PRMU基礎研究における
オープンアイデア
～ PRMU第二期グランドチャレンジ ～

安倍満・舩冨卓哉・木村昭悟
中澤篤志・山崎俊彦・松下康之
内田誠一・前田英作

2017/12/17

オープンアイデアの試み

- 新しい研究の問題設定・解き方の切り口をオープンに議論しよう！
- 皆様にとって、次の研究のヒントになれば本望
- 願わくば、PRMUから次の潮流を！

基礎研究における
諸問題のオープンアイデア

観測

本当にきれいかつ条件に制約のない
産業用途に耐える3D動画像生成

全データを取るのではなく
異常データのみを収集する
適応的センシング

全ての光線空間をキャプチャ

新しい計測デバイスの提案
・いまあるデータの中で考えるのではなく
　結局我々はどんなデータがほしいのか？
・イノベーションは新しい計測機器から生まれている

収集

負例の収集

危険性／コンプライアンスの問題で
データが集めにくい問題
（自動運転，監視カメラなど）

問題を解くために
必要なデータを自動で収集

真値データ入力から解放される方法
・「強い」センサによる
　「弱い」センサ用dataset（半）自動構築
・Simulationの併用

ラベル付け

正解ラベルの問題
・ラベルがない
・ラベルにノイズが多い
・正しくラベルの定義ができない

もっとパターン認識にadversarial的視点を
・パターン認識はラベルを信じる性善説
・セキュリティは反対策を見つける性悪説

０からの言語・音声・画像理解
（赤ちゃんが行うような）
ラベルなし学習

わからないことを認識する
・予め定義されたクラスの
　どれかを出力しない
・計算機による能動的学習

表現

異なるメディアの融合
・Nominal, Ordinal, Interval, Ratio Scales全てを、
　状況に応じて統合できるようにすること
・不定長のデータを、うまくエンコードできること

入力データ形式の多様化
・グラフ構造への対応
・未観測値を許す
・実数値以外（複素数など）
・多次元配列でないもの

InputからOutputへ
・認識や理解のみならず、
　制御、計画まで → 例：強化学習

問題の定式化

非定常な問題
・ベイズリスク
・対象の分布，ラベル
・対象自体の特徴
・目的関数自体，制約条件

多目的最適化を用いた
パターン認識

最適から快適へ、
大衆最適から個人最適へ
・パーソナライズされたAI
　自分を知り尽くしてくれるAI
例：急ぎの時／家族と一緒の時で
　　経路を変更するナビ等

DNNの概念学習と
人の概念のwarping

・人のような結果を返すAI
・人の常識をエンコーディングしたAI
・人にとって安心できる結果を返すAI
・人が経験的にうまくやっていることの自動化
　→例：逆強化学習等

処理

Classifier, regressorの出力の理由説明

帰納と演繹
（機械学習とシミュレーション）

統計的機械学習に
記号論理の導入

AIシステムと性能保証のあり方
→ 例：AIと非AIの組合せ等
・「学習」のみから、「記憶＋学習」
　→ 明示的なメモリの実装
・Deterministicな安心感実現
　(教えた事を記憶、破壊的忘却しない)

