

# Neural DTS：自然言語推論システムへの双曲分類器の組み込み

小林ほのか 大洞日音\* 戸次大介  
お茶の水女子大学

{g2220520,daido.hinari,bekki}@is.ocha.ac.jp

## 概要

従来の依存型意味論 (DTS) に基づく自然言語推論システムでは、推論において必要不可欠な世界知識を手で付与する必要があり、膨大な知識獲得コストが課題であった。本研究ではこの課題を解決するため、概念階層の埋め込みに適した双曲空間を利用する手法である Hyperbolic Entailment Cones を統合した自然言語推論システムを提案・実装した。本手法は、概念間の包含関係を双曲空間上で自動判定し、推論に必要な公理として動的に追加するものである。本手法を用いることで、人手による知識定義のコストを大幅に削減しつつ、「りんごは果物である」といった語彙間の包含関係を考慮した、より広範な言い換えに対応する自然言語推論を実現した。

## 1 はじめに

自然言語の意味を計算的に扱うアプローチには、形式言語学に基づく言語学的手法と、大規模データから知識を獲得するニューラル言語モデルに基づく手法が存在する。前者は、文の構造と意味の対応を厳密に定式化でき、推論の正当性を証明によって保証できるという利点を持つ反面、推論に必要な世界知識を公理として人手で与える必要があり、実用上の制約が大きい。対照的に後者は、柔軟な知識獲得能力を持つ反面、推論過程が不透明であり、論理的整合性や説明可能性の保証が難しいという課題がある。

Neural DTS は、依存型意味論 (Dependent Type Semantics; DTS [1]) に基づく証明可能な意味の理論を中核に据えつつ、外部で獲得される知識を推論に組み込むことで、言語機能と一般認知過程の相互作用を理論的・計算的に明らかにすることを目標とする研究プロジェクトである。その目標に向けて、本論文では、DTS に基づく証明構築の過程で必要とな

る概念間の包含関係に関する世界知識を、双曲分類器を用いて動的に補完する手法を提案・実装する。

具体的には、上位語・下位語関係に代表される概念間の包含関係を Hyperbolic Entailment Cones [2] により表現し、証明探索の過程で当該の包含関係が成立するかを判断する分類器を“oracle”として導入する。外部で学習された埋め込みを利用しつつも、その判定結果を依存型意味論に基づく推論規則として組み込むことで、推論全体を意味論的に解釈可能な枠組みに拡張することを目指す。

## 2 先行研究

### 2.1 自然言語推論パイプライン

言語学的手法による自然言語推論システムの最新の研究の一つとして、図 1 のような、組み合わせ範疇文法 (CCG)[3][4] を用いた統語解析器 lightblue<sup>1)</sup> と、依存型意味論 (DTS) の部分体系を用いた定理証明器 wani [5][6] により構成される自然言語推論システムが提唱されている [7]。

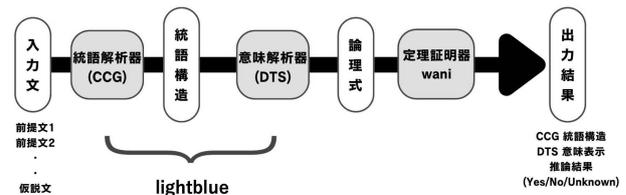


図 1: 自然言語推論パイプライン

入力としていくつかの前提文と仮説文が与えられると、まず lightblue によって CCG を用いた統語解析、DTS を用いた意味解析が行われる。次に、文の意味表示が type という型を持つか確認する型検査が行われた後、wani による証明探索が行われる。wani では、前提文の意味表示を証明の前提とし、仮説文の意味表示を結論とする証明項が存在するかどうかの証明探索が行われる。証明探索の後、証明項が存在する場合には Yes、仮説文の否定の意味表示を導く

