

Extending ILP-based Abductive Reasoning with Cutting Plane Inference

井之上 直也, 乾 健太郎

東北大学

アブダクション (Abduction)

- 観察に対する最良の説明 (仮説)を求める推論

観察 (Observation):

John got a gun John went to a store

背景知識 (Background Knowledge):

go-hunt → get-gun

go-shopping → go-to-store

rob → get-gun & go-to-store

説明 (Explanation):



John will be robbing?

John goes hunting and shopping?

アブダクション (Abduction)

- 観察に対する最良の説明 (仮説)を求める推論

観察 (Observation):

get-gun(John) ∧ go-to-store(John)

背景知識 (Background Knowledge):

$(\forall x) go-hunt(x) \rightarrow get-gun(x)$

$(\forall x) go-shopping(x) \rightarrow go-to-store(x)$

$(\forall x) rob(x) \rightarrow get-gun \wedge go-to-store(x)$

説明 (Explanation):



robbing(John)

hunting(John) ∧ shopping(John)

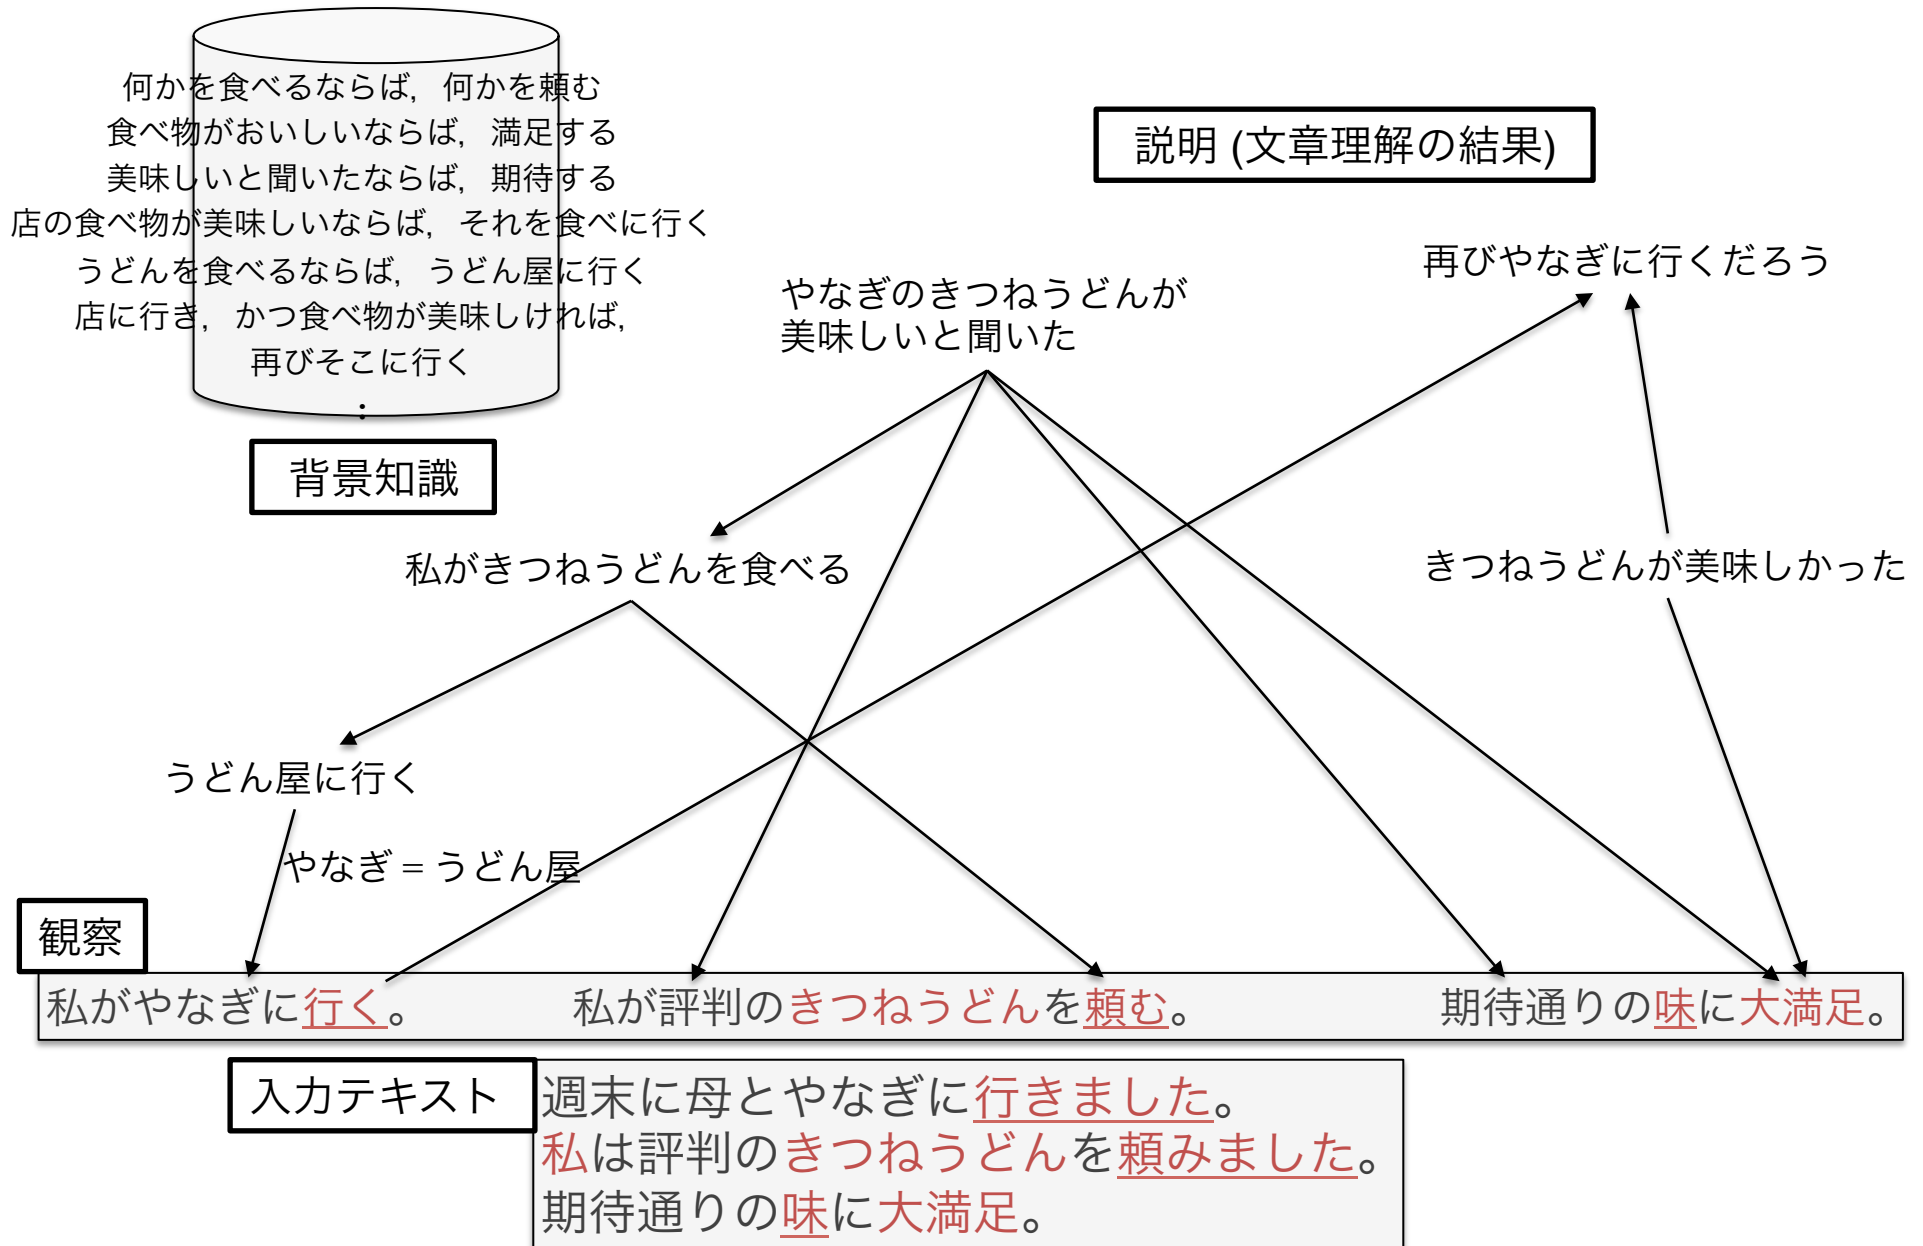
アブダクションによる談話解析

- ゴール: 談話理解の一般的な枠組みを作る
 - 談話解析の各コンポーネント (照応, 談話構造の理解など) を統合し, 結合推論できる枠組みを作りたい
 - 談話に潜在する情報 (意図など) を顕在化したい
 - 世界知識を談話理解に有効利用したい
- Interpretation as Abduction (IA) にもとづく談話理解モデルの構築に取り組んでいる

