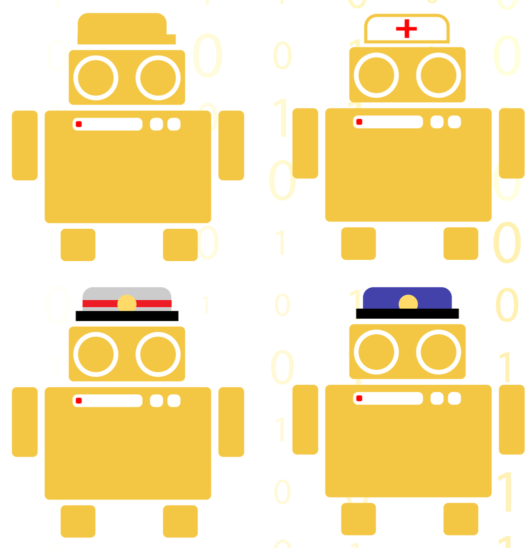

ある場所から移動したい時に、安いけど遅い移動方法を使うか、高いけど時間のかからない移動方法を使うか迷ってしまいますね。安くしたい、または早く着きたいという二つの**目的が混在**しているため、どの案がいいか迷ってしまいます。このように、複数の目的が存在し、**同時に全ての目的を満たす案がない**状況の時、どの案を採用すべきかという問題が生じます。

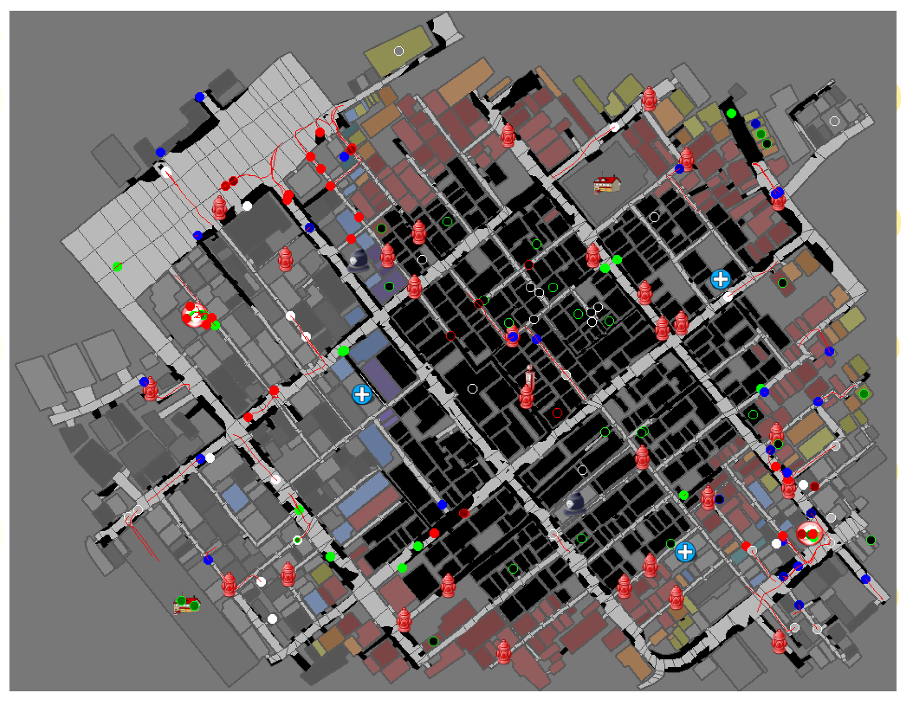

例えば、非常事態が発生した時に、どのようなレスキュー隊を派遣すべきかを考えましょう。災害が起きている場所から離れている経験の高いチームを派遣するか、災害の場所から近くにいる経験の少ないチームを派遣するか、このような状況での意思決定方法について研究をしています。

