

対話システムの類型と その実現に向けた方法論

奈良先端科学技術大学院大学

科学技術振興機構

吉野 幸一郎

**Nara Institute of Science and Technology
Augmented Human Communication Laboratory
PRESTO, Japan Science and Technology Agency**



自己紹介

- **吉野 幸一郎 (よしの こういちろう)**

- 2008 SFC, 2009-2015 京大河原研
- 2015- 奈良先端大 助教
- 2016- JST さきがけ研究員 (兼任)

- 2008年頃から対話システム研究を始めてもうじき10年？

- **対話関連の学会活動など**

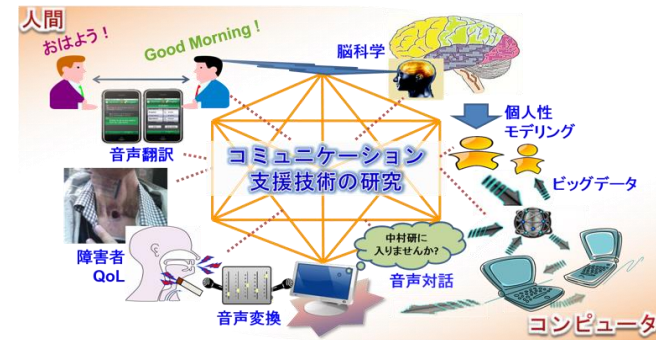
- 2016- Dialogue System Technology Challenge, Organizer
- 2016- 対話システムシンポジウム 委員

- **その他の近況**


- 最近疲れているように見えるらしい...

- **今日の発表資料**

- <http://pomdp.net/docs/SLUD-tutorial-pub.pdf>



DSTC6
Dialog System Technology Challenges
Long Beach, USA, December 10, 2017



このチュートリアルのゴール

- **対話システムの類型とその用途がわかる**
 - 各類型（というか2種類）の問題意識と指向するものを理解する
 - 自身が作りたいものがどこに属するかがわかる
- **タスク指向型対話システムの構成と問題定義がわかる**
 - 対話状態推定と行動制御の問題定義を理解する
 - 一般的な対話状態と行動の設計がわかる
- **非タスク指向型対話システムの構成と問題定義がわかる**
 - タスク指向型との違いを理解する
 - End-to-endと呼ばれる対話システムの問題定義を理解する

よくある対話システム構築のモチベーション

- コールセンターやお客様案内を自動化したい
- 受付を自動化したい



- **人間が行っている業務を100%代替することは不可能**
- **人間の業務負担を軽減することは可能**
 - 必ずしも現在の人間の業務が自動化の最適解ではない
 - 洗濯機は洗濯板の利用を自動化したわけではない
 - ルーティン化できているものを対話で代替することは可能

タスク指向対話と一問一答の違い

- **タスク指向型対話は対話状態を持つ**

- システムは対話状態に当てはめながらユーザの意図を理解する
- 対話状態はシステムの機能に合わせてデザインする
- 必要に応じて確認などの行為を行う

乗換案内における
対話状態の例

```
train_info{  
  $FROM=早稲田  
  $TO_GO=NULL  
  $LINE=東西線  
}
```