「定石」と「現実」のギャップ
～パターン認識で解きにくい問題への切り口～

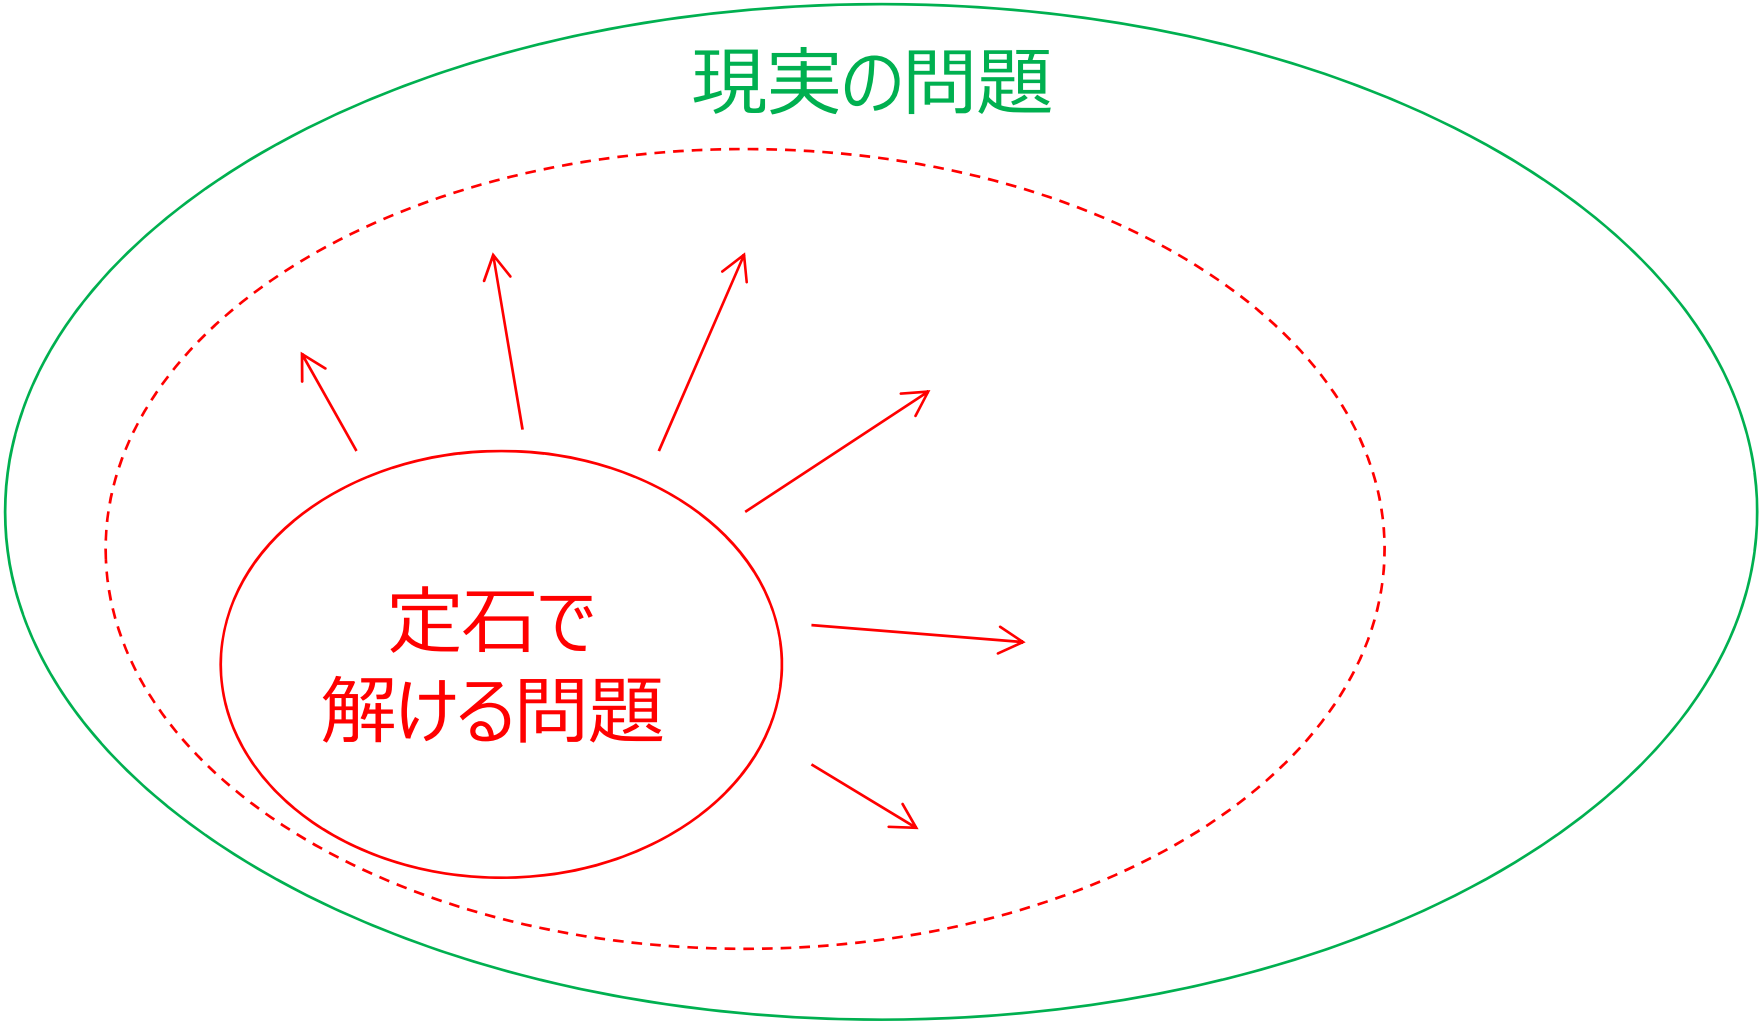

「定石」と「現実」のギャップ
～パターン認識で解きにくい問題への切り口～

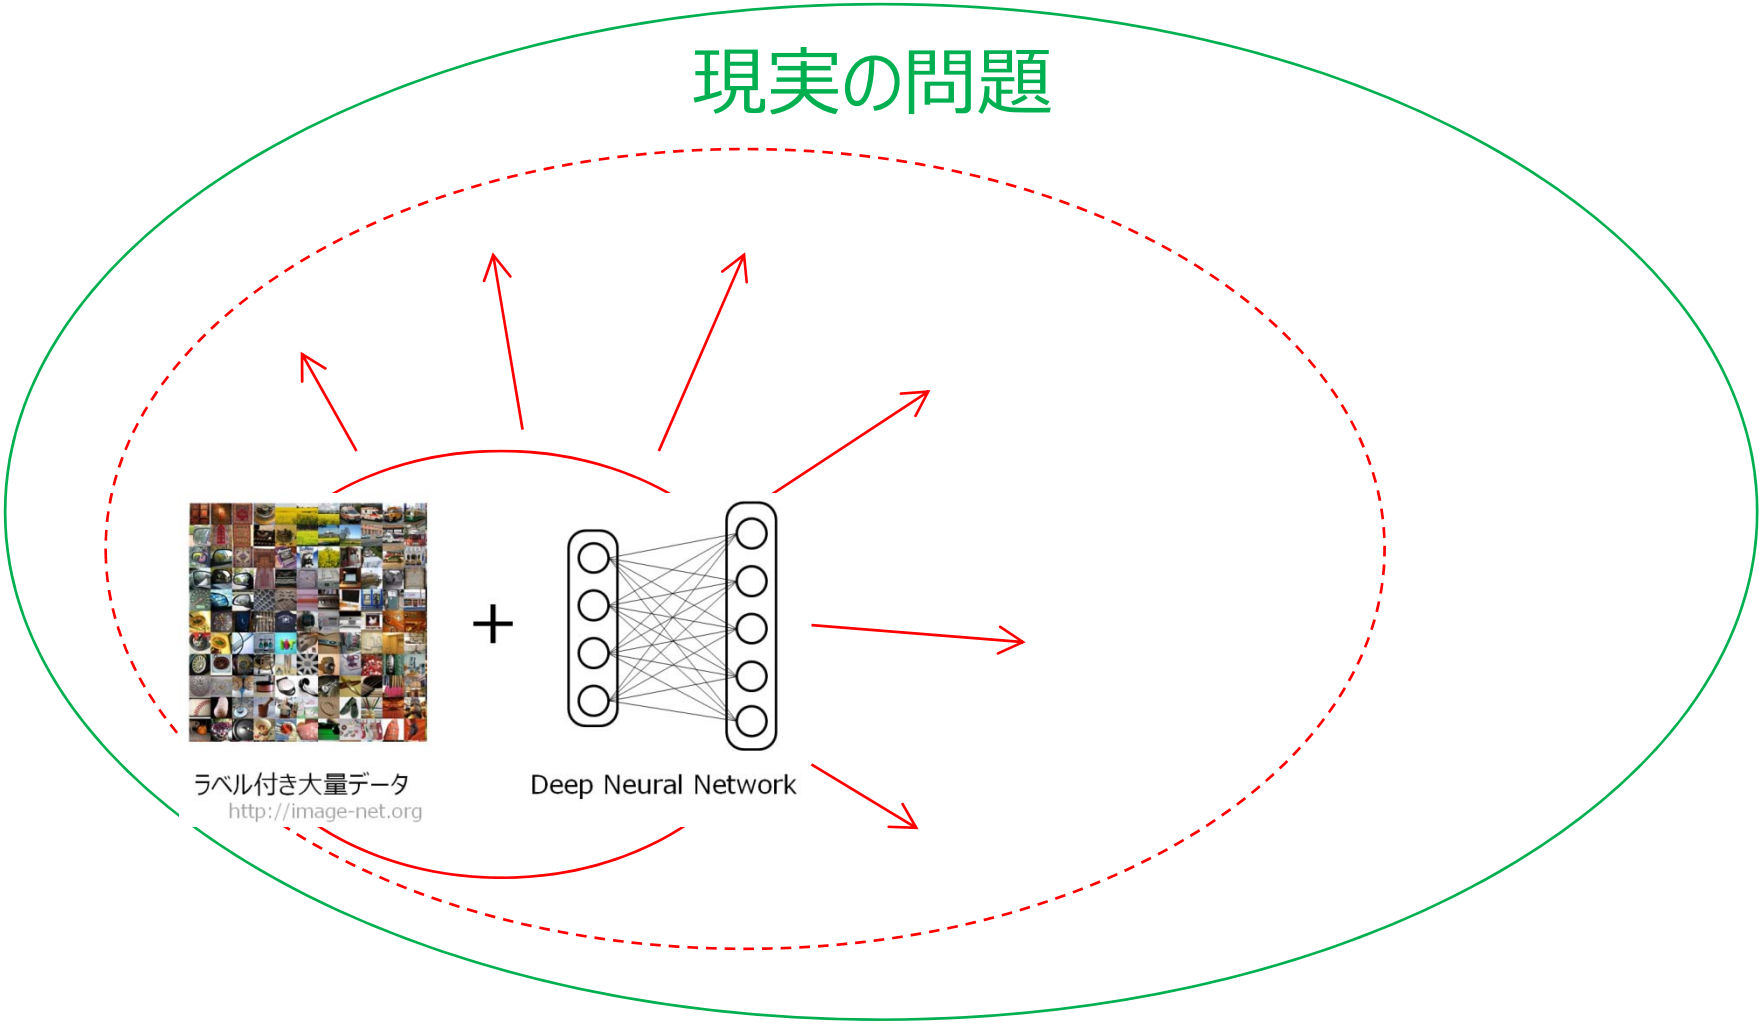

「定石」と「現実」のギャップ
～パターン認識で解きにくい問題への切り口～

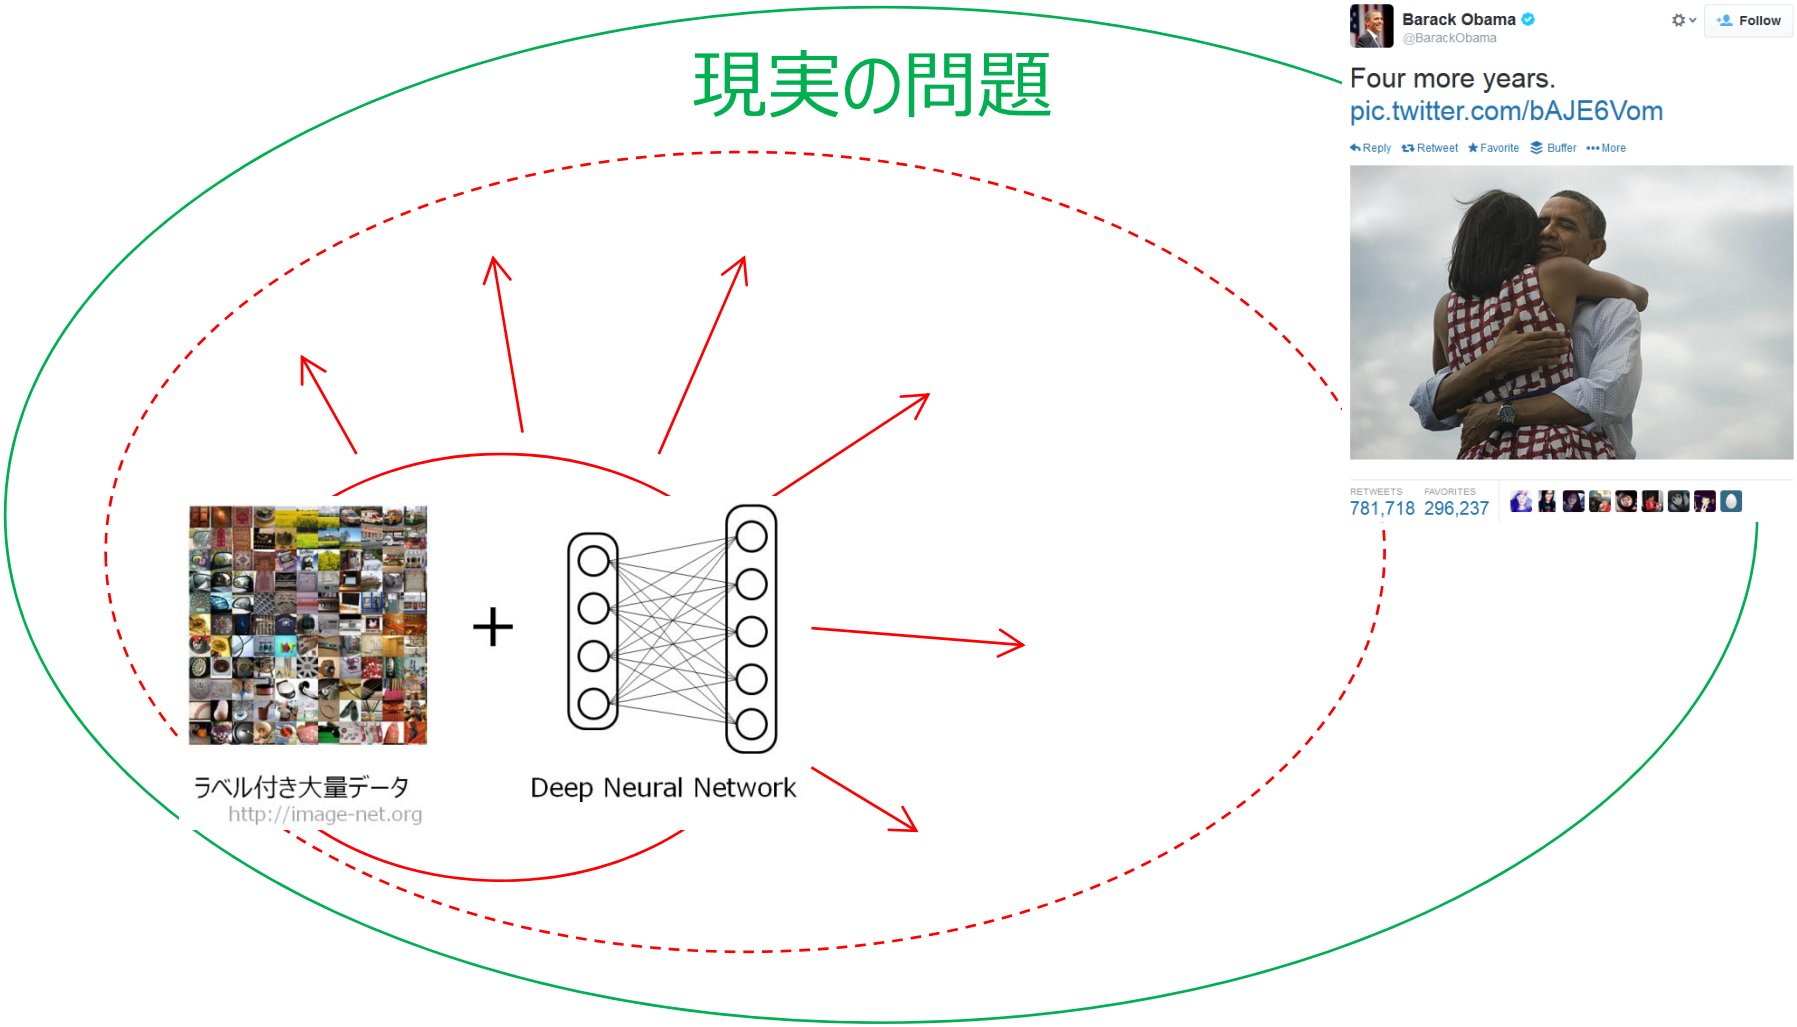

帰納的アプローチと演繹的アプローチの併用

PR基礎研究におけるオープンアイデア

教師あり学習を抽象化すると

$$x \rightarrow y$$

例）画像 → オブジェクト名

音声 → テキスト

組み合わせ最適化問題を考える