解釈遷移からの学習

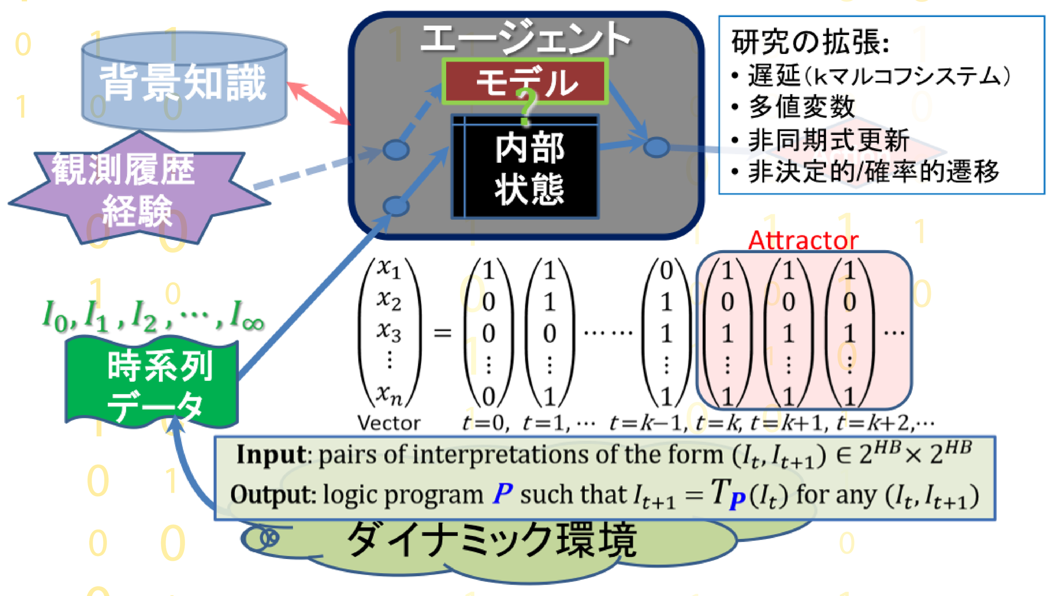

LFIT（解釈遷移からの学習）は**状態遷移**からその背後で支配するルールを**学習**するための手法です。学習したルールは**NLP（標準論理プログラム）**で表されます。NLPを用いて、各変数間の関係性を発見したり、予測にも使えます。LFITの実装方式として、論理的手法とニューラルネットワークを用いた手法が提案されています。

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。

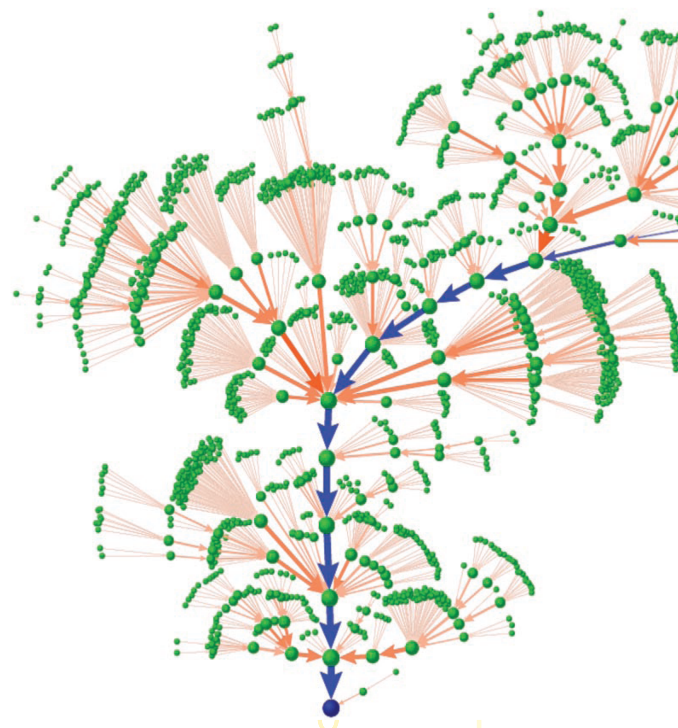

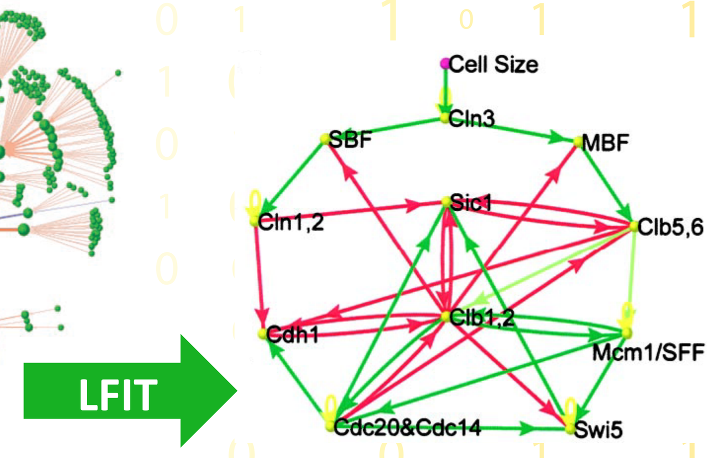

$x_6 \leftarrow \neg x_5 \wedge \neg x_9 \wedge x_{11} \wedge x_{12}$
$x_7 \leftarrow x_4 \wedge \neg x_6 \wedge x_7$
$x_9 \leftarrow \neg x_6 \wedge x_7 \wedge x_8 \wedge x_{10} \wedge \neg x_{11}$
⋮