- **一問一答型対話は必ずしも対話状態は定義しなくてもよい**

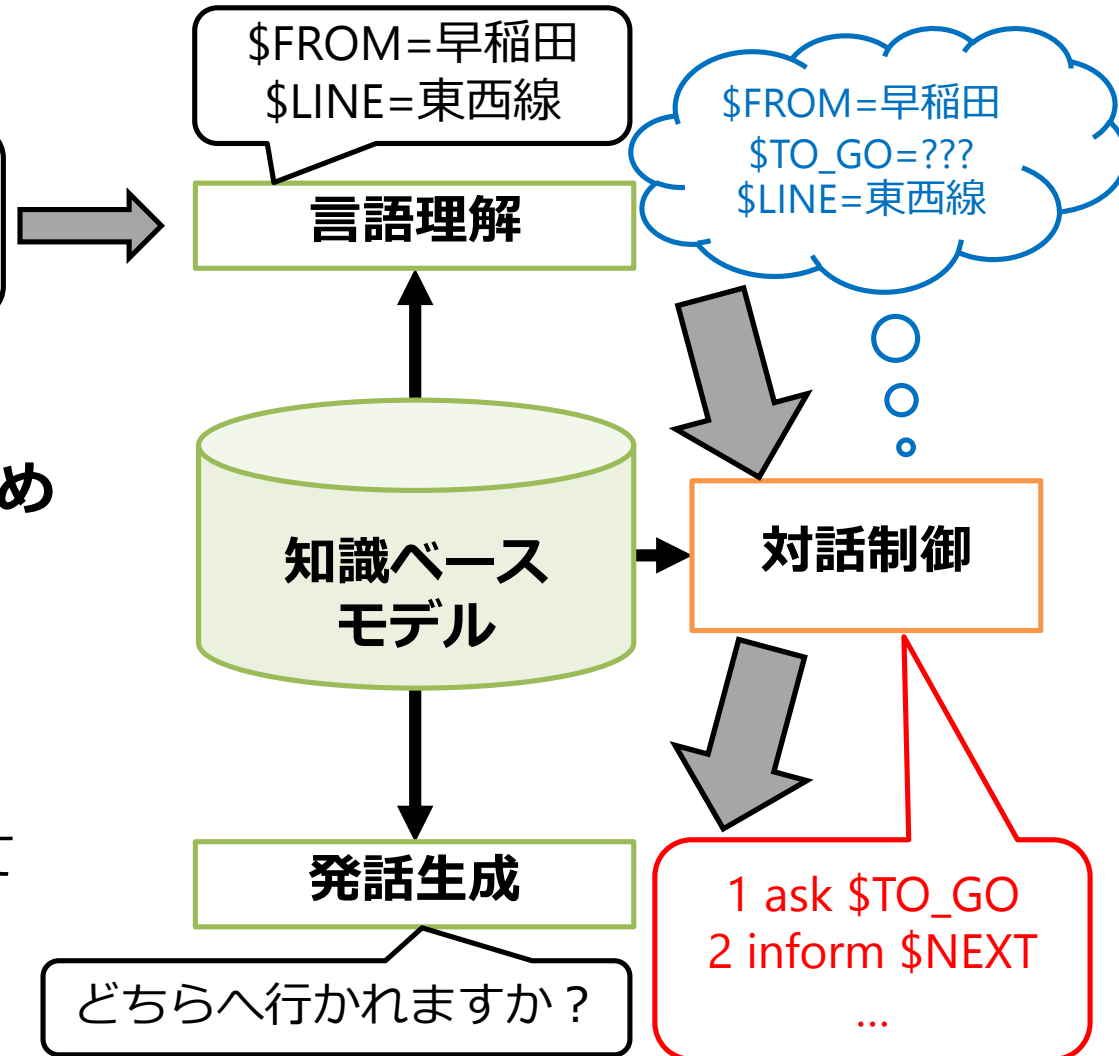
- 大量の応答ペアを用意し統計的学習を行うことが多い
- 対話状態のデザインは不要
- システムが持つ機能に対話システムを結びつけるのは難しい
(電話をかけて、音楽を流してなど)

タスク指向対話システムの構成



早稲田から東西線に乗りたいんだけど

- 言語理解を通じてユーザ発話を**対話状態**に当てはめ
 - 履歴も考慮
- 対話状態に応じて次の**システムの行動**を決定
 - システムの行動に応じて発話を生成



言語理解と対話制御

• 言語理解

- ユーザの発話を機械が理解可能な形に変換

早稲田から東西線に乗りたい

早稲田から東西線に乗りたい
駅名 FromLine

Train_info{\$FROM=
早稲田,\$LINE=東西線}

• 対話制御

- 言語理解の結果と過去の履歴から次の行動を決定

言語理解

Train_info{\$FROM=
早稲田,\$LINE=東西線}

履歴

\$FROM=???
\$TO_GO=大手町
\$LINE=???

履歴を考慮した対話状態

Train_info{
\$FROM=早稲田
\$TO_GO=大手町
\$LINE=東西線
}

行動の決定

1 inform \$NEXT_TRAIN
2 ask \$TO_GO
...

対話における前後の文脈の利用

- 同じ言語理解結果でも履歴の存在により対話状態は異なる

– 対話状態が異なれば次の行動も異なる

履歴なし

言語理解

```
Train_info{
$FROM=早稲田,
$LINE=東西線}
```

履歴を考慮した対話状態

```
Train_inform{
$FROM=早稲田
$TO_GO=NULL
$LINE=東西線
}
```

履歴

```
Train_inform{
$FROM=NULL
$TO_GO=NULL
$LINE=NULL
}
```

履歴を考慮

言語理解

```
Train_info{
$FROM=早稲田,
$LINE=東西線}
```

履歴を考慮した対話状態

```
Train_inform{
$FROM=京都駅
$TO_GO=大手町
$LINE=東西線
}
```

履歴

```
Train_inform{
$FROM=NULL
$TO_GO=大手町
$LINE=NULL
}
```

対話状態とシステム行動のデザイン

- 対話状態はフレームとフレームが持つSlot-Valueで管理
 - フレームがドメインを表わす
 - フレームに記述されたSlotとValueの組により状態を記述