\* 本研究は著者が独自に実施したものであり、Amazon の見解や立場を反映するものではない。

1) <https://github.com/DaisukeBekki/lightblue>

ための証明項が存在する場合には No, それ以外の場合 Unknown といった推論結果を得ることができる。

## 2.2 Neural DTS

依存型意味論 (DTS) は, 依存型理論 (Dependent Type Theory; DTT [8]) に基づく形式意味論の枠組みであり, 否定, 条件文, 量化, 照応, 前提などの複雑な言語現象を, 統一的かつ厳密に扱うことができる。DTS における推論は, 型理論における証明図の構築として定式化されるため, 推論結果の正当性が保証される。一方で, 語彙的な包含関係をはじめとする世界知識を公理として記述するコストが, 実用上の課題として指摘されている。

この課題に対し, DTS とニューラル言語モデルを統合する枠組みとして Neural DTS [9][10] が提案された。Bekki et al.[9][10] では, Neural DTS の数学的理論および学習アルゴリズムが提案されている。

さらに, 飯沼ら [11] はこの Neural DTS の実装に取り組み, MLP や NTN [12] を用いた実装がなされた。同研究は Neural DTS の実用可能性を切り拓いた成果である一方で, 分類精度のさらなる向上や学習アルゴリズムの改良という点において, 依然として発展の余地が残されている。

## 3 双曲分類器の構築

本研究では Neural DTS の新たな手法として, 依存型意味論に基づく自然言語推論システムに, Hyperbolic Entailment Cones を用いた双曲分類器を統合する手法を提案する。

### 3.1 双曲空間への埋め込みの利点

語彙的な上位語・下位語関係は階層的な木構造を持つ。このような構造では, 深さが深くなるほどノード数が指数関数的に増加するが, ユークリッド空間の空間領域は半径に対して多項式的にしか増大しない。このため, 低次元のユークリッド空間ではノードを適切に配置できず, 構造的歪みが生じる。対して双曲空間は, 半径に対して空間領域が指数関数的に拡大する性質を持ち, 低次元の空間でも, 階層構造を極めて小さな歪みで埋め込むことが可能である。特に, 本研究で採用する Hyperbolic Entailment Cones は, 概念を円錐として表現することで包含という非対称な関係を幾何学的に定義でき, WordNet [13] を用いた含意判定で高い性能が報告されている [2]。

### 3.2 埋め込みモデルの数学的定義

Hyperbolic Entailment Cones では, ポアンカレ球体  $\mathbb{D}^n$  上で各概念を円錐としてモデル化する。各概念  $u$  の埋め込みベクトル  $\mathbf{u} \in \mathbb{D}^n$  に対し, 上位概念としての広がりとしての抽象度を反映する円錐の半頂角  $\psi(\mathbf{u})$  は, 学習可能な正のパラメータ  $K$  を用いて以下のように定義される。

$$\psi(\mathbf{u}) = \sin^{-1} \left( K \cdot \frac{1 - \|\mathbf{u}\|^2}{\|\mathbf{u}\|} \right) \quad (1)$$

ここで, 概念  $v$  (下位語) が概念  $u$  (上位語) に包含されるための幾何学的条件は, 二つのベクトルのなす測地的角度  $\Xi(\mathbf{u}, \mathbf{v})$  が, 上位語  $u$  の形成する円錐の広がり収まること, すなわち以下の条件を満たすことである。

$$\Xi(\mathbf{u}, \mathbf{v}) \leq \psi(\mathbf{u}) \quad (2)$$

測地的角度  $\Xi(\mathbf{u}, \mathbf{v})$  は以下のように定義される。

$$\begin{aligned} \Xi(\mathbf{u}, \mathbf{v}) &:= \pi - \angle O\mathbf{u}\mathbf{v} \\ &= \cos^{-1} \frac{\langle \mathbf{u}, \mathbf{v} \rangle (1 + \|\mathbf{u}\|^2) - \|\mathbf{u}\|^2 (1 + \|\mathbf{v}\|^2)}{\|\mathbf{u}\| \cdot \|\mathbf{u} - \mathbf{v}\| \sqrt{1 + \|\mathbf{u}\|^2} \sqrt{1 + \|\mathbf{v}\|^2} - 2\langle \mathbf{u}, \mathbf{v} \rangle} \end{aligned} \quad (3)$$

