

自然言語を意味表現に変換 する手法と展望

田 然 (TIAN Ran)

東北大学

「意味」の一つの捉え方

- ◆ 言語の基本的な機能の一つは、
実世界を記述することにある。
- ◆ 発話の「意味」を理解することは、
発話が実世界のどの状況に**対応する**
かを理解することである。



問題が二つに分かれる

◆ 意味表現は何なのか？

◆ 自然言語を意味表現に変換するにはどうすれば？

概要

- ① Semantic Parsing
- ② 推論
- ③ 知識表現とは何か？
- ④ 展望

概要

① Semantic Parsing

自然言語を意味表現に変換する

CCG

DCS

Freebase-QA

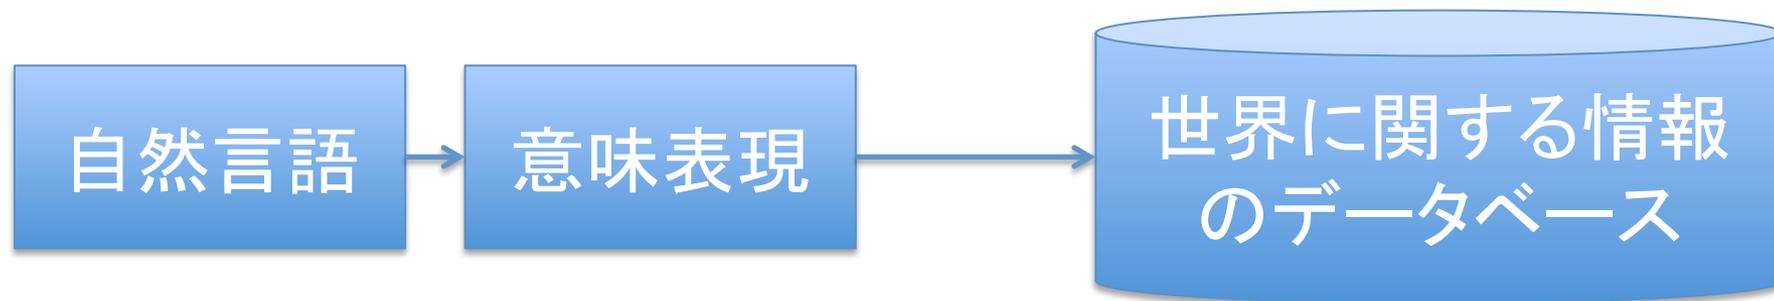
この流れを一言で言えば…

意味表現の性質を捉えて、
ダイレクトに変換しよう！

概要

② 推論

世界に関する情報とどうマッチする？



1. フレームのマッピング
2. 関係データベースのクエリ
3. 論理推論

より複雑



概要

③ 知識表現とは何か？

– “What is a Knowledge Representation?”
AI Magazine, 1993

- 実世界の代用物
- 実世界にある概念の部分集合
- インテリジェントな推論に関する断片的理論
- 効率的な計算を行うための媒介
- 人間が世界を表現する媒介物

概要

④ 展望

より高度なインテリジェンス目指して

1. 東ロボ世界史オントロジー

2. Common Sense Reasoning
(Event Calculus)

① Semantic Parsing

概要

10

① Semantic Parsing

自然言語を意味表現に変換する

CCG

DCS

Freebase-QA

この流れを一言で言えば…

意味表現の性質を捉えて、
ダイレクトに変換しよう！

Semantic Parsing with CCG

11

CCG: Combinatory Categorical Grammar

自然言語文

at the chair, move forward three steps past the sofa

CCG parsing

意味を表す論理表現

$$\lambda a. pre(a, \iota x. chair(x)) \wedge move(a) \wedge len(a, 3) \wedge dir(a, forward) \wedge past(a, \iota y. sofa(y))$$

色んなインテリジェントなタスクに使う

Semantic Parsing with CCG

12

Complete meaning is sufficient to
complete the task

自然言語文から（なるべく）**完全**な意味を引き出す。
出来上がった意味表現を様々なタスクに応用する。

- データベース・クエリに変換して質問に答える [1]
- 記述に合った物体を探し出す [2]
- 指示通りにロボットを動かす [3]

全てのインテリジェントな
タスクに適する、完全に
整合性の取れる意味表現は
ほぼ無理では？

個人的感想：

「Complete」なんかあり得ない…

Semantic Parsing with CCG

14

◆ もっとと詳しい説明は Yoav Artzi の
スライド参照

<http://yoavartzi.com/tutorial/>

◆ 前 2 ページで使った図は上記スライドから引用した

Semantic Parsing with DCS

DCS: **D**ependency-based **C**ompositional **S**emantics [4]

✦ 自然言語をデータベース・クエリに変換して質問に答えるタスク

Database

What is the largest city in California?



Los Angeles

city		state	
San Francisco		Alabama	
Chicago		Alaska	
Boston		Arizona	
...		...	
loc		border	
Mount Shasta	California	Washington	Oregon
San Francisco	California	Washington	Idaho
Boston	Massachusetts	Oregon	Washington
...

...

<http://semantics.representation.stanford.edu/Slides/Percy-Liang.pdf>

Semantic Parsing with DCS

16

✦ 質問・答えのペアからクエリの作り方を学習

Input to Learning Algorithm

Training data (600 examples)

<i>What is the highest point in Florida?</i>	⇒	<i>Walton County</i>
<i>How many states have a city called Rochester?</i>	⇒	<i>2</i>
<i>What is the longest river that runs through a state that borders Tennessee?</i>	⇒	<i>Missouri</i>
<i>Of the states washed by the Mississippi river which has the lowest point?</i>	⇒	<i>Louisiana</i>
...		...

Lexicon (75 words)

city	⇒	city
state	⇒	state
mountain	⇒	mountain, peak
...		...

Database

city	state
San Francisco	Alabama
Chicago	Alaska
Boston	Arizona
...	...