計算量の爆発

$$x \rightarrow y$$

例）巡回セールスマン問題

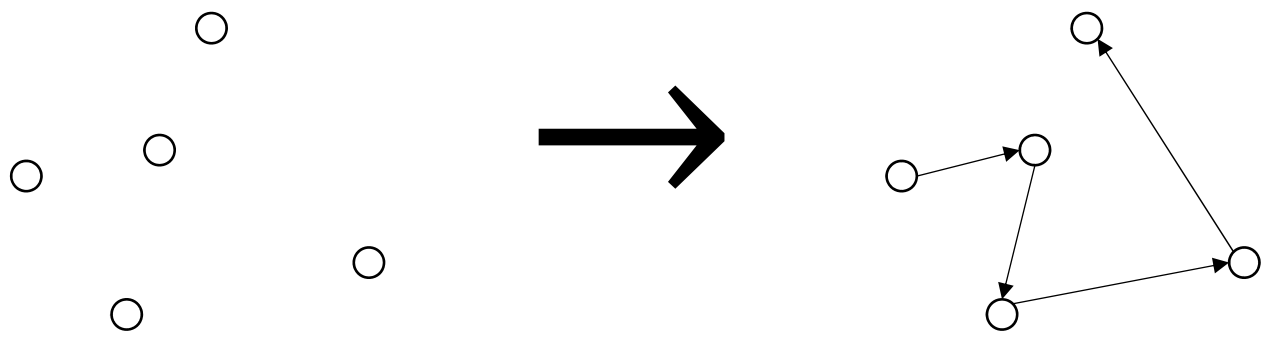

組み合わせ最適化問題を考える

$$x \rightarrow y$$

パターン認識・機械学習で
困難さをバイパスできるだろうか？

演繹的アプローチ(Deduction)

公理・ルールから合理的推論によって結論を導く

- 組み合わせ最適化問題
- 物理モデルによる予測（天気予報・渋滞予測・流体）
- 多視点幾何
- etc.

帰納的アプローチ (Induction)

経験的データを収集して結論を導く

- 組み合わせ最適化問題
- 物理モデルによる予測（天気予報・渋滞予測・流体）
- 多視点幾何
- etc.

