

About the paper, entitled
“Towards Data-and Knowledge-Driven AI:
A Survey on Neuro-Symbolic Computing”

by Wenguan Wang, Yi Yang, , and Fei Wu

第114回AGI輪読会資料

2025年07月30日

担当：岡島義憲

Wenguan Wang :
ZJU100 Young Professor,
College of Computer Science and Technology, Zhejiang Univ. (浙江大学)
Doctoral supervisor
<https://person.zju.edu.cn/en/wenguanwang>



Yi Yang (full professor in Zhejiang University.)



Fei Wu (full professor in Zhejiang University.)



Abstract

NeSy (Neural-symbolic) には、記号表現の推論・解釈可能性とニューラルネットワークのロバストな学習という長所を両立させる期待があり、次世代のAIの起爆剤となる可能性がある。

構成

1. Introduction
2. History (NeSyの初期の研究成果、及び、最近の議論)
3. Background and Context (背景となる概念)
 - 3.1 Human Cognition: Biologic Neural Network vs Symbolic Logic Machinery
 - 3.2 NeSy: Best-of-Both Worlds 心理学と認知科学における「心」の一般的概念(NeSyの理論的基礎)
 - 3.3 Current Debate on AI
4. NESY: TAXONOMY AND STATE OF THE ART (最近のアプローチを分類)

4.1 Our Taxonomy for NeSy 4.2 Neural-Symbolic Integration 4.3 Knowledge Representation 4.4 Knowledge Embedding 4.5 Functionality	} NeSy(文献)の分類: > 神経と記号の相互関係 > 知識表現 > 知識の埋め込み > 機能性
--	--
5. APPLICATION AREAS AND TASKS (成功事例)
6. PERFORMANCE COMPARISON
 - 6.1 Performance Benchmarking: Retrosynthesis Prediction
 - 6.2 Performance Benchmarking: Visual Semantic Parsing
 - 6.3 Performance Benchmarking: Math Word Problem
7. OPEN CHALLENGES (未解決の問題)
8. CONCLUSIONS

概要：ニューラル・シンボリック・コンピューティング(NeSy)

NeSy：記号的パラダイムと統計的パラダイムの統合(データと知識駆動型AI)

- > 次世代のAIの起爆剤
- > 記号表現による推論・解釈可能性
- > ニューラルネットワークの頑健な学習

1. 歴史

- > 初期の研究
- > 背景となる概念
- > NeSy開発のモチベーション

2. Nesyの特徴と、近年の動向

- > 神経と記号の統合
- > 知識表現
- > 知識の埋め込み
- > 機能性、など

3. 応用分野と、成功事例

- > 科学的発見、
- > プログラミングシステム、
- > 質問応答
- > 視覚言語分析と推論
- > ロボット工学と制御
- > 視覚的情景理解
- > 数学的推論

4. ベンチマーク (複数のNeSy手法に関して)

- > 逆合成予測
- > 視覚的意味解析
- > 数学の単語問題解決

5. 今後の方向性と、未解決の問題

結論の章では、「強力なシステムの実現にはまだ程遠い」と締めくくる。

本稿の目的

- ・ 過去5年間に焦点を当て、NeSyに関する最近の重要な文献を体系的に収集
- ・ 調査対象分野
 - > コンピュータビジョン
 - > 自然言語処理(NLP)
 - > ナレッジグラフ

[13] A. Garcez (2019); “Neural-symbolic computing: An effective methodology for principled integration of machine learning and reasoning”.

[23] V. Belle (2020); “Symbolic logic meets machine learning: A brief survey in infinite domains”.

[24] L. C. Lamb, et al. (2021); “Graph neural networks meet neural-symbolic computing: A survey and perspective”.

[25] D. Yu, et al. (2021); “A survey on neural-symbolic systems”.

[26] E. Giunchiglia, et al. (2022); “Deep learning with logical constraints”.

[27] “Deep learning with logical constraints,” in International Joint Conferences on Artificial Intelligence, 2022.

Fig.1 Structure of the overall review

Data-and Knowledge-Driven AI: Neuro-Symbolic Computing (NeSy)




Fig. 1. Structure of the overall review.

1. INTRODUCTION

- ・ 現代のAI技術の信頼性、安全性、解釈可能性、説明責任に関して、一般社会と科学界で懸念も高まっている[1]

[1] Y. Yang, et al.(2021); "Multiple knowledge representation for big data AI: framework, applications, and case studies,"

- ・ AI開発史の2大潮流

> Symbolism :

> Connectionism : DNN、神経系の生理学、fault-tolerant、帰納的学習、構成的汎化能力は不十分、データ効率が悪い、論理的に不透明

[2] J. Haugeland (1989); "Artificial Intelligence: The very idea".

[3] J. Zhang, et al.(2021); "Neural, symbolic and neural-symbolic reasoning on knowledge graphs".

- ・ 両者の融合戦略： Neural-Symbolic Computing

学習(経験から学ぶ能力)と推論(学んだことから推論する能力)という2つの基本的な認知能力[12, 13]の統合を模索

(分散表現に基づく統計的帰納的学習と、局所的表現に基づく論理的演繹的推論)

[10] B. M. Lake, et al. (2017); "Building machines that learn and think like people".

[11] G. Marcus(2018); "Deep learning: A critical appraisal".

[12] L. G. Valiant (2003); "Three problems in computer science".

[13] A. Garcez (2019); "Neural-symbolic computing: An effective methodology for principled integration of machine learning and reasoning".

[23] V. Belle (2020); "Symbolic logic meets machine learning: A brief survey in infinite domains".

[24] L. C. Lamb, et al. (2021); "Graph neural networks meet neural-symbolic computing: A survey and perspective".

[25] D. Yu, et al. (2021); "A survey on neural-symbolic systems".

[26] E. Giunchiglia, et al. (2022); "Deep learning with logical constraints".

1-1. Neural-Symbolic Computing

- 戦略：「学習(経験から学ぶ能力)と推論(学んだことから推論する能力)の統合^[12, 13]
(シンボリズムとコネクショニズムのハイブリッド)
(分散表現に基づく統計的帰納的学習 + 局所的表現に基づく論理的演繹的推論、等)
- 応用実証：
 - > 視覚的關係理解^[15, 16]
 - > 視覚的質問応答^[17, 18, 19]
 - > 視覚的シーン解析^[20, 21]
 - > コモンセンス推論^[22]

1-2. Symbolism (ルールベースの記号論的モデル)

・ 記号論的モデル

- ：「記号」が人間知性の基本単位
- ：記号表現による「ルール」と「論理演算」を元に、認知プロセスが進むと想定^{[2][3]}
- ：トップダウン戦略
- ：1950年代半ば～1980年代後半のAIの多くで採用

> 長所 :

- ：わずかな入力サンプルしか必要としない。
- ：宣言言語を整備することで、概念の明確な知識表現が可能

> 欠点

- ：ルールベース(学習能力による概念獲得機能が無い)
- ：ルールが明確な為、異なるタスクへの一般化能力に限界あり
- ：離散的な記号表現とルールの整備に、多くのハンドチューニング作業が必要
- ：曖昧でノイズの多いデータに対して不寛容(実世界の問題を扱うには、不十分)

2. History : NeSy設立

- NeSy協会設立(2005年)

Neural-Symbolic Learning and Reasoning Association

- > スコットランド・エディンバラで開催されたIJCAI 2005の一環として初めて開催されたワークショップ「NeSy 2005」が起源
- > 設立目的は、Symbolism(記号論理重視)と Connectionism(DNN)を統合した“Computational Methodologies“を構築すること [14].

[14] T. R. Besold (2022); Neural-symbolic learning and reasoning: A survey and interpretation".

- > Executive Board :

Artur d'Avila Garcez, City St George's, University of London, UK

Tarek R. Besold, Sony AI, Barcelona, Spain

Ernesto Jimenez-Ruiz, City St George's, University of London, UK

Leilani H. Gilpin, UC Santa Cruz, CA, USA

Pascal Hitzler, Kansas State University, USA

- > Sponsor :

Carnegie Bosch Institute (カーネギーメロン大学, ペンシルバニア)

AllegroGraph Franz Inc.

- > 2010年代、DNNアーキテクチャの成功により、NeSyの注目度低下

- > Nesy-2025 (第19回、9月8～10日) : <https://2025.nesyconf.org/>

2. History (NeSyの経緯と直近の活動)

- McCulloch & Pittsの1943年の論文^[9]で示した、「ニューラルネットは、ブール代数(有限オートマトン)と等価な論理を実行する」との見解は、SymbolismとConnectionismの融合の出発点だった^[28, 29, 14]。

[9] W. S. McCulloch and W. Pitts (1943); "A logical calculus of the ideas immanent in nervous activity".

[14] T. R. Besold (2022); Neural-symbolic learning and reasoning: A survey and interpretation".

[28] S. Bader and P. Hitzler (2005); "Dimensions of neural-symbolic integration – a structured survey".

[29] A. S. Garcez, et al.(2009); "Neural-symbolic cognitive reasoning".

- 1990年代から、NeSyが研究分野となり始め、2000年代初頭に、NeSyに関する体系的な研究が始まった^{[31] [30]}。

[31] G. G. Towell, et al. (1990); "Refinement of approximate domain theories by knowledge-based neural networks".

[30] S. Shi, et al. (2020); "Neural logic reasoning".

[32] J. B. Pollack (1990); "Recursive distributed representations,".

[33] L. Shastri and V. Ajanagadde (1993); "From simple associations to systematic reasoning: A connectionist representation of rules, variables and dynamic bindings using temporal synchrony".

[34] S. Hölldobler, et al. (1991); "Towards a new massively parallel computational model for logic programming".

[35] A. Garcez and G. Zaverucha, "The connectionist inductive learning and logic programming system".

[36] G. G. Towell & J. W. Shavlik (1994); "Knowledge-based artificial neural networks".

[37] T. A. Plate (1995); "Holographic reduced representations".

[38] I. Cloete & J. M. Zurada (2000); "Knowledge-based neurocomputing".

[39] A. Browne, & R. Sun (2001); "Connectionist inference models".

[40] A. S. d. Garcez, et al. (2002); "Neural-symbolic learning systems: foundations and applications".

