

音声言語処理アプリケーション

奈良先端科学技術大学院大学

吉野 幸一郎

<http://www.pomdp.net>

**Nara Institute of Science and Technology
Augmented Human Communication Laboratory**




自己紹介

- 吉野 幸一郎 (よしの こういちろう)
- 2009年 慶大 SFC 石崎研卒業 (自然言語処理)
- 2014年 京大 情報 河原研博士修了 (音声言語処理) + PD
- 2015年 NAIST 情報 中村研 (音声言語処理、ビッグデータ)
- 研究分野
 - 音声対話システム
 - 音声認識
 - 意味解析
 - ビッグデータ解析



奈良先端科学技術大学院大学 (NAIST)


1. 東京から京都へ2.5時間
 2. 京都から高の原へ40分
 3. 高の原からバスで30分
- 音声・言語処理が盛ん
(中村研・松本研)



音声言語処理アプリケーション

- **「音声で何かを操作する」
ことが普及**
 - 電話を掛ける
 - カーナビを操作する
 - 少なくとも「できる」とは認識されている
 - 使われているかどうかは別
- **現在の音声言語処理は何ができるのか？**
 - 実際に音声認識が使われている場面
 - 音声言語処理の性能を理解したアプリケーションの構築

音声言語処理アプリケーションの構造




音声認識と深層学習

- 音声認識の仕組み


$$\operatorname{argmax}_W P(W|X) = \operatorname{argmax}_W \underbrace{P(X|W)}_{\text{音響モデル}} \underbrace{P(W)}_{\text{言語モデル}}$$

W は単語列、 X は音声

GMM-HMM



DNN-HMM



音声認識の現在

• 既にできること

- 大規模計算クラスタを用いたクラウドでの大語彙音声認識
 - ドメインに適応できればさらに認識精度は向上
- 接話マイクでの音声認識
 - 衆議院の議事録作成、スマートフォンの認識アプリ

• これからの課題

- モバイル上でのスタンドアローンでの音声認識
 - 現状は認識はクラウド → **リアルタイムではない**
- 非接話での認識
 - 離れると劇的に認識精度が低下・マイクアレイが必要

実用的な音声言語処理アプリを作るために

- **入力される音声が想定しやすいデザイン**
 - システム側から発話の形を誘導する
 - 対話システムに対する目的を明確化する
- **音声認識率は100%にならない**
 - 必ず認識誤りを想定した処理を行う
 - 100%に近付ける努力（音響・言語モデルの適応）
- **競合する入出カインタフェースとの比較**
 - 音声よりも効率的な入力手段はないか
 - 他のモダリティが使いづらい状況

タスク指向型対話システム

- ユーザの目的（ゴール）を達成


- チケットの予約
- レストランの案内

- ゴールに合わせたタスク・ドメイン知識の定義

e.g. オートマトン + RDB

- 定義されたタスク・ドメインでよく動く☺

- タスクフロー・ドメイン知識の定義が大変☹



ゴール・タスク・ドメイン知識

- **ゴール**

- **対話参与者（ユーザとシステム）で共有される対話目標**

- バス案内システム: 次の銀閣寺行きのバスの時間 ...
 - 質問応答システム: 富士山の高さ、金閣寺の拝観料 ...

- **タスク**

- ゴールに到達するために定義される

- タスクフロー、質問のパターンなど


- **ドメイン知識**

- タスクを実現するのに必要な知識


- バス停の名前 など

タスク指向型対話システムの成功例 (京都市バス案内システム)

- Flexible guidance generation using user model in spoken dialogue systems. Komatani et al. In Proc. ACL, pp.256—263, 2003.
- 京都市バスのサービスとして実運用
 - サービスの電話番号に電話すると IVR (自動音声応答)
- 乗車場所、降車場所、系統番号を音声で入力
 - 指定したバスがどれくらいで到着するかが得られる
- 制御: VoiceXMLを動的に生成
- 語彙: バス停: 652, 名所・施設: 756



認識誤りを考慮した言語理解



- ユーザの発話生成（真の意図から発話）
- 音声認識（声を発話内容へ）
- 意図理解（音声認識結果を意図理解結果へ）


$$P(o|s) = \sum_h P(o, h|s) \approx \sum_h \underbrace{P(o|h)}_{\text{意図理解の識別確率}} \underbrace{P(h|u)}_{\text{音声認識の尤度}}$$

対話における前後の文脈の依存

$$b' = P(s^{t+1} | o^{1:t+1}) \propto \underbrace{P(o' | s'_j)}_{\text{観測確率}} \sum_{s_i} \underbrace{P(s'_j | s_i, \widehat{a}_k)}_{\text{状態遷移確率}} \underbrace{b^t}_{\text{現在の信念}}$$



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

- Recurrent Neural Network と相性がよい!