帰納的アプローチでもこれらの問題は解きうるか？

最も単純な例：四則演算を『学習』する

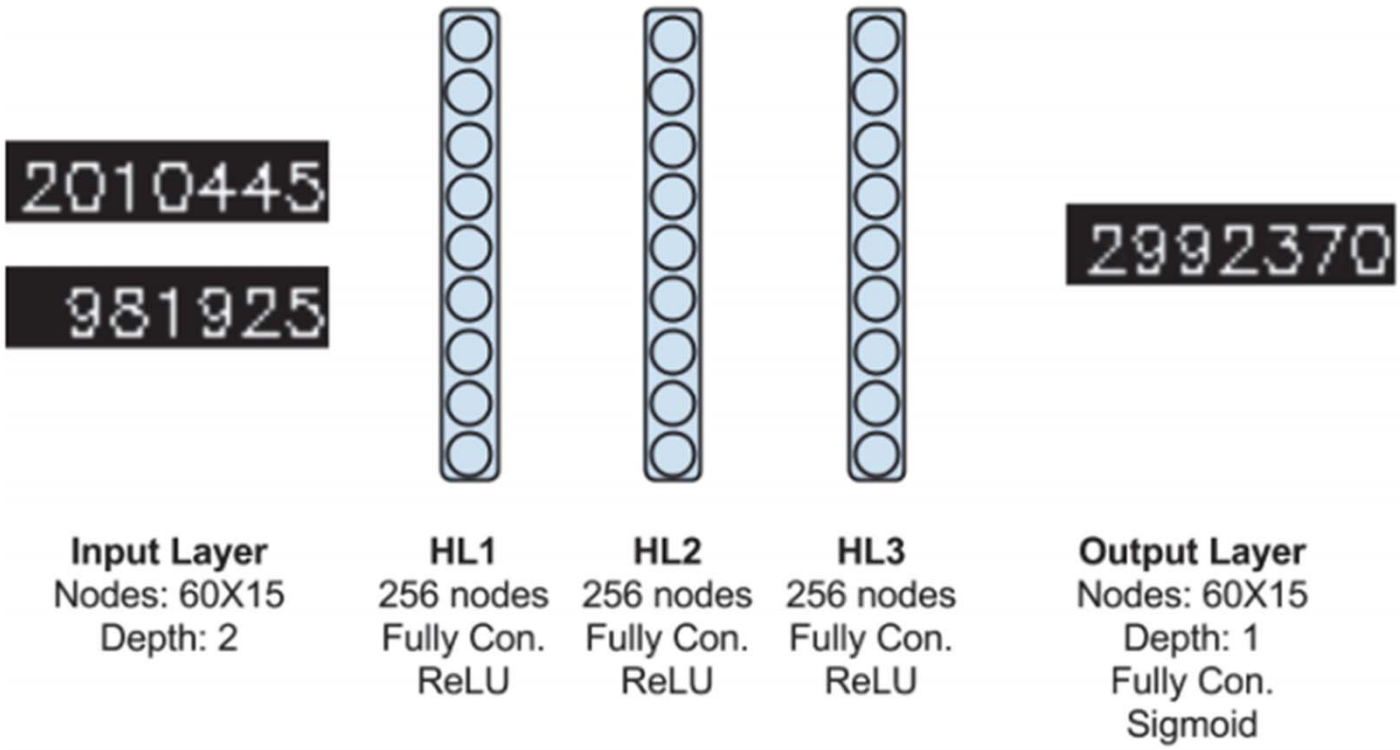

Visual Learning of Arithmetic Operations, AAAI2016

最も単純な例：四則演算を『学習』する

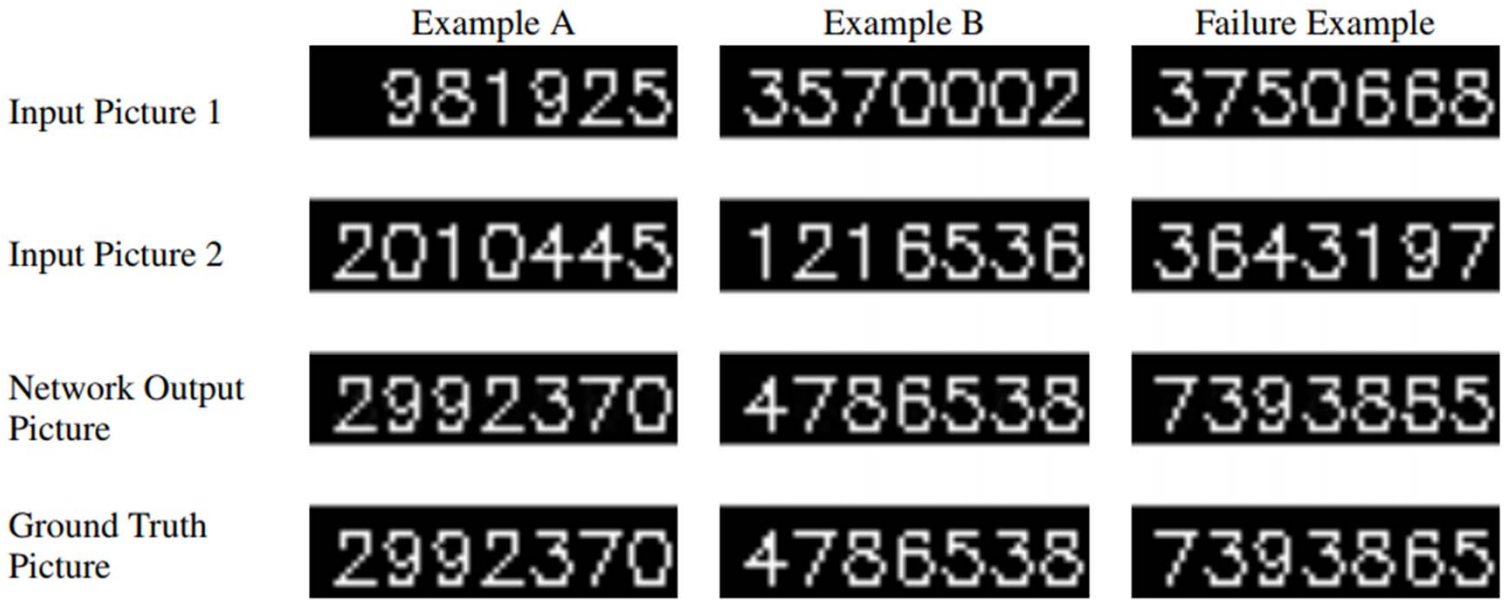

Figure 1: Input and output examples from our neural network trained for addition. The first two examples show a typical correct response. The last example shows a rare failure case.

Visual Learning of Arithmetic Operations, AAAI2016

最も単純な例：四則演算を『学習』する

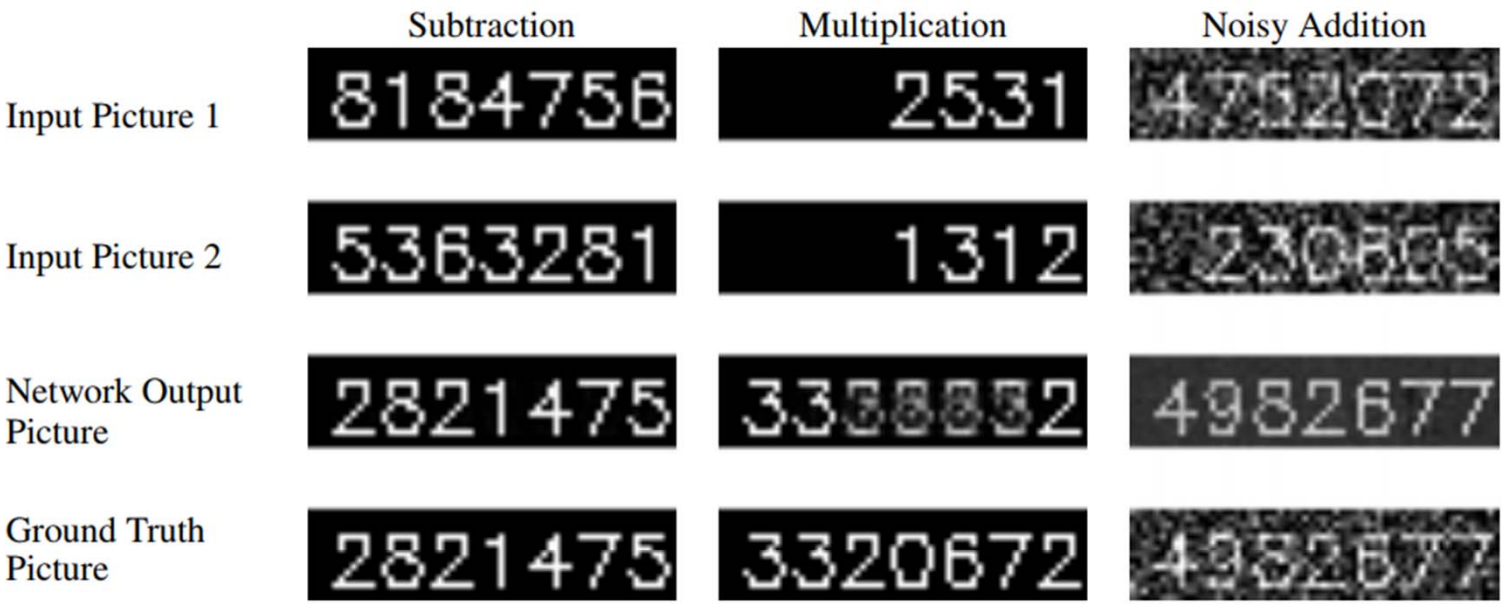

Figure 3: Examples of the performance of our network on subtraction, multiplication, and addition with noisy pictures. The network performs well on subtraction and is insensitive to additive noise. It performs poorly on multiplication. Note that the bottom right image is not the ground truth image, but an example of the type of training output images used in the Noisy Addition scenario.

Visual Learning of Arithmetic Operations, AAAI2016

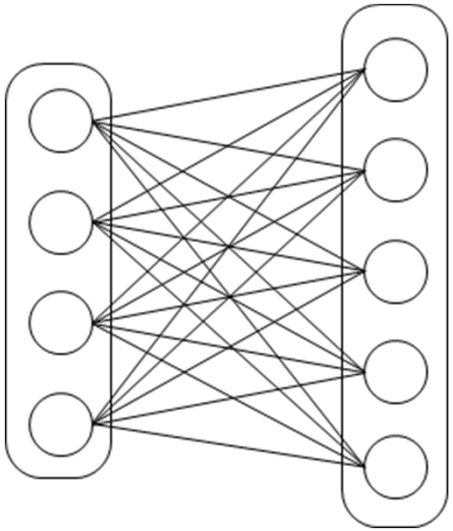

Neural Network
約82万パラメータ

1978年製CPU 8086
トランジスタ数29,000
(積・和の計算が可能)

RNN(LSTM)による離散最適化

・学習に基づく離散最適化（！）

***Pointer Networks**, NIPS2015 (UC Berkeley, Google Brain)*

例）凸包の算出

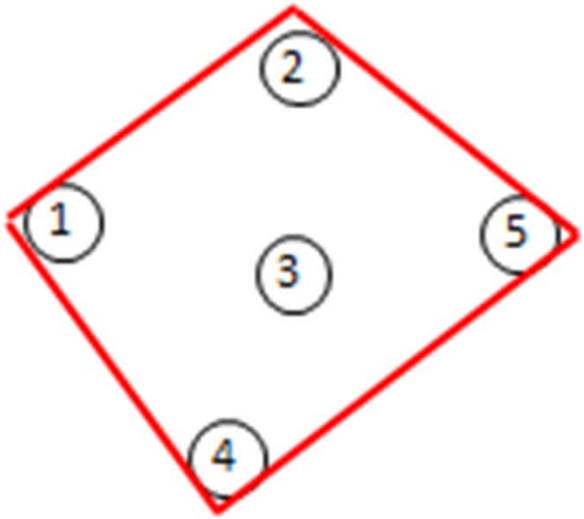

$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix} \begin{pmatrix} x_2 \\ y_2 \end{pmatrix} \begin{pmatrix} x_3 \\ y_3 \end{pmatrix} \begin{pmatrix} x_4 \\ y_4 \end{pmatrix} \begin{pmatrix} x_5 \\ y_5 \end{pmatrix}$

点群の座標列を入力

→

1　4　5　2

凸包のインデックス（ポインタ）を出力

Copyright (C) 2017 DENSO IT LABORATORY, INC. All Rights Reserved.