<pre>フレーム名{ Slot1=Value1 Slot2=Value2 Slot3=Value3 }</pre>	<pre>Train_inform{ \$FROM=早稲田 \$TO_GO=NULL \$LINE=東西線 }</pre>
--	---

- システムの行動 = 対話システムの挙動
 - 基本的な挙動が定義できれば
あとはフレーム + Slot-Valueの組に対応させる
 - 基本的な行動: 実行、確認など

対話状態デザインの例: 意図依存グラフ

- **タスク：音楽を流す・ボリュームを上げ下げする**


1. ROOT[] (=no specified request)
 - 疑似的なルートノード
2. PLAY_MUSIC[artist=null, album=null]
3. PLAY_MUSIC[artist=\$artist_name, album=null]
4. PLAY_MUSIC[artist=null, album=\$album_name]
5. PLAY_MUSIC[artist=\$artist_name, album=\$album_name]
 - Artist, Albumという2つのスロットを持つ音楽再生のフレーム
6. CONTROL_VOLUME[value=null]
7. CONTROL_VOLUME[value=\$up_or_down]
 - 音量に相当するスロットを1つ持つボリュームの上げ下げフレーム



対話状態デザインの例: 意図依存グラフ

- **タスク：音楽を流す・ボリュームを上げ下げする**

1. ルートノード
2. 音楽を再生 (アルバム・アーティスト未指定)
3. 音楽を再生 (アーティストのみ指定)
4. 音楽を再生 (アルバムのみ指定)
5. 音楽を再生 (アルバム・アーティスト共に指定)
6. 音量を変更 (変更量未指定)
7. 音量を変更 (変更量指定)




対話状態デザインの例: 意図依存グラフ

- 全ての達成対象となるタスクをフレームとして書き下す
- 各フレームが取り得るSlotを書き下す
 - タスク実行時にNULLになるスロットがあっても可
- スロットに値が入っている場合・入っていない場合の組み合わせを1つの対話状態とする
 - スロットの数を n としてそのフレームに 2^n 個の対話状態ができる
 - 特定のスロット値 (=Value) を状態として加えても可
 - 対話制御の精度は高くなるがより多くの計算資源が必要
- 実行可能なフレームの状態を設定する
 - 全部として設定しても可能

システム行動のデザインの例: 意図依存グラフ

- **タスク：音楽を流す・ボリュームを上げ下げする**

1. ルートノード
2. 音楽を再生 (アルバム・アーティスト未指定)
3. 音楽を再生 (アーティストのみ指定)
4. 音楽を再生 (アルバムのみ指定)
5. 音楽を再生 (アルバム・アーティスト共に指定)
6. 音量を変更 (変更量未指定)
7. 音量を変更 (変更量指定)



