

第8回人工知能セミナー

知能の原理解明と創発に向けて

2016年7月4日

国立研究開発法人産業技術総合研究所
人工知能研究センター

実世界に埋め込まれるAI



人間と協働して問題解決するAI

知能の解明と社会実装

Grand Challenge
マイルストーンの設定

Grand Challenge
マイルストーンの設定
Ajail な社会実装

知能の解明

社会実装

メディエータ
インタプリタ

数理的基盤

論理、機械学習・確率モデリング
非線形ダイナミカルシステム

ベイズ的な確率モデリング による知的情報処理

国立研究開発法人産業技術総合研究所
人工知能研究センター(AIRC, AIST)

麻生 英樹

AIRC 人工知能セミナー
知能の原理解明と創発に向けて
2016年7月4日

知能の創発に向けて

- 環境の中で試行錯誤的に相互作用しながら自律的に学習するシステム
→ 言語記号的知能にまで到達したい
- 好奇心を持ちつつ世界とインタラクションし、それを通じて言語を獲得して、人と対話したり、自分で本を読んだりしながら、自律的に賢くなってゆくシステム

知能とはなんだろうか？

- 複雑な情報処理プロセスである
(認知革命, 1960年代)
- どのような情報処理プロセスか？
- 何を何から計算しているのか？
- どのような情報を扱っているのか？
- 情報はどう表現されているのか？
- 情報はどう操作されているのか？

知能 = 記号計算？

- 記号操作や論理的推論が知能の中心的な情報処理
- チューリングマシン
- 一般問題解決器
- 物理的記号システム仮説
- 論理推論マシン




積み木の
世界

記号処理とパターン処理

意識に登る
記号処理

無意識の
パターン処理



パターン情報処理装置としての脳

- 脳への入力も出力も、膨大な数の神経線維
= 高次元の時系列信号
- コンピュータとはかなり違う仕組みで動いている
- にもかかわらず記号操作ができる
- 記号操作の背後には
膨大なパターン情報処理がある

Marr の脳の三部作 [Marr 1969-71]

- 脳が行っている情報処理は？
 - 小脳の理論 (1969) : パーセプトロン
 - 大脳皮質の理論 (1970) : 教師無し学習
 - 古皮質 (海馬) の理論 (1971) : 連想記憶
- cells in the neocortex are flexible categorizers—that is, they learn the **statistical structure of their input patterns** and become sensitive to combinations that are frequently repeated. (Wikipedia)

David Marr の3つのレベル

[David Marr, 1982]

- 脳のような複雑な情報処理メカニズムを理解するには3つのレベルでの考察が必要
 - Computational Level (計算理論)
What: 情報処理の目的の定式化
 - Representation and Algorithm Level (表現とアルゴリズム)
How1: 目的達成のための情報・知識の表現とその操作手続き
 - Implementation Level (実装)
How2: 表現とアルゴリズムの物理的実現方法

視覚情報処理の計算理論

[Marr 1982]

- 視覚情報処理を
2D 表現（網膜像）→ 3D 世界の状況
の推定問題（逆問題）として定式化
- 視差からの 3D形状復元
- 陰影からの 3D形状復元
- . . .


潜在変数の推定問題

生成モデルと識別モデル

- $Z = (X, Y)$
 - Y : 観測が容易な変数 (2D 網膜像)
 - X : 観測が難しい変数 (3D 構造)
 - Y から X を推定したい $p(x|y)$
- 生成モデル: $p(x, y) = p(y|x) p(x)$ をモデル化して、
ベイズの定理で $p(x|y)$ を計算
- 識別モデル: $p(x|y)$ を直接モデル化

生成モデル（順モデル）

- 観測データ Y の生成過程 = 潜在変数の生成過程 $p(x)$ + 潜在変数 $\rightarrow$ 観測データの生成過程 $p(y|x)$



$$p(z) = p(x, y) = p(y|x)p(x)$$
$$p(x|y) = \frac{p(x, y)}{p(y)} = \frac{p(x, y)}{\sum_x p(x, y)}$$