- これらアーキテクチャは、主にハードロジック推論のために設計されているため、表現学習能力や、大規模データの推論能力が低かった^[30]。

■ 以下の5軸に、ニューラル-シンボリック統合に関する既存研究を体系的に調査した

a) 表現 (Representation)

知識や論理をどのようにニューラルネットワークに「符号化」するか。
論理式、命題論理、一階述語論理などをどう表現するか。

b) 意味論 (Semantics)

ニューラルネットが持つ重みや活性化関数に、論理的意味を持たせられるか。
論理モデルとの整合性があるかどうか。

c) 推論 (Reasoning)

ニューラルネットワークを用いて、どのような推論が可能か。
論理的帰結を導けるか、帰納的推論ができるか。

d) 学習 (Learning)

記号的知識を含む状態で、ニューラルネットに学習させる方法。
教師あり・教師なし学習、ルールの発見、パラメータ調整など。

e) 実装 (Implementation)

実際のアルゴリズムやアーキテクチャ(例:拡張されたRBFネットワークなど)。
ソフトウェアやツールキットの実用性。

■ 課題と展望

- ・ スケーラビリティの観点
- ・ 学習と推論の統一的理論の必要性
- ・ 解釈可能性とブラックボックス性のバランス
- ・ 統合モデルの汎用性の向上

- ・ 深層学習を用いて論理的推論を行う方法を提案
 - > ニューラルネットが「論理的な推論」をどのように扱うか？
 - ： 論理ゲートを模倣したネットワークモジュールを含むアーキテクチャで、命題論理推論を行い、推論結果を導出しようとした。
 - > それをどう訓練するか？
 - ： 強化学習を用いて、論理演算を直接学習させる
(論理的推論のタスクにおいて過学習を起こすリスクがみられた)
 - > ハードロジック推論のために綿密に設計されているため、表現を学習する能力や、大規模で異種混合のノイズの多いデータを推論する能力に欠けていた。
 - > ニューラルネットワークベースであるため、推論プロセスがブラックボックスであり、推論結果の解釈性が欠如していた。

(参考) [28] S. Bader and P. Hitzler (2005);

"Dimensions of neural-symbolic integration – a structured survey"




Figure 1. Neural-symbolic learning cycle

AI研究者がNeSyの重要性を認識するようになった動機；

3.1 人間の認知のモデル化

3.2 コネクショニズムとシンボリズムの融合

3.3 AAI-2020の影響 → **3.3 Current Debate on AI に掲載**

> ヨシュア・ベンジオ、ゲイリー・マーカスのモントリオールAIディバートの影響[45]

> AAI-2020 ファイヤーサイド対談（ヒントン、ベンジオ、ルカン）

3.1.1 「認知」を模倣できるのは、神経回路か？ 述語論理マシンか？

- ・ 人間の認知は、ほとんど均質な神経回路(基盤)にて進行する。従って、人工ニューロンで脳神経系の動作を模倣できれば、コンピュータで知能が発達する筈
(コネクショニストの見解)
 - ： シナプス接続と発火パターンが、注意、問題解決、記憶、学習、意思決定、言語、
 - ： 知覚、想像力、論理的推論などのさまざまな認知過程を支えている。
- ・ 人間の思考は、シンボルベースの論理に依存している (認知科学者の見解)
 - ： 記号論理は、明示的な認知推論を行う際の「内省」を抽象化したもの^[44]
- ・ 「2つの抽象化(神経回路と述語論理マシン)を、結びつけ、統一する」、もしくは、「神経基盤から記号操作を出現させる」のいずれかが「解」となる筈だ^[45, 14]。

[14] T. R. Besold (2022); Neural-symbolic learning and reasoning: A survey and interpretation".

[45] G. Marcus (2020); "The next decade in AI: Four steps towards robust artificial intelligence".

【YoK】 脳内の近接回路の接続はコネクショニスト的で、遠方との接続はシンボルベース的？

3.1.2. Deduction(演繹) vs Induction(帰納)[46]

- ・ 演繹^[47]は、「記号論理による高レベルの推論」に優位性ある
 - ： 知識ベースから推論するための「**証明システム構築**」をターゲットとして来た。
 - ： オブジェクト、属性、および関係の観点から「**構造化表現**」を重視^[23, 49]
 - ： 知識を表現するための「**形式言語の表現力獲得**」を目指して来た。
- ・ 帰納派は、「ニューラルネットワークによる統計的学習」で優位性がある^[48]
 - ： ニューラルネットワークは、統計的に「**実体の分散表現**」を学習する。
 - ： 大量の情報から**ボトムアップ**的般化を試みて来た^[23]。
- ・ **演繹的推論と帰納的学習の関係を再考することが不可欠**
 - ： 両者を調整できるロバストな計算モデルが必要
 - ： 人間の認知のどの部分が記号的で、どの部分が統計的なのかは分離できない

【YoK】 脳内神経回路の近接接続は帰納的で、遠方との接続は演繹的？

3.1.3. Compositionality(分解可能性) vs Continuity(微分可能性)

- ・ スモレンスキーの「認知の中核的逆説(Central Paradox of Cognition)」^[55]

[55] P. Smolensky (1988); "On the proper treatment of connectionism".

：人間の認知は、強力な構成的汎化能力を持ち、潜在的に無限に存在する世界の状態を扱うことができる^[6]が、文章生成は、離散的な記号計算である。

：「連続性原理(連続なベクトル空間内の神経計算)」と「構成性原理(離散的な記号構造処理)」の両方に同時に対処する新しい計算メカニズムが必要となる。

↳ 連想

⇒ Neurocompositional Computing 提案^[7]

連続的なニューラル・コンピューティングによって構成構造処理を直接実現しようとする

[7] P. Smolensky, et al.(2022); "Neurocompositional computing: From the central paradox of cognition to a new generation of ai systems".

- ・ Continuity (連続性 / 微分可能性の源泉、神経生理学的根拠に基づく見解)
- ・ Compositionality (分解可能性、哲学と認知科学的根拠に基づく見解)^[51,52,53,54]
- ・ NeSyの見解と提案は、スモレンスキーと少し違っている。
NeSyは、ニューラル・アプローチ(DNN)とシンボリック・アプローチ(プログラム)を結合させたハイブリッド・システムを目指している。

【YoK】 Neurocompositional Computingは、「ニューラルネットワークを用いた連想」だろう。

- Kahneman's 'fast and slow thinking' theory^[57]

- カーネマンの「速い思考(直感的、経験的、無意識的)と遅い思考(論理的、意識的)」も、NeSyやP. Smolenskyの研究に似る^[56]。

システム1とシステム2の特徴は、コネクショニストとシンボリックの特徴と似る

- 構成的汎化は、システム1の思考とシステム2の思考の両方に見られる^[7]。
- 最初はシステム2に頼らないと解決できなかった問題が、システム1によって対処できるようになることがある^[56]。
- システム2を一貫して効果的に使用することで、システム1を調整することができ、その結果、システム2が促進され、フィードバック・ループにつながる。

3.2 NeSy: Best-of-Both Worlds

- NeSy研究の開発目標
 - : コネクショニストと記号論理を組み合わせたComputingアーキテクチャ
 - : DNNと記号論理(プログラム)の長所/短所を補完

	コネクショニスト技術(Connectionism)	記号的アプローチ (Symbolism)
長所	・ 生データからの統計的パターンの発見が得意 ・ ノイズの多いデータに対してもロバスト ・ 直感的な判断(画像分類、等)に有効	・ 論理的推論/原理的判断に優れる ・ 本質的に高い説明可能性ある ・ 知識表現に用いる宣言言語を使える
短所	・ データを大量に消費する ・ ブラックボックス的 (意思決定プロセスの理解が困難)	・ 訓練可能性が低い。 ・ 領域外に脆い。

【YoK】「ニューラルネットワークで連想はできない」と見なしているのは不思議だ。

3.3 Current Debate on AI

- ・「コネクショニスト・アプローチ(ディープラーニング)」には、深刻な難点がある^[68]

- > データ効率
- > 理解可能性
- > 構成的汎化

[45] G. Marcus (2020); "The next decade in AI: Four steps towards robust artificial intelligence".

[68] N. C. Thompson, et al.(2020); "The computational limits of deep learning".

- ・ダニエル・カーネマン、ジェフ・ヒントン、ヨシュア・ベンジオ、ヤン・ルクンによるAAAI-2020 ファイヤーサイド対談 (<https://www.youtube.com/watch?v=UX80ubxsY8w>)

- > マーカス： ハイブリッドシステムの重要性を強調（「ロバストな人工知能を実現するためには、抽象的な知識を日常的に獲得/表現/操作できるシステムを構築するためのフレームワークが必要ある」）
- > ヒントン：「汎化のためには、上位概念が根拠を持ち、分散表現されている必要がある」、「記号が明示されなくても、DLで記号の属性の多くを得ることができる」、「記号処理では、十分に豊かな表現とならない」
- > カーネマン： システム2(記号操作)の重要性を強調（「コネクショニズムとシンボリズムのハイブリッドの実現方法では意見が分かれるが、いずれにしても、新世代のAIシステムは抽象概念を扱い、健全な推論を行うことができるべきである」）

4. NeSy: Taxonomy and State of the Art

第4.1節 : NeSyの分類法

以下は、この分野での最近の研究成果

第4.2節 : ニューラル・シンボリック統合

第4.3節 : 知識表現

第4.4節 : 知識埋め込み

第4.5節 : 機能性

4.1 ニューラル・シンボリック統合提案の分類

- Sebastian & Hitzler (2005) [28] は、ニューラル・シンボリック統合開発には、4課題(問題認識、筆者は“dimension”という)があるとした。

[28] S. Bader and P. Hitzler (2005); "Dimensions of neural-symbolic integration – a structured survey".

4.2節 : ニューラル・シンボリック統合 (neural-symbolic integration) の「構造(アーキテクチャ)」による分類 [58]


[58] H. Kautz (2022); "The third AI summer: AAAI Robert s. Englemore memorial lecture".

4.3節 : 知識の表現方法による分類 (knowledge representation) : 知識表現は、記号的か論理的か？

4.4節 : 知識埋め込まれ方による分類 (knowledge embedding) : ニューラル・マシンのどの部分に記号的知識が統合されるか？

4.5節 : 機能性による分類 (functionality) : 知識の埋め込みのどの過程で、記号的知識が統合されるか？ : データの前処理、ネットワークのトレーニング、ネットワークのアーキテクチャ、最終的な推論の様々な統合方法が試されている(が、十分に抽象的な知識が獲得されているとはいいいがたい)。 → 5章のベンチマーク、6章で評価

Figure 2: Our four-dimensional taxonomy for NeSy.



この4次元にて、最近の注目研究の特徴を調べ、表Iに要約した。

アーキテクチャの分類[58]


[58] H. Kautz (2022); "The third AI summer: AAAI Robert s. Englemore memorial lecture".

Neuro-Symbolicの統合は、ネットワーク・アーキテクチャとしての統合以外にも、データの前処理、ネットワークのトレーニング、推論、等の工程でも検討されている。

- Type 1 : Symbolic Neuro Symbolic
(記号入出力を持つニューラルネットワーク。現在のDLの標準形態)
- Type 2 : Symbolic[Neuro]
(記号処理を行うコアと、ニューラルネットを内蔵するサブルーチンからなるシステム)
- Type 3 : Neuro|Symbolic
(ニューラル処理とシンボリック処理が相互作用し、補完的にタスクを行うシステム)
- Type 4 : Neuro: Symbolic→Neuro
(ニューラルネットワークや訓練枠組みの中に、知識を記号的ルールとして組み込むシステム)
- Type 5 : NeuroSYMBOLIC
(記号的知識をDNNの訓練に使用される損失関数の追加的なソフト制約として用い、DNNの重みの中に知識を埋め込むタイプ)
- Type 6 : Neuro[Symbolic]
(ニューラルネット表現の中に記号推論論理を組み込んだ究極の融合形)

Type 1 : Symbolic $\rightarrow$ Neuro $\rightarrow$ Symbolic (表1参照)

■ コア部(ニューラルネットワーク) + 記号入出力 のタイプ




- ・ NLP等、現在のDLの標準形態 (このタイプはNeSyとは呼びづらい)

表 1 : Type-1 と Type-2 の 調査対象の一覧

Neural-Symbolic Integration	Method	Knowledge Representation	Knowledge Embedding	Functionality	
				Learning	Reasoning
Type-1 Symbolic Neuro Symbolic	word2vec [59]	-	-	✓	
	Glove [60]	-	-	✓	
	GPT-3 [61]	-	-	✓	
Type-2 Symbolic[Neuro]	AlphaGo [62]	-	-	✓	✓
	NeSS [63]	-	-		✓
	PLANS [64]	Programming Language	-		✓
	VisProg [65]	-	-	✓	✓
	HuggingGPT [66]	-	-	✓	✓
	ViperGPT [67]	-	-	✓	✓

Type 2: Symbolic[Neuro] (Neuro Subroutines) P6左下 (表1参照)

- コア部(記号処理アルゴリズム) + サブルーチン(ニューラルネット内蔵)のシステム
(一般に、記号処理部とニューラル処理部の結合はNarrow)




- DeepMindのAlphaGo^[62] : 問題ソルバーはモンテカルロ木探索アルゴリズム
評価関数がニューラルネットワーク。
- NESS^[63] : ニューラルネットワーク(seq2seq)によって実行トレースを生成し、結果を記号論理型アルゴリズムで実行。(学習後の構成規則の一般化目指した。)
[63] X. Chen, et al.(2020); "Compositional generalization via **neural-symbolic stack machines**".
- Plans^[64] : ニューラルネットが生の入力動画から抽象的な高レベルの情報を抽出。
抽出情報を基に、記号論理型アルゴリズムで合成を行う。
[64] R. Dang-Nhu (2020); "Plans: **Neuro-symbolic program learning from videos**".
- VisProg^[65]、HuggingGPT^[66]、ViperGPT^[67]などの最近の大規模言語モデル
(LLM)ベースのAIエージェントを持ち、複雑なタスクをサブタスク列に分解して処理

Type 3: Neuro|Symbolic (Neural Learning + Symbolic Solver.)