- **ノードに対応する行動の設定**

- 3, 4, 5, 7を実行 = 指定されたSlot値でのタスクの実行
- 1, 2, 6を実行 = 「○○を指定して下さい」という要求

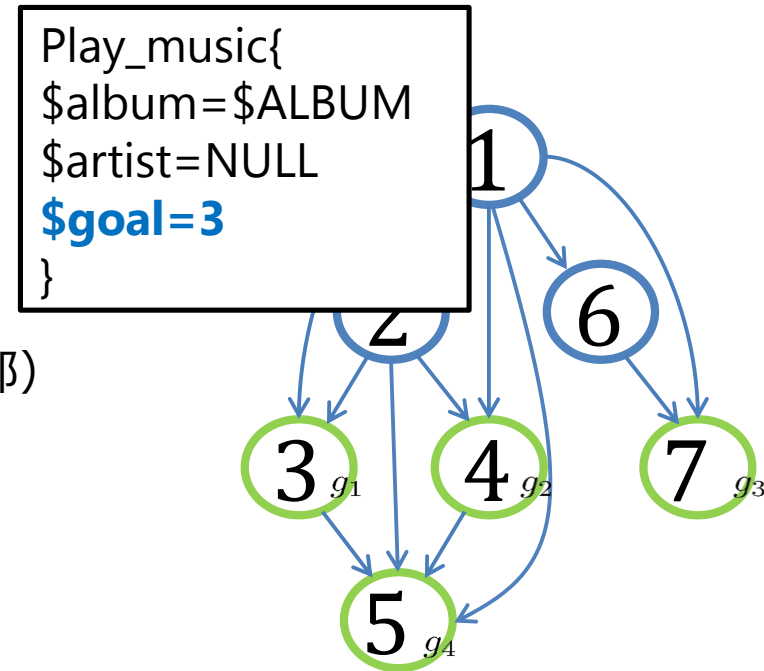
システム行動のデザインの例: 意図依存グラフ

• 行動が複数存在し得る場合は？

- 認識されたユーザの意図=3
音楽を再生（アーティストのみ指定）



1. 音楽を再生（指定されたアーティスト全部）
 2. アルバムの指定を要求（意図5へ行く）
- どちらが正解？




• ユーザゴールの設定

- ユーザがやって欲しい行動があると仮定
- これまで観測された事例からユーザのゴールがどこにあるか推測
 - 「ビートルズのアルバムを全部流して」

その他のシステム行動: 意図依存グラフ

- 各状態に対して確認の行動を付与

- 認識されたユーザの意図=3
音楽を再生 (アーティストのみ指定)
- 「ビートルズのアルバムを全て再生してよろしいですか？」
 - 毎回されると煩わしい場合もある
 - 可能性の高いゴールの仮説がまだ残っている場合には有効



- まとめると、今回状態3に対して定義する行動は

- 実行 (指定されたアーティストのアルバムを全て再生)
- 情報要求 (アルバムの指定を要求)
- 確認 (実行を行ってもよいか確認)

- その他の行動: 挨拶、対話の開始などの定型文などがありうる

対話状態推定の定式化


- 変数

- $s^t \in I_s$ ターン t のユーザ状態 (ゴールを含む)
- $a^t \in K$ システムの行動
- $o^t \in I_s$ 観測状態
- $b_s^t = P(s|o^{1:t})$ ユーザ状態が s である信念 (確率変数)

- 対話状態推定は $b_s = P(s|o^{1:t})$ を推定する問題

- Belief update: $b^{t+1} = P(s^{t+1}|o^{1:t+1}) \propto P(o'|s'_j) \sum_{s_i} P(s'_j|s_i, \widehat{a}_k) b^t$
- Recurrent NN: $h^{t+1} = U w_i + W h^t$, $b^{t+1} = V(h^{t+1})$
 - LSTMやGRUを含む

対話状態推定: 実際の動作や変数の中身



• 対話状態推定

- そのターンにおける適切な対話状態（スロット値つきフレーム）をどれだけ尤度高く（または1-bestで）予測できるか
 - 言語理解の出力する事後確率 $P(o_i | s_i)$
 - RNNに現在のユーザ発話を入力した結果の出力

システムの行動決定

- $\pi(s, a)$ **政策関数: 状態 s で行動 a を選ぶ確率**
 - 決定的に見る場合 $\pi(s) = a$ とも解釈可能
 - 政策関数でユーザ状態 s (現在の対話状態) からシステムの行動 a の写像を定義
 - ルールで言う「ユーザの状態が s の時の行動 a を記述」
- **強化学習を用いる場合**
 - 以下の報酬を定めれば最適な政策関数が定まる
 - $r = R(s, a, s')$ s の時 a を行い s' に遷移したときの報酬
 - $r_E = R_E(s, a)$ s の時 a を行い得られる報酬の期待値
 - **別に無理に強化学習を用いる必要はない**
 - **ルールで十分な場合も多々ある**

閑話休題

- **強化学習とか深層学習
使いたいんですけど...**
 - これらを使う環境が整っているか十分に考える必要
 - データはあるか
 - アノテーションはあるか
 - 計算資源はあるか
 - 十分な状態アノテーションがされた対話データがない場合、ルールベース対話から始めるのも良い選択肢

深層学習で何ができるか

- ニューラルネットワークやディープラーニングは、基本的に**写像を認識する**問題であって、写像を定義するものではありません
- 言い換えれば、**写像問題に置き換えられて、かつ正解がきちんと与えられるもの**についてはディープラーニングでほとんど解けるでしょうが、それ以外は難しいということです

【人工知能はいま 専門家に学ぶ】(11)
音声認識研究の第一人者、河原達也氏が見るA Iの世界,
Sankei-biz, 2016.12.19

行動決定の定式化

- $\pi(s) = a$ の最適なものを求める

- $Q^\pi(s, a) = \sum_{k=0}^{\infty} \gamma^k r_E$

- a が有限個であれば全ての a に対して $Q(s, a)$ が計算でき

$\max_a Q(s, a)$ により最適な政策 $\pi^*(s) = a$ が定まる

- Q学習

- $Q(s^t, a^t) \xrightarrow{\text{update}} (1 - \alpha)Q(s^t, a^t) + \alpha \left(r^t + \gamma \max_{a^{t+1}} Q(s^{t+1}, a^{t+1}) \right)$