ベイズの定理、ベイズの逆転公式

順光学

- 3D 情報 $X \rightarrow 2D$ 情報 Y $p(y|x)$
- 物理的過程 + 観測雑音
 - 対象の形状
 - 視点と対象の相対位置関係
 - 照明条件
 - 対象の面反射率
 - 写真、コンピュータ・グラフィクス

逆光学

- 観測データ y だけからは解が一意に決まらない（不良設定問題）
- X の事前分布 $p(x)$ を使えば
事後確率 $p(x|y)$ が計算できて
それを最大にする X は一意に決まる
- ベイズ的な確率モデリングが有効

知的情報処理が解いている問題

- 不良設定性のある潜在変数推定（逆問題）
は、知能の重要な情報処理課題
 - クラスタリング
 - パターン認識
 - タグづけ
 - 信号分解
- 少ない情報からできるだけ多くを
正しく読み取るものが生き残る
- 知能 = 見えないものを見る力

いろいろな生成モデル

- Boltzmann Machine
 - Deep Belief Network
 - スパースモデリング
 - Wide and Deep Learning
 - 混合分布などの確率モデル
 - 確率的プログラム
-
- 汎用性の高いヒューリスティクス

スパースモデリング

- Y の生成モデルにスパース性を仮定

$$y = \sum_i \Phi_i x_i + \varepsilon$$

観測データ ^{i} 基底 係数 雑音

基底と係数の
両方を推定する


$$E(\mathbf{x}) = \left\| \mathbf{y} - \sum_i \Phi_i x_i \right\|^2 + \lambda \sum_i |x_i|$$

観測データのモデリング誤差 係数のスパース性

Olshausen and Field: Emergence of simple-cell receptive field properties by learning a sparse code for natural images, Nature 1996

初期視覚情報処理
のモデル

多層マルチモーダルLDA



図の出展：長井隆行、他：多層マルチモーダルLDA と
強化学習による意味理解に基づく行動決定, JSAI 2015

確率的プログラム

- 確率モデルを使った学習・推論
 - 確率モデル記述（知識表現）
 - 学習・推論アルゴリズム
- モデルの記述と学習・推論の分離
- 汎用の学習・推論エンジンを構築



- 複雑な確率モデルを容易に利用可能に
 - BUGS, Stan, ...
 - PRISM, BLOG, Church, Venture, ...
(DARPA PPAML)

ベイズの泣き所

- 生成モデル+ベイズの定理でなんでも解ける？
 - ベイズの泣き所：解析的に解けない
 - 計算が大変
 - 大規模データに適用困難
- 
- A large, light blue downward-pointing arrow is positioned between the two main bullet points, indicating a logical flow or consequence.
- いろいろな近似解法の工夫が発達
 - 変分ベイズ
 - マルコフ連鎖モンテカルロ

識別モデル（逆モデル）

- 観測データ $\rightarrow$ 潜在変数の関係
 $p(x|y)$ を直接的にモデル化
- 事後確率最大化識別等と組み合わせると
確率分布 $\rightarrow$ 識別関数

$$\hat{x} = f(y; w)$$

確率モデルとしてのニューラルネット

- 階層的なニューラルネットワークも確率分布 $p(x|y)$ として解釈可能
 - $f(y;w)$ + 雑音（正規分布、他）
 - $p(x|y;w)$ を $y \rightarrow x$ の関数 $f(y;w)$ として近似（確率値を出力する）
- CNN などの深層パーセプトロンも確率モデルの一種と見做せる

生成モデルと識別モデル

- 生成モデル : $p(x, y) = p(y|x) p(x)$
- 識別モデル : $p(x|y)$
- どちらも同時分布 $p(x, y)$ を前提としている
- 識別モデルにもデータ生成過程の構造が反映されている
- 全体をベイズ的な枠組みで捉えることが可能