Recurrent Neural Networkを用いた言語理解

- Word-Based Dialog State Tracking with Recurrent Neural Networks. Henderson et al., In Proc. SIGDIAL, pp, 292-300, 2014.




図は論文より引用


Recurrent Neural Network → Long Short Term Memory Neural Network

- LSTMは（大まかに言うと）より距離が離れた系列情報を保持可能なRNN
- Dialogue State Tracking using Long Short Term Memory Neural Networks. Yoshino et al., In Proc. IWSDS, 2016.
- Context Sensitive Spoken Language Understanding using Role Dependent LSTM layers. Hori et al., In Proc. NIPS-WS, 2015.
- Incremental LSTM-based Dialog State Tracker. Zuka et al., In Proc. ASRU, 2015.


Long Short Term Memory Neural Networkを用いた言語理解



Long Short Term Memory Neural Networkを用いた言語理解




Long Short Term Memory Neural Networkを用いた言語理解



言語理解結果に対する行動選択

- s^t : ターン t のユーザの行動
 - 具体的な行動: Select \$FROM, Select \$TO_GO ...
 - 対話の履歴: \$FROM=神保町駅, \$LINE=半蔵門線
- a^t : ターン t のシステムの行動
 - 次の行動: Ask \$TO_GO, Ask \$LINE, Confirm ...
- ユーザの行動は $P(s^{t+1}|s^t, a^t)$ に従う
(マルコフ性があると仮定する)
 - 強化学習で解ける



強化学習を用いた対話制御

- $s \in I_s$ ユーザ状態
- $a \in K$ システムの行動
- $R(s, a)$ 報酬関数 タスク達成時に報酬を与える
- $\pi(s) = a$ 政策関数 **これを効率よく学習したい**
- ϵ 学習率
- γ 忘却率

- 価値関数 $V^\pi(s) = \sum_{k=0}^{\infty} \gamma^k R(s^{t+k}, a^{t+k})$ を最大化する
政策関数の選択

- Q学習では以下の式で政策関数を学習する


$$- Q(s^t, a^t)$$

$$\xleftarrow{\text{update}} (1 - \epsilon)Q(s^t, a^t) + \epsilon \left(R(s^t, a^t) + \gamma \max_{a^{t+1}} Q(s^{t+1}, a^{t+1}) \right)$$

曖昧な言語理解結果に対する行動選択

- **いずれの手法も言語理解結果は確率変数として与えられる**
 - アプリケーションは入力に対して行動選択が必要
 - 与えられるのは s ではなく b_s
- 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**

POMDPによる対話制御




音声言語理解
の結果

学習ステップ
で学習

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


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)
報酬関数
政策関数

POMDPの更新




- $$b' = P(s^{t+1} | o^{1:t+1}) \propto \underbrace{P(o' | s'_j)}_{\text{観測確率}} \underbrace{\sum_{s_i} P(s'_j | s_i, \hat{a}_k)}_{\text{状態遷移確率}} \underbrace{b^t}_{\text{現在の信念}}$$
- 信念を更新
 - 次の行動を出力する政策関数の入力


(古典的な) POMDPの学習



- 信念空間上でサンプリングされた任意の点にマッピング
- マッピングされた点においてシミュレータとの学習で得られた政策関数で行動を決定 ($Q(b, a)$ を最大化)



MDP → POMDPの効果



図は論文より引用

- POMDPの方がエラーが多い場合でも頑健に動作
 - Partially observable Markov decision processes for spoken dialog systems. Williams et al., Computer Speech & Language, 393—422, Vol.22, No.1, 2007.

対話システムにおけるPOMDPの問題


- **最適な π^* () を得られるほど学習データがない**
 - 効率的な学習手法が必要
1. **ルールとPOMDPの併用**
 2. **効率的なサンプリング**
 3. **効率的なQ関数の計算**

ルールとPOMDPの併用

- The hidden information state model: a practical framework for POMDP-based spoken dialogue management
Young et al., Computer Speech & Language, Vol.24, No.2, pp.150-174, 2010.
- Statistical dialogue management using intention dependency graph. Yoshino et al., In Proc. IJCNLP, pp.962-966, 2013.
- **人手で与えたルールを探索空間の制約とする**

Hidden Information State Model


Turn 0



1 partition: task() b= 1.0

S: How may I help you?