Semantic Parsing with DCS

17

◆ DCSの考え方：

- 質問を答えるために必要なデータベースの操作を整理してモジュール化
- 木構造でモジュールを組み立ててデータベース・クエリを表す
- 依存構造解析のように自然言語からクエリの木構造を解析する
- 正しい答えを出力するような木構造を学習する

Semantic Parsing with DCS

city in California

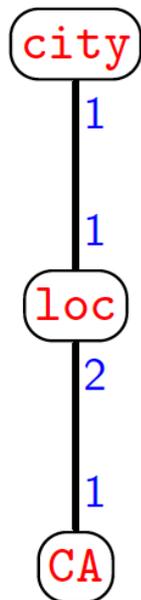
Database

city

San Francisco
Chicago
Boston
...

DCS tree

Constraints



$$c \in \text{city}$$

$$c_1 = l_1$$

$$l \in \text{loc}$$

$$l_2 = s_1$$

$$s \in \text{CA}$$

loc

Mount Shasta	California
San Francisco	California
Boston	Massachusetts
...	...

CA

California

Semantic Parsing with DCS

city in California

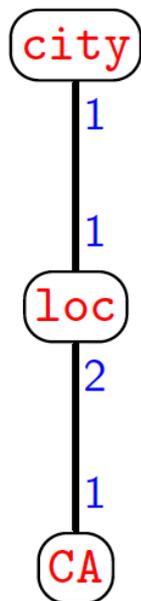
Database

city

San Francisco
Chicago
Boston
...

DCS tree

Constraints



$c \in \text{city}$

$c_1 = l_1$

$l \in \text{loc}$

$l_2 = s_1$

$s \in \text{CA}$

city₁ と loc₁ をジョインする

loc

Mount Shasta	California
San Francisco	California
Boston	Massachusetts
...	...

CA

California

Semantic Parsing with DCS

city in California

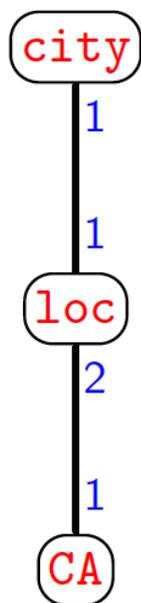
Database

city

San Francisco
Chicago
Boston
...

DCS tree

Constraints



$c \in \text{city}$

$c_1 = l_1$

$l \in \text{loc}$

$l_2 = s_1$

$s \in \text{CA}$

loc

Mount Shasta	California
San Francisco	California
Boston	Massachusetts
...	...

CA₁ と loc₂ をジョインする

CA

California

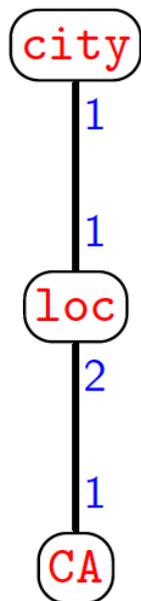
Semantic Parsing with DCS

city in California

依存構造木に類似

DCS tree

Constraints



$$c \in \text{city}$$

$$c_1 = l_1$$

$$l \in \text{loc}$$

$$l_2 = s_1$$

$$s \in \text{CA}$$

Database

city

San Francisco
Chicago
Boston
...

loc

Mount Shasta	California
San Francisco	California
Boston	Massachusetts
...	...

CA

California

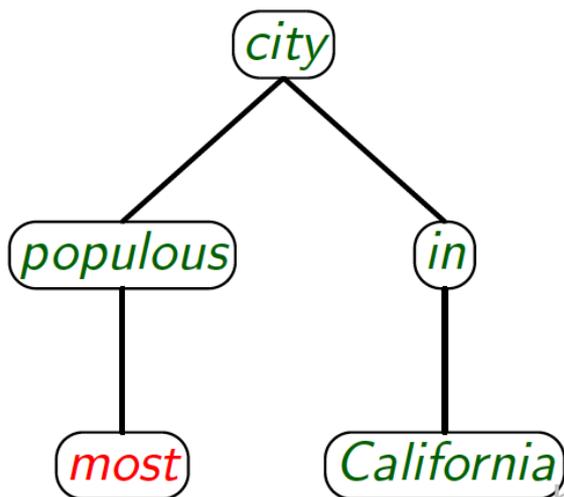
Semantic Parsing with DCS

✦ 依存構造木とデータベース操作の順序はそのまま対応してなくても、依存構造に合わせる

Divergence between Syntactic and Semantic Scope

most populous city in California

Syntax



Semantics

$\text{argmax}(\lambda x. \text{city}(x) \wedge \text{loc}(x, \text{CA}), \lambda x. \text{population}(x))$