RNN(LSTM)による離散最適化

・学習に基づく離散最適化（！）

Pointer Networks, *NIPS2015 (UC Berkeley, Google Brain)*

例）巡回セールスマン問題

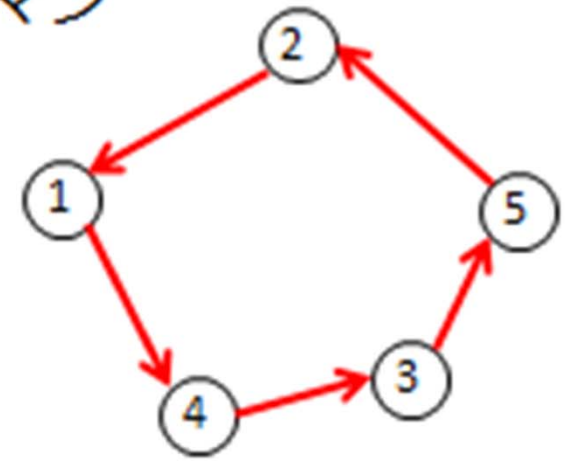

$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix} \begin{pmatrix} x_2 \\ y_2 \end{pmatrix} \begin{pmatrix} x_3 \\ y_3 \end{pmatrix} \begin{pmatrix} x_4 \\ y_4 \end{pmatrix} \begin{pmatrix} x_5 \\ y_5 \end{pmatrix}$

都市の座標列を入力

→

1　4　3　5　2

都市のインデックス（ポインタ）を出力

Copyright (C) 2017 DENSO IT LABORATORY, INC. All Rights Reserved.

巡回セールスマン問題への適用結果

都市数 n	OPTIMAL	$O(n^2)$ A1	$O(n^2)$ A2	$O(n^3)$ A3	$O(n)$ PTR-NET
5	2.12	2.18	2.12	2.12	2.12
10	2.87	3.07	2.87	2.87	2.88
50 (A1 TRAINED)	N/A	6.46	5.84	5.79	6.42
50 (A3 TRAINED)	N/A	6.46	5.84	5.79	6.09
5 (5-20 TRAINED)	2.12	2.18	2.12	2.12	2.12
10 (5-20 TRAINED)	2.87	3.07	2.87	2.87	2.87
20 (5-20 TRAINED)	3.83	4.24	3.86	3.85	3.88
25 (5-20 TRAINED)	N/A	4.71	4.27	4.24	4.30
30 (5-20 TRAINED)	N/A	5.11	4.63	4.60	4.72
40 (5-20 TRAINED)	N/A	5.82	5.27	5.23	5.91
50 (5-20 TRAINED)	N/A	6.46	5.84	5.79	7.66

Copyright (C) 2017 DENSO IT LABORATORY, INC. All Rights Reserved.

巡回セールスマン問題

演繹的アプローチ(Deduction)

離散最適化アルゴリズム $o(n^2), o(n^3)$

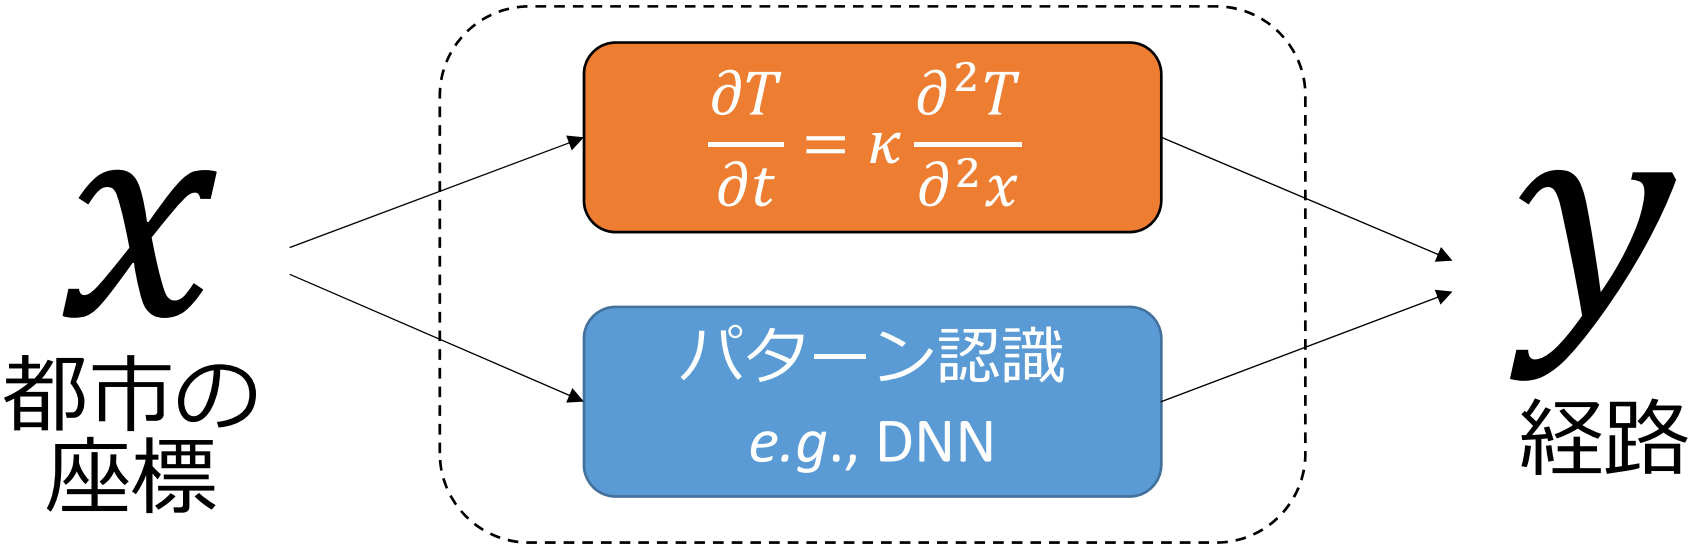

帰納的アプローチ (Induction)

RNNによる学習 $o(n)$

さらなる先の姿として

演繹的アプローチ(Deduction)

離散最適化アルゴリズム $o(n^2), o(n^3)$

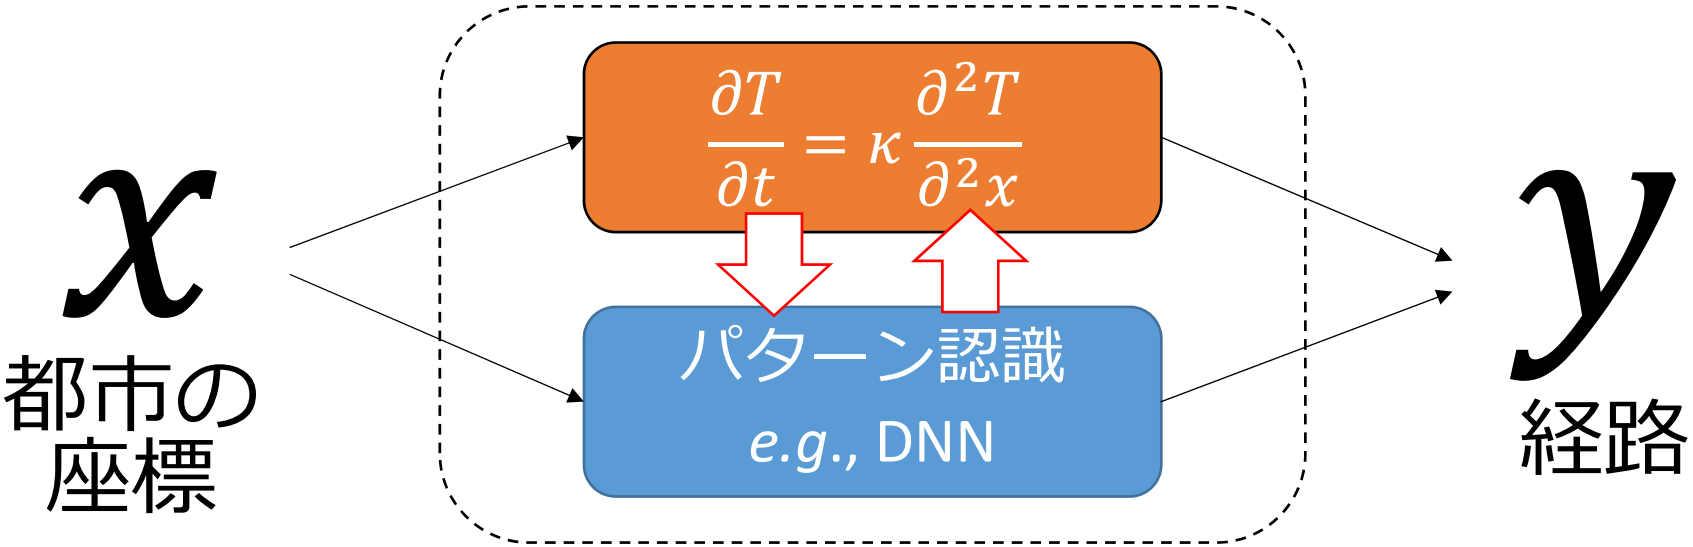

帰納的アプローチ (Induction)