- α : 学習率 γ : 割引率

- 深層学習でも定式化は同じ

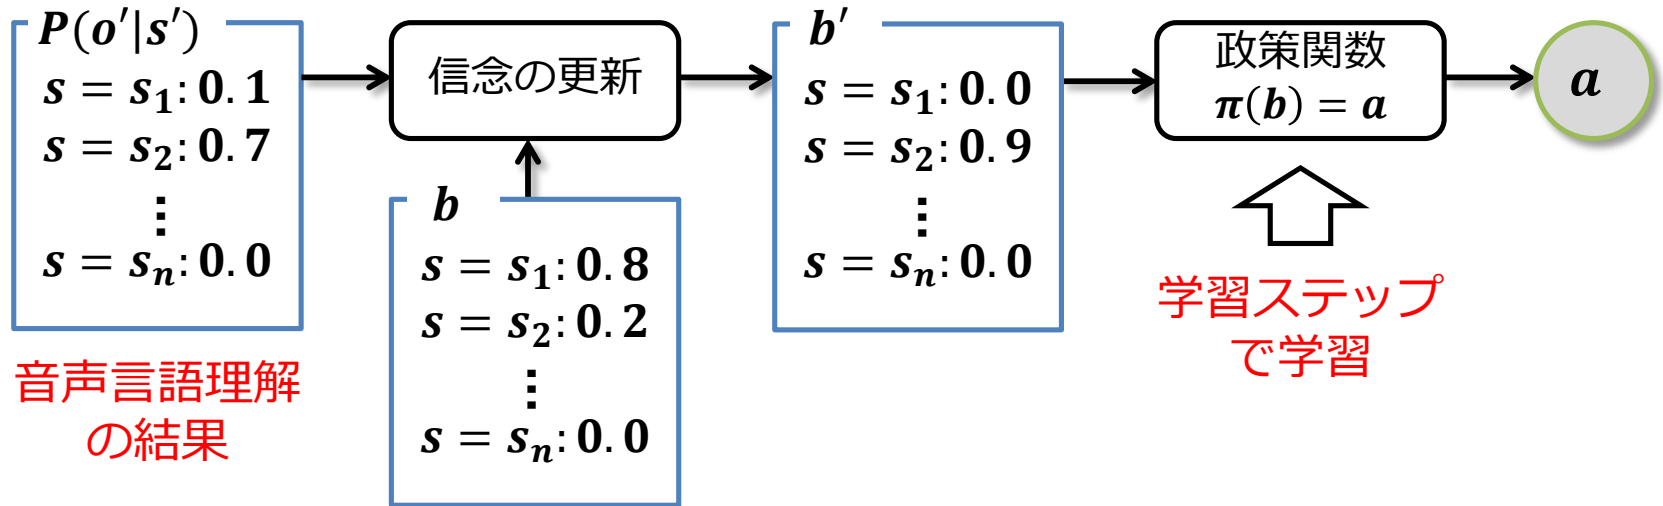
- Q値を予測する教師あり学習 $\mathcal{L}(\theta_i) = E_{s,a,r,s'}[(y - Q(s, a))^2]$

- Q値のターゲットは試行ごとに更新 $y = r^t + \gamma \max_{a^{t+1}} Q(s^{t+1}, a^{t+1})$

誤りを含む音声認識・言語理解

- **音声認識結果・言語理解結果には誤りが含まれる**
 - 統計的言語理解において結果は確率変数として与えられる
 - 与えられるのは s ではなく b_s (信念)
- **Partially Observable Markov Decision Process (部分観測マルコフ決定過程) による行動選択**
- **部分観測下で最適となる政策 $\pi^*(b) = a$ を学習したい**
 - 対話研究の大きな問題の1つ
 - 学習に使える対話データの量は限られている
- **最新の研究などについては以下**
 - <http://pomdp.net/docs/Kyoto-U0321.pdf>
 - <https://sites.google.com/site/deeplearningdialogue/>

対話制御の全体像



- $s \in I_s$
- $a \in K$
- $o \in I_s$
- $b_i = P(s_i | o^{1:t})$
- $\pi(b, a)$

ユーザ状態

システムの行動

観測状態

$s = s_i$ である信念 (確率変数)

政策関数

タスク指向型対話のまとめ

- システムに想定される振る舞い（APIで規定される応答）が存在する場合は非常に有効
 - タスクを厳密に定義する必要
 - モジュールが個別化しているのでコントロールが容易
- **タスク指向型対話システム構築に役立つデータセット**
 - DSTC2 and 3: Dialogue State Tracking Task
<http://camdial.org/~mh521/dstc/>
 - DSTC6: End-to-End Goal Oriented Dialogue Learning
<http://workshop.colips.org/dstc6/call.html>