また, エネルギー関数  $E(\mathbf{u}, \mathbf{v})$  を以下のように定義する。

$$E(\mathbf{u}, \mathbf{v}) = \max(0, \Xi(\mathbf{u}, \mathbf{v}) - \psi(\mathbf{u})) \quad (4)$$

モデルの学習においては, 正例集合  $P$  のエネルギーを最小化し, 負例集合  $N$  のエネルギーがマージン  $\gamma$  以上となるように以下の損失関数  $\mathcal{L}$  を最小化する。

$$\mathcal{L} = \sum_{(\mathbf{u}, \mathbf{v}) \in Pos} E(\mathbf{u}, \mathbf{v}) + \sum_{(\mathbf{u}', \mathbf{v}') \in Neg} \max(0, \gamma - E(\mathbf{u}', \mathbf{v}')) \quad (5)$$

この最適化により, 双曲空間上に幾何学的に整合した階層構造が構築される。

### 3.3 学習データの前処理

本研究では先行研究 [2] に倣い, 以下の手順で学習データセットの構築を行う。<sup>2)3)</sup>

1. 関係性の抽出: WordNet [13] の SynsetID に基づき, 名詞間の上位語・下位語関係 (Hypernym-Hyponym) を抽出する。

2) [https://github.com/dalab/hyperbolic\\_cones](https://github.com/dalab/hyperbolic_cones)

3) <https://github.com/facebookresearch/poincare-embeddings>

2. **関係性の分類**: 推移閉包 (Transitive closure) および推移簡約 (Transitive reduction) を計算し、直接の親子関係にあたる「BASIC エッジ」と、それ以外の推移的な「NON-BASIC エッジ」に分類する。
3. **データ分割**: 全データを学習用 (Train), 検証用 (Valid), 評価用 (Eval) に分割する。階層構造の維持に不可欠な BASIC エッジは全ペアを学習データに含め、追加する NON-BASIC エッジの割合を変化させて精度を比較する。
4. **フィルタリング**: 日本語分類器としての性能を測るため、評価用データからは日本語訳が存在しないペアを除外する。ただし、学習用データについては、グラフ構造の連続性を維持するためこのフィルタリングは行わない。

## 4 自然言語推論システムへの統合

次に、構築した分類器を自然言語推論システムへと統合する枠組みを提案する。

### 4.1 動的な公理追加の枠組み

wani は、構築済みの分類器を入力の一部として受け取った場合、後ろ向き推論の一環として双曲分類器 oracle を用いた推論を実施するかを都度判断する。wani における後ろ向き推論は、前提と仮説が与えられたとき、仮説に対して DTT の規則の一部を適用することでサブゴールを生成し探索を進める処理を指す。この過程において生成されたサブゴールの仮説が述語 (DTT 上では定項) に 1 つ以上の項が与えられた形式であるとき、wani は分類器を用いた推論を行う。本節における述語は、与えられた項についての性質を表すものと仮定している。分類器を用いた推論では、まず、前提の中でサブゴールの仮説と同一の項を持ち、述語部分のみが異なるものを探索する。次に、その述語部分を下位語候補、サブゴールの述語部分を上位語候補として分類器に与える。分類器によって算出された確率があらかじめ学習時に定めた閾値を上回る場合は、wani は対象となるサブゴールが導き出されたものとして扱う。

### 4.2 分類器 Oracle による包含関係の判定

学習済みモデルに基づく分類器 oracle は上位語候補の埋め込み  $u$  と下位語候補の埋め込み  $v$  を入力とする。両者の間に包含関係が成立する確率は、3.2 節で述べた測地的角度  $\Xi$  と半頂角  $\psi$  を用いて以下