RNNによる学習 $o(n)$

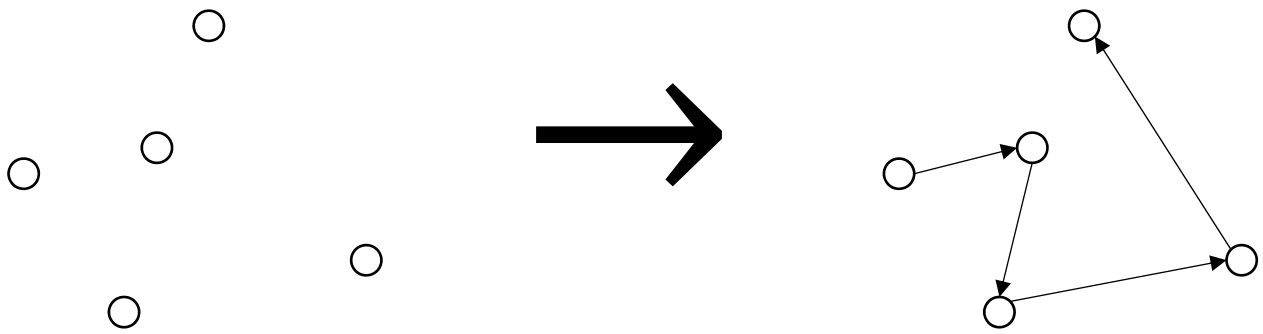

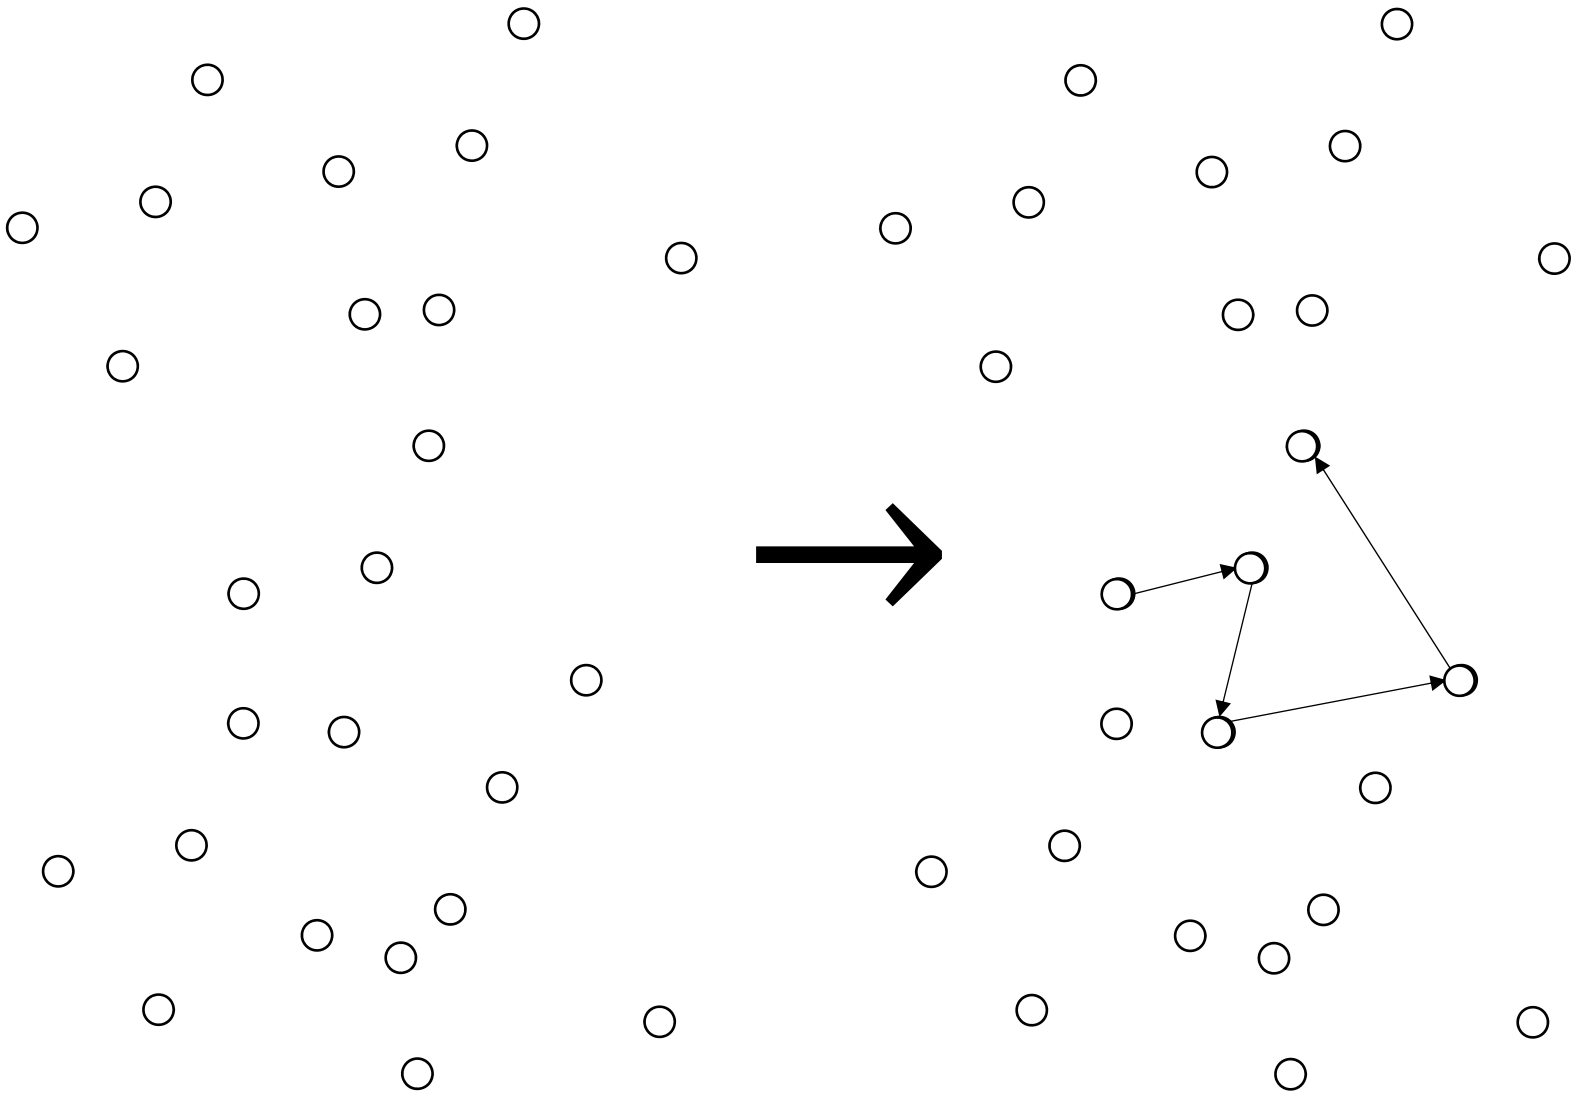

画像だけで理解することの難しさ

- A man hugging someone close under a cloudy sky.
- Barack Obama is in this picture.
- The other is probably his wife, Michelle.

画像だけで理解することの難しさ

- **情報統合と推論の欠如 –**
  画像に記述されていない内容をつなぎ合わせた推論がないとその真の意味を理解できない
  - 選挙候補者が映っている
  - 選挙期間中に投稿された
  - 任期が4年である
  - 故にこの画像は選挙運動の一環

- **情報受容の任意性 –**
  自身の好みや思想次第で画像の持つ意味が正反対に
  - 民主党支持層 – 何と感動的な
  - 共和党支持層 – けっ

記号的な論理推論との融合

演繹的アプローチ(Deduction)

記号論理

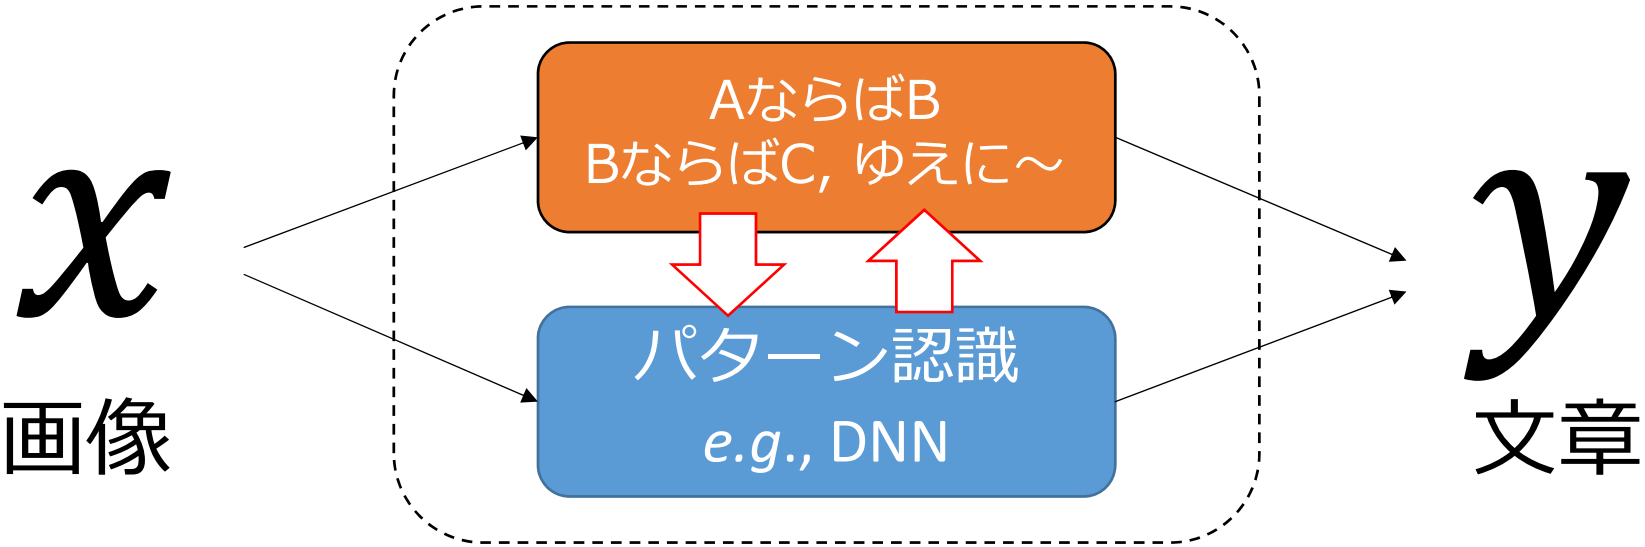

帰納的アプローチ (Induction)