多デバイス接触履歴からの視聴行動モデル化と知識更新

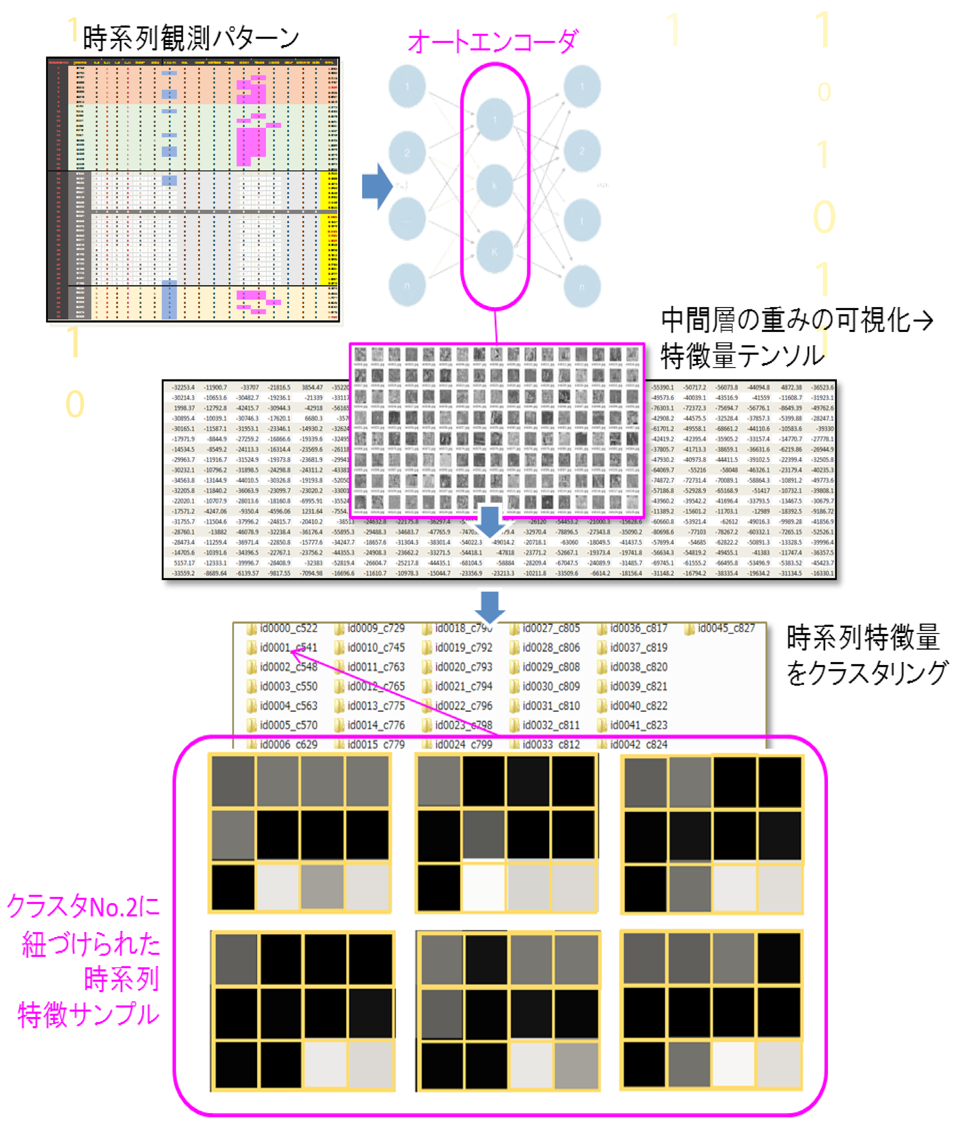

昨今進む**随時異なるデバイス**経由でのテレビ視聴体験により、視聴者はお茶の間での世帯視聴から解放されています。媒体やデバイスを跨ぐ**視聴特徴**はどのように抽出されるでしょうか？抽出した特徴に介在する視聴態度モデルは何でしょうか？モデルを駆動させる作用や規則は何でしょうか？それらを知識化できるのでしょうか？新たな知識から未知の仮説を得られるでしょうか？本研究ではこうした探究に答えるため、同一コンテンツに纏わる複合的な視聴履歴を捉えた調査データに対して、**自然言語処理**、**ニューラルネットワーク**、**自動推論分野**の人工知能技術を適用しています。視聴態度を表す特徴量を示すデータシーケンスから状態空間モデルを推定し, 制約や規則を知識として抽出します.