*“Interpreting sentences is to find
the lowest-cost explanation to the sentence.”*

--- Hobbs+ [93]

談話の最良の説明を求める = 談話を理解する



ための課題

C. 効率的な説明選択の実現

(組み合わせ最適化問題であるため)

→ ☺ 整数線形計画法による定式化

[Inoue & Inui 11]

→ 本研究はこの枠組みを拡張する

評価関数の学習

伝播による学習

[2], 若手 (発表3.)

$$\arg \min_{E \in \mathcal{E}_0} \text{cost}(E; \theta)$$

\mathcal{E}_0 : 説明候補の集合
 cost : 説明評価関数

A. 多様な説明候補を生成する

ための背景知識ベースの構築

→ ☺ 大規模知識獲得技術の発展

- ✓ イントロダクション

- 整数線形計画問題 (ILP) による
アブダクションの定式化

- Cutting Plane Inference
による高速化

- 評価実験

ILP によるアブダクションの定式化

アブダクション:
観測 O を最も良く説明する仮説 H^* を,
背景知識 B から求める推論

1. **仮説候補生成**: 最良仮説の候補 H の集合 \mathcal{H} を生成する
 - 観測 O を含意せよ ($B \cup H \models O$)
 - 矛盾するな ($B \cup H \not\models \perp$)
2. **仮説選択**: 最良の仮説 H^* を選択する
 - コストが最小となる仮説を選べ
($H^* = \arg \min_{H \in \mathcal{H}} cost(H)$)

ILP によるアブダクションの定式化

→ 0-1 ILP 変数への値割り当ての組み合わせから、観測 O を含意する仮説 H^* を、

背景知識

求める推論

1. **仮説候補生成**: 最良仮説の候補 H を生成する

- 観測 O を含意せよ ($B \cup H \models O$)
- 矛盾するな ($B \cup H \not\models \perp$)

→ ILP 変数間の制約

2. **仮説選択**: 最良の仮説 H^* を選択する

- コストが最小となる仮説を選べ

$$(H^* = \arg \min_{H \in \mathcal{H}} \text{cost}(H))$$

→ ILP 目的関数

入力

- ILP 変数
- ILP 目的関数
- ILP 制約

背景知識 B :

$sick(x) \rightarrow resign(x, y)$
 $hate(x, y) \rightarrow resign(x, y)$
 $old(x) \rightarrow resign(x, y)$

$sick(x) \rightarrow go(x, y) \wedge hospital(y)$
 $hospital(AbcHospital).$
 $boring(y) \rightarrow hate(x, y)$

観測 O :

$resign(Steve, Microsoft) \wedge \exists m go(m, AbcHospital)$

ILP による定式化

$resign(Steve, Microsoft) \quad go(m, AbcHospital)$
 $sick(Steve) \quad hate(Steve, Microsoft) \quad old(Steve) \quad sick(m) \quad hospital(AbcHospital)$
 $m=Steve \quad boring(Microsoft) \quad hospital(AbcHospital)$
 $cost(H) =$

出力

最良の説明 $H^* (B \cup H^* \models O)$:

入力

背景知識 B :

$sick(x) \rightarrow resign(x, y)$

$hate(x, y) \rightarrow resign(x, y)$

$old(x) \rightarrow resign(x, y)$

$sick(x) \rightarrow go(x, y) \wedge hospital(y)$

$hospital(AbcHospital).$

$boring(y) \rightarrow hate(x, y)$

👉 **ILP 変数**

ILP 目的関数

ILP 制約

観測 O :

$resign(Steve, Microsoft) \wedge \exists m go(m, AbcHospital)$

ILP による定式化

$$h_{sick(Steve)} = 1, h_{hate(Steve, Microsoft)} = 0, h_{old(Steve)} = 0, h_{sick(m)} = 1, h_{hospital(AbcHospital)} = 0$$
$$s_{m, Steve} = 1, h_{boring(Microsoft)} = 0, h_{hospital(AbcHospital)} = 0$$

$$cost(H) =$$

出力

最良の説明 H^* ($B \cup H^* \models O$):