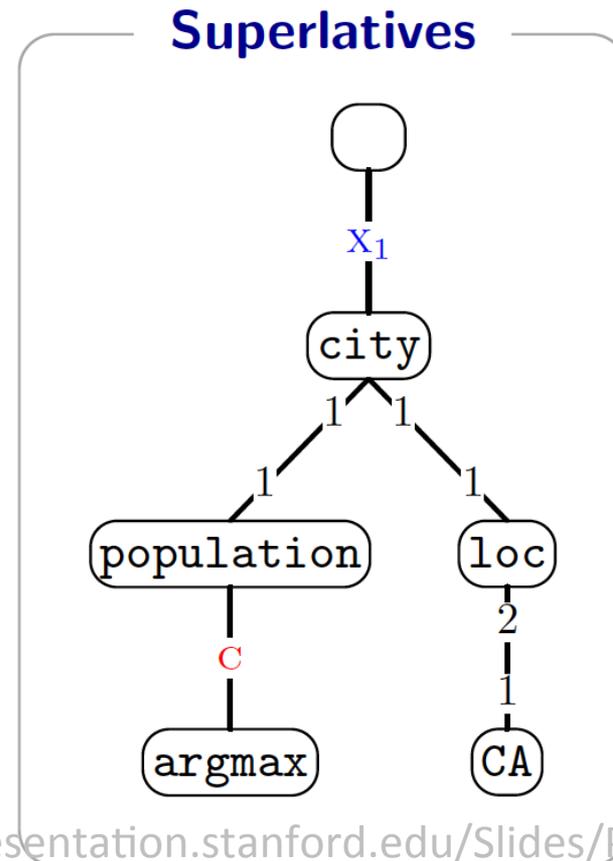
Semantic Parsing with DCS

◆ 統語スコープで **マーク** ・ 意味スコープで **実行**

most populous city in California

Execute at semantic scope

Mark at syntactic scope



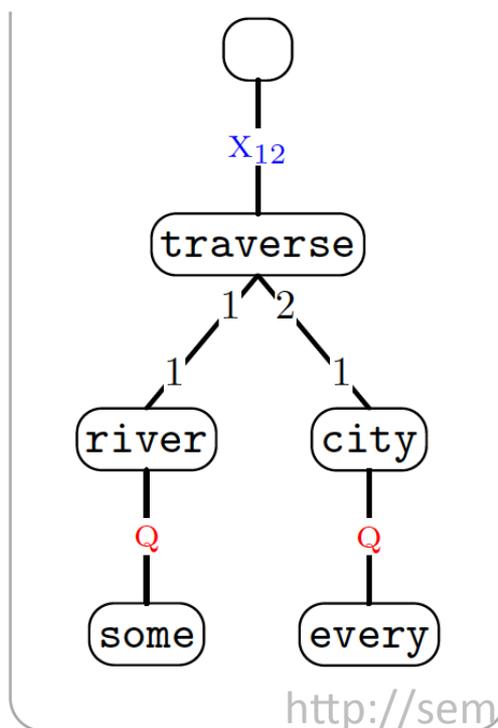
Semantic Parsing with DCS

24

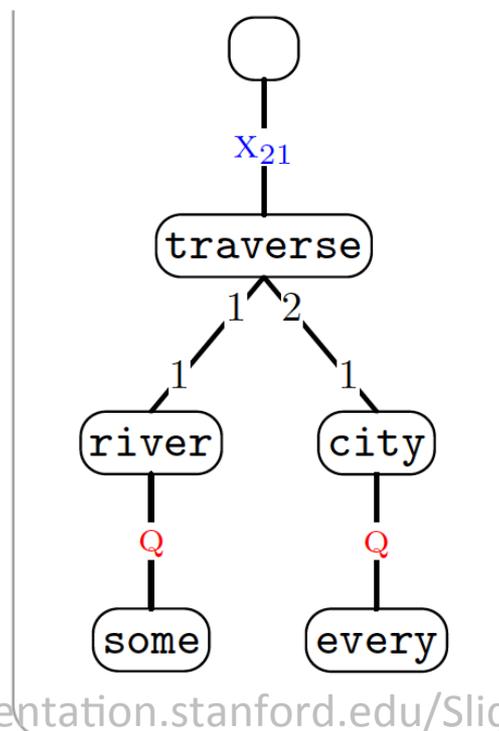
✦ 量化子のスコープ違いは、実行順序の違い

Some river traverses every city.

Quantification (narrow)



Quantification (wide)



- 文の「完全な意味」を表す一般的な論理形式ではなく、必要なデータベース操作を関数化
- 間接的な訓練データ（質問回答ペアなど）で自然言語文からのマッピングを学習する手法は、もはや Semantic Parsing 基本

個人的感想：

目標とする意味表現（データベース・クエリ）をよりダイレクトに表す設計

Semantic Parsing with DCS

26

◆ もっと詳しい説明は Percy Liang
のスライド参照

[http://semanticrepresentation.stanford.edu/
Slides/Percy-Liang.pdf](http://semanticrepresentation.stanford.edu/Slides/Percy-Liang.pdf)

◆ 前 7 ページで使った図は上記スライドから引用した

Freebase-QA

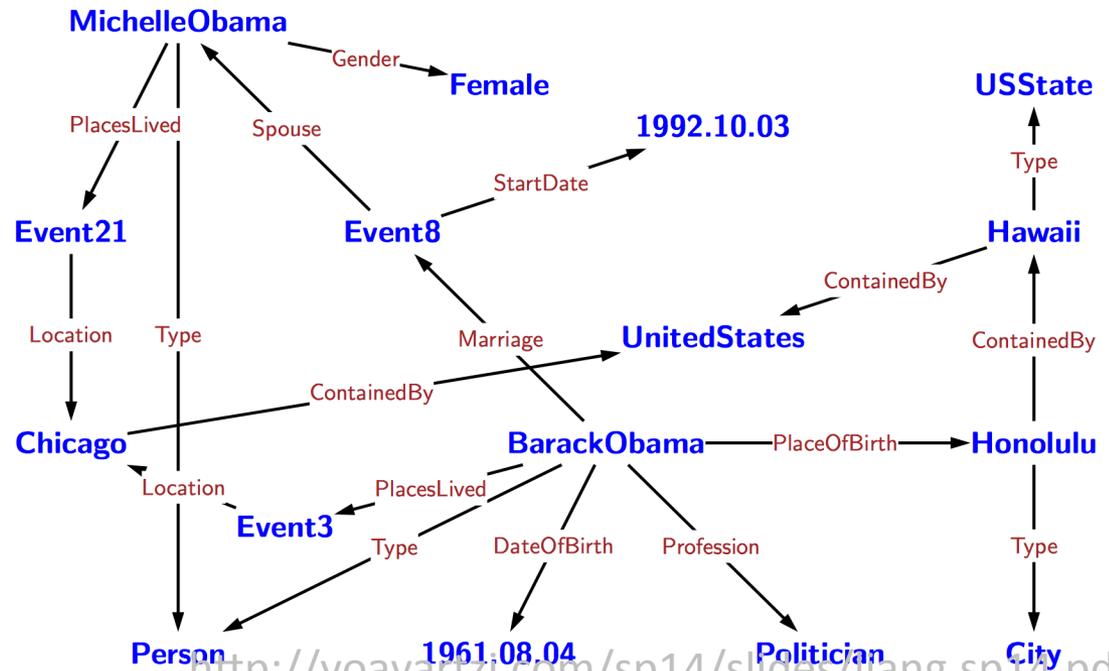
◆ Freebase: 共同で作るデータベースで世界中の知識をシェアする、という壮大な構想