Turn 1




U: I want to find a <mumble>.
=> inform(task=find, type=restaurant)
inform(task=find, type=bar)

4 partitions: b=0.6 task()
b=0.12 find(venue(restaurant(food=?, ...), name=?, ...))
b=0.16 find(venue(bar(drinks=?, ...), name=?, ...))
b=0.12: find(venue(type=?, name=?, ...))

図は論文より引用

Hidden Information State Model




図は論文より引用

Intention Dependency Graph

- あらかじめ定義されたタスク構造間の遷移確率を定義

1. ROOT[] (=no specified request)
2. PLAY_MUSIC[artist=null, album=null]
3. CONTROL_VOLUME[value=null]
4. PLAY_MUSIC[artist=\$artist_name, album=null]
5. PLAY_MUSIC[artist=null, album=\$album_name]
6. CONTROL_VOLUME[value=\$up_or_down]
7. PLAY_MUSIC[artist=\$artist_name, album=\$album_name]




ルールやタスク構造を併用するメリット

- **新ドメイン・システムのローンチ**
 - まずはルールベースでデータを集める
 - スムーズに統計ベースにシフトできる
- **未観測の状態・系列に対して重み付け可能**
 - 全ての状況をカバーする対話データを学習用に用意することは困難
- **未観測の状態・新しいドメインへの適応は大きな課題**

効率的なサンプリング

- 均等に信念空間をサンプルするのは非効率



- GBVI: 均等なグリッドに沿って Belief point を選択
- PBVI: 実際の分布にあわせて Belief point に偏りを持たせる
 - 例では s_1 と s_3 がよく間違われやすい状態

効率的なQ関数の計算

- POMDPの学習は $Q(\mathbf{b}, \mathbf{a})$ の最大化問題
 - あらゆる \mathbf{b}, \mathbf{a} に対しQ値が計算できればよい
- $Q(\mathbf{b}_i, \mathbf{a}_i)$ が既知の場合、 $Q(\mathbf{b}_k, \mathbf{a}_k)$ を求めるためには $(\mathbf{b}_i, \mathbf{a}_i)$ と $(\mathbf{b}_k, \mathbf{a}_k)$ の類似度を用いればよい
 - この類似度を求めるカーネルを学習する
- Bayesian update of dialogue state: A POMDP framework for spoken dialogue systems. Thomson et al., Computer Speech & Language, vol. 24, no. 4, pp. 562–588, 2010.

一問一答の質問応答

- 2000年頃から盛んに行われていた研究タスク
 - NTCIRなど
- **IBM Watson の登場**
 - 質の良い質問・応答ペアを集めるというアプローチ
 - 近年では推論の研究が盛ん
- **これまでの多くの音声対話システムは**
 - **特定のタスク達成対話システム**
 - **一問一答の質問応答**
 - **Webなどを用いた検索**

などの組み合わせで構成されている

タスク指向対話システムの構築に重要な点

- **ユーザが明確な意図発信をできるタスクデザイン**
 - ユーザが何を言っているかわからない状態を防ぐ
 - ファーストフード店の優秀な店員を目指す
- **必要十分なタスク構造**
 - 大ざっぱすぎると何も出来ない
 - 細かすぎると制御の学習がうまくいかない
- **対話が失敗したときのフォールバック**
 - Webで調べるなどで何もできない印象を軽減

非タスク指向におけるシステム構築

- Conversational System for Information Navigation based on POMDP with User Focus Tracking. Yoshino et al., Computer Speech & Language, Vol.34, Issue.1, pp.275--291, 2015.
- **ユーザの意図が曖昧でも動作するデザイン**
 - システムからの能動的な働きかけ
 - 対話が失敗したときのフォールバック
- **ユーザの意図を大まかに抽象化**
 - 対話のシチュエーションを限定
- **システムが行いたい行動に合わせた観測状態の導入**
 - 情報案内システムでは話題の注目状態に相当する焦点を導入


情報案内対話システム

- **知識ベース（文書）に記述された内容を案内するタスク**
 - 日々動的に更新されるニュース記事
 - ドメインを規定
 - 自動抽出したドメイン知識の利用
- **話し手（システム）が順番にトピックを提示**
 - 聞き手の聞きたいことを明確化
 - ドメイン知識
 - ユーザの意図
 - ユーザの焦点




今日阪神はー...