(表2参照)

P6右下

- ニューラル処理とシンボリック処理が相互作用し、補完的にタスクを行うシステム。
(Type-2のニューロ部はサブルーチンだったが、Type-3は両者が相互作用するコルーチン。)



[84] : サブシンボル知覚学習とシンボル論理推論を相互作用的に行うフレームワーク
[84] W.-Z. Dai, et al.(2019); "Bridging machine learning and logical reasoning by abductive learning".

[18] : ニューラル知覚モジュールが視覚的概念を学習。
記号的推論モジュールが記号的プログラムを実行し、質問に応答する。

[18] J. Mao(2019); "The neuro-symbolic concept learner: Interpreting scenes, words, and sentences from natural supervision".

[70, 71, 69, 72, 74, 78, 85] : ディープラーニング技術を活用して、高レベルのタスク仕様を満たす記号プログラム／ルールシステムを生成する。

[79, 75, 76, 77, 80, 81, 73, 83] : Neural-Symbolic Reinforcement Learning
RLによって生成される「記号的計画」にてタスクが実行され、結果から記号的計画を改善する。

・ Neural Theorem Provers(NTP)[86]、Conditional Theorem Provers(CTP)[87]、NLProlog[88]、DeepProbLog[89]、NeuroLog[90]、DiffLog[91]

表 2 : Type-3 の 調査対象の一覧

Neural-Symbolic Integration	Method	Knowledge	Knowledge	Functionality	
		Representation	Embedding	Learning	Reasoning
Neuro Symbolic	NS-VQA [69]	Symbolic Expression	-	✓	
	NSPS [70]	Symbolic Expression	-	✓	
	NeRd [71]	Symbolic Expression	-	✓	
	Synth [72]	Symbolic Expression	-	✓	
	NSM [73]	Symbolic Expression	-	✓	
	PS-GM [74]	-	-	✓	
	NS-CL [18]	-	-	✓	
	DSRL [75]	-	-	✓	
	CDSE [76]	-	-	✓	
	NSCA [77]	Propositional Logic	-	✓	
	HOUDINI [78]	Programming Language	-	✓	
	PEORL [79]	Programming Language	-	✓	
	SDRL [80]	Programming Language	-	✓	
	SORL [81]	Programming Language	-	✓	
	RRN [82]	First-order Logic	-	✓	
	NLRL [83]	First-order Logic	-	✓	
	ABL [84]	First-order Logic	-	✓	✓
	Neural LP [85]	First-order Logic	-		✓
	NTPs [86]	First-order Logic	-		✓
	CTPs [87]	First-order Logic	-		✓
	NLProlog [88]	First-order Logic	-		✓
	DeepProbLog [89]	First-order Logic	-		✓
	NeuroLog [90]	First-order Logic	-		✓
	DiffLog [91]	First-order Logic	-		✓
	TensorLog [92]	First-order Logic	-		✓

(参考) [84] W. Z. Dai, et al.(2019);

"Bridging machine learning and logical reasoning by abductive learning".

- ・機械学習と論理的推論を統合した”Abductive Learning (ABL)”を提案
- ・ニューラルネットで入力情報からprimitive symbols中の或るシンボルを推測し、そのシンボルに、暫定ラベルを付け、Abduction工程に進む。

Abduction工程：擬似ラベルが背景知識ベース(first-order logic rules)と整合しない場合、矛盾を解消する候補ラベル群(abduction space)を生成し、事前確率などを使って最も一貫性の高い候補を選ぶ。(仮説生成し、評価し、改善するというプロセスを通じて試行錯誤的に、より一貫性の高い論理推論を行う)

Consistency-guided Selection動作：信頼度モデルと整合性スコアに基づき最適な修正ラベルを選び、これを次の教師信号として用いる。

モデル更新：選ばれた修正ラベルを使って Perception Model を再訓練。これを繰り返してループさせることで、モデル全体が知覚と推論双方の一貫性を高めていく。





Figure 3: The structure of ABL framework.

(参考) [89] R. Manhaeve, et al.(2018);

"Deepproblog: neural probabilistic logic programming".

- **ProbLog** という確率論的 Prolog をベースにして、「ニューラル予測を確率的事実として扱う」という形で Neural-Symbolic 統合する。
- 確率論的論理プログラミングで命題論理や述語論理のルールを定義し、それに基づいて推論 Probabilistic Logic Programming (PLP) <https://nips.cc/media/nips-2018/Slides/12755.pdf>
- 学習と推論のステップは単独ではなく、**並行して進行し、動的にインタラクションする**。
- 推論部に組み込まれたニューラルネットが出力する**確率分布**を、**論理プログラム内の確率付き事実**(ニューラル述語)として扱い、それらを通常の ProbLog ルール^[129]と組み合わせて、確率的に推論する。
- 学習では、出力クエリのラベルに対し「損失」を定義し、aProbLog の勾配セミリング機構により、論理プログラム部分とニューラル部分の両方を微分可能にしている。




(a) The learning pipeline.

Type 4: Neuro: Symbolic→Neuro (表3参照) (Symbolic Compilation into Neural Topology).

P7左下

- 定義: 知識を記号的ルールとしてコンパイルして、ニューラルネットワークのアーキテクチャ、もしくは、学習工程に組み込むシステム [103, 97, 111, 94, 95, 96, 124, 125]



- 数式をツリー表現し学習データとして使用したニューラル・シンボリック数学システム [98, 99, 100]
- 応答時に記号プログラムを生成し、実行することで応答する「質問応答モデル」 [101, 102, 104, 19, 108, 109, 110, 105]
- 指定した論理的制約に従うよう、出力層に制約論理の知識を組み込む [123, 126, 127]
- 入力層の確率モデルにて語彙的制約を課す [128][130]。
- グラフニューラルネットワーク(GNN)に、外部知識と実体と関係を埋め込み、画像処理や自然言語処理の性能を向上させる [112, 113, 114, 115, 116, 117, 118, 119, 120, 121]。


表3 : Type-4 の 調査対象の一覧

Neural-Symbolic Integration	Method	Knowledge Representation	Knowledge Embedding	Functionality	
				Learning	Reasoning
Neuro: Symbolic → Neuro	SD-VAE [94]	Programming Language	Data, Neural Inference	✓	
	Tree2tree [95]	Programming Language	Data, Neural Inference	✓	
	JTAE [96]	Knowledge Graph	Data	✓	
	EQNet [97]	Symbolic Expression	Data	✓	
	DLSM [98]	Symbolic Expression	Data	✓	
	NGS [99]	Symbolic Expression	Data, Neural Inference	✓	✓
	NeuralMath [100]	Symbolic Expression	Data	✓	
	IEP [101]	Symbolic Expression	Sub-Symbolic Rep.	✓	
	NSVR [19]	First-order Logic	Sub-Symbolic Rep.	✓	
	DrKIT [102]	First-order Logic	Sub-Symbolic Rep.	✓	
	Alps [103]	First-order Logic	Sub-Symbolic Rep.	✓	
	∂ ILP [104]	First-order Logic	Sub-Symbolic Rep.		✓
	NGCLP [105]	First-order Logic	Sub-Symbolic Rep.	✓	✓
	NMLNs [106]	First-order Logic	Sub-Symbolic Rep.	✓	✓
	NLIL [107]	First-order Logic	Network Architecture	✓	✓
	NSM [108]	Knowledge Graph	Network Architecture	✓	
	XNMs [109]	Knowledge Graph	Network Architecture	✓	
	Prob-NMN [110]	Knowledge Graph	Network Architecture	✓	
	LENSR [111]	Propositional Logic, Knowledge Graph	Sub-Symbolic Rep., Network Architecture	✓	
	CNIF [112]	Knowledge Graph	Network Architecture	✓	
	HHP [113]	Knowledge Graph	Network Architecture	✓	
	KagNet [114]	Knowledge Graph	Network Architecture	✓	
	GRHEK [115]	Knowledge Graph	Network Architecture	✓	
	GraIL [116]	First-order Logic, Knowledge Graph	Data, Network Architecture	✓	
	KB-GAN [117]	Knowledge Graph	Knowledge Graph	✓	
	KRISP [118]	Knowledge Graph	Data, Network Architecture	✓	
	SGN [119]	Knowledge Graph	Network Architecture	✓	
	SGR [120]	Knowledge Graph	Network Architecture	✓	
	SYMNET [121]	Knowledge Graph	Network Architecture	✓	
	NSLMs [122]	-	Network Architecture	✓	
	MultiplexNet [123]	First-order Logic	Network Architecture	✓	
	C-HMCNN(h) [124, 125]	Propositional Logic	Network Architecture., Neural Inference	✓	
	SPL [126]	-	Network Architecture, Neural Inference	✓	✓
	CCN+ [127]	Propositional Logic	Network Architecture, Neural Inference	✓	
	GeLaTo [128]	-	Network Architecture, Neural Inference		✓

(Symbolic Integration in Loss Function). (表4参照)

- 記号的知識を、DNNの訓練に使用される損失関数の追加的なソフト制約として用い、DNNの重みを調整する [135, 136, 137, 138, 140, 141, 142, 143, 144, 145, 146, 139]。


NEURAL NETWORK



Output



Loss



SYMBOLIC KNOWLEDGE




- 論理テンソルネットワーク(LTN)[131, 132, 133]、ロジスティック回路[134]、ソフトファジィ論理[153]
 - 一階論理式(ブーリアン一階論理)を、ファジィ論理を表現するニューラル論理に変換し、勾配ベースのサブシンボリック学習を進め、近似的推論を行う。
 - 多くの場合、予測とクラス階層の関係を保つために、異なる訓練目的関数を用いる[21]、[139]。
- [注]・ LTNは、微分不可能な論理接続子($\wedge, \vee, \neg, \Rightarrow$)と量化子($\exists, \forall$)を微分可能なファジィ論理演算子で近似する[141]。ファジィ論理では、変数は[0, 1]の範囲の真理度を持つ。(エンド・ツー・エンドの学習のために、論理ルールをネットワーク学習目的に組み込む)
- 分類器を設計する際にクラス階層を考慮するアプローチもある[147, 148]。(クラス階層は分類目標と背景知識の両方として機能する。)

Type 6: Neuro[Symbolic] (表4参照) (Full Hybridization of Neural and Symbolic Components).