のように定義される。

$$oracle(u, v) = \frac{1}{1 + e^{\Xi(u, v) - \psi(u)}} \quad (6)$$

この確率が、あらかじめ学習時に定めた閾値を上回るかどうかで包含関係が判定される。

## 5 実験

### 5.1 実験設定

本研究では、Order Embedding [14], Poincaré Embedding [15], Hyperbolic Entailment Cones [2] の 3 手法でそれぞれ学習を行い、その精度を比較する。学習時に設定したパラメータは付録 A を参照されたい。

### 5.2 学習結果

各手法での学習の F1 値を以下に示す。

表 1: 実験結果 (5 次元)

Model	Embedding Dimension = 5				
	0%	10%	25%	50%	90%
Order Embedding	<b>38.0%</b>	72.7%	<b>78.3%</b>	83.3%	87.4%
Poincaré Embedding	28.6%	55.2%	73.8%	79.4%	82.4%
Entailment Cones	29.9%	<b>73.2%</b>	75.1%	<b>92.0%</b>	<b>93.3%</b>

表 2: 実験結果 (10 次元)

Model	Embedding Dimension = 10				
	0%	10%	25%	50%	90%
Order Embedding	<b>46.0%</b>	72.4%	81.4%	87.0%	87.0%
Poincaré Embedding	30.2%	68.0%	82.3%	84.5%	86.3%
Entailment Cones	30.9%	<b>76.9%</b>	<b>87.9%</b>	<b>92.8%</b>	<b>93.9%</b>

表 1 および表 2 の結果から、全手法において訓練データに NON-BASIC なエッジを追加する割合が増加するに従い、F1 値が向上する傾向が確認された。特に、10 次元以下という低次元において Hyperbolic Entailment Cones が高精度を達成したという結果は、指数関数的に増加する WordNet の階層構造を低次元に歪みなく埋め込んでいることを示している。これらの結果は先行研究である Ganea et al.(2018)[2] の結果と整合しており、本研究の実装が各手法のモデル特性を正しく再現できていることが確認された。

### 5.3 oracle 単体の精度評価

本研究では、前節で学習したモデルに基づき、自然言語推論システムに統合する双曲分類器 oracle を Haskell を用いて実装し、精度評価を行った。埋め込み次元 10, 90% の学習結果の埋め込みを用いた評価

$s_0: \left[ \begin{array}{l} u_0: \left[ \begin{array}{l} x_0: \text{entity} \\ x_1: \text{entity} \\ \text{りんご}(x_1, x_0) \end{array} \right] \\ x_2: \text{entity} \\ \text{食べる/たべる/ガマ}(x_2, \text{太郎/たろう}; \pi_1(u_0)) \end{array} \right]$	$\vdash s_0: \left[ \begin{array}{l} u_3: \left[ \begin{array}{l} x_3: \text{entity} \\ x_4: \text{entity} \\ \text{りんご}(x_4, x_3) \end{array} \right] \\ x_5: \text{entity} \\ \text{食べる/たべる/ガマ}(x_5, \text{太郎/たろう}; \pi_1(u_3)) \end{array} \right]$	(Var)
$s_0: \left[ \begin{array}{l} u_0: \left[ \begin{array}{l} x_0: \text{entity} \\ x_1: \text{entity} \\ \text{りんご}(x_1, x_0) \end{array} \right] \\ x_2: \text{entity} \\ \text{食べる/たべる/ガマ}(x_2, \text{太郎/たろう}; \pi_1(u_0)) \end{array} \right]$	$\vdash \pi_1(\pi_2(\pi_2(\pi_1(s_0)))): \text{りんご}(\pi_1(\pi_2(\pi_1(s_0))), \pi_1(\pi_1(s_0)))$	(SE)
$s_0: \left[ \begin{array}{l} u_0: \left[ \begin{array}{l} x_0: \text{entity} \\ x_1: \text{entity} \\ \text{りんご}(x_1, x_0) \end{array} \right] \\ x_2: \text{entity} \\ \text{食べる/たべる/ガマ}(x_2, \text{太郎/たろう}; \pi_1(u_0)) \end{array} \right]$	$\vdash \text{oracle}(\pi_1(\pi_2(\pi_2(\pi_1(s_0))))): \text{果物}(\pi_1(\pi_2(\pi_1(s_0))), \pi_1(\pi_1(s_0)))$	(Con)