順・逆モデリング

- 順モデルと逆モデルを組み合わせる



- 生成モデルの学習・推論の効率化
- 識別モデルの学習・推論の効率化

Generative Adversarial Networks


[Goodfellow+ 2014]

- 生成モデルと識別モデルを相互に学習させる
- 識別モデルは、入力が学習データか生成モデルが作ったデータかを学習
- 生成モデルは識別モデルになるべく間違えるように学習
 - Adversarial: 敵対的な

Variational Auto-Encoder

[Kingma 2014]

- 連続潜在変数のベイズ生成モデルを大規模データで学習させたい
- 近似的な識別モデル (逆モデル) の利用



Variational Auto-Encoder

[Kingma 2014]

- 連続潜在変数のベイズ生成モデルを大規模データで学習させる方法
 - 潜在変数の事後分布 (encoder) $p(x|y)$ を簡単な分布 (例: 正規分布) $q(x|y)$ で近似
 - 正規分布パラメータを y の関数としてその関数をデータから学習させる
 - 簡単な関数の最適化問題に帰着される
 - 順モデルと逆モデルを同時に学習可能
- ベイズ的生成モデルと DL の融合
- ベイズ的な半教師あり学習が可能

Deep Generative Models

- Variational Auto-Encoder [Kingma 2014]




- Deep Recurrent Attentive Writer: DRAW [Gregor 2015]



- Generating Images from Captions with Attention: AlignDRAW [Mansimov 2016]

DRAW [Gregor 2015]


- Deep Recurrent Attentive Writer




図の出典 : Gregor, K. et al.: DRAW: A Recurrent Neural Network For Image Generation, arXiv:1502.04623, 2015

AlignDRAW

[Mansimov 2016]



A stop sign is flying in
blue skies.



図の出典 : Mansimov, E. et al.: Generating Images from Captions with Attention, ICRL 2016 (arXiv:1511.02793)

国立研究開発法人 産業技術総合研究所 人工知能研究センター

順・逆モデリング

- 近似逆モデルによる高速緩和ベイズ計算
- 早川、和田、川人：画像生成過程の順モデル・近似逆モデルに基づく非線形視覚問題の一解法、電子情報通信学会論文誌. A, 基礎・境界 J77-A(12), 1683-1693, 1994-12-25 (1994)

潜在変数推定・観測変数想起 encoder/decoder


- 知能（特に知覚系）が解いている
情報処理の問題
 - － 順モデルと逆モデル
 - － 順・逆モデリング
- ベイズ的な確率モデリングと
深層ニューラルネットワークの統合
- 知能 = 見えないものを見る力

予測・シミュレーション

- 時間（ダイナミクス）の導入
- 知能：変化する世界での生存ツール
- 知能の源泉は予測？
 - 予測は常に正解データが得られる
- 時系列データの生成モデル：
一般化状態空間モデル
 - 状態遷移モデル： $p(x_t|x_{t-1})$
 - 観測モデル： $p(y_t|x_t)$

一般化状態空間モデル

- 潜在変数のある時系列データの生成モデル



予測と構造化された記憶

- 複雑な環境下で予測をするためには、
超高次元のパターン時系列情報を
分節・構造化して記憶することが必須
[Hawkins 2004]
- 組み合わせ構造は普遍的
 - 世界：原子－分子－アミノ酸－タンパク
 - 細胞－器官－個体－家族－共同体－国家・・・
- 世界認知のための記号の構造の基盤

順・逆モデリング

- encoder: $Y(t) \rightarrow X(t)$
- decoder: $X(t) \rightarrow Y(t)$
- internal simulator : $X(t) \rightarrow X(t+1)$
- 一期先予測 + シミュレーション
- すべてを $Y(t)$ だけから教師なし学習可能
- Deep Generative Model を組み込み？
- 潜在状態空間の学習も可能

データ同化（ベイズフィルタ）


- $p(x(t)|y(1), \dots, y(t))$ を逐次更新計算
- 予測と観測データの誤差を情報として潜在状態を修正
 - 線形正規モデルならカルマンフィルタ
 - より一般にはパーティクルフィルタ等
 - Deep Generative Model を組み込む？