P8左下

- ・ 定義：ニューラルネット表現の中に記号推論論理を組み込んだ統合型システムの究極形
- ・ テンソル計算で論理的推論を模倣し、ニューラルネットワークを通じて記号演算の実行を学習する^[149, 150, 151]。但し、それらの記号的推論能力は弱く、実用レベルになっていない。

NEURAL NETWORK




[注] これは、AAAI-2020で、Henry Kautzが最も可能性を秘めているとしたタイプ。Kautzは、タイプ6の手法をKahnemanのシステム1およびシステム2に相当するとみなしていたので、タイプ6の手法は組み合わせ推論が可能であるべきであるとしていた。但し、そのような能力を示すNeSyアプローチは今のところ未だ存在しない。

Neural-Symbolic Integration	Method	Knowledge Representation	Knowledge Embedding	Functionality	
				Learning	Reasoning
Neuro _{SYMBOLIC}	LTN [131]–[133]	First-order Logic	Sub-Symbolic Rep.	✓	
	Logistic Circuits [134]	First-order Logic	Sub-Symbolic Rep.	✓	
	LRI [135]	First-order Logic	Sub-Symbolic Rep.	✓	
	HDNNLR [136]	First-order Logic	Sub-Symbolic Rep.	✓	
	LFS [137]	Propositional Logic	Sub-Symbolic Rep.	✓	
	Semantic Loss [138], [139]	Propositional Logic	Sub-Symbolic Rep.	✓	
	DANN [140]	Propositional Logic	Sub-Symbolic Rep.	✓	
	DFL [141]	First-order Logic	Sub-Symbolic Rep.	✓	
	LFIE [142]	First-order Logic	Sub-Symbolic Rep.	✓	
	ANNFL [143]	First-order Logic	Sub-Symbolic Rep.	✓	
	SBR [144]	First-order Logic	Sub-Symbolic Rep.	✓	
	LYRICS [145]	First-order Logic	Sub-Symbolic Rep.	✓	
	DL2 [146]	First-order Logic	Sub-Symbolic Rep.	✓	
	HSS [21]	Knowledge Graph	Sub-Symbolic Rep., Neural Inference	✓	
	HMC [147]	Knowledge Graph	Sub-Symbolic Rep.	✓	
	MBM [148]	Knowledge Graph	Sub-Symbolic Rep.	✓	
Neuro[Symbolic]	NLM [149]	Propositional Logic	Network Architecture	✓	✓
	SATNet [150]	-	Network Architecture	✓	✓
	GVR [151]	-	Network Architecture	✓	✓
	LogicSeg [152]	First-order Logic	Sub-Symbolic Rep., Neural Inference	✓	✓

4.3 Knowledge Representation

- 記号学習と深層学習を統合することが可能な主な方法
- 記号知識(Symbolic Knowledge)：ニューラルネットと統合され得るシンボリック表現
記号操作／論理微積分を行うことができる手段が必要
- 記号知識がどのように表現されるか？
 - 知識グラフ : Knowledge Graph
 - 命題論理 : Propositional Logic
 - 一階論理 : First-Order Logic
 - プログラミング言語 : Programming Language
 - 記号表現 : Symbolic Expression : (1)から(4)以外の知識表現


Fig. 9. NeSyの知識のシンボリック表現(例) → 表現方法が、統合方法を考える上でヒントとなる

Knowledge Graph	Propositional Logic	First-Order Logic	Programming Language	Symbolic Expression
	Proposition A: cat is an animal Proposition B: cat is a living thing $A \wedge B$ $A \vee B$ $\neg A$ $A \Rightarrow B$	cat is an animal $\forall x \text{ Cat}(x) \Rightarrow \text{Animal}(x)$ everybody has a father $\forall x \exists y \text{ Father}(y, x)$	<pre>(machine lookalgo (state lookleft (running [robot move: [:msg angular z: search]])) (state returnleft (running [robot move: [:msg angular z: search negated]])) </pre>	$3+4 \times (1+6) \div 2$ $2x^2 - \sin(3x) + 1$ How many cylinders are small? 1. filter_shape(scene, cylinder) 2. filter_shape(scene, small) 3. count(scene)

1) Knowledge Graph (知識グラフ)

- ・ 定義： ノード(人、場所、物、等)とエッジ(「関係」)からなる有向ラベル付きグラフ。
「関係」に「重み」を付けるグラフと、付けないグラフがあり。
- ・ グラフで言語のSPO (Subject:主語, Predicate:述語, Object目的語)を表現できる。SとOはノード、Pはエッジ。エッジには重み情報を付加できる(重み付きグラフ)
- ・ 画像処理や自然言語処理の分野では、知識グラフにてNeSyシステムを構築する研究多い。^[108, 109, 110, 111, 112, 113, 114, 115, 116, 117, 118, 154, 119, 120, 21, 147, 148, 122]
- ・ ImageNet^[155]、WordNet^[157]
(ノードの関係が構造化/階層化された)が行われる。
- ・ Cityscapes^[156]
- ・ 視覚的構文解析アルゴリズム^[21, 112, 113]
(the part-of (compositional) relations が解釈可能)
- ・ 階層的分類^[147, 125, 148, 124]
(階層的分類と呼ばれる、クラス分類法を機械学習させた)

Knowledge Graph



2) Propositional Logic (命題論理)

- 定義：二つの命題間の論理的関係を論理接続詞によって示した複合命題の表現。
 (「命題」とは、真か偽か宣言文。ブーリアン論理や、ゼロ次論理、ともいう。)

「論理接続詞(または演算子)」には、以下がある。
 接続詞(「 $\wedge$ 」)、 論理和(「 $\vee$ 」)、
 否定(「 $\neg$ 」)、 含意(「 $\Rightarrow$ 」)、 など。

例1： 通常の言語文(IF A THEN B)を命題論理として表現すると、 $A \Rightarrow B$ となる。

例2： ROAD-Rデータセット^[158]にて、「交通信号(TL)では、赤信号と青信号の両方を同時に点灯してはいけない」というルールを表現すると以下となる。

$$\neg \text{RedTL} \vee \neg \text{GreenTL}$$

[注] 多くのNeSyシステムは、記号的知識を命題論理の形式で命題間の論理を表現しようとした^{[36, 35], [138, 137, 111, 140, 139]}。

しかしながら、命題論理の表現力はかなり限定的であり、特に、構造の要素に関する宣言を表現するに難があった。

Propositional Logic

Proposition A:

cat is an animal

Proposition B:

cat is a living thing

$$A \wedge B$$

$$A \vee B$$

$$\neg A$$

$$A \Rightarrow B$$

3) First-Order Logic (FOL、一階論理)

定義：「変数」と「量化子(数量表現に関する記述子)」を追加し、命題論理を拡張した表現

(注) “ $\forall$ ”は、普遍量化子。“ $\exists$ ”は、実存量化子。

- ・ 拡張により、命題論理には無い「抽象概念の存在」に基づく命題を議論できるようになる。(変数の導入は、「或る対象」を指すための代名詞の導入でもある。普通名詞は、特定の状況で、具体的値に置換されうる)

- ・ DNNで一階論理を表現する提案の多くは、一部の一階論理しか扱えない[104, 86, 91, 107, 82, 103, 116, 136]。

(DNNで一階論理の全てを扱えるようにするための提案も多いが、「一階論理の表現能力は無限」なのに対して「DNNの表現空間は有限^[28]」なので、コネクショニスト戦略で全ての一階論理をニューラルネット・モデルに学習させるのには根本的な困難がある。)

- > 知識を一階論理の節(clause)表現に変換し、ニューラルネットを用いたファジィ論理に学習させる。[15, 144, 134, 152]
- > 一階論理のルールを微分可能な演算形式にコンパイルし、学習させる[85, 92]
- > マルコフ論理ネットワーク^[162]に一階論理を学習させて、述語論理の式(ルール)に、重みを付けて、不完全で曖昧な世界をモデル化する。[159, 160, 161, 106]

- ・ 知識表現に論理プログラミング言語(Prolog)を用いることが多い[135, 89, 88]。

First-Order Logic

cat is an animal

$\forall x \text{ Cat}(x) \Rightarrow \text{Animal}(x)$

everybody has a father

$\forall x \exists y \text{ Father}(y, x)$

(参考) コネクショニスト戦略にて一階論理をニューラルネット・モデルに学習させることの根本的な困難に関して

- ・ニューラルネットは、通常、スパースなデータを学習(シンボル間に独立性を想定)し、モデル・パラメータの数は有限なので、表現能力は有限。

しかし、一階論理では、シンボル間の複雑な関係(述語間の依存関係)が表現でき、かつ、変数の設定が容易。命題論理の枠組みを超えて、関数記号や述語を用いて複雑な構造を表現できるので表現空間のサイズは無限

従って、、「論理的な制約をネットワークに組み込む」や「DNNの一般化能力の向上」には、本質的な困難がある。

(つまり、このプロセスで、一階論理の無限の構造を正確に再現することは困難)

- ・モデルの一般化能力の問題
DNNが論理を一般化し、訓練データに存在しない関係を発見する能力には限界がある。

- Artur d'Avila Garcez, et al.(2012); "Neural-Symbolic Learning and Reasoning: A Survey and Interpretation".
- Linas Baltrunas, et al.(2012); "Learning to Reason with Neural Logic Machines".
- David J. McCloskey, et al.(2021); "Symbolic Knowledge Graphs for Neural Network Models: A Survey".
- Artur d'Avila Garcez,et al.(2019); "End-to-End Neural-Symbolic Learning and Reasoning: A Survey"

4) Programming Language (プログラミング言語)

- 「知識をプログラムの形態に変換してメモリに格納し、必要に応じて実行する」
との方式。この方式を採用するNeSyは多い。^[69, 70, 71, 72, 74, 78, 80, 81]

例1：アクション言語(BC)で定式化した「計画」によって領域知識を表現する。^[78, 80, 81]

例2：HOUDINI言語で定義されたパラメータ化されたプログラム・ライブラリを「型」
指向で検索(type-directed search)し、他のタスクで概念を再利用する^[78]。

(注) DatalogやPrologを採用した
NeSyシステムは、一階論理の
グループに分類される。
(知識を一階論理のサブセットで
表現しているとみなせるので)

Programming Language

```
(machine lookalgo
  (state lookleft
    (running [robot move: [:msg|
      angular z: search]))
  (state returnleft
    (running [robot move: [:msg|
      angular z: search negated]))
    .....
```

5) 上記以外の「記号を用いた知識表現」

- 数学表現（記号列を用いた代数式や論理式）^[97]
- 多くの場合、学習と推論が数式と連動して行い、文法的、または、構造的知識に従って構文ツリーに翻訳^[98,99,100]。
- 複雑なプログラムの生成を複数の定義済み演算子に分解して進め、後でそれらを合成^[71, 72, 73]。

（このような合成性が可能となるのがNeSyの特徴）

Symbolic Expression

$$3 + 4 \times (1 + 6) \div 2$$

$$2x^2 - \sin(3x) + 1$$

How many cylinders are small?