– 実際の内容は、有名な人物・場所・物などに関する情報

100M entities (nodes) 1B assertions (edges)

```
{
  "id": "/en/barack_obama",
  "name": "Barack Obama",
  "notable": {
    "name": "US President",
    "id": "/government/us_president"
  }
}
```

<https://www.freebase.com>



Freebase-QA

28

- ✦ インターネットによく聞かれる質問に対して、Freebaseから答えを探し出すタスク

people who have lived in Chicago



{BarackObama,MichelleObama,...}

Freebase-QA

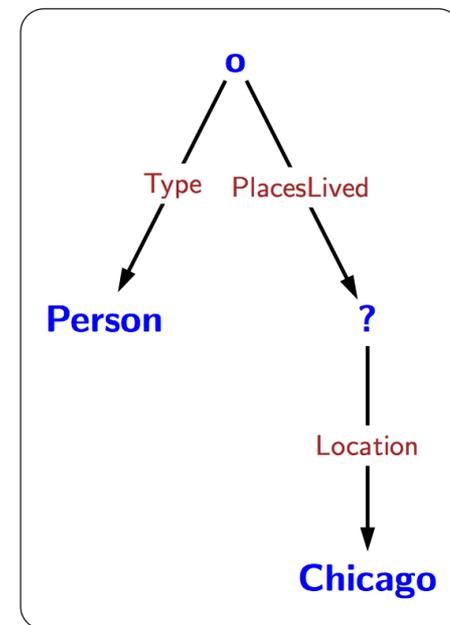
✦ 「DCS的な」アプローチ [5]

people who have lived in Chicago

Type.Person \sqcap PlacesLived.Location.Chicago



{BarackObama,MichelleObama,...}



Freebase-QA

30

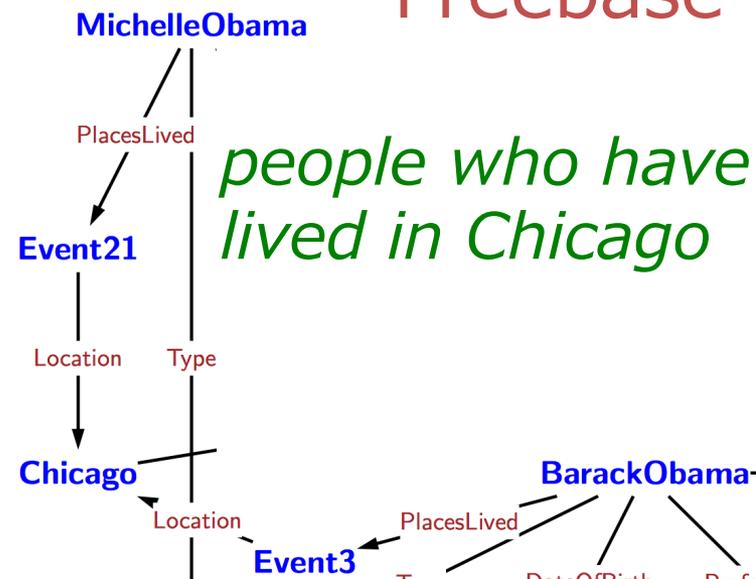
✦しかし Freebase は関係DBではなかった…

- Freebaseは、有名な物事を中心に情報をまとめている
- 「よく聞かれる質問」も、有名な物事に関するのが多い

関係DB

“What is the longest river that runs through a state that borders Tennessee?”

Freebase



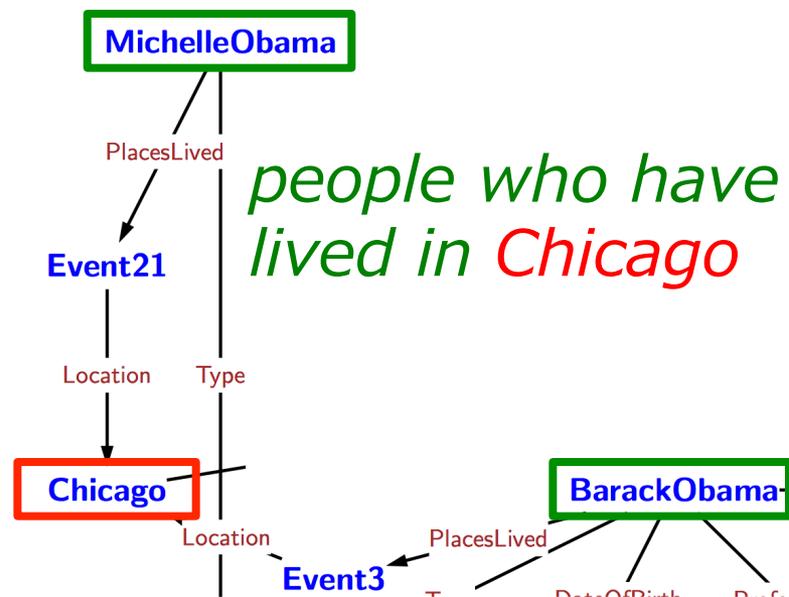
Freebase-QA

31

◆Freebase-QA を扱う、もっとダイレクトな方法 [6]

- 「DCS的な手法」とほぼ同じ（場合によって少しよい）性能を出した

1. 質問文の中の固有名詞をFreebaseのノードにマッチ
2. マッチされたノードのまわりのノードに対して、それが答えであるかどうかを判定する分類器をかける



Freebase-QA

32

✦ 詳しくは Xuchen Yao と Jonathan Berant
の論文^[7] を参照

<http://yoavartzi.com/sp14/>

❖ 前 4 ページで使った図は上記 Percy Liang のスライドから引用した

- Freebaseも関係データベースも一言でデータベースだけど、Freebaseの方は「フラット」
- DCS的クエリを仲介するやり方は、一般論理表現を「余計に」中間層に取り付けたCCGと同じ「過ち」を犯した気がする