$sick(Steve) \wedge sick(m) \wedge Steve=m \wedge resign(Steve, Microsoft) \wedge go(Steve, AbcHospital)$

入力

ILP 変数

👉 ILP 目的関数

ILP 制約

背景知識 B :

sick(x) \rightarrow resign(x, y)

hate(x, y) \rightarrow resign(x, y)

old(x) \rightarrow resign(x, y)

sick(x) \rightarrow go(x, y) \wedge hospital(y)

hospital(AbcHospital).

boring(y) \rightarrow hate(x, y)

観測 O :

resign(Steve, Microsoft)

ILP による

説明の評価関数

新しい仮説を推論 ($h=1$): コスト増

他の仮説により説明 or 単一化 ($r=1$): コスト減

$h_{\text{sick}(\text{Steve})} = 1, h_{\text{hate}(\text{Steve}, \text{Microsoft})} = 0, h_{\text{go}(\text{Steve}, \text{AbcHospital})} = 0, h_{\text{sick}(m)} = 0, h_{\text{hospital}(\text{AbcHospital})} = 0$
 $s_{m, \text{Steve}} = 0, h_{\text{boring}(\text{Microsoft})} = 0, h_{\text{hospital}(\text{AbcHospital})} = 0$

$$cost(H) = \sum_{p \in P} h_p cost(p) - r_p reward(p)$$

出力

最良の説明 H^* ($B \cup H^* \models O$):

sick(Steve) \wedge resign(Steve, Microsoft) \wedge go(Steve, AbcHospital)

入力

背景知識 B :

$sick(x) \rightarrow resign(x, y)$
 $hate(x, y) \rightarrow resign(x, y)$

1. 論理変数の等価関係は推移律を満たす

e.g., $s_{m,St} = 1 \wedge s_{m,u} = 1 \Rightarrow s_{St,u} = 1$

$h_{sick(Steve)} = 1, h_{hate(Steve, Microsoft)} = 0, h_{hold(Steve)} = 0, h_{go(Steve, AbcHospital)} = 0, \Pi_{hospital(AbcHospital)} = 0$

$s_{m,Steve} = 0, h_{boring(Microsoft)} = 0, h_{hospital(AbcHospital)} = 0$

$$cost(H) = \sum_{p \in P} h_p cost(p) - r_p reward(p)$$

出力

最良の説明 $H^* (B \cup H^* \models O)$:

$sick(Steve) \wedge resign(Steve, Microsoft) \wedge go(Steve, AbcHospital)$

ILP 変
ILP 目
ILP 制

2. 仮説間の含意関係

e.g., $h_{boring(Mi)} \leq h_{hate(St, Mi)}$

$sick(x) \rightarrow go(x, y) \wedge hospital(y)$
 $hospital(AbcHospital).$
 $boring(y) \rightarrow hate(x, y)$

$ft) \wedge \exists m go(m, AbcHospital)$

3. 報酬を受け取る条件

e.g., $r_{hate(St, Mi)} \leq h_{boring(Mi)}$

ILP による定式化の問題点

- 論理変数の等式間の推移律制約が多項式オーダーで増加
 - 論理変数の組み合わせ (x, y, z) について
 - $x=y \wedge y=z \Rightarrow x=z$
 - $y=z \wedge x=z \Rightarrow x=y$
 - $x=z \wedge x=y \Rightarrow y=z$
- 長い文章を入力したときに大きな問題となる
 - 論理変数の数 = 文章における mention の数
- ILP 最適化問題を解く段階になかなか到達できない
→ ILP の準最適解も得られない

Cutting Plane Inference (CPI) の適用

- ボトルネック解消のアイデア
 - 逐次最適化法: Cutting Plane Inference の応用
 - 大規模な制約付き最適化問題を解く一テクニク:

制約なしの状態でも最適化
→満たされぬ制約を追加→最適化
→満たされぬ制約を追加→最適化
→... を繰り返しながら最適化する手法
 - 推移律制約に対して Cutting Plane Inference を適用

Cutting Plane Inference (CPI) の適用

- 適用例

- 1回目: 最良の説明: $x=y, y=z, x \neq z$
 - $x=y \wedge y=z \Rightarrow x=z$ を制約として追加
- 2回目: 最良の説明: $x=y, y \neq z, x=z$
 - $x=z \wedge x=y \Rightarrow y=z$ を制約として追加
- 3回目: 最良の説明: $x=y, y=z, x=z$
 - すべての制約を満たしているので最適化終了
 - 最適化に必要な制約は **2/3** で済んだ!