1. filter_shape(scene, cylinder)
 2. filter_shape(scene, small)
 3. count(scene)
-

4.4 Knowledge Embedding

P10左下

ニューラルネットのどこに、or どの段階に記号知識が埋め込まれるか？

- Type 1 : Symbolic Neuro Symbolic : アーキテクチャ上は、記号知識を考慮しない。
(記号入出力を持つニューラルネットワーク。現在のDLの標準形態)
- Type 2 : Symbolic[Neuro] :
(記号処理を行うコアと、ニューラルネットを内蔵するサブルーチンからなるシステム)
- Type 3 : Neuro|Symbolic : 知識を利用するために独立した記号処理モデルを装備
(ニューラル処理とシンボリック処理が相互作用し、補完的にタスクを行うシステム)
- Type 4 : Neuro: Symbolic→Neuro
(ニューラルネットワークや訓練枠組みの中に、知識を記号的ルールとして組み込むシステム)
- Type 5 : NeuroSYMBOLIC
(記号的知識をDNNの訓練に使用される損失関数の追加的なソフト制約として用い、DNNの重みを調整するタイプ)
訓練データ、訓練ソフト、ニューラル推論、等からなるニューラル・パイプラインのどこか(or 複数箇所)に、記号知識を埋め込む。
- Type 6 : Neuro[Symbolic]
(ニューラルネット表現の中に記号推論論理を埋め込んだ究極の融合形)

訓練データに、記号論理(に関する知識)を埋め込む

- ・ 専門知識に関する記号表現(下記)を構造化した(ツリーやグラフにて表現し組織化した)記号列に変換し、訓練データとして用いる。



> コンピュータプログラム [94,95]

> 数式 [97,99]

> 分子構造 [94,96]

> 論理式 [111]

【Type-4(再掲)】 ニューラルネットや訓練枠組みの中に、記号的ルールを埋め込む。 但し、この戦略では、複雑な知識を埋め込めない。



4.4.2 Sub-Symbolic Representation: P10右中


知識に特化した訓練目標によって、記号的知識を分散表現に埋め込む

- ・ 記号知識の分散エンコードに適した損失関数を設計すること
そのためには、離散的な記号操作を微分可能にする必要がある^[152]。
- ・ アーキテクチャ変更や入力データの前処理による余分な負荷を必要としない
- ・ 構成的汎化^[70, 71, 72, 101]のような抽象的な記号的知識の符号化は困難
(ニューラルネットが、設定した記号的知識に基づいて出力するとは限らない。)

【Type-5(再掲)】

- ・ 記号的知識を、DNNの訓練に使用される損失関数の追加的なソフト制約として用い、DNNの重みを調整するタイプ^[135, 136, 137, 138, 140, 141, 142, 143, 144, 145, 146, 139]。

NEURAL NETWORK



Output



Loss



SYMBOLIC
KNOWLEDGE




知識の構造を反映するようなネットワーク・アーキテクチャを開発すること

- ・ 知識グラフや構造化された記号式の複雑な関係をGraph Neural Network(GNN)に学習させ、埋め込む [112, 113, 114, 115, 116, 117, 118, 154, 119, 120, 165, 121]。
 - > 視覚的実体間の複合的な関係を、微分可能なネットワーク層/モデルにて符号化し、学習させる [112, 113] 。
- ・ 見通し:ニューラルネットのアーキテクチャ設計にて解が見出せるかどうか？
(多大な工学的努力を要する。この戦略は、Type 3の発想と同じであり、Type 6の構成要素となる可能性はある。)


【Type-3(再掲)】

ニューラル処理とシンボリック処理が相互作用し、補完的にタスクを行うシステム。

SYMBOLIC MODEL



NEURAL NETWORK



4.4.4 Neural Inference :

- Network Feedforward Inference (フィードフォワード部)に記号的知識を埋め込み、知識と一致するように出力を制御する方法(推論ネットワークに記号的知識を埋め込み、推論時の出力が知識と一致するように出力に明示的に制約(強制)する)
- 研究例:
 - > ツリー構造の知識空間から実行可能なパスを解析することで、構文的にも意味的にも正しい分子構造の予測を生成する^[94, 95, 99]。
 - > 論理的制約を反復プロセスにパッケージ化し、論理的推論をネットワークのフィードフォワード予測に結合するように、いくつかの行列乗算の形でDNNに注入する^[152]。
 - > 推論時に階層的マルチラベル分類で階層違反が起こらないようにする^[124, 125]。
 - > 厳密な確率的推論と論理的推論を組み合わせ、構造化出力予測のための推論中に、予測が常に制約と一致することを保証する^[126]。
 - > 命題論理の要件とデータポイントに関する利用可能な知識が与えられ、要件への準拠を保証する複数の推論ルールを適用する^[127]。
 - > 複雑な語彙要件を満たしながら明瞭なテキストを生成するために、ニューラル言語モデルに力を与える論理制約を使用した効果的なアルゴリズム^[166, 167]

4.5 Functionality

- いずれのNeSy提案も、学習能力、もしくは、推論能力のいずれかに長けているかが、両方を兼ね備えているとは言い難い。
- 各タイプの長所と短所をよりよく理解するために、各タイプの「コア機能」を検証する。
(各タイプは、システムが統計的学習と記号的推論のどちらに重視しているのか?)

4.5.1 Learning

:

4.5.2 Reasoning

:

4.5.3 Reasoning and Learning

:

} 次頁の表にまとめる

各タイプの「コア機能」の検証

			Learning	Reasoning	Reasoning & Learning
Type-1 : Symbolic Neuro Symbolic	現在のDLの標準形	アーキテクチャ上は、記号知識を考慮しない。			
Type-2 : Symbolic [Neuro]	記号処理を行うコア + ニューラルネット内蔵のサブルーチン	知識を利用するために独立した記号処理用のモジュールを装備			
Type-3 : Neuro Symbolic	ニューラル処理とシンボリック処理が相互作用				
Type-4 : Neuro: Symbolic → Neuro	ネットワークや訓練枠組みの中に、記号的ルール(知識)を埋め込む				
Type-5 : Neuro SYMBOLIC	知識を表現するソフト制約でDNNの重みを調整する	記号知識を、ニューラルネットに埋め込む。			
Type-6 : Neuro [Symbolic]	ニューラルネットの中に記号推論論理を埋め込み				

ここを議論

	Learning	Reasoning	Reasoning & Learning
Type-1 : (DLの標準形) Symbolic Neuro Symbolic			
Type-2 : Symbolic [Neuro] (記号処理コア + ニューラル ネット・サブルーチン)		比較的強力な推論能力 (シンボルの操作に主眼 [63, 64])	
Type-3 : Neuro Symbolic (ニューラル処理とシンボリック 処理が相互作用)	ニューラル・シンボリック RL [79, 75, 76, 80, 81]	比較的強力な推論能力 (シンボルの操作に主眼 [86, 87, 89, 88, 91]) スケーラビリティに制限 あり	
Type-4 : Neuro: Symbolic → Neuro (訓練枠組みに、記号的ルールを 埋め込む)	強力な学習能力 [98, 99, 100, 112, 113, 114, 115, 116, 117, 118] ニューラル・シンボリック RL [79, 75, 76, 80, 81] 視覚的推論アルゴリズム [101, 102, 19, 108, 109, 110]	比較的苦手 説明可能性も弱い (記号的知識はDNNの 重みに暗黙的にエンコー ドされるだけ)	
Type-5 : Neuro SYMBOLIC (ソフト制約でDNNの重みに知 識を反映)	強力な学習能力 [15, 134, 135, 136, 144, 137, 138, 145, 146, 21] インフォームド・マシン・ラーニングの論理推論能力 に可能性あり[217, 218]	比較的苦手	
Type-6 : Neuro [Symbolic] (ニューラルネット中に記号推論 論理を埋め込み)			Type-6と見なせる研究少 ない[151, 149, 150]

- a) Scientific Discovery
- b) Programming Systems (Program synthesis)
- c) Question-Answering
- d) Vision-Language Analysis and Reasoning
- e) Robotics and Control
- f) Visual Scene Understanding
- g) Mathematical Reasoning
- h) Argumentation

5a) Scientific Discovery

- ・ 特徴 (NeSyにとって非常に良いテストベッド)
 - データから科学的仮説や概念を発見する。
 - 既存の制約や領域固有の知識を尊重する。
 - どのように解を導き出したかを適切に解釈・説明し、その洞察を人間に伝える^[219]
- ・ 最近の報告
 - 機械系の実験データから記号モデルを抽出した^[169]
 - 天文学の実験データから記号モデルを抽出した^[119]
(宇宙論的暗黒物質のデータを学習したGNNモデルに、記号回帰技術を適用し、明示的な物理的関係を表現する解析式を発見した)
 - タンパク質の構造予測^[171] (タンパク質の3次元グラフ構造を解明)
 - 実験動物の行動を解析^[170, 174]
(動物の行動を連続的に分類、動物の行動を解釈可能な方法でクラスタリング、等)
 - 有機化学における逆合成や反応予測^[168, 172, 173]。
 - 逆合成ルートを、モンテカルロTree探索とExpansion Policy Networkを組み合わせて発見^[175]
 - 分子合成中に構文とセマンティクスのチェック^[94]
 - 化学反応の技術的/戦略的実現可能性を考慮して、反応テンプレートにあるルールを適用するべきタイミングを示す「条件付きグラフ論理ネットワーク」を考案^[176]

5b) Programming Systems (Program synthesis)

- ・ 特徴 (NeSyツールが、純粋なDLシステムよりも優位と思われる分野)
 - 高レベルのタスク仕様(A Hard Logical Constraints)からプログラムを自動生成する。
- ・ 最近の報告
 - 大規模データを用いて、ニューラルネットに「プログラミング言語の形式的な論理制約や論理展開」を学習させる^[177, 178, 180, 179]。
 - APIコール、型、キーワードなどの「プログラム用のトークン」を幾つか与えると、Javaソースコードを2ステップで生成する^[177]。
^[177] V. Murali, et al. (2018); "Neural sketch learning for conditional program generation".
 - DNNと確率的探索の組合せを利用して図面を記号的仕様に解析し、これらの仕様を汎用のプログラム合成エンジンに供給して、構造化されたグラフィックス・プログラムを生成する^[180]。
^[180] K. Ellis, et al.(2018); "Learning to infer graphics programs from hand-drawn images".
 - 確率的文脈自由文法と静的プログラム解析によって計算された意味属性を組み合わせたニューロシンボリック属性文法の概念を導入。ニューラルネットワークは、生成動作をこれらの属性に条件付けるように学習し、有用な意味の手がかりと長距離依存関係を提供する^[179]。
^[179] R. Mukherjee, et al.(2021); "Neural program generation modulo static analysis".

- 課題 : 複数の主題、複合関係、数値演算を含む複雑な質問に答えること
- 提案
 - a) 意味解析に基づく手法(意味解析パラダイム) [73, 184, 185, 186]
意味解析と構文解析を行うことで、質問を記号論理形式に変換することを学習し、解析された論理形式を知識ソースに対して実行することで、答えを導き出す。
 - b) 知識のニューラル表現を学習して記憶し、質問で伝達された情報を考慮して答えを検索する。(Knowledge embedding-based methods [182, 181, 183])
- 知識埋め込みパラダイム
 - > 知識埋め込みを構造化する利点は明確だが、これら提案はいずれも、論理形式と構文解析アルゴリズムの設計に大きく依存するのが難点。
 - > 追跡可能な推論を欠いている。

- ・ 視覚と言語モダリティの両方を包括的に理解し、推論する必要がある視覚言語分析、及び、推論タスクへの適用
(モジュールは、物体の認識、色の分類など、特定のAtomic Reasoning Stepに対応して選ばれ、近年の多くののはニューラル・アテンション機構を備える)
 - > 応用例1 : Visual Question-Answering, VQA [108, 109, 18, 188]
視覚的な内容に基づいて質問に答えるタスク (質問と視覚シーンを構造化された表現に変換し、Cross-Modality Reasoning を行う。)
 - > 応用例2 : 視覚的グラウンディング[220]
[220] J. Hsu, et al.(2023); "Ns3d: Neuro-symbolic grounding of 3d objects and relations."
ビジュアル・グラウンディング (Large Language-to-Code Modelsとモジューラー・ニューラル・ネットワークを組み合わせで、自然言語を3D視覚推論のためのプログラムに変換)
- ・ 提案
 - > 質問文章をニューラルモジュールで構成されたプログラムに変換し、そのプログラムを画像に適用し、応答を得るとしたVQAシステムに関する先駆的研究 [17]
[17] J. Andreas, et al. (2016); "Neural module networks".
 - > 後続の研究 [189, 190, 101, 187, 191, 192, 69, 110, 19]