個人的感想：

意味表現の性質により合致する変換法こそベスト

Freebaseと関係DB

✦では、Freebaseと関係DBの違いは
どうして生じたのだろうか？

- 関係DBの情報はFreebaseに変換できるし、
逆も頑張ればできるはず
- 本当に違うもの？

✦いや、本質的に違う！

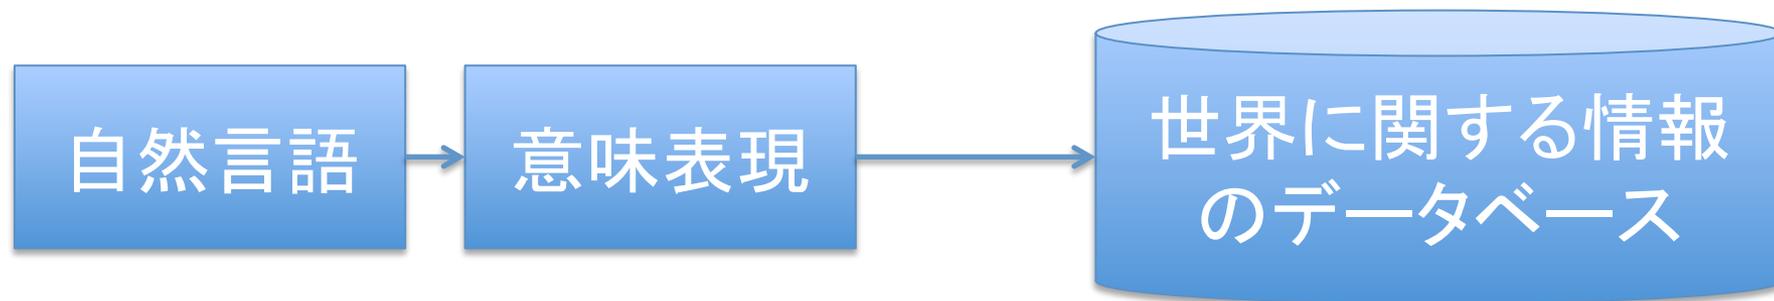
→推論

② 推論

概要

② 推論

世界に関する情報とどうマッチする？



1. フレームのマッピング
2. 関係データベースのクエリ
3. 論理推論

より複雑



マッピング的な推論

◆ AIにおける「フレーム」の考え方

- ある概念に関するすべての事実と属性が一箇所に置かれていたら、データベース内を手間をかけて検索する必要がない
- 手元にあるデータを「プロトタイプ」に関するフレームに当てはめて、関連する事実や属性を導き出す推論

マッピング的な推論

◆例 1 : Freebase

```
{  
  "type": "/people/person",  
  "name": "Barack Obama",  
  "*": null  
}
```



```
{  
  "type": "/people/person",  
  "name": "Barack Obama",  
  "children": [  
    "Natasha Obama",  
    "Malia Ann Obama"  
  ],  
  "place_of_birth": "Honolulu",  
  "date_of_birth": "1961-08-04",  
  "height_meters": 1.85,  
  "parents": [  
    "Barack Obama, Sr.",  
    "Ann Dunham"  
  ],  
  ...  
}
```

マッピング的な推論

◆例 2 : 格フレーム

積む/つむ:動2

<ガ格> 一人一人, 人, 選手, 私, ...

* <ヲ格> 研鑽, 修行, 練習, トレーニング, ...

<ニ格> 自分, 相手, ...

<デ格> 下, 元, 病院, 音楽+院, レストラン, ...

<修飾> 更に, 為, シツカリ, もっと, ...

修行を 積む



マッピング的推論に関して一言：

直感的。論理的でない場合もある。
大雑把で型に嵌った推論しかできない

データ・クエリ

◆ 関係モデル

- 関係によってデータレコードをまとめる
- 様々な関係の制約を満たすレコードを探す

“What is the longest river that runs through a state that borders Tennessee?”

state

Alabama
Alaska
Arizona
...

loc

Mount Shasta	California
San Francisco	California
Boston	Massachusetts
...	...

border

Washington	Oregon
Washington	Idaho
Oregon	Washington
...	...

データ・クエリ

✦レコード取り出す操作は関係代数の演算子で記述される

\times : 直積 *“books read by students”*

\cap : 交わり $\pi_{\text{OBJ}} \{ \text{read} \cap (\text{student} \times \text{book}) \}$

π : 射影

	read		student	book
	SUBJ	OBJ	ARG	ARG
	Mark	New York Times	Mark	Linear Algebra
	Mary	A Tale of Two Cities	John	A Tale of Two Cities
	John	Ulysses	Emily	Ulysses
...

データ・クエリに関して一言：

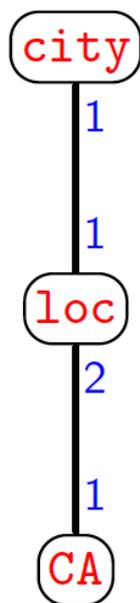
カノニカルな関係が複数絡まっている
場合、要求に合った情報を取り出せる

論理推論

◆ 関係DBのクエリは論理式の種類

city in California

DCS tree



Constraints

$c \in \text{city}$

$c_1 = l_1$

$l \in \text{loc}$

$l_2 = s_1$

$s \in \text{CA}$

クエリ (関係代数式)

$$\pi_1 \{ \text{loc} \cap (\text{city} \times \text{CA}) \}$$

論理式 (ラムダ式)

$$\lambda c. \exists l. \exists s. (c \in \text{city} \wedge c_1 = l_1 \wedge l \in \text{loc} \wedge l_2 = s_2 \wedge s \in \text{CA})$$


論理推論は「開世界」

- ✦ 一般的な論理推論とデータ・クエリとは、一つ大きな違いがある
- ✦ データ・クエリでは、テーブルに記録がなければ、その関係を満たさないものとする（閉世界仮説）
- ✦ 論理推論では一般にこれを仮定しない（開世界）
- ✦ 「開世界」において、データ・クエリのやり方そのままでは正しく推論できない可能性がある
- ✦ それを端的に表したのは**エディプスの例**[\[10\]](#) である

エディプスの例

- ✦ エディプスは父親を殺し、母親のイオカステと結婚した。二人の間にポリュネイケスという子が生まれた。そして、ポリュネイケスは後に自分の子のテルサンドロスを生んだ。
- ✦ エディプスは父殺しである。テルサンドロスは父殺しではない。
- ✦ 問題：イオカステの子供で、父殺しで、かつ父殺しでない子を持つような人物はいるか？

エディプスの例

◆ 関係データベースで表現すると

親子関係

親	子
イオカステ	エディプス
イオカステ	ポリュネイケス
エディプス	ポリュネイケス
ポリュネイケス	テルサンドロス
...	...