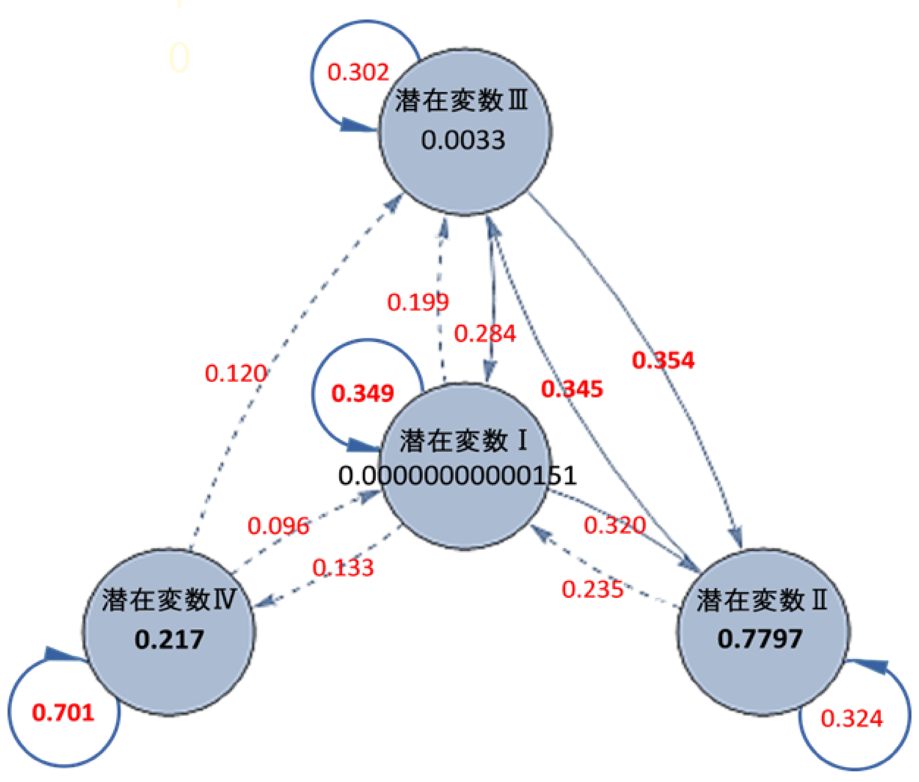

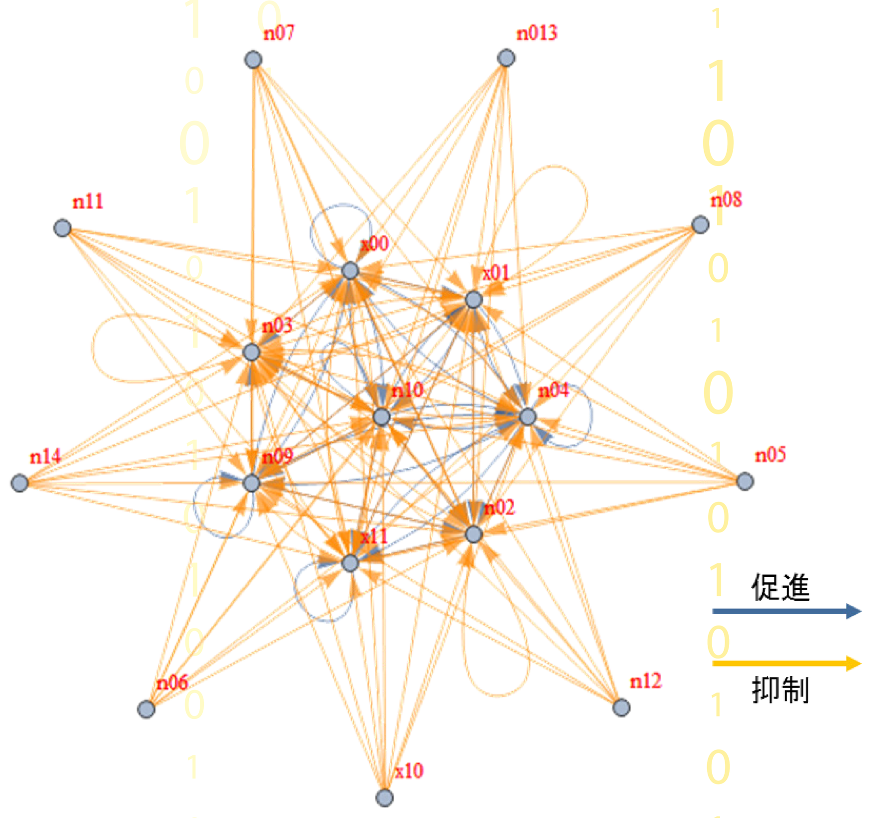

NII
連絡先：井上　克巳 教授／国立情報学研究所　情報学プリンシプル研究系
Email: inoue@nii.ac.jp

How to extract important knowledge from big data and use it for inference?

Knowledge Representation and Learning

Katsumi Inoue

Sophie Tourret; Kotaro Okazaki; Maxime Clement; Abderrahmane Chaabani; Alexis Robbes; Nguyễn Đình, Hiển; Hitomi Komata; Junya Yamaguchi; Yin Jun Phua; Kensuke Kikuchi; Junichi Sakuma; Taisuke Sato; Tenda Okimoto; Nicolas Schwind; Chiaki Sakama; Tony Ribeiro; Morgan Magnin

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**.

Highly Parallel Computing with GPU

By using GPU to solve **SAT (Boolean Satisfiability Problem)**, perform logical inference and abduction, we hope to utilize the highly parallel nature of GPU to speed up the **"thinking"** of AI. This has the implication of being able to speed up the time it takes to solve certain real world problems, such as model checking, planning, scheduling and many more.