一問一答型対話

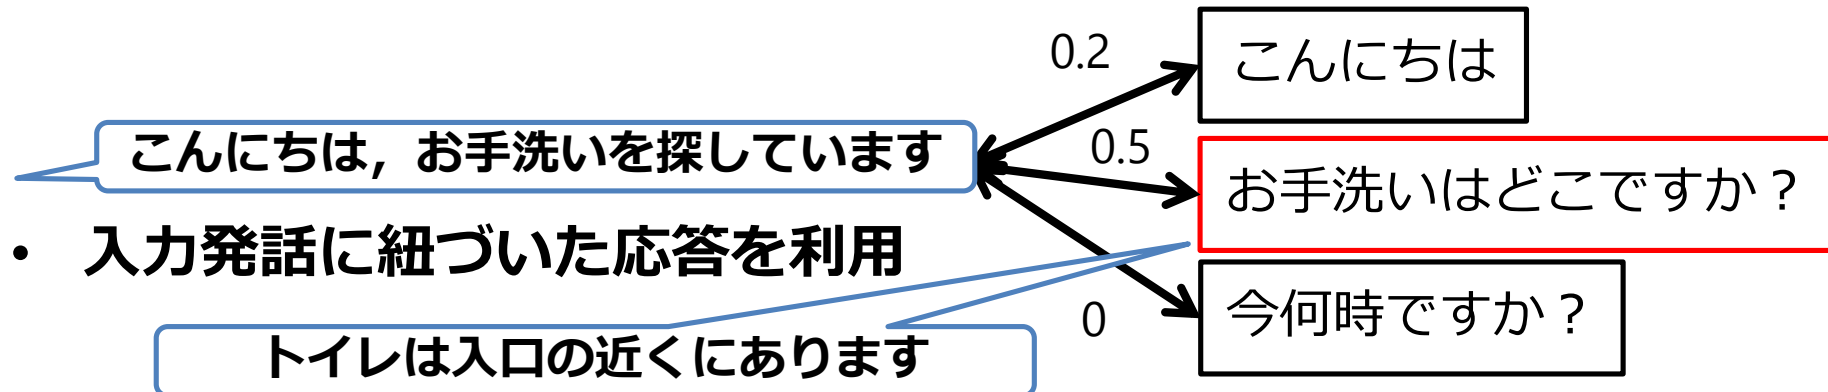
- 一問一答ではタスク指向と異なりクエリに対応する応答を学習
 - オープンドメインで有効（データ量がモノをいう）
 - チャットボット・質問応答など一問一答で完結する（履歴を用いる必要がない）場合に非常に有効
 - 履歴を用いるとより複雑なモデルに
 - 近年は履歴もNNが勝手に管理するというモデルも
 - **基本的には制御を放棄する**
 - システムが何を言うのかコントロールするのが非常に難しい
- 近年Seq2seq（Sequence to sequence）の流行から一大ブームに