プランニングと制御

- 認識・予測から制御へ
- 行動（外界への出力）と報酬の導入
 - 累積期待報酬（未来の報酬）を最適化する行動系列（方策）の計算
- モデルフリー強化学習
 - 試行錯誤、方策テーブルの直接学習
- モデルベース強化学習
 - 予測モデルを利用して方策計算
 - 最適制御
- 状態空間、行動空間の特徴表現獲得

プランニングと制御

- 行動と報酬（コスト）の導入



AlphaGo

[D.Silver+ 2016]


- 囲碁の世界の良い行動方策の構築に成功
 - 深層学習と強化学習の融合？
 - 有段者の棋譜データを使った教師あり学習で次の手を予測するネットワークを学習
 - ランダムな1着＋自己対戦を使った強化学習で行動価値関数ネットワークを学習
 - 行動価値関数ネットワークでモンテカルロ木探索を制御して読む手を削減しつつ状態価値を評価
 - 行動価値関数ネットワークを状態価値関数ネットワークにコンパイル
 - モンテカルロ木探索の状態価値評価と状態価値関数ネットワークの重みつき和で盤面評価関数計算

囲碁と実世界

- 囲碁：完全情報・閉世界
 - 状態空間：盤面（離散有限（非常に多い））
 - 行動空間：打ち手（離散有限（非常に多い））
 - 状態遷移ルール：簡単で決定的
- 実世界：不完全情報・開世界
 - 状態空間：連続的で枚挙不可能
 - 行動空間：連続的で枚挙不可能
 - 状態遷移ルール：不明確、不確実、不完全情報
- 囲碁に近いところから徐々に攻略？
 - 物体操作学習 (UCB)
 - 自動運転学習 (PFN)
 - ピッキング学習 (Google)

運動制御
観測と介入の繰り返し


記号処理とパターン処理



記号の創発

- 予測（と介入）に基づく時系列データの分節化、チャンキング、要素記号化
[Tani 1996, Wolpert and Kawato 1998]
- 記号の系列の分節化（多重分節）
 - 音声データ → 音韻、単語、文、談話・文書
 - モーションキャプチャデータ
→ 動作要素、動作、行動、踊り・作業
 - マルチモーダルデータ
→ セグメンテーションと組み合わせ


手書き文字の確率的生成モデル



図の出展 : Lake+: Human-level concept learning through probabilistic program induction, Science 350, 6266, 2015


記号計算

- 強化学習の方策： $(x(t), a(t)) \rightarrow a(t+1)$
→ 文法的な系列生成と系列認識 = 言語操作
 - Long-Short Term Memory ?
 - Neural Turing Machine ?
 - 時定数の異なる階層的RNN ?
 - 分散埋め込み表現
- 柔らかな記号：
分散表現された記号



1988

柔らかな記号、あるいは Bayesian Linguistics に向けて




まとめ

- 知能が解いている情報処理課題は？
 - 潜在変数推定
 - 予測
 - 最適制御
 - 記号操作による計画・推論
 - 文法的な生成と理解＝言語操作
- 汎用原理：ベイズ的な確率モデリング？
- 技術的には、近似計算が本質的

知能の創発に向けて

- 環境の中で試行錯誤的に相互作用しながら自律的に学習するシステム
→ 言語記号的知能にまで到達したい
- 好奇心を持ちつつ世界とインタラクションし、それを通じて言語を獲得して、人と対話したり、自分で本を読んだりしながら、自律的に賢くなってゆくシステム

実世界Q&Aタスク



- 感覚・運動 $\Leftrightarrow$ 意味 DGM 等
- テキスト $\Leftrightarrow$ 意味 LSTM 等
- 感覚・運動情報についての適切な質問応答ができることをゴールとして学習



対話から地図を学習する
オフィス事情通口ロボット
[Asoh+ 1997]