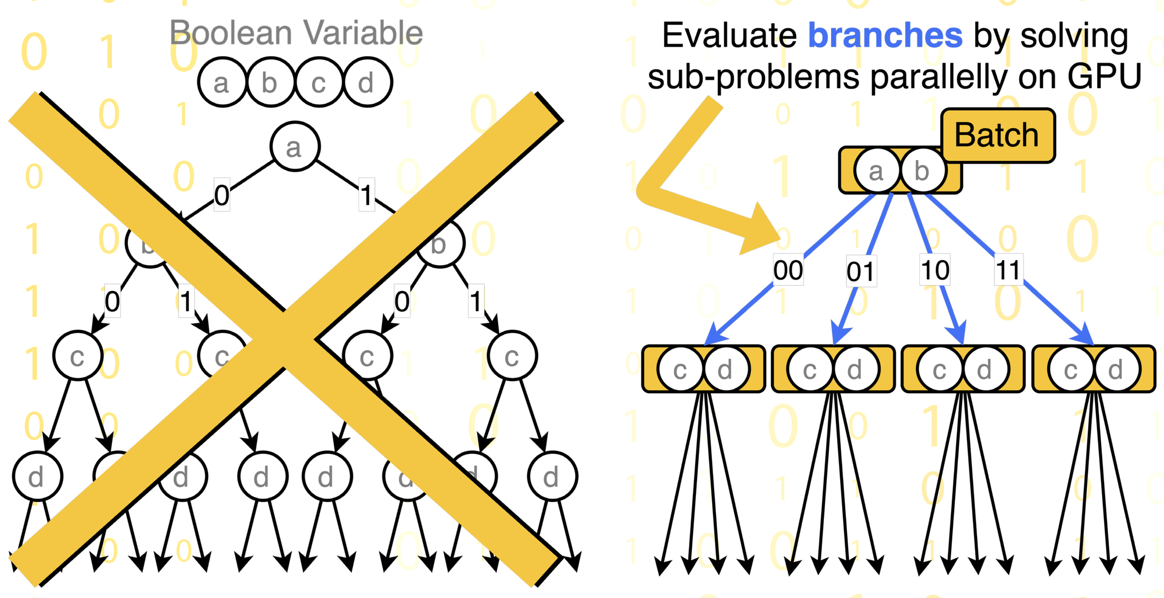

In this research, we have developed an algorithm to parallelize SAT solving. A SAT solver called **BatSAT** has also been implemented based on this algorithm. BatSAT relies on an original implementation of a weighted partial **MaxSAT solver** that runs on GPU. This MaxSAT solver **performs better** than the current state-of-the-art MaxSAT solvers. This is used to speed up the branching heuristc in BatSAT.

Multi-Objective Constraint Optimization

In real life, we are often confronted with problems which have **multiple solutions** with **different trade-offs**. For example, when travelling from one place to another, we can often choose between a route which is faster but more expensive, or another route which is slower but cheaper. Deciding which route to take often depends on our current financial situation and the time available.

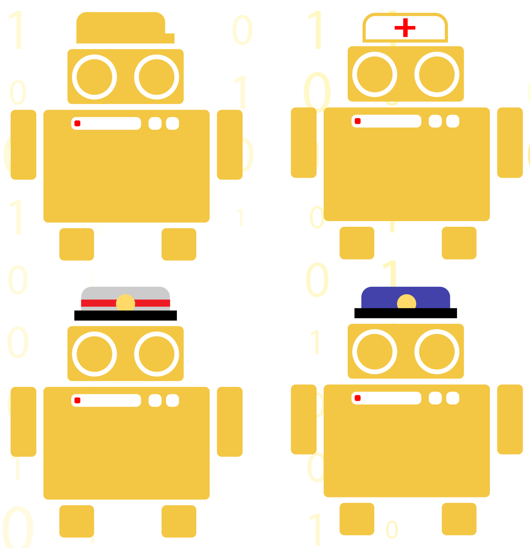

We can also consider an **emergency situation**, in which we have to **form a rescue team**. We might have to choose between forming a team that can work well together, but is too far away from the emergency site, or forming a team that doesn't work well together, but is situated near the emergency site. Additionally, we might have to consider a situation in which even in the event of losing a team member, the team as a whole still has to be functional.