CNN, RNN

データを収集することの難しさ

- **データ量の問題**

- **データの偏りの問題（正例>>負例）**
  - 外観検査
  - 医用画像処理

- **収集の危険性／コンプライアンスの問題**
  - 自動運転における安全な学習とは？

画像生成との融合

演繹的アプローチ(Deduction)

コンピュータグラフィクス

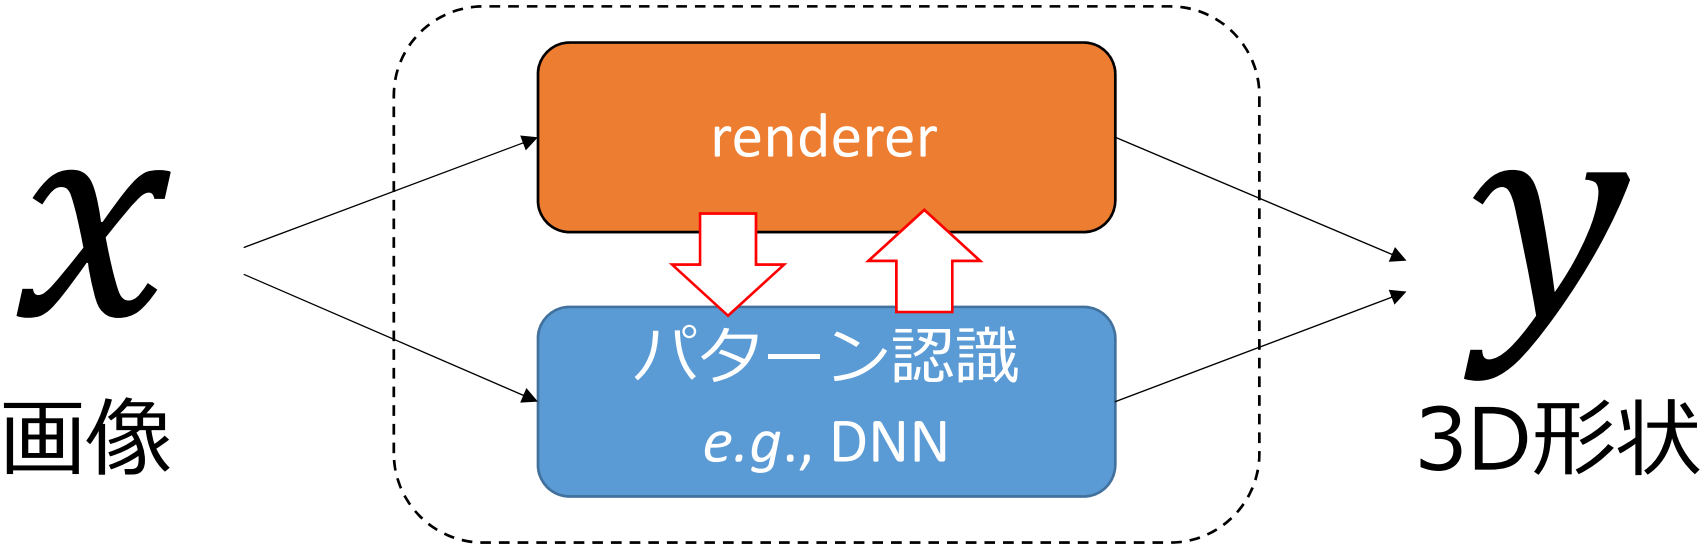

帰納的アプローチ (Induction)

CNN, RNN

Visual SLAMの事例

演繹的アプローチ(Deduction)

多視点幾何学

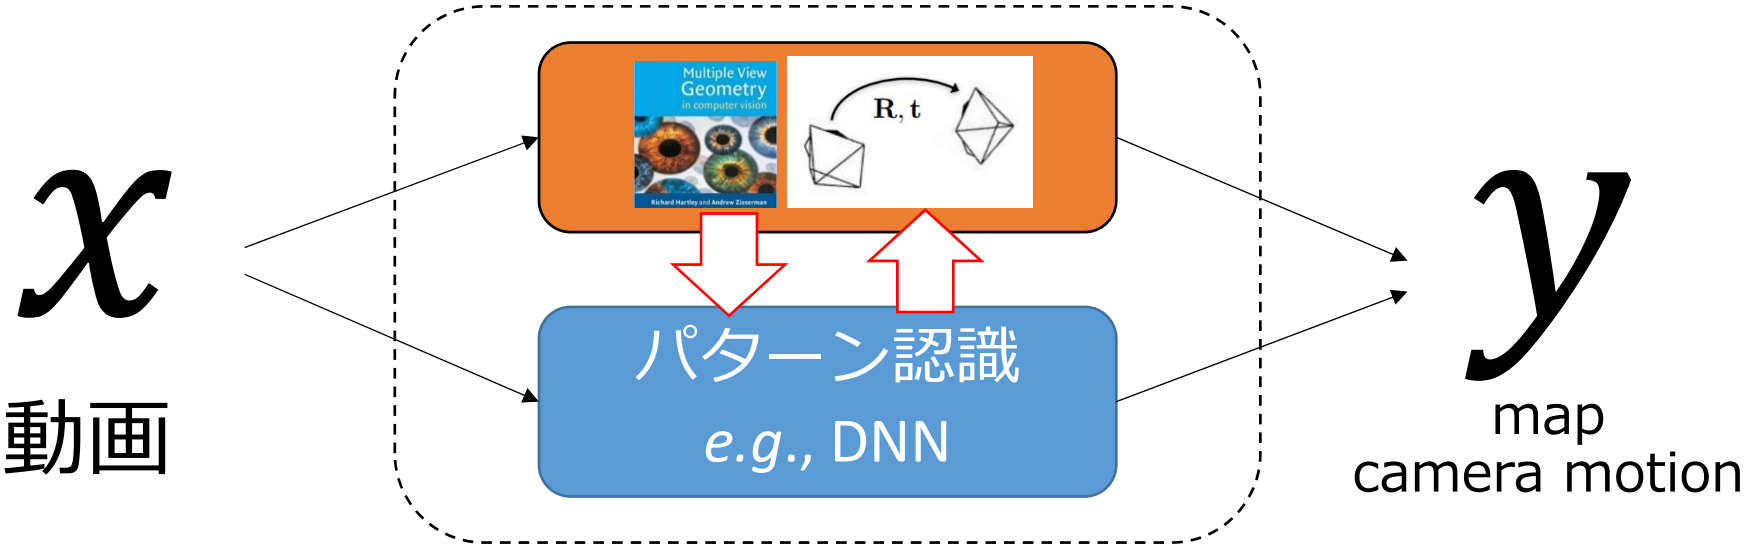

帰納的アプローチ (Induction)

Convolutional Neural Network

Unsupervised Learning of Depth and Ego-Motion From Video, CVPR2017

(a) Training: unlabeled video clips.

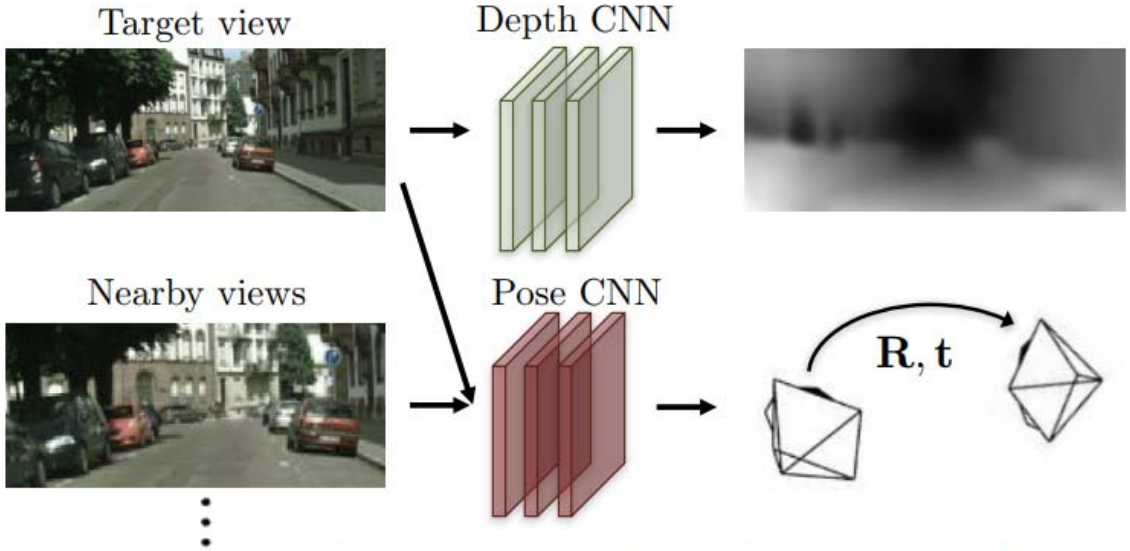

(b) Testing: single-view depth and multi-view pose estimation.