- ロボット分野のNeSyベースの自律システムの特徴 [79, 196, 193, 195, 194]
 - > 合理的な機械的制約の中で動作することを保証する適切なポリシーを設計すること
 - > 安全性とデータ効率
 - > 意思決定には、高レベル(すなわち、何を行うか)と低レベル(すなわち、どのように行うか)の2種類ある。
 - > タスク実行と学習のための低レベルRLをガイドするために、高レベルのシンボリックプランニングが生成される必要がある。
- アーキテクチャ
 - > Hierarchical RL [221, 222] (タスクの構造に基づいて、学習方針を策定)
 - オペレータとサンプラーを組み合わせるパラメータ化されたポリシーを学習し、それをモジュール化されたニューロシンボリックスキルにパッケージ化し、新しいタスクで容易に再利用する[194]。
 - GNNを活用して、操作シーンの2階層抽象化として幾何学的シーングラフと記号的シーングラフを組み合わせ、高レベルのタスク計画と低レベルのモーションを予測する [195] 。
 - > 自律走行意思決定モジュール設計のためのプログラム探索手法[193]
(すべての動作を規定可能な微分可能なニューロシンボリックプログラムを合成)

(interpreting high-level semantics from visual perception)

- ・ 視覚認識から高レベルの意味解釈 (オブジェクトの構造化)^[15, 21, 112, 111, 113, 148, 152]
- ・ 提案
 - > オブジェクト間の“part-of relations between objects”を一階論理の形式で形式化し、エンドツーエンドのオブジェクト分類学習のための微分可能な学習目標(群)に変換する^[15]。
 - > 意味概念とその複雑な「部分-全体(meronymy)関係」を、ツリー/有向非周期グラフに整理し、そこから階層的意味セグメンテーションのためのboosting network trainingのための制約条件を導出する^[21]。
(注) meronym(部分語)、holonym(全体語)
 - > 視覚的關係に関する記号的知識を命題形式に変換し、GNNを介して多様体に埋め込む^[111]。
 - > NeSyに基づく視覚的意味解析器(LogicSegと呼ぶ)により、記号概念間の複雑なmeronymyとexclusion関係を一階述語論理に形式化した後、ファジィ論理により連続値(soft constraints)に変換(連続緩和)し、連続化した論理式をニューラルグラフ上に位置付け、ネットワークのフィードフォワード推論を行う。^[152]。
- ・ 最近では、複雑な視覚タスクを解決するために、「LLMを利用して自動的に計画を作成し、外部ツール(市販の特殊モデルなど)を体系的に呼び出して計画を実行し、解を得る」との方向での発表も増えている。(LLMベースのAIエージェント^[65, 66, 67])

・言語的推論、視覚的推論、常識的推論、論理的推論、数値的推論、記号的推論[229]

- ・ 数学的問題を理解し解決するためには、「(統計的な)経験に基づく確率的論理」ではなく、「法則/公理/記号操作規則が持つ記号論理」を学習し、その論理を(疑い)、適用し、推論する必要がある [230]。
- ・ 構造化を探索し論理的推論を多用する数学的問題(The structured and reasoning-heavy nature of mathematical problems)には、NeSyベースのソルバーが必要[205]。
- ・ 数学的な問題解決のために、は、数学的な式の抽象的な構文ツリーを明示的に探索するためのツリー構造化デコーダが必要[197, 198]。(後続研究[199, 202, 201, 203])
- ・ 定理証明に関して、数式の構文ツリーをグラフとみなし、高階証明探索にメッセージパッシングを適用[200]。
- ・ 手書きの数式評価のために、記号解の「状態」をボルツマン分布としてモデル化して推論[205]。(ネットワーク学習と記号推論との間の相互作用、高価な状態探索を回避)
- ・ DNNによって支援されるモンテカルロ木探索計画法を利用[204]。

5h) Argumentation

- ・ 議論は人間特有の認知能力。多様な精神的態度を管理し、不完全または矛盾した情報に特徴付けられる状況を乗り越えるために必要な機能^[206]。
- ・ 議論とその関係性を有向グラフとして表現する議論枠組みは、「論理的矛盾を持つルールが有る時の対応」や、「例外への対処」にて不可欠な能力^[207]。
(非単調な推論(non-monotonic reasoning)を生成する能力^[231, 232])
- ・ 議論ネットワークをニューラルネットワークに変換^[208]
- ・ 議論フレームワークとニューラルネットワーク間の対応関係を探索^[209]
- ・ ネットワークを用いて議論フレームワークを抽出し、そのフレームワークを用いて記号的推論および議論的推論を行う^[210]
- ・ 議論ボルツマンマシン^[212]
(議論の枠組みに基づく推論、帰納的バイアスをニューラルネットワークに統合)
- ・ ニューラルネットワークにおける反事実的説明^[234, 235]
- ・ 議論の枠組みと意思決定のための分散推論を組み合わせたマルチエージェント議論システム^[213, 214, 215, 216]

表5 : NeSy開発で使われているPyPIパッケージ : The Python Package Index

Package Name	Key Feature	Dependency	Quick Installation	Project Link
LTN	Differentiable first-order logic	PyTorch	pip install LTNtorch	https://pypi.org/project/LTNtorch/
		TensorFlow	pip install ltn	https://pypi.org/project/ltn/
Pylon	Programmatic constraint specification	PyTorch	pip install pylon-lib	https://pypi.org/project/pylon-lib/
PiShield	Background knowledge injection	PyTorch	pip install pishield	https://pypi.org/project/pishield/
DeepProbLog	Probabilistic Logic Programming	PyTorch	pip install deepproblog	https://pypi.org/project/deepproblog/
KENN2	Universally quantified FOL clauses	TensorFlow	pip install KENN2	https://pypi.org/project/KENN2/
PyNeuraLogic	Differentiable logic programming	Java Backend	pip install neuralogic	https://pypi.org/project/neuralogic/
torch-explain	Explainable deep learning models	PyTorch	pip install torch-explain	https://pypi.org/project/torch-explain/

6. Performance Comparison (各種NeSyシステム提案の性能比較)

P14左下

- 第 5 章のレビューにあったタスク(3種)について、各種NeSyの性能を比較し表にする。

> NeSy は様々な応用タスクは非常に広範囲にわたっており、アルゴリズムがカスタマイズされることが多いので、全てを公平に比較することは困難なので、特定のタスクにて評価する。
(性能スコアは、原著論文に載る値、もしくは、当論文の筆者が独自に実装し評価した値)

6.1 Retrosynthesis Prediction : 表6
(USPTO-50K テスト^[223] ; 有機合成の核となる生成物から、反応物を予測)

6.2 : Visual Semantic Parsing : 表7
(PASCAL-Person-Part^[238] : 定量的視覚的意味解析)

6.3 Math23K^[246]での定量的 MWP 解答結果 : 表8

NeSyは、様々なタスクの性能向上に貢献してきた。例えば、

- ・ 半教師付きおよび弱教師付きシナリオ^[236, 237]におけるサンプルの生成と精緻化、
- ・ 推論を多用するタスクの構造化予測の強化^[198, 173]、
- ・ 意味解析^[152]のためのネットワークにおけるハード制約の強制

しかし、NeSyへの構成的汎化のアルゴリズムの実装の試みは、未だToy段階。

以下の研究が必要だろう。

- ① 専門的知識は、どのように獲得(構築)されるものなのか？
- ② 知識の完全性と妥当性をどのように保証するか？(既存の知識を疑う能力)

6.1 各種NeSy間の性能比較(1) : Visual Semantic Parsing P14左下 (有機合成の核となる生成物から、反応物を予測)

- **Dataset** : 逆合成予測データセットUSPTO-50K [223]
(反応物と生成物の間の原子マッピングを持つ約50Kの反応からなる。)
- **Benchmarking Algorithms** :
ニューラル手法5種(Seq2seq [224], GTA [225], RetroPrime [226], Dual-TF [227], GraphRetro [228])
及び、逆合成アルゴリズム4種(NSR [168], GLN [176], MEGAN [172], Graph2Edits [173])
- **Evaluation Metric** : Top-k完全一致精度を評価指標として使用。
k値は{1, 3, 5, 10, 20, 50}の範囲で振る。

表6 : USPTO-50K テスト[223] における定量的逆合成予測結果 (1位が赤、2位は緑、3位は青)
Graph2Edits [173]は、従来のどのニューラル・モデルよりも明らかに優れている。

Method		NeSy	k = 1	3	5	10	20	50
Seq2seq [224]	[Chem Eur J17]		37.4	52.4	57.0	61.7	65.9	70.7
GTA [225]	[AAAI21]		51.1	67.6	74.8	81.6	-	-
RetroPrime [226]	[Chem Eng J21]		51.4	70.8	74.0	76.1	-	-
Dual-TF [227]	[NeurIPS21]		53.3	69.7	73.0	75.0	-	-
GraphRetro [228]	[NeurIPS21]		53.7	68.3	72.2	75.5	-	-
NSR [168]	[Chem Eur J17]	✓	44.4	65.3	72.4	78.9	82.2	83.1
MEGAN [172]	[JCIM21]	✓	48.1	70.7	78.4	86.1	90.3	93.2
GLN [176]	[NeurIPS19]	✓	52.5	69.0	75.6	83.7	89.0	92.4
Graph2Edits [173]	[Nat Commun23]	✓	55.1	77.3	83.4	89.4	-	92.7

- Dataset : PASCAL-Person-Part [238]
(1,716/1,817画像 for train/test. 3階層(全身、上半身/下半身、20個の細かな人体パーツ)
- Benchmarking Algorithms :
階層を持たない7種のセグメンテーションアルゴリズム (DeepLabV3+ [239]、PCNet [240]、CrossSeg[241]、ProtoSeg [242]、Mask2Former [243]、GMMSeg [244]、ClustSeg [245]、及び、4 種の NeSy ベースの構造化ビジュアルパーサー ; CNIF [112]、HHP [113]、HSSN [21]、LogicSeg [152])
- Evaluation Metric : 各階層レベルの「平均交差-結合(mIoU)」の平均スコア
(公平性を保つため、比較したモデルはすべてSwin-Sをバックボーンとして使用している。)

表7 : LogicSeg[152]は、ClustSeg[245](ニューラル・ソリューションのトップ)の性能を凌駕する。

Method		NeSy	Head	Tors o	U- Arm	L- Arm	U- Leg	L- Leg	U- Body	L- Body	F- Body	B.G.	mIo U3↑	mIo U2↑	mIo U1↑
DeepLabV3+ [239]	[ECCV18]		87.02	72.02	60.37	57.36	53.54	48.52	90.07	65.88	93.02	96.07	94.55	84.01	67.84
PCNet [240]	[CVPR20]		90.04	76.89	69.11	68.40	60.78	60.14	94.02	68.71	96.50	96.78	96.64	86.47	74.59
CrossSeg [241]	[ICCV21]		90.05	75.62	68.58	66.25	58.21	57.94	92.67	67.54	96.11	96.17	96.14	85.46	73.26
ProtoSeg [242]	[CVPR22]		90.09	77.20	69.16	68.44	60.89	60.13	93.64	68.71	96.44	96.82	96.63	86.39	74.68
Mask2Former [243]	[CVPR22]		90.21	78.26	70.14	69.51	60.73	60.31	94.52	69.23	96.80	97.04	96.92	86.93	75.17
GMMSeg [244]	[NeurIPS22]		90.15	79.10	70.99	69.43	61.32	60.42	93.37	70.52	97.10	97.02	97.06	87.17	75.49
ClustSeg [245]	[ICML23]		90.20	78.94	71.23	69.69	61.87	61.39	94.52	70.81	97.20	97.23	97.26	87.52	75.79
CNIF [112]	[ICCV19]	✓	88.02	72.91	64.31	63.52	55.61	54.96	91.82	66.56	94.33	96.02	95.18	84.80	70.76
HHP [113]	[CVPR20]	✓	89.73	75.22	66.87	66.21	58.69	58.17	93.44	68.02	96.77	96.94	96.86	86.13	73.12
HSSN [21]	[CVPR22]	✓	90.19	78.72	70.67	69.71	61.15	60.44	95.86	71.56	98.20	97.18	97.69	88.20	75.44
LogicSeg [152]	[ICCV23]	✓	90.23	79.56	71.44	70.52	62.26	61.46	95.97	72.51	98.43	97.35	97.89	88.61	76.12