図 2: 証明図の中で oracle が用いられている箇所

の結果, F1 = 92.85% を達成した. これは Python による学習時の評価と同程度であり, 十分な判定能力を備えていることを確認した.

### 5.4 自然言語推論システムの評価

自然言語推論システムに oracle を統合し, 導入前後での推論結果を比較評価した. 語彙的な包含関係に関する世界知識を必要とするテストデータを独自に計 12 個作成した. その一例を以下に示す.

**前提** 太郎はりんごを食べる.

**仮説** 太郎は果物を食べる.

従来手法では, 「りんごは果物である」という知識が明示的に公理として与えられない限り, 推論結果は Unknown となる. 一方, 提案手法である oracle を導入した場合, 明示的な前提の追加なしに Yes という推論結果が得られる. 図 2 は本事例における証明図の一部である. ここでは, 「りんご」と「果物」の包含関係を必要とした際, 内部で oracle が呼び出され, 双曲分類器の判定に基づき動的に公理を生成している様子が確認できる.

表 3: oracle 導入前

	Yes	No	Unk	Other
Yes	0	0	0	0
No	0	0	0	0
Unk	9	0	3	0
Other	0	0	0	0

表 4: oracle 導入後

	Yes	No	Unk	Other
Yes	7	0	0	0
No	0	0	0	0
Unk	2	0	3	0
Other	0	0	0	0

表 3,4 の通り, oracle 導入前には正解が Yes である 9 事例すべてが Unknown と判定されていた. これに対し導入後にはそのうち 7 事例が Yes へと改善された. この結果から, 本手法が人手による知識付与のコストを大幅に削減しつつ, 自然言語推論の適用範囲を拡張できることが示された.

## 6 エラー分析

正解ラベルが Yes であるのに, Unknown と判定された事例を分析する.

**前提** 太郎はりんごとブロッコリーを食べる.

**仮説** 太郎は果物と野菜を食べる.

本例は, 複数の語彙的な含意を伴う推論である. 同様に複数回 oracle を呼び出す例では正しい推論結果を導いている一方で, 本例では設定された制限時間内に証明探索が終了せず Unknown となった. 検証の結果, 本例では等号型に関する規則適用によって, 探索空間が膨大になったことが原因と判明した. 実際に, 枝切りによって等号型の規則適用を制限することで, 不正解であった 2 例とも制限時間内に正解を得ることができた.

## 7 おわりに

本研究では, 依存型意味論 (DTS) に基づく自然言語推論システムに対し, Hyperbolic Entailment Cones を用いた双曲分類器を統合する枠組みを提案・実装した. 従来手法では手動での知識付与なしには判定不可能であった語彙的な包含関係を伴う推論において, 提案システムが自動的に公理を導出し, 正しい推論結果を導出できることを確認した. これにより, 依存型意味論の信頼性と説明可能性を維持しつつ, ニューラル言語モデルによる広範な世界知識を柔軟に利用可能にするハイブリッドな推論システムの有効性を示した. 一方, 特定の推論において等号型の規則適用に伴う探索空間の増大が課題として明らかになった. 今後は, 前向き推論の適用順序の最適化や, 機械学習による枝切りの導入など, より効率的かつ頑健な証明探索アルゴリズムの検討が求められる.