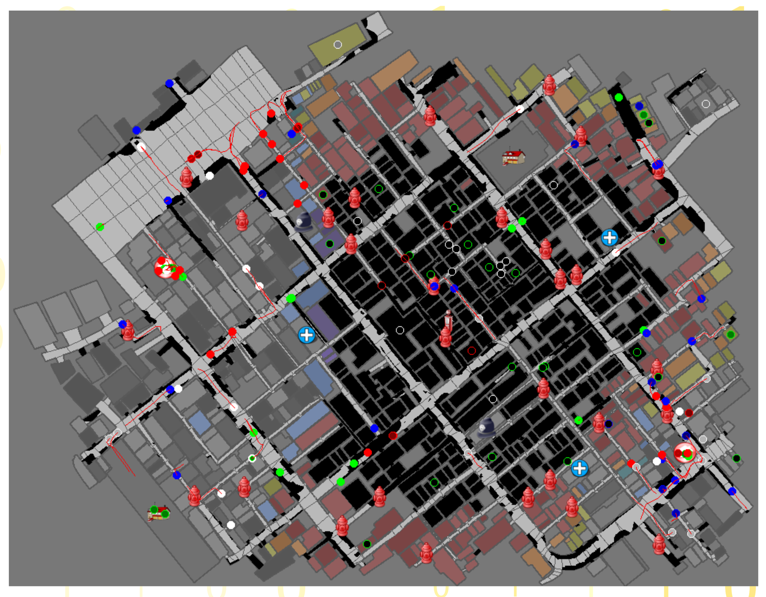

Learning from Interpretation Transition

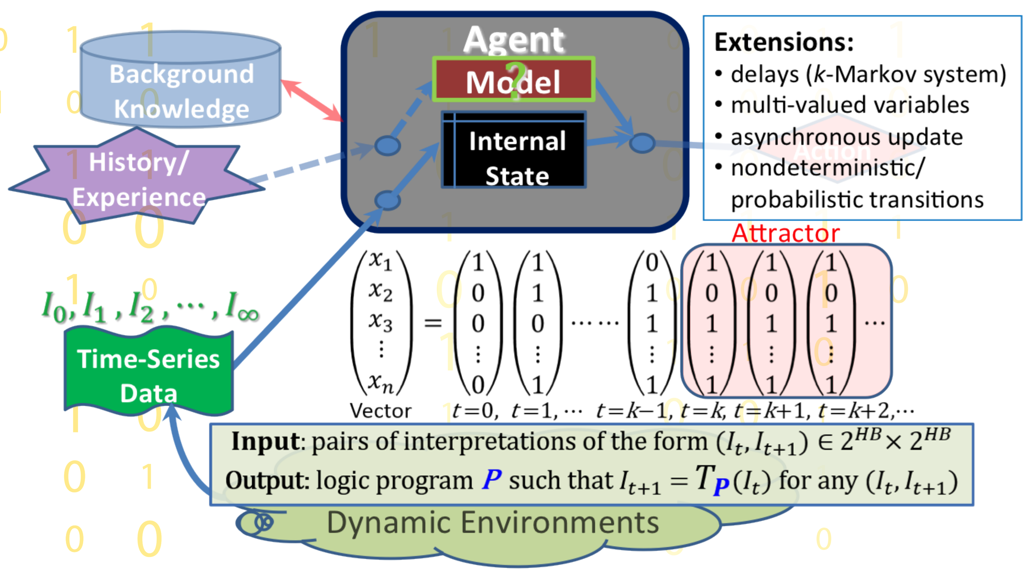

➢ Inoue, K., Ribeiro, T., Sakama, C.: "Learning from Interpretation Transition", *Machine Learning*, 94(1):51-79, 2014.

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.