阪神が巨人に逆転
勝ちしたよ




情報案内システム




情報案内対話の構造

話し手 (System)



聞き手 (User)



情報案内対話における対話の機能

- 各ターンのユーザ意図に対する最適なモジュールの選択
- ユーザ意図 s :
 - **TP**: トピックの紹介要求
 - **ST**: 詳細の説明要求
 - **QA**: 質問
 - **GR**: 挨拶
 - **II**: 音声認識誤りに起因する無効入力
 - **NR**: 一定時間の無音
- システムの行動 a :
 - TP**: トピックの紹介
 - ST**: トピックの詳細説明
 - QA**: 質問に対する回答
 - GR**: 挨拶
 - KS**: 無音 (反応なし)
 - CO**: 意図の確認
 - PP**: プロアクティブな情報推薦

対話における焦点

Example 1

...

Usr: **田中は** どこで練習したの？

Sys: 田中は20日、ヤンキースのキャンプでブルペンに入り投球練習を行ったよ。

Usr: (無音)

Sys: ところで、田中は2月18日にも落ちるツーシームを練習したよ。

...

Example 2

...

Usr: 何かあったんですか？

Sys: 宮崎でゴジラ弾が復活したよ。

Usr: (無音)

Sys: スーパーエースへ。藤浪晋太郎はルーキーイヤーから進化しているのか

...

- 例1: ユーザが焦点を持っているのでシステムは話題を継続
- 例2: ユーザに焦点がないのでシステムは次の話題を提示



適応的な対話制御に**発話内での焦点の有無の導入が効果的**
焦点は「ユーザへの情報案内に不可欠な対象」として定義

音声言語理解の評価

焦点解析

問題	精度
文節ごとの解析精度	78.5%
発話中に焦点があるか(0 or 1)	99.9%

意図理解

素性	タグ	再現率
	TP	98.7%
	ST	81.1%
	QA	95.1%
	GR	97.7%
	II	31.3%
	All	93.6%

- 事前に収集した18話者918発話を書き起こし・アノテーション
 - **ユーザの意図**: どのモジュールがユーザへの応答に最適か
 - **焦点**: 発話で最も情報案内に不可欠な対象 (最大1個)
 - 5分割交差検定
- $P(o|h)$ (前後のターンを考慮しない場合)

焦点を用いた対話制御の拡張

- 発話に焦点が存在するかのブール値 $f = 0$ or 1 を導入

- $b' \propto P(o'_{s'}, o'_{f'} | s'_j, f'_m) \sum_i \sum_l P(s'_j, f'_m | s_i, f_l, \widehat{a}_k) b_{s_i, f_l}^t$

- 観測モデル (独立を仮定)

- $P(o'_{s'}, o'_{f'} | s'_j, f'_m) \approx P(o_s^{t+1} | s'_j) P(o_f^{t+1} | f'_m)$

- 遷移モデル (焦点が定まってからユーザ状態が定まる)

- $P(s'_j, f'_m | s_i, f_l, \widehat{a}_k) = P(f'_m | f_l, s_i, \widehat{a}_k) P(s'_j | f'_m, f_l, s_i, \widehat{a}_k)$

- 政策関数

- $\widehat{a} = \pi^*(b_{s,f})$

情報案内システムの評価

- 評価指標

- DST (ユーザの意図の追従精度)
- ACT (システムの行動の選択精度)

- 評価データ

- 12ユーザ24対話626発話の実ユーザとの対話を収集
- アノテータ2名によって各発話のユーザの意図(s)
 - 対応するシステムの行動(a)をアノテーション
- アノテーション一致率
 - s : 0.958 ($\kappa=0.938$)
 - a : 0.944 ($\kappa=0.915$)

情報案内システムの評価

	Rule	POMDP w.o. focus	POMDP proposed
DST	0.812 (=508/626)	0.853 (=534/626)	0.867 (=543/626)
ACT	0.788 (=539/684)	0.751 (=514/684)	0.854 (=584/684)

- 焦点の導入によりユーザ意図の追従精度が向上
- 焦点の導入により行動選択の精度が向上
- 提案法はユーザ焦点に応じた情報の推薦が可能
 - 35回推薦を行い、17回でユーザのさらなる興味を誘発

非タスク指向型システムの構築

- **ユーザがシステムと対話する場面の想定**
 - 場面を明確化
→システムがとる行動・観測するユーザ情報を明確化
- **必要な会話の粒度に合わせた抽象化・階層化**
 - 使う手法に応じた抽象化が必要
 - 無理に統計的手法を使う必要はない


発話生成（文生成）

- Semantically Conditioned LSTM-based Natural Language Generation for Spoken Dialogue Systems. Wen et al., In Proc. EMNLP, 2015.
- **これまでの対話システムにおける文生成の問題**
 - **ルールやテンプレートを利用**
 - 表現のバリエーションを生み出すことが難しい
 - 異なるドメインに移行するのが大変
 - **統計ベースの制御の難しさ**
 - 上記の問題を解決するが適切な文を生成しないことがある
 - **適切さ、自然さ、理解しやすさ、バリエーションが重要**
 - 同時に満たすのが難しい