推論時間の評価実験

- CPI はアブダクションをどれほど高速化できるだろうか?
- 実験データセット: *Recognizing Textual Entailment*
 - RTE2 開発セットを論理式に変換
 - 入力: 平均30リテラル x 800問
 - 知識:
 - 289,655 個の WordNet axioms (e.g. $\text{synset9}(x) \Rightarrow \text{synset10}(x)$)
 - 7,558 個の FrameNet axioms
(e.g. $\text{GIVING}(e1, x, y) \Rightarrow \text{GETTING}(e2, y, z)$)
- 実行環境
 - ILP ソルバー: Gurobi optimizer 5.0
 - semantic parser: Boxer [Bos 08]

結果 (1): 全体の推論時間の変化

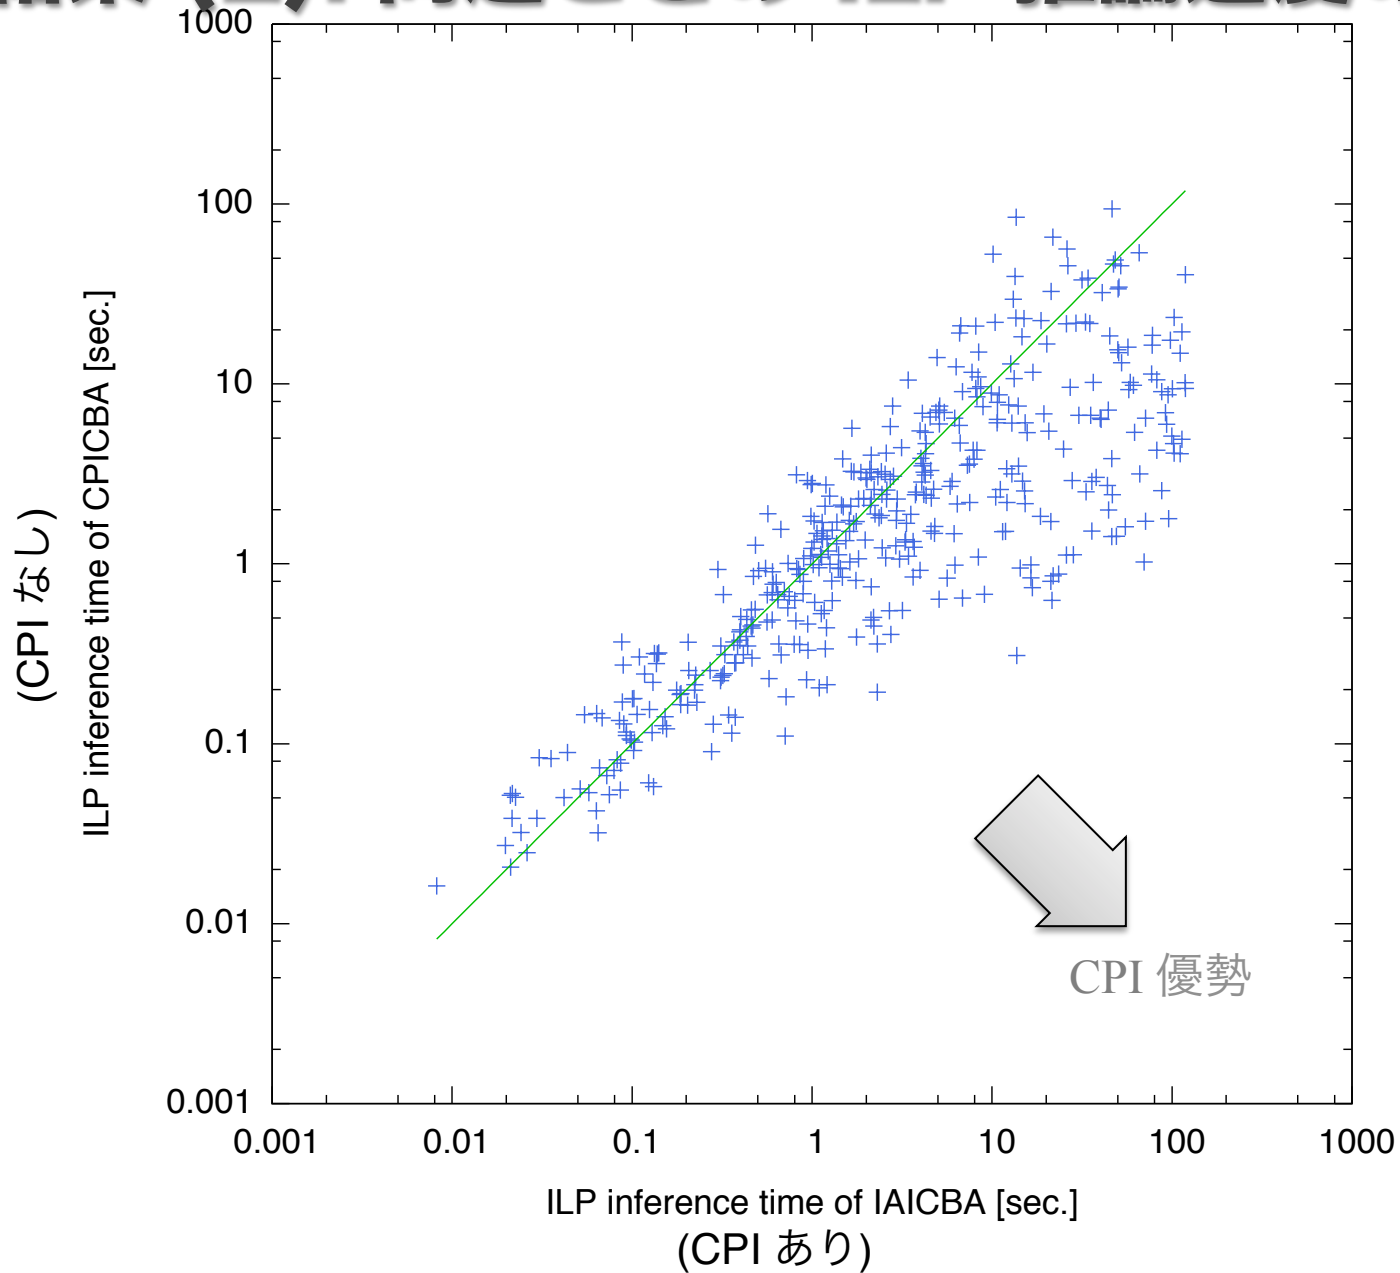
Method	Depth	Generation [sec.] (timeout = 120)
CPI なし	1	0.01 (100.0 %)
	2	0.08 (100.0 %)
	3	0.56 (99.9 %)
	∞	4.78 (90.7 %)
CPI あり	1	0.01 (100.0 %)
	2	0.04 (100.0 %)
	3	0.09 (100.0 %)
	∞	0.84 (98.4 %)