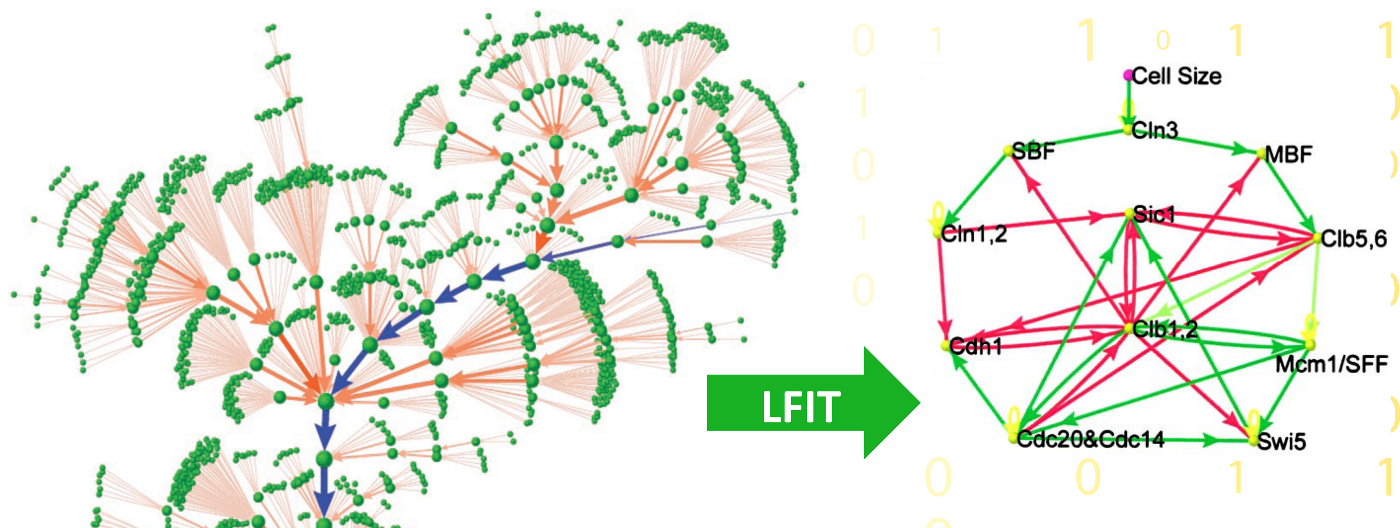

$x_6 \leftarrow \neg x_5 \wedge \neg x_9 \wedge x_{11} \wedge x_{12}$

$x_7 \leftarrow x_4 \wedge \neg x_6 \wedge x_7$

$x_9 \leftarrow \neg x_6 \wedge x_7 \wedge x_8 \wedge x_{10} \wedge \neg x_{11}$

⋮

Modelling Trans-Device Content Experience and Knowledge Development for Detection of TV Audience

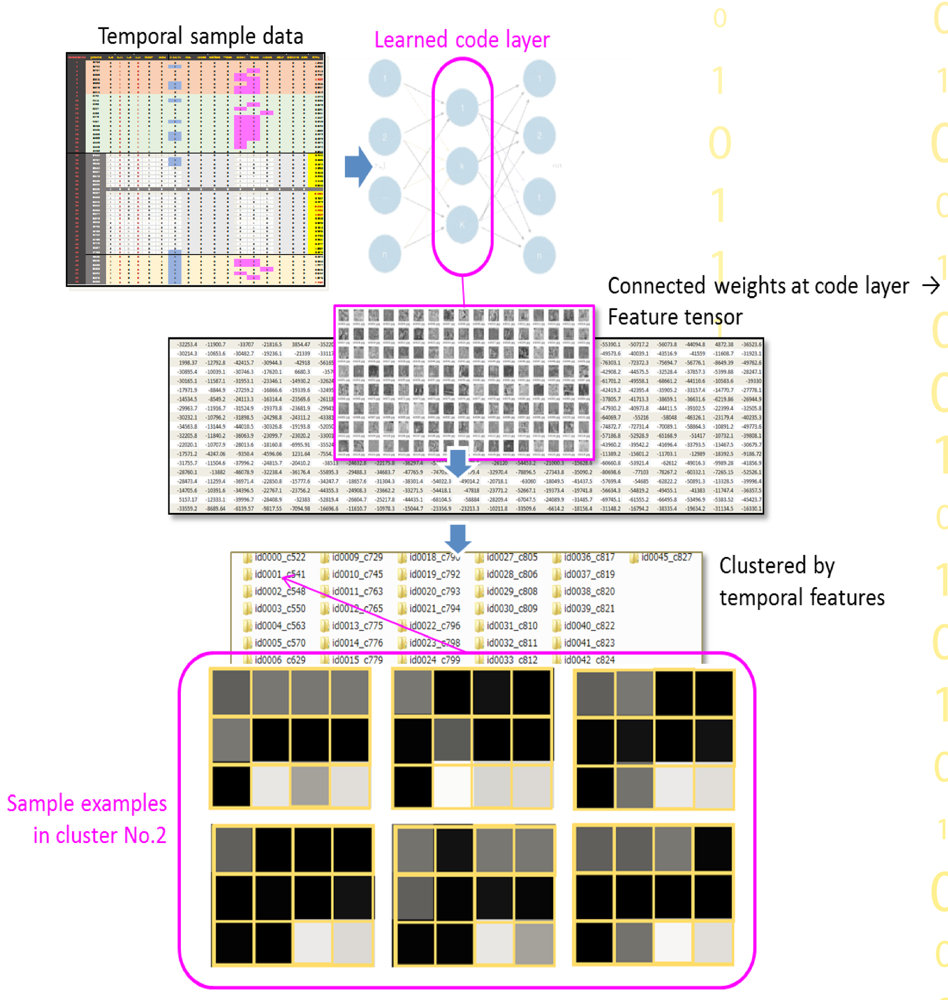

Many people no longer watch television at fixed times. This research focuses on **obtaining consumer characteristics** across **multiple mediums and devices**, attempting to construct a model that could **explain consumer behaviors**. By answering what the rules and functions that drive consumer behaviors are, whether these can be encoded into knowledge base, and whether this knowledge can lead to the discovery of unknown behavior patterns, the television industry might be able to **devise more effective content promotion**. We apply several AI techniques such as **natural language processing**, **neural networks**, and **automated reasoning** based on survey data which captures a composite viewing history for a particular content. A state space model is constructed from data sequence representing feature vectors of consumer attitude. Rules and constraints are then extracted as knowledge.