6.3 各種NeSy間の性能比較(3) : Math Word Problem Solving P15左

(数値的な答えを計算し、文脈で提示された数量を論理的に推論する)

- Dataset : Math23K [246]
(小学生を対象とした合計23,161の実数字の単語問題。問題の説明、構造化された方程式、解答からなる。)
- Benchmarking Algorithms :
4 種のニューラルネットワーク : DNS [246]、Math-EN [247]、T-RNN [248]、GROUP-ATT [249]
6種のNeSy ベース : TSD[197]、GTS[198]、Graph2Tree[199]、NSS[202]、HMS[201]、BERT-Tree[203]
- Evaluation Metric : Answer Accuracy (MWP解法における標準的な評価指標)

表8 : Math23K [246]での定量的 MWP 解答結果 (* は 5 回のクロスバリデーション)
NeSyベースのソルバーが、4つの競合ニューラルよりも優れている。

Method		NeSy	Accuracy (%) ↑	Accuracy* (%) ↑
DNS [246]	[EMNLP17]		-	58.1
Math-EN [247]	[EMNLP18]		66.7	-
T-RNN [248]	[AAAI19]		66.9	-
GROUP-ATT [249]	[ACL19]		69.5	66.9
TSD [197]	[EMNLP19]	✓	69.0	-
GTS [198]	[IJCAI19]	✓	75.6	74.3
Graph2Tree [199]	[ACL20]	✓	77.4	75.5
NSS [202]	[ACL21]	✓	-	75.7
HMS [201]	[AAAI21]	✓	76.1	-
BERT-Tree [203]	[ACL22]	✓	82.4	-

7. Open Challenges (未解決な課題)

- 1) 大規模な記号／論理推論への対応能力の面での課題 (Scalability)
 (現実世界の複雑性に対応するには、スケーラビリティの向上が必要^[254, 255, 256])
 - ・「大規模な記号/論理ルール」や「複雑な構文」にて、健全なシンボル推論、分布外の汎化、データ効率の良い学習、透明性、新しいドメインへの移行が可能なのかは明らかでない^[250, 251, 252]。
 - 〔
 - ・ 記号的知識を頻繁に使用する大規模なアプリケーションにおける困難^[191, 253]。
 - ・ 特定のドメインでの大規模な記号的知識の収集は、しばしば困難。
 〕
- 2) 構成的汎化 (Compositional Generalization)
 - ・ NeSyへの構成的汎化のアルゴリズムの実装の試みは、未だToy段階^[63, 257]。
 - ・ 様々な形式の論理(様相的 / 時間的 / コモンセンス / 認識論的)と様々なタイプの知識(宣言的 / 手続き的 / 因果的 / 関係的)にて包括的な汎化を尽くして問題を解決するには未だ程遠い。構成性の原理^[258, 259, 209]、コモンセンス推論^[207]
- 3) 知識獲得の自動化 (Automated Knowledge Acquisition)
 - ・ NeSyシステムを実世界に実装するには、知識の獲得がボトルネックになっている。
 - ・ 以下のような課題を無視して、「十分な知識が存在する」と仮定してしまっている。
 - ① 専門的知識は、どのように獲得(構築)されるものなのか？
 - ② 知識の完全性と妥当性をどのように保証するか？(既存の知識を疑う必要がある)
 - ・ 知識獲得の自動化には、人間の内省的能力をモデル化する必要がある^[260, 261]。
 (しかし、その取り組みは、未だ、概念的知識グラフの構築の段階に留まっている)

7. Open Challenges (筆者らが考える必要な研究) ^{P14右}

- ・「知識獲得の自動化」、「記号的推論」、「サブ記号的学習」の統合に関する根本的問題
：「AIが、古い知識や情報に疑問を抱き、新知識を生成する」よう設計するには、以下を明確化する必要がある。
 - ① NeSyシステムの構築に適した知識表現（の形式）
 - ② データから知識を抽象化し抽出する方法
 - ③ 演繹的推論と帰納的学習の間の相互フィードバックを構築する方法
(データに基づいて知識を生成(抽出)し、実行結果に応じて知識を更新する。)

そのためには、以下の4)から6)の研究必要：

- 4) 脳内のサブシンボリックな神経活動が、どのようにして言語や論理的推論のようなシンボリックな行動を生むのか？： Type-6のRecursive Neuro[Symbolic]
 - > “Sub-SymbolicなNeural-Engine”と”Symbolic Reasoning Engine”の相互作用 (“Symbolic Engine”の知識が“Sub-SymbolicなNeuralNet”を訓練し、訓練後の“Sub-SymbolicなNeuralNet”の活動にて、知識を再帰的に進化させる)
 - > この相互作用は、KahnemanのSystem-1(直感)とSystem-2(論理的思考)に類似する。

7 (続)

5) NeSyに人間のメタ認知スキルを習得させ、根本的な進歩に挑戦すること (より挑戦的な「試行錯誤」が必要: Testbed for Metacognitive Skills of NeSy)

- > NeSyのメタ認知能力の日常的シーンへの実装 (生産性、系統性、構成性、推論的一貫性^[8]、因果的思考と反事仮想^[263]、演繹的推論^[264]、解釈可能性^[54, 6]など)
- > 有望な領域でのベンチマーク (社会ロボット工学、健康情報学、ハードウェア／ソフトウェア仕様、ゲノム学、化学、天文学の科学的問題への対応や仮説発見に関して)

6) 大きなAIモデルを使ってNeSyを開発すること : NeSy in the Big Model Era

- > 現在の大規模AIモデルは、様々な欠点を抱えている。
 - : データや計算リソースへの巨大化要求、不透明性、幻覚、無意味(不誠実)なコンテンツを生成する傾向、固有のバイアス、実世界の理解不足、異分野での推論への一般化能力の弱さ、など。
- > これらの弱点は、コネクショニスト・モデルの本質的な限界であり、高度化 / 大規模化により更に悪化している
- > 外部ツールを自動的に構成できるLLMベースのAIEージェント^[265]は、ニューラル・シンボリック統合の方向が重要であることを示唆している(と解釈できる)

8. Conclusions

以下の5つの観点から、NySy研究開発を調査

2章：NeSy研究の歴史

3章：NeSy研究を促進する最近のAI議論

4章：NeSyシステム実現に向けての現在のアプローチの分類 / 分析
①神経と記号の統合、②知識表現、③知識の埋め込み、④機能性

5章：NeSyシステムの主要な応用分野
科学的発見、プログラミングシステム、質問応答、視覚言語分析と推論、
ロボット工学と制御、視覚的情景理解、数学的推論、等

6章：現在の各種NeSyシステムの性能ベンチマーク
①逆合成予測、②視覚的意味解析、③数学の問題解決

7章：未解決の課題と今後の研究分野
強力なNeSyシステムの実現にはまだ程遠い。
NeSyが次世代AIの開発にとって有望な方向性である。

以上

IEEE Computer SocietyのHPに載るNeSyの関連文献

<https://www.computer.org/csdl/journal/tp/2025/02/10721277/2179549p9QY>

Knowledge Inference and Knowledge Completion Methods using Neuro-Symbolic Inductive Rules

2021 International Conference on Computational Science and Computational Intelligence (CSCI)

Knowledge-Infused Learning: A Sweet Spot in Neuro-Symbolic AI

IEEE Internet Computing

Neurosymbolic Reinforcement Learning and Planning: A Survey

IEEE Transactions on Artificial Intelligence

Hybrid Crowd-AI Learning for Human-Interpretable Symbolic Rules in Image Classification

2023 14th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)

Towards Neuro-Symbolic AI for Assured and Trustworthy Human-Autonomy Teaming

2023 5th IEEE International Conference on Trust, Privacy and Security in Intelligent Systems and Applications (TPS-ISA)

A Survey on Symbolic Knowledge Distillation of Large Language Models

IEEE Transactions on Artificial Intelligence

Towards Cognitive AI Systems: Workload and Characterization of Neuro-Symbolic AI

2024 IEEE International Symposium on Performance Analysis of Systems and Software (ISPASS)

Neuro-Symbolic AI for Military Applications

IEEE Transactions on Artificial Intelligence

Exploring Aspects Regarding Reasoning in Neuro-Symbolic Rules and Connectionist Expert Systems

2021 12th International Conference on Information, Intelligence, Systems & Applications (IISA)

Neat Versus Scruffy. How Early AI Researchers Classified Epistemic Cultures of Knowledge Representation


IEEE Annals of the History of Computing

(参考) [17] J. Andreas, et al. (2016); "Neural module networks".

- 入力されたテキスト(質問)や画像の構成を解析し、応答するニューラルモジュールのネットワーク^[17]
(質問文章をニューラルモジュールで構成されたプログラムに変換し、そのプログラムを画像に適用し、応答文章を得る。モジュールは通常、ニューラル・アテンション機構を持ち、物体の認識/色の分類など、Atomic Reasoningを行う。)
- 提案するアーキテクチャ : 複数のニューラルモジュールのネットワーク
 - > モジュール : 特定の種類の計算や推論を担当
(入力された質問に基づいて、推論パス(Inference Path)が決められ、使用モジュールが選ばれる)
 - > トレーニング : 各モジュールが独立して学習
- 特徴
 - > モジュールごとに役割が明確であるため、結果を解釈する際にも有利
- 性能評価
 - > 従来のアーキテクチャと比較し、視覚的質問応答タスクにおいて優れた性能
 - > 複雑な推論や構造化された質問に対して、NMNは高い精度を発揮
 - > 視覚的質問応答タスクにおいて大きな進歩を遂げた

(参考) [73] C. Liang, et al.(2017); "Neural symbolic machines: Learning semantic parsers on freebase with weak supervision".

- ・ 課題 : セマンティックパッシング (Semantic Parsing、自然言語の文をその意味を表す形式的な表現、主に 論理的な形式(論理式)に変換すること) を正しく生成するのは、ニューラルネットワークによっても、また、論理形式による変換でも困難。
- ・ 提案 : 言語合成性と複雑な意味論をサポートするために、「シンボリック推論」を「ニューラル言語理解」と組み合わせた斬新な枠組み(MPC (Manager-Programmer-Computer)フレームワーク)を提案 : 強化学習と組合せ、アノテーション(ラベル付与)なしで大規模KBを扱える可能性ある。
 - > 言語発話(入力列)をニューラルseq2seqモデルによって論理プログラム(空間)にマッピング(中間実行結果を保存して再利用するためのキー変数メモリを利用)(特徴工学や手動ルールに依存せずにセマンティック・パーサーを構築)
 - > シンボリックLispインタプリタによって、知識ソース上でプログラム実行(探索空間をプルーニングすることによって良いプログラムを見つける)(論理プログラムを知識ベース上で実行して答えを導出する)
 - > 弱い教師信号(質問と答えのみ)から学ぶ



(参考) [75] M. Garnelo, et al.(2016);

"Towards deep symbolic reinforcement learning".