用例対話システム

- 入力発話例/応答文対を用意

入力発話例	応答文
こんにちは	こんにちは
お手洗いはどこですか？	トイレは入口の近くにありますが
今何時ですか？	今は<Hour>時<Minute>分です

- 入力発話例と実際の入力との類似度を計算



- 入力発話に紐づいた応答を利用

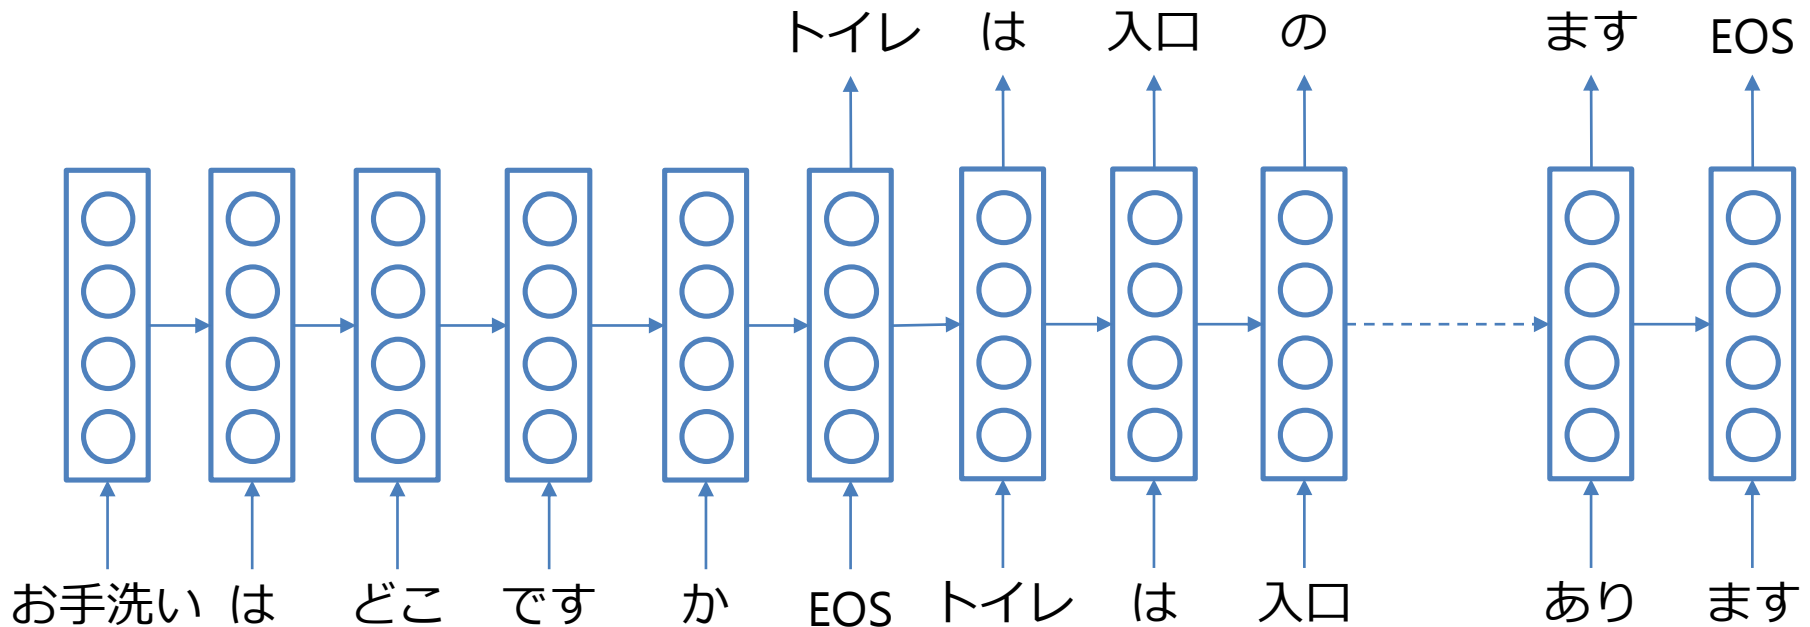
学習ベースアプローチ

入力発話例 (q_i)	応答文 (r_i)
こんにちは	こんにちは
お手洗いはどこですか？	トイレは入口の近くにあります
今何時ですか？	今は<Hour>時<Minute>分です

- **用例をそのまま用いるのではなく用例中の写像を学習**
 - $r_i = f(q_i)$ を学習
 - 誤差関数として例えば二乗誤差 ($|r_i - f(q_i)|^2$) を用いる
- **用例対話では明らかに対応できない場合でも生成可能**
- **写像になっていない場合学習が難しい**
 - データのクリーニングが重要
 - 「こんにちは→こんにちは」 「こんにちは→おはよー」

Seq2seqモデル

- 発話を一単語ずつNNに入力し出力を生成
 - Encoder-decoderとも呼ばれる
 - RNN, GRU, LSTMなどで動く
 - 長い発話を生成することが（経験的には）難しい



一問一答型対話の定式化

- $\langle q_i, r_i \rangle$: データ中のユーザクエリと応答のペア
- q_u : ユーザ発話
- r_s : システムの応答

- 用例アプローチ（ひと昔前の質問応答システムもこの方法）
 - $r_s = \operatorname{argmax}_i (\operatorname{Sim}(q_i, q_u))$
 - ユーザに最も類似するクエリを見つけ、その応答を応答として利用
- 学習アプローチ
 - $r_s = f(q_u)$ を学習
 - 用例と比較して色々な場合に対応可能だが非文を生成する可能性

ニューラル以後の展開

- **NNのバリエーションによって様々なモデルが提案**
 - Memory Networkなど
 - <http://deeplearning.hatenablog.com/>
- **基本的にはコントロールが非常に難しい**
 - 学習に使ったデータによっては口調もバラバラになったりする
 - A Persona-Based Neural Conversation Model
データにおける話者の情報を学習に含めコントロール
 - パラメータの設定による発話のコントロールは研究のトレンド

非タスク指向のまとめ

- **オープンドメインで大量の発話対から学習**
 - とりあえず何かしらの応答を行うものが作成可能
 - 対話状態の定義・アノテーションは不要
 - 学習データのクリーニング・統制が可能なら適切な応答生成が可能
 - それ以外の方法でのコントロールは困難が伴う