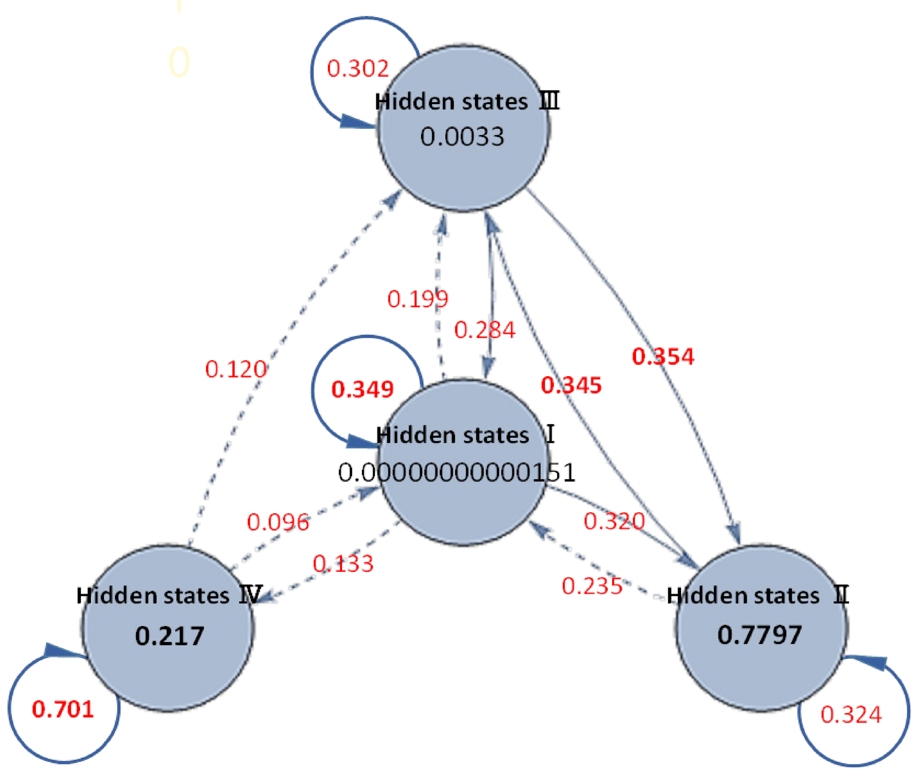

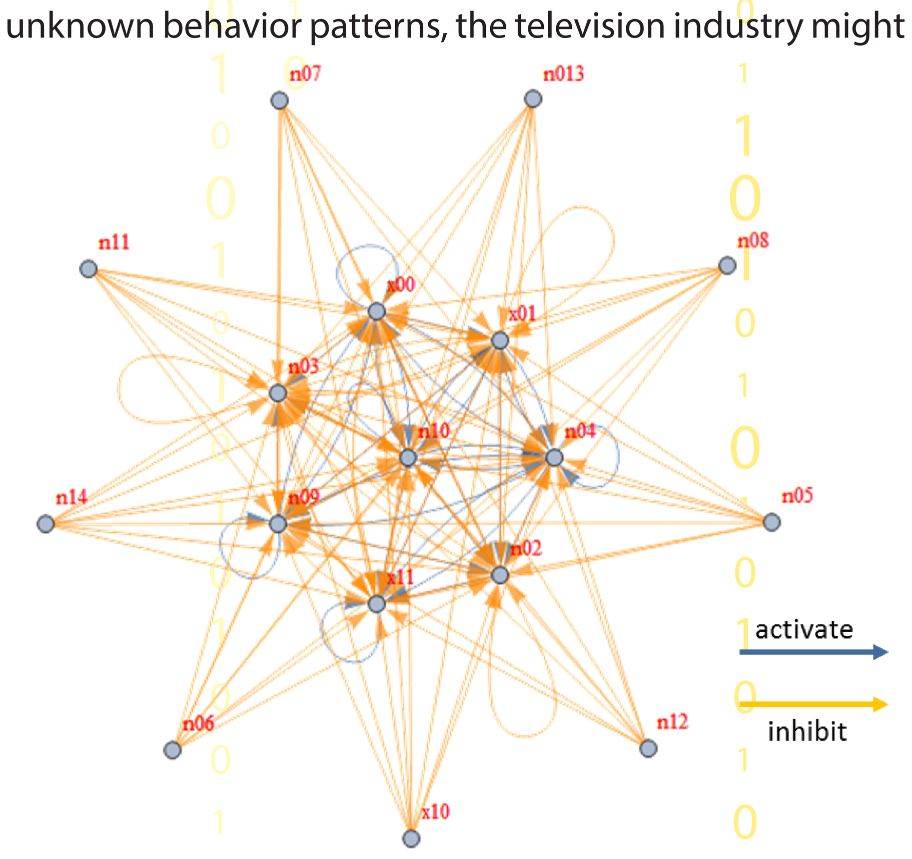

Contact: Professor KATSUMI INOUE, Principles of Informatics Research Division
Email: inoue@nii.ac.jp