父殺し

エディプス
...

父殺しでない

テルサンドロス
...

問題: イオカステの子供で、父殺しで、かつ父殺しでない子を持つような人物?

エディプスの例

✦ 間違った推論 (データ・クエリのやり方)

問題: イオカステの子供で、父殺しで、かつ父殺しでない子を持つような人物?

- イオカステの子は二人いる。一人、エディプスは父殺しだが、彼の子供のポリュネイケスが父殺しでないかどうかは分からない。そしてもう一人、ポリュネイケスは父殺しでない子テルサンドロスを持つが、彼自身が父殺しかどうか分からない。

- よって、答えはNO

エディプスの例

✦正しい推論

問題: イオカステの子供で、父殺しで、かつ父殺しでない子を持つような人物?

- ポリュネイケスは父殺しか父殺しでないかどちらかである。もし、ポリュネイケスは父殺しである場合、ポリュネイケスは問題の条件を満たす。一方、もしポリュネイケスは父殺しでないとすると、エディプスは問題の条件を満たす。
- よって、答えは「ポリュネイケスかエディプスカのいずれか」で、YESである!
- 条件にも問題にも **AND** しかない。にも関わらず答えには **OR** が出た!

論理推論に関して一言：

明示的に言われた事以外は仮定しない。
それでいて手掛りは何一つ見逃さない。

含意関係認識への応用

◆ 自然言語文をDCSによって、関係代数の演算に変換できる

◆ 関係代数の演算の間に、どんなデータベースにおいても成り立つような、論理的性質が考えられる

$$A \times (B \cap C) = (A \times B) \cap (A \times C), A \cap B \subset A, \dots$$

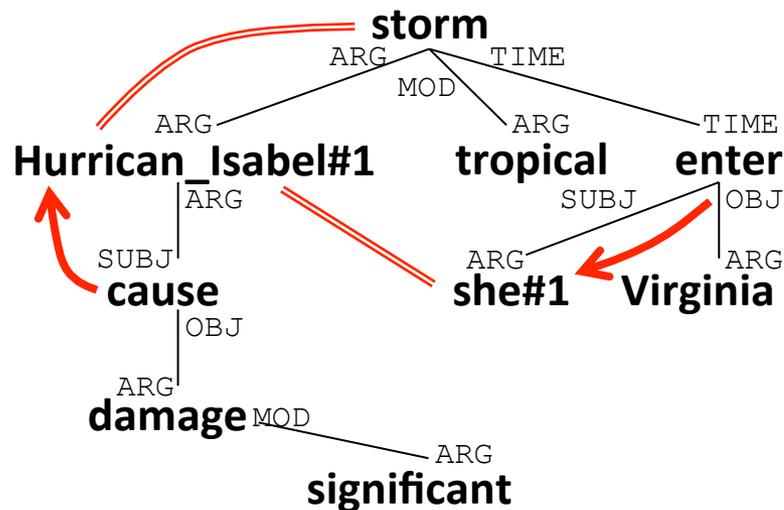
◆ 二つの文が同じ意味かどうかは、論理推論で判定できる

含意関係認識への応用

- ◆ 本来、（係り受けにない）述語項構造が認識されないといけない問題が、係り受け木（に近いDCS木）と共参照と論理推論で解かれる

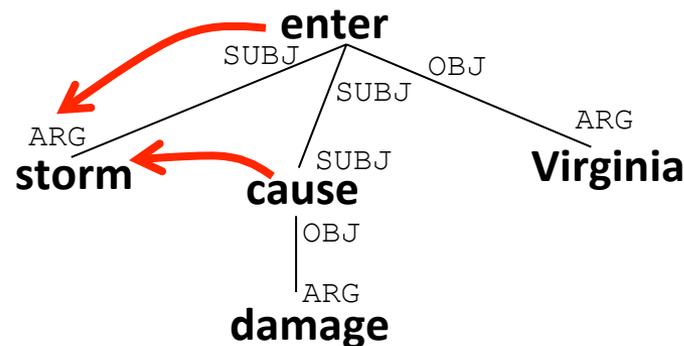
[8,9]

T: *Hurricane Isabel, which caused significant damage, was a tropical storm when she entered Virginia.*