- ニューラル・バックエンド


畳み込みオートエンコーダで画面(例:ゲーム画面)の画素入力を圧縮・特徴抽出。
特徴ごとのスパース活性に基づくクラスタリングで「オブジェクト」候補を自動認識。

- シンボリック・フロントエンド

物体の種類(t)、位置(x,y)、対象間距離、関係を「低次元のシンボル(状態)」として、
フレーム間のオブジェクトの継続、生成・消滅なども追跡し、論理的表現を作成。

- シンボリック強化学習

オブジェクト・タイプ間の相互作用ごとに個別のQ-関数を持つ。シンボル状態に対して
モデルベースではなく、独立したテーブル型 Q-learningで行動方策を学習。




- DNNに事前知識としてのシンボリック表現(論理式)を組み込む方法の提案
- ニューラルとシンボリックを融合させる必要性
 - 深層学習(ディープラーニング)は大量データに頼るため、事前知識(制約やルール)を利用しづらい。
 - 論理・ルールベースのシンボリック知識は明示的・解釈可能であるが、ノイズへのロバスト性が低い。
- 提案内容
 - 1) 命題論理の知識(ルールや制約)を、d-DNNF(deterministic decomposable negation normal form)という**計算的**論理形式にコンパイルする。
 - 2) d-DNNF をノード(AND, OR, リテラルなど)とエッジ(論理的構造)からなるグラフ構造に変換する。
 - 3) この論理グラフを「グラフ畳み込みネットワーク(GCN)」を使って、ベクトル表現(埋め込み)に変換する。 ノードタイプの違いや論理構造を反映する工夫を含む。
 - 4) 埋め込みが論理的意味に忠実になるように、semantic regularization(意味的損失)を導入。ニューラルネットワークの訓練中に、論理制約を満たすようにネットワーク出力を促す(Semantic loss による正則化)。

- ・ オープンドメイン知識のシナリオ

(KRISP (Knowledge Reasoning with Implicit and Symbolic rePresentations))

トランスフォーマーモデルの強力な暗黙的推論を回答予測に活用しつつ、知識グラフからの記号的表現を統合し、その明示的意味を暗黙的埋め込みに失わないように制御する。 多様な知識源を組み合わせることで、広範な知識をカバーする。



(参考) [112] W. Wang, et al.(2019);

"Learning compositional neural information fusion for human parsing"

(注) Human Parsingとは、画像内の人物をセグメント化して、各部位(例えば、顔、腕、足など)を識別するタスク (画像処理にて人体の局所的な特徴と全体的な特徴の両者を効率的に統合することが課題)

- ・ 概要

構成的融合(“Compositional Neural Information Fusion, C-NIF“)の提案 : 人体の部位毎の高精度な解析と 部位間の相互作用(関係性)をニューラルネットワークに学習させる。(グラフニューラルネットワークにて、各部位をノードとして表現し、「腕と肩の連携動作」や、「足と腰の位置関係の変化」などを学習)

階層的な特徴学習や、マルチスケールの情報融合、Attention Mechanismを用いた「部位間連携の学習」も提案されていた。

(参考) [152] L Li, et al.(2023);

"Logicseg: Parsing visual semantics with neural logic learning and reasoning".

- ・ 問題認識

DLは、大量データに基づく Sub-Symbolicな（シンボルではなく、連続値・分散表現などに基づく）処理であり、視覚世界に存在する意味階層や構造を無視している。（人間の視覚認識は「階層的な抽象化」を経て「シンボリックな推論」を行うが、DNNではこれらを再現してはいない。）

- ・ 提案手法：LOGICSEG

- 1) 概念階層の定義と論理ルールの導出

概念をツリー構造で整理。その構造に基づき、第一階述語論理(FOL)形式のルールを構成する。（例:「犬→動物」, “ $\forall x. (\text{Dog}(x) \rightarrow \text{Animal}(x))$ ”）。

- 2) ファジィ論理による連続化(Relaxation)

離散的な論理ルールをファジィ論理で連続値(soft constraints)に変換し、ニューラルネットワークで訓練できるようにする。

- 3) トレーニング時のロジック誘導

連続化された論理式をニューラル計算グラフへ侵入させ、通常のセグメンテーション損失に加えた形でロジック誘導損失を導入し、意味的に一貫した予測を促す。

- 4) 推論時の反復的統合

推論フェーズでは、学習済みモデルの出力に対して複数のマトリクス積による制約処理を反復適用し、階層整合性を整える。

"Probabilistic logic neural networks for reasoning".

- ・ 論理的なルールとニューラルネットワークを用いた確率論的推論を統合した「確率論的論理ニューラルネットワーク(Probabilistic Logic Neural Networks; PLNN)」
- ・ PLNNの定義：入力層、論理的推論層、確率的推論層、統合層、出力層からなり、統合層で、論理層から得られた知識と、確率的推論層で得られた推論結果を統合して、ニューラルネットワークの動作に論理的な制約や関係性を制約として課す。(使うルールベースの知識は、Markov Logic Networks(MLN) として表現される。)
 - 確率的推論層(Probabilistic Inference Layer)にて、推論時に、確率分布を出力する。(ノイズや不確実性を含むデータを処理するために、ベイズ推論やマルコフ決定過程(MDP)などの確率的手法を使い、入力データが不完全であったり、確実性が低い場合でも、ロバストに推論を行う。)
 - 統合層(Integration Layer):論理的推論と確率的推論を統合する層。確率論的推論のために特定のネットワーク層を設計し、論理的なルールを適用する方法を提供します。これにより、ニューラルネットワークの学習能力を活かしつつ、論理的な制約やルールを尊重した推論が可能になります。
 - PLNNは、マルコフランダムフィールド(Markov Random Fields, MRF)とその関連技術を活用して、局所的な依存関係(隣接する変数の相互作用)を捉えて推論動作を進める。

(参考) [161] G. Marra, et al.(2020); "Relational neural machines (RNM)".

- ・ 背景理解：

ニューラルネットワークは確率的な出力を予測するが、背後にある論理構造の理解/推論に弱い。一方、First-Order Logic (FOL)ベースの推論器は、知識に基づいた演繹推論ができるが、パターン認識能力やスケーラビリティに弱い。

- ・ 本稿で示す対策アイディア

- > シンボル論理のグラフのエッジ(データ/単語)間の相互関係を、ニューラルネットワーク(RNM)によって動的に学習し、結果をグラフに反映させる。

(RNMによって、「その一階論理」が真である確率(データに基づいた信念、もしくは信頼度)をスコアリングし、結果をグラフのエッジに付与する。)

- > 推論時には、更新したグラフを用いて、新たなデータに対する予測動作を行う。
(例えば、自然言語処理(NLP)のタスクでは、文中の語の関係性(主語と述語の関係、動詞と目的語の関係など)を理解したうえで、文の意味を動的に解釈し、応答動作を行う。)

- > 教師あり学習とFirst-Order Logic(FOL)に基づく推論器のパラメータを共同で訓練する。

- ・ 概要

計画問題に対する従来の「STRIPS(Stanford Research Institute Problem Solver)と呼ばれる古典的な計画アルゴリズム」を現代の機械学習技術を用いて拡張して解決する方法を提案

(注) 計画問題とは、与えられた初期状態から目標状態に至る一連の操作(アクション)の列を求める問題

- ・ 提案内容

- > 従来のシンボリックプランニングと深層学習を組み合わせ、計画問題を効率的に学習・解決するニューラル-シンボリックな手法
- > ニューラル-シンボリックプランニングを改善する上で、Cube-Space Priors (計画の状態空間をCubeとしてモデル化) を想定

(参考) [181] P. Verga, et al.(2021);

"Adaptable and interpretable neural memory over symbolic knowledge".

問題：従来の大規模言語モデルは、訓練過程で知識をパラメータに埋め込むため、新たな知識追加や修正が困難で、また内部の知識が不透明(ブラックボックス)であり、現実の変化への追従も難しい

提案：「Fact Memory)」という解釈可能な神経記号型知識ベースと「ニューラル言語モデル」を統合するアーキテクチャの提案。動的な知識更新と解釈性向上を狙う。

- > Fact Memory (言語モデルが回答を作成するためのコンテキスト化されたリファレンストリプル(主語/関係/目的語)毎にそれぞれのエンティティや関係に対応したベクトルを生成し埋め込みを行い、これを「記号的記憶」として保持し、言語モデルと連携する。
- > 知識と言語モデルの統合 (より解釈しやすい推論プロセス)
通常の文脈エンコーディングと共に、Fact Memoryから関連トリプルを 検索・取得 (retrieval)し、質問応答などに用いる。(モデル自体は既存のトランスフォーマーベース(例えばBERTやT5)で、記憶部分は外部モジュールとして構築)
- > 知識の更新
パラメータを固定したまま、“Fact Memoryの書き換え”(新規追加・上書き)を行う。
埋め込みを差し替えるだけで新たな知識を反映し、訓練し直す必要がない。

効果

- ・モデル本体のパラメータは従来比5%だが、WebQuestionsSP評価が27ポイント精度向上
- ・性能が、論理形式と構文解析アルゴリズムの設計に大きく依存。

提案：神経シンボリックAI (Neuro-Symbolic AI) を用いて、二階層計画のスキルを学習する新しいアプローチ

二階層計画 (bilevel planning)：

- ＞ 複雑で階層的な計画タスクを効率的に解決するための手法
- ＞ 上位計画(メタ計画)と低位計画(実行計画)の2階層

スキル学習： 学習結果を再利用することで、学習効率を高める。

- a) ニューラルネットワークによる抽象化 ～
環境から入力された情報から、ニューラルネットワークが、入力情報が持つ高次の特徴(高次の特徴、or 概念)を抽出(or 学習)する。
- b) 得られた抽象特徴(群)を元に上位のシンボリックな計画(メタ計画)を立案
(タスクが目標指向である場合、シンボリックなルールを用いて「どのようにして目標に到達するか」を論理的に推論する。)
- c) 低位計画(実行計画)の立案
メタ計画で決められた方針に従って、最適な行動を選び、低位計画とする。
(低位計画は、強化学習のアルゴリズムを使用して学習する)
- d) 複雑なタスクの分割と、2階層間の協調:
上位による目標設定と、低位による目標達成のための具体的な行動選択」の協調により、複雑なタスクを分割して効率的に解決する。

- ・ 概要

3D 空間におけるオブジェクトを画像処理的に理解(認知)し、オブジェクト間の関係をシンボリックに定義し処理するNeuro-Symbolic アーキテクチャの提案
(ユールネットワークの強力な特徴抽出能力や柔軟性と、シンボリックな推論による高精度なロジック処理を両立させることを狙った)

- ・ シンボルグラウンディングのためのアーキテクチャ

3D オブジェクトの関係(位置関係、空間的關係など)をシンボリックに表現し、それを視覚(画像処理)情報と関連付けさせてグラウンディング(現実世界との対応付け)

- > 視覚的モジュール(Visual Module)

3D 空間内のオブジェクトを識別するためのニューラルネットワーク。オブジェクトの形状や位置、姿勢などの特徴を抽出し、それをシンボリックな表現に変換する。
(そのために、3D 空間内でのオブジェクト間の関係性を学習させる)

- > シンボリック推論モジュール(Symbolic Reasoning Module)

視覚(画像処理)的に得られた情報を基に、シンボリックな推論を行うモジュール。オブジェクトの位置関係や空間的配置をシンボリックな命題として表現し、基本的な論理演算(AND, OR, NOT)や集合論、空間的な推論を行い、3D 空間内のオブジェクト間の複雑な関係を推定する。