## 謝辞

本研究の一部は JST CREST JPMJCR2565 および JSPS 科研費 JP23H03452 の支援を受けたものである。

## 参考文献

- [1] Daisuke Bekki and Koji Mineshima. Context-passing and underspecification in dependent type semantics. In **Studies in Linguistics and Philosophy**, pages 11–41, 2017.
- [2] Octavian Ganeva, Gary Becigneul, and Thomas Hofmann. Hyperbolic entailment cones for learning hierarchical embeddings. In **Proceedings of the 35th International Conference on Machine Learning**, pages 1646–1655, 2018.
- [3] Mark Steedman. **Surface Structure and Interpretation**. The MIT Press, Cambridge, 1996.
- [4] Mark Steedman. **The Syntactic Process**. MIT Press, 2000.
- [5] Hinari Daido and Daisuke Bekki. Development of an automated theorem prover for the fragment of dts. In **In the 17th International Workshop on Logic and Engineering of Natural Language Semantics (LENLS17)**, 2020.
- [6] 大洞日音. DTS の部分体系を用いた定理自動証明器への等号型の導入, 2022. お茶の水女子大学 修士論文.
- [7] Asa Tomita, Mai Matsubara, Hinari Daido, and Daisuke Bekki. Natural language inference with ccg parser and automated theorem prover for dts. In **In Proceedings of the Second Workshop on the Bridges and Gaps between Formal and Computational Linguistics (BriGap-2)**, pages 1–7, 2025.
- [8] Per Martin-Löf. **Intuitionistic Type Theory, Vol. 9**. Bibliopolis Naples, 1984.
- [9] Daisuke Bekki, Ribeka Tanaka, and Yuta Takahashi. Integrating deep neural networks with dependent type semantics. In **Proceedings of the Symposium Logic and Algorithms in Computational Linguistics 2021 (LA-CompLing2021)**, 2021.
- [10] Daisuke Bekki, Ribeka Tanaka, and Yuta Takahashi. Learning knowledge with Neural DTS. In **Proceedings of the 3rd Natural Logic Meets Machine Learning Workshop (NALOMA III)**, pages 17–25, 2022.
- [11] 飯沼瑞稀 and 戸次大介. 自然言語推論システム Neural DTS の学習アルゴリズムの実装. In **言語処理学会第 31 回年次大会発表論文集**, pages 488–492, 2025.
- [12] Richard Socher, Danqi Chen, Christopher D Manning, and Andrew Ng. Reasoning with neural tensor networks for knowledge base completion. In **Advances in Neural Information Processing Systems (NIPS 2013)**, pages 926–934, 2013.
- [13] Richard Fothergill Francis Bond, Timothy Baldwin and Kiyotaka Uchimoto. Japanese SemCor: A sense-tagged corpus of Japanese. In **Proceedings of the 6th International Conference of the Global WordNet Association (GWC-2012)**, pages 56–63, 2012.
- [14] Ivan Vendrov, Ryan Kiros, Sanja Fiedel, and Raquel Urtasun. Order-embeddings of images and language. In **Proceedings of the 4th International Conference on Learning Representations (ICLR 2016)**, 2016.
- [15] Maximilian Nickel and Douwe Kiela. Poincaré embeddings for learning hierarchical representations. In **Advances in Neural Information Processing Systems (NIPS 2017)**, pages 6338–6347, 2017.

## 付録

### A 学習時に設定したパラメータ

Item	OrderEmb	Poincaré	HypCones
埋め込み次元	5 / 10	5 / 10	5 / 10
学習率 (LR)	$1 \times 10^{-1}$	$1 \times 10^{-4}$	$3 \times 10^{-4}$
エポック数	500	300	300
最適化手法	SGD	ExpMap	RSGD
負例サンプル数	10	10	10
マージン ( $\gamma$ )	1.0	—	0.01
初期化モデル	None	Poincaré	Poincaré
負例の付与先	parent	child	parent