天気予報

演繹的アプローチ(Deduction)

全球モデルによる予測

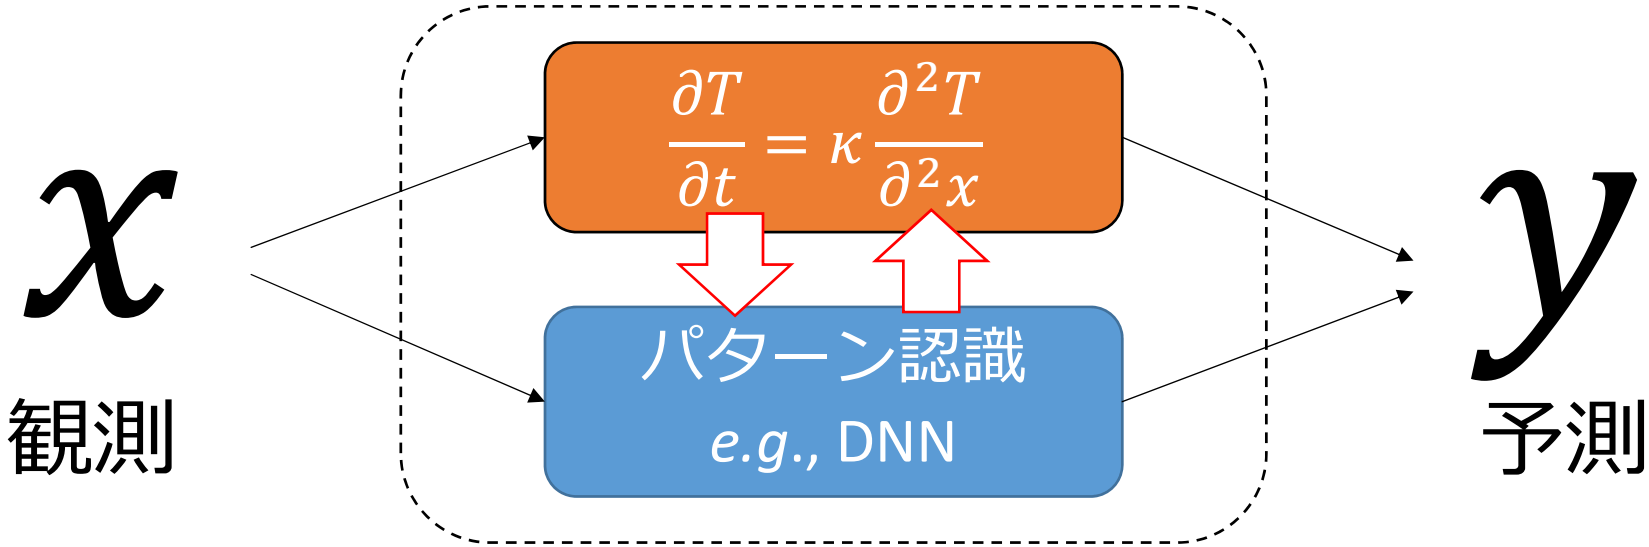

帰納的アプローチ (Induction)

過去の観測データによる予測

基礎研究における
諸問題のオープンアイデア

観測

本当にきれいかつ条件に制約のない
産業用途に耐える3D動画像生成

全データを取るのではなく
異常データのみを収集する
適応的センシング

全ての光線空間をキャプチャ

新しい計測デバイスの提案
・いまあるデータの中で考えるのではなく
　結局我々はどんなデータがほしいのか？
・イノベーションは新しい計測機器から生まれている

収集

負例の収集

危険性／コンプライアンスの問題で
データが集めにくい問題
（自動運転，監視カメラなど）

問題を解くために
必要なデータを自動で収集

真値データ入力から解放される方法
・「強い」センサによる
　「弱い」センサ用dataset（半）自動構築
・Simulationの併用

ラベル付け

正解ラベルの問題
・ラベルがない
・ラベルにノイズが多い
・正しくラベルの定義ができない

もっとパターン認識にadversarial的視点を
・パターン認識はラベルを信じる性善説
・セキュリティは反対策を見つける性悪説

０からの言語・音声・画像理解
（赤ちゃんが行うような）
ラベルなし学習

わからないことを認識する
・予め定義されたクラスの
　どれかを出力しない
・計算機による能動的学習

表現

異なるメディアの融合
・Nominal, Ordinal, Interval, Ratio Scales全てを、
　状況に応じて統合できるようにすること
・不定長のデータを、うまくエンコードできること

入力データ形式の多様化
・グラフ構造への対応
・未観測値を許す
・実数値以外（複素数など）

InputからOutputへ
・認識や理解のみならず、
　制御、計画まで → 例：強化学習

本日はここにフォーカス

問題の定式化

非定常な
・ベイ
・対象の分布，ラベル
・対象自体の特徴
・目的関数自体，制約条件

・パーソナライズされたAI
　自分を知り尽くしてくれるAI
例：急ぎの時／家族と一緒の時で
　　経路を変更するナビ等

・人のような結果を返すAI
・人の常識をエンコーディングしたAI
・人にとって安心できる結果を返すAI
・人が経験的にうまくやっていることの自動化
　→例：逆強化学習等

処理

Classifier, regressorの出力の理由説明

帰納と演繹
（機械学習とシミュレーション）

統計的機械学習に
記号論理の導入

AIシステムと性能保証のあり方
→ 例：AIと非AIの組合せ等
・「学習」のみから、「記憶＋学習」
　→ 明示的なメモリの実装
・Deterministicな安心感実現
　(教えた事を記憶、破壊的忘却しない)

基礎研究における
諸問題のオープンアイデア

観測

本当にきれいかつ条件に制約のない
産業用途に耐える3D動画像生成

全データを取るのではなく
異常データのみを収集する
適応的センシング

全ての光線空間をキャプチャ

新しい計測デバイスの提案
・いまあるデータの中で考えるのではなく
　結局我々はどんなデータがほしいのか？
・イノベーションは新しい計測機器から生まれている

収集

負例の収集

危険性／コンプライアンスの問題で
データが集めにくい問題
（自動運転，監視カメラなど）

問題を解くために
必要なデータを自動で収集

真値データ入力から解放される方法
・「強い」センサによる
　「弱い」センサ用dataset（半）自動構築
・Simulationの供用

ラベル付け

正解ラベルの問題
・ラベルがない
・ラベルにノイズが多い
・正しくラベルの定義ができない

もっとパターン認識

・セキュリ

いことを認識する
義されたクラスの
を出力しない
による能動的学習

表現

異なるメディアの融合
・Nominal, Ordinal, Interval, Ratio Scales全て
　状況に応じて統合できるようにすること
・不定長のデータを、うまくエンコード

（複素数など）
配列でないもの

tへ
みならず、
で → 例：強化学習

問題の定式化

非定常な問題
・ベイズリスク
・対象の分布，ラベル
・対象自体の特徴
・目的関数自体，制約条件

多目的最適化を用いた
パターン認識

最適から快適へ、
大衆最適から個人最適へ
・パーソナライズされたAI
　自分を知り尽くしてくれるAI
例：急ぎの時／家族と一緒の時で
　　経路を変更するナビ等

DNNの概念学習と
人の概念のwarping

・人のような結果を返すAI
・人の常識をエンコーディングしたAI
・人にとって安心できる結果を返すAI
・人が経験的にうまくやっていることの自動化
　→例：逆強化学習等

処理

Classifier, regressorの出力の理由説明

帰納と演繹
（機械学習とシミュレーション）

統計的機械学習に
記号論理の導入

AIシステムと性能保証のあり方
→ 例：AIと非AIの組合せ等
・「学習」のみから、「記憶＋学習」
　→ 明示的なメモリの実装
・Deterministicな安心感実現
　(教えた事を記憶、破壊的忘却しない)

MIRU2017特別企画
第2期グランドチャレンジ
中間報告にて紹介
（http://www.ieice.org/iss/prmu/jpn/pdf/MIRU2017-GC.pdf）

まとめ

- 新しい研究の問題設定・解き方の切り口を
  オープンに議論しよう！

- 皆様にとって、次の研究のヒントになれば本望

- 願わくば、PRMUから次の潮流を！