- **非タスク指向型対話システムに役立つデータセット**
 - bAbIタスク: QAやチャットなどのデータセット
 - <https://research.fb.com/downloads/babi/>
 - DSTC6: End-to-End Conversation Modeling
 - <http://workshop.colips.org/dstc6/call.html>

非タスク指向とタスク指向

- **タスク指向**

- システムに想定される振る舞い（APIで規定される応答）が存在する場合は非常に有効
- Out domain発話に対しては無力（理解できませんでした）

- **非タスク指向**

- オープンドメインで何かしらの応答を行うものが作成可能
- 制御とは無縁: システムが想定するアプリで使えない

それぞれを組み合わせられればよいのでは？


複数の対話システムのハイブリッド

- **それぞれを対話モジュールとして階層化**
 - どの対話モジュールが話すかを選択する対話制御を行う
Information Navigation System
 - 対話制御の報酬としてはユーザの満足度・対話継続長を利用
- **対話モジュールの合議制**
 - どのモジュールを利用するか各モジュールが出力する仮説と事後確率に応じて都度決める
Bayesian Committee Machine

対話システムを作成する前に

- **自身が作成する対話システムの目的を明確化する**
 - ユーザに伝える情報が明確・すべきゴールが明確 → タスク指向
 - オープンドメインで雑談・種々の文書からの検索 → 非タスク指向
 - 対話的文書検索はそれはそれで先行研究あり
- **どのようなリソースがあるかを明確化する**
 - 想定するタスクの対話状態は定義できるか → タスク指向
 - 想定する対話相当のデータは存在するか → データドリブン
 - ルールで描ける範囲内か → 描けるならルールで
- **どの程度労力が割けるのかを明確化する**
 - 対話状態をデータに付与することは可能か
 - 対話データがない場合収集は可能か

DSTC6



Dialog System Technology Challenges

Long Beach, USA, December 10, 2017

- **6回目になる対話システム関連技術のコンペ**
 - 今回は以下の3タスク
 - End-to-End Goal Oriented Dialog Learning
 - End-to-End Conversation Modeling
 - Dialog Breakdown Detection
- <http://workshop.colips.org/dstc6/>
 - 今日紹介したデータもいくつか入手可能
 - 学習データはコンペに参加しなくても利用可能
 - 2, 3回目のデータも利用可能

参考論文

- **対話状態推定**

- Word-Based Dialog State Tracking with Recurrent Neural Networks. Henderson et al., In Proc. SIGDIAL, pp, 292-300
- Dialogue State Tracking using Long Short Term Memory Neural Networks. Yoshino et al., In Proc. IWSDS, 2016.
- A MULTICHANNEL CONVOLUTIONAL NEURAL NETWORK FOR CROSS-LANGUAGE DIALOG STATE TRACKING. Shi et al., In Proc. IEEE-SLT 2016

- **行動決定**

- Towards End-to-End Learning for Dialog State Tracking and Management using Deep Reinforcement Learning. Zhao et al., In Proc. SIGDIAL, 2016
- The hidden information state model: A practical framework for POMDP-based spoken dialogue management. Young, et al. *Computer Speech & Language* 24.2 (2010): 150-174.

参考論文

- **End-to-End modeling**

- "A neural conversational model." Vinyals, Oriol, and Quoc Le. *arXiv preprint arXiv:1506.05869* (2015).
- "Learning phrase representations using RNN encoder-decoder for statistical machine translation." Cho, Kyunghyun, et al. *In Proc. EMNLP* (2014).

- **ハイブリッドアプローチ**

- "Conversational system for information navigation based on POMDP with user focus tracking." Yoshino, Koichiro, and Tatsuya Kawahara. *Computer Speech & Language* 34.1 (2015): 275-291.
- "Policy committee for adaptation in multi-domain spoken dialogue systems." Gašić, M., et al. *Automatic Speech Recognition and Understanding (ASRU), 2015 IEEE Workshop on*. IEEE, 2015.

参考論文

- その他スライドで出した論文

- "Statistical Dialogue Management using Intention Dependency Graph." Yoshino et al. *IJCNLP*. 2013.
- Towards End-to-End Learning for Dialog State Tracking and Management using Deep Reinforcement Learning. Zhao et al., In Proc. SIGDIAL, 2016
- Adaptive selection from multiple response candidates in example-based dialogue. Mizukami et al., In Proc. ASRU, 2015.
- "A Persona-Based Neural Conversation Model." Li, Jiwei, et al. In Proc. ACL 2016.