ILP 最適化問題の生成時間を大幅に短縮できた

実際に考慮された制約数は大幅に少なかった

- ILP 推論の時間も短縮
- 最適解を得られた問題数も増えた

結果 (2): 問題ごとの ILP 推論速度の変化



CPI その後

- コスト関数の学習が実用的な規模で実現可能に!
- CPI ベースの推論エンジンを用いた談話解析の結果を、共参照解析の評価セットで評価してみた!
 - データセット: CoNLL Shared Task 2011, 303 documents
 - 1 document は, RTE のそれよりかなり長い
 - 知識ベース: WordNet, FrameNet, Narrative Schemas [Chambers & Jurafsky 07, 08, 09]
 - コスト関数のパラメタはデータから自動学習

System	BLANC-R	BLANC-P	BLANC-F
Abduction	59.9	60.9	60.3
Stanford CoreNLP	63.5	76.2	66.7

- 改良を重ね, 徐々に state-of-the-art に近づいている
- ツールはこちら (旧バージョン, CPI 実装版は近日公開)
 - <http://code.google.com/p/henry-tacitus/>

まとめと今後の課題

- アブダクションによる談話解析の実現を目指して、推論効率の問題に取り組んだ
- 推論効率のボトルネックは、論理変数間の推移律制約が多項式オーダーで増えることであった
- 推移律制約を逐次的に追加して最適化することにより、スケーラブルな推論が実現できることを示した
- 今後の課題
 - 潜在仮説空間の生成に CPI のアイデアを応用
 - [Riedel 06] の Markov Logic Networks における CPI のアナロジー
 - 言語処理タスクにおける評価 (c.f. 若手発表17: “杉浦ら, 談話関係認識への連想情報の応用”)