含意
→

H: *A storm entered Virginia, causing damage.*

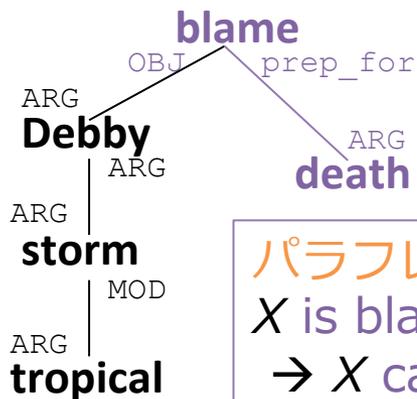


言語知識との組み合わせ

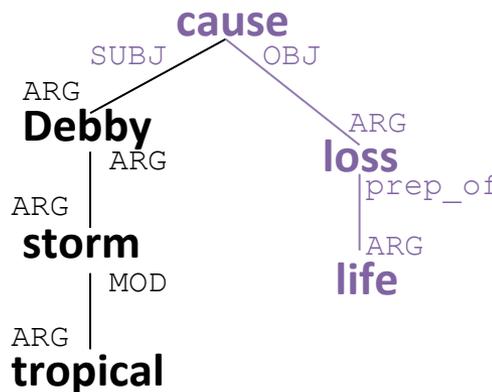
✦パラフレーズ知識と組み合わせせて使うこともできる

T: *Tropical storm Debby is blamed for death.*

H: *A storm has caused loss of life.*



パラフレーズ
X is blamed for death
 → *X cause loss of life*



論理

✦単語ベクトルを足して得られるフレーズ・ベクトルの類似度をパラフレーズ知識として利用することで、含意関係認識の State of the Art

含意関係認識への応用

◆ 詳しくはTIFMOシステムに参照

<http://kmcs.nii.ac.jp/tianran/tifmo/>

◆ 東ロボプロジェクトによってサポートされた研究です

TIFMOに関して一言：

論理的推論とマッピング的推論（パラフレーズ）を組み合わせたと言える

論理的知識推論

- ✦ **論理的な知識**を使って、論理推論を行う推理を、ここで「論理的知識推論」と呼ぶ。
- ✦ 現在AIの主流で想定する知識（オントロジーなど）の使われ方は、マッピング的推論に型制限を入れたようなもの
- ✦ しかし、色んな知能現象を、原則に基づいて、論理的に説明しようとする**理論研究**はたくさんある。中には「論理的知識推論」を実用化するヒントも埋もれているかもしれない。

③ 知識表現とは何か？

③ 知識表現とは何か？

– “What is a Knowledge Representation?”
AI Magazine, 1993 [11]

- 実世界の代用物
- 実世界にある概念の部分集合
- インテリジェントな推論に関する断片的理論
- 効率的な計算を行うための媒介
- 人間が世界を表現する時の媒介物

概要

③ 知識表現とは何か？

- “What is a Knowledge Representation?”
AI Magazine, 1993

更にこの論文の要点を幾つかまとめてみた

一、完全はあり得ない

- ◆ 知識表現は世界の**一部**を代表し、完全ではあり得ない
- ◆ 一部である故、フォーカス絞れる
- ◆ 一部である故、いつか必ず間違う
(たとえ厳密な論理推論としても)
- ◆ どの部分にフォーカスするかこそ本質、データ構造自体は本質でない

二、表現と推論は切り離せず

61

- ◆何をインテリジェントな推論と考える？
- ◆許容・**推奨**する推論は何か？
- ◆知識表現の性質を大きく左右するのは、世界のどの部分をモデル化し、どんな推論を行うかである
- ◆フレームとロジックとは大分違う

三、KRは組み合わせさせて使おう

- ◆ 知識表現の本質にはこだわる。
- ◆ データ構造が似ているからと言って当初意図しない使い方はするな。
- ◆ 違う知識表現を組み合わせさせて使おう。
- ◆ 組み合わせる時は、違う知識表現にインテリジェンスの違う部分の推論を担ってもらおう。

四、効率性と理解しやすさ

- ◆ 五つの側面すべてが重要である
- ◆ 知能現象を説明するために、厳密な論理しか認めず、使われた知識を全て解き明かそうとするロジック的アプローチは重要な理論研究だが、
- ◆ 計算の効率性やアノテーションしやすさもないとAI作るのには不完全

④ 展望

概要

④ 展望

より高度なインテリジェンス目指して

1. 東ロボ世界史オントロジー

2. Common Sense Reasoning
(Event Calculus)

東ロボ世界史オントロジー

66

- ◆ 「出来事（イベント）の成立を記述する文」の真偽判断をサポートするための、イベントに関するオントロジー [12]

西郷隆盛は織田信長と戦った？

- ◆ 記述するのはイベントの内容の詳細ではなく、それが成立するための前提条件、及び成立した場合に他のイベントの成立・不成立にどう影響するかである

東ロボ世界史オントロジー

67

✦ イベントの概念クラスに対して以下の属性を記述する：

– イベント成立の必要条件（参加者・回数など）

西郷隆盛は織田信長と戦った？ - 参加者の存在時間が一致しない

– 参加者の粒度との関係

北フランスを占領した → パリを占領した

– 異なるイベント間の関係

「勝利」と「敗北」両立しない、「勝利」の前には「戦い」、…

– イベントを記述する言語表現例（動詞＋項構造）

evt:勝利 agentがsituationに勝つ, agentがthemeを倒す, …

東ロボ世界史オントロジー

68

◆ 自然言語処理の課題

- 「出来事の成立を記述する文」を、世界史オントロジーで記述される知識表現に変換する Semantic Parsing はどの位できる？
- この知識表現にモデル化されている推論を使って、大学入試の世界史問題をどれ位解ける？

東ロボ世界史オントロジー

69

✦ 詳しくは下記参照

<http://researchmap.jp/zoeai/event-ontology-EVT/>

❖ 「ロボットは東大に入れるか。」プロジェクト <http://21robot.org>

- オントロジーである以上、マッピング的な推論を想定している（それが十分である）知識表現
- **DCSと論理推論**を含意関係認識に応用した研究は東ロボ世界史の為に始めたが…**オントロジー+述語項構造解析**が近道かも

個人的感想：

すごく使ってみたい。が、DCSや論理推論とはあまり関係なさそう

Common Sense Reasoning

71

✦我々が「日常的」に行っている推論

- リサは新聞を持って台所に入った。→ 新聞は台所にある。
- 日本銀行は預金準備率を1.5%に上げた。→ 特に何も言わない限り預金準備率は1.5%のままである。
- ...

✦そこにはどういう論理があって、どんな知識が必要で、どんな推論過程を辿って行くのか

✦これらの問題を真正面から答えた理論がある (←論理的知識推論のヒントになるか?)