LSTMを用いた発話生成

recurrent
hidden layer

embedding of
a word



1-hot dialog
act and slot
values

上のセルは言語モデル
に相当

下のセルは「言うべきこと」を満たしているかに対応

図は論文から引用

End-to-endの音声言語処理

- **言語理解・対話制御を行わない**
 - 入力発話から直接出力発話を推定する
- **用例対話システム**
 - ユーザ発話とシステムの応答の対を大量に用意
 - 用意された用例のどれに一番一致するか
- Adaptive selection from multiple response candidates in example-based dialogue. Mizukami et al., In Proc. ASRU, 2015.
 - 用例の良さをユーザ満足度で定量化・好みを学習
- End-to-end memory networks. Sukhbaatar et al., In Proc. NIPS, 2015.
 - Neural Network (LSTM)を用いて入力から直接出力発話を推定

フロントエンド出力層に 統計的手法を配置するリスク

- **Neural Networkなどの統計的手法は制御が難しい**
 - 出力してはいけない文
 - 文法的には正しいが意味的に正しくない文
- **これらの問題をフィルタする機構が必要**
 - 用例作成の段階でのフィルタ
 - 意味的な正しさを向上させる機構
- **構築する際に手法に対する理解が必要**
 - ブラックボックスのままでは難しい

オープンドメインシステムの構築

- **チャット型対話システムのオープンドメイン化**
 - 用例ベースなどのシステムは拡張が容易
 - 多様なドメインに対応可能
- **タスク対話システムもドメイン適応の研究は盛ん**
 - Policy committee for adaptation in multi-domain spoken dialogue systems. Gasic et al., In Proc. ASRU, 2015.
 - 複数のドメインシステムを構築し「どのドメインについて話すのが適切か判定する」
 - 異なるドメインの対話データも学習に利用可能

その他の音声言語処理の可能性

- **より自然な音声合成**
 - 現在の音声合成は既に非ネイティブ以上
- **講演に対する字幕付与（情報保障）**
 - SIG-AAC（情報処理学会アクセシビリティ研究会）
- **音声言語処理技術を用いた語学教育**
 - 音声認識結果と字幕を使ったリスニング教育
 - 非英語母語話者の音声認識を用いたスピーキング教育
 - 既に中国では国家プロジェクトとしてシステム開発を開始
- **音声言語処理技術を用いた教育**
 - 発達障害に対するコミュニケーショントレーニング
- **高齢者社会へ向けた見守りシステムの実現**

音声言語処理のこれから

- **様々なモダリティの併用**
 - 人間は音声以外にも視線・ジェスチャーなどを利用
- **より粒度の細かいターンテイキング**
 - 従来は「音声区間の検出 = 相手のターン」
- **漸進的な処理**
 - リアルタイムコミュニケーション
- **意味の扱い**
 - 文意をどう扱っていくか

より自然な音声言語インタラクションを目指して

- ERATO 石黒共生ヒューマンロボット
インタラクションプロジェクト




- 人間らしいコミュニケーション技術
 - 自然な応答タイミング・ジェスチャー・相槌 etc...
- 遠隔音声認識
 - 非接話・雑音環境下での音声認識
- 適切な意図理解
 - タスク指向・非タスク指向

音声言語処理分野における国際コンペ

- 音声認識: CHiME challenge
 - 実環境下における音声認識精度の向上
- 対話状態推定: Dialogue State Tracking Challenge
 - タスク対話におけるユーザ発話意図の推定
- 言語処理: CoNLL Shared Task
 - 係り受け、項構造など言語処理の分野における重要なタスク
- その他機械翻訳・音声翻訳・音声認識など多数のコンペ
 - 配布されるデータに対する精度を競う

Dialogue State Tracking Challenge

- 発話の意図理解



意図

```
"frame_label": {  
  "情報":  
    ["アクティビティ"],  
  "NEIGHBOURHOOD":  
    ["奈良駅"]  
}
```

- 多様な研究機関が参加する国際コンペ
 - 過去に NAIST, Panasonic, MIT, XEROX, IIR, Microsoft, Cambridge などが参加

Take home messages

- **音声言語処理は実用のフェーズに入っている**
- **ただし現状は目的・手法をよく理解した
専門家が必要**
- **これからを考える上で他分野との連携が重要**
- **Shared Task などを通じた資源の整備も重要**