Event Calculus 超概要

◆ Event と Fluent

- Event はある時点で「起こる」動作や出来事
 $WakeUp(p), FallAsleep(p), \dots$
- Fluent は各時点で真理値が変わりうる性質
 $Awake(p), \dots$
- 言語学のイベントとステートの区別に通じる

◆ Event が Fluent を変える

- $Initiates(WakeUp(p), Awake(p), t)$
(任意の時点 t で) 起きると目覚めた状態が真になる
- $Terminates(FallAsleep(p), Awake(p), t)$

Event Calculus 超概要

★ The Common Sense Law of Inertia

- 何もイベントが起こらなければ、多くの状態はそのまま保ち続ける傾向がある

明かりをつけると、ついたままになる

- コモンセンスの慣性法則はこの経験則を定式化した公理

$\neg \text{HoldsAt}(\text{On}(\text{Light1}), 0), \neg \text{HoldsAt}(\text{On}(\text{Light2}), 0)$

時刻 0 において、どの明かりもついてない

$\text{Initiates}(e, f, t) \Leftrightarrow \exists l (e = \text{TurnOn}(l) \wedge f = \text{On}(l))$

「つける」こと以外、明かりをオンにする方法はない

$\text{Happens}(e, t) \Leftrightarrow (e = \text{TurnOn}(\text{Light2}) \wedge t = 1)$

時刻 1 で Light2 をつけた。それ以外何も起こらなかった



$\neg \text{HoldsAt}(\text{On}(\text{Light1}), 2), \text{HoldsAt}(\text{On}(\text{Light2}), 2)$

Event Calculus 超概要

✦ 知識は何種類あって、それぞれどんな論理式の形をしていて、推論においてどんな役割を果たすのか、全部整理してある

– 使う知識はこれこれの形しかない、という表がある：

Observation: $HoldsAt(\beta, \tau), \dots$

Trigger: $\gamma \Rightarrow Happens(\alpha, \tau), \dots$

Positive Effect: $\gamma \Rightarrow Initiates(\alpha, \beta, \tau), \dots$

...

✦ この枠組みで人間の感情までモデリングした

Event Calculus 超概要

✦例

- “Smoking increases the risk of cancer.”

HoldsAt(Risk(p, r_1), t)

\Rightarrow *Initiates*(Smoke(p), Risk(p, r_2), t)
& *Initiates*(Smoke(p), $r_2 > r_1$, t)

HoldsAt(Risk(p, r_1), t)

\Rightarrow *Terminates*(Smoke(p), Risk(p, r_1), t)

- 「一回喫煙した後は、リスク値が大きくなって、何もしないと大きいまま」、などの推論が出来る
- increase(smoking, risk) のような書き方して、後で ad hoc なルールでこれを扱うよりは、多分ずっといい

Event Calculus 超概要

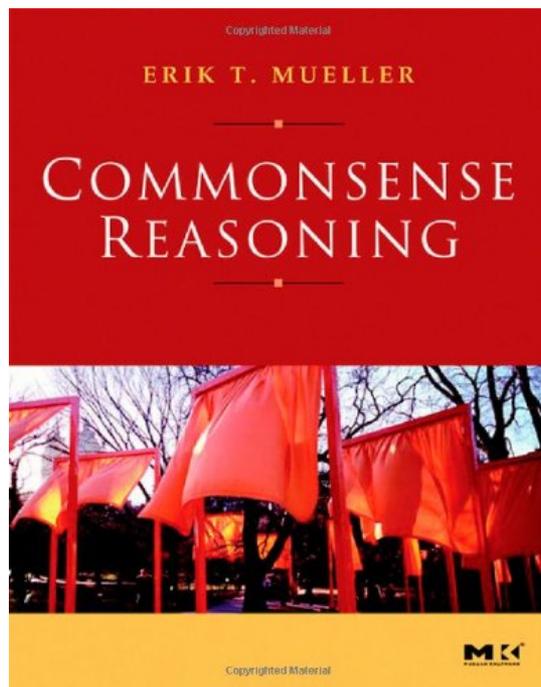
- ✦ 言語処理の研究者はデータを持って、データを見ることに強みがあるが、AI理論の研究者は何十年も知識や推論の問題を考えてきた。彼らのインサイトは信じるべきかもしれない
- ✦ 自然言語から大規模な知識抽出を行う研究はたくさんあるが、数量の変化をきちんと扱って論理推論を行えるようなインテリジェンスはまだない気がする（「円安になると株価が上がる」ことを数値レベルで理解しているインテリジェンスとか）

Event Calculus 超概要

77

✦ 詳しくは Erik T. Mueller の著書
『Common Sense Reasoning』に参照

<http://www.amazon.co.jp/dp/0123693888/>



個人的感想：

私的には、最初にDCSと出会った時と同じようなトキメキを感じた

ご清聴ありがとうございます

ディスカッションしよう！

参考文献

- [1] Tom Kwiatkowski; Eunsol Choi; Yoav Artzi; Luke Zettlemoyer; (2013) Scaling Semantic Parsers with On-the-Fly Ontology Matching; EMNLP
- [2] Matuszek, C., FitzGerald, N., Zettlemoyer, L., Bo, L., and Fox, D. (2012). A joint model of language and perception for grounded attribute learning. ICML.
- [3] Artzi, Y. and Zettlemoyer, L. (2013). Weakly supervised learning of semantic parsers for mapping instructions to actions. TACL, 1(1)
- [4] Percy Liang, Michael I. Jordan, and Dan Klein. (2013). Learning dependency-based compositional semantics. Computational Linguistics, 39(2)
- [5] Jonathan Berant; Percy Liang; (2014) Semantic Parsing via Paraphrasing; ACL
- [6] Xuchen Yao; Benjamin Van Durme; (2014) Information Extraction over Structured Data: Question Answering with Freebase; ACL
- [7] Xuchen Yao, Jonathan Berant and Benjamin Van Durme. (2014) Freebase QA: Information Extraction or Semantic Parsing? ACL 2014 Workshop on Semantic Parsing

参考文献

[8] Ran Tian; Yusuke Miyao; Takuya Matsuzaki; (2014) Logical Inference on Dependency-based Compositional Semantics; ACL

[9] Ran Tian, Yusuke Miyao and Takuya Matsuzaki. (2014) Efficient Logical Inference for Semantic Processing. ACL 2014 Workshop on Semantic Parsing

[10] Franz Baader, Diego Calvanese, Deborah L. McGuinness, Daniele Nardi, and Peter F. Patel-Schneider, editors. (2003). The Description Logic Handbook: Theory, Implementation, and Applications. Cambridge University Press, New York.

[11] R. Davis, H. Shrobe, and P. Szolovits. What is a Knowledge Representation? (1993). AI Magazine, 14(1)

[12] 川添愛、宮尾祐介、松崎拓也、横野光、新井紀子; (2014) 出来事の成立・不成立の判断をサポートするイベントオントロジー; 人工知能学会全国大会