

ソフトウェアとハードウェアを融合し
現実世界を計算可能にする

～AI技術の産業領域への取り組み～

高橋 正和

株式会社Preferred Networks
執行役員 最高セキュリティ責任者

Preferred Networks, Inc. (PFN)

- 設立：2014年3月
- 所在地：東京都千代田区大手町（日本）、カリフォルニア州バークレー（米国）
- 取締役：西川 徹、岡野原 大輔、奥田 遼介
- 従業員数：約250名（2019年4月現在）
- ミッション：
ソフトウェアとハードウェアを融合させ、
現実世界を計算可能にする。
- 事業内容：
交通システム、産業用ロボット、バイオヘルスケア、
パーソナルロボット、スポーツ解析、クリエイティブ
などの分野に深層学習を応用



Our Strategic Partners



HakuhodoDY holdings



 A member of the Roche group



and Collaborators



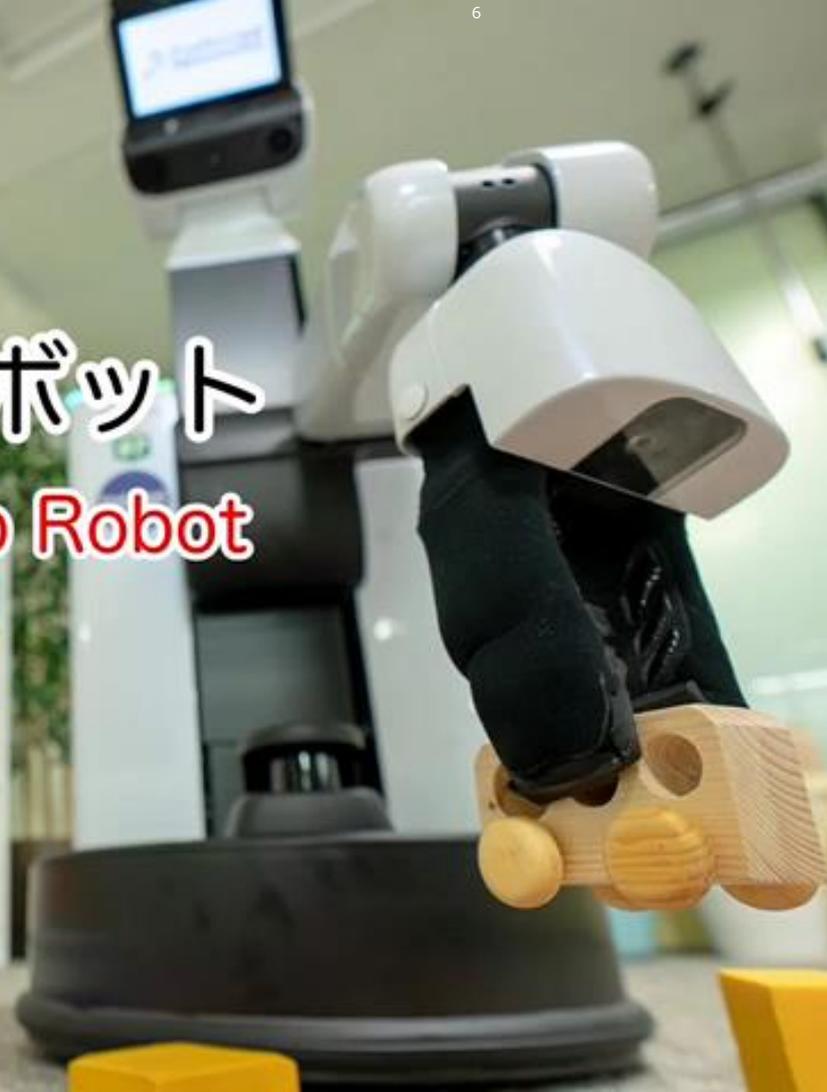
AGENDA

- 今日のDeep Learning応用領域
 - なぜDeep Learningが注目されるのか？
- Deep Learningが必要とする計算資源
 - Deep Learningに求められる膨大な計算資源と技術基盤
- AI応用領域に求められるセキュリティ
 - Trusted AI lifecycle への取り組み
- むすび

今日のDeep Learning応用領域

全自動お片付けロボット

Autonomous Tidying-up Robot



ロボットを題材に考察する

なぜDeep Learningが注目されるのか？

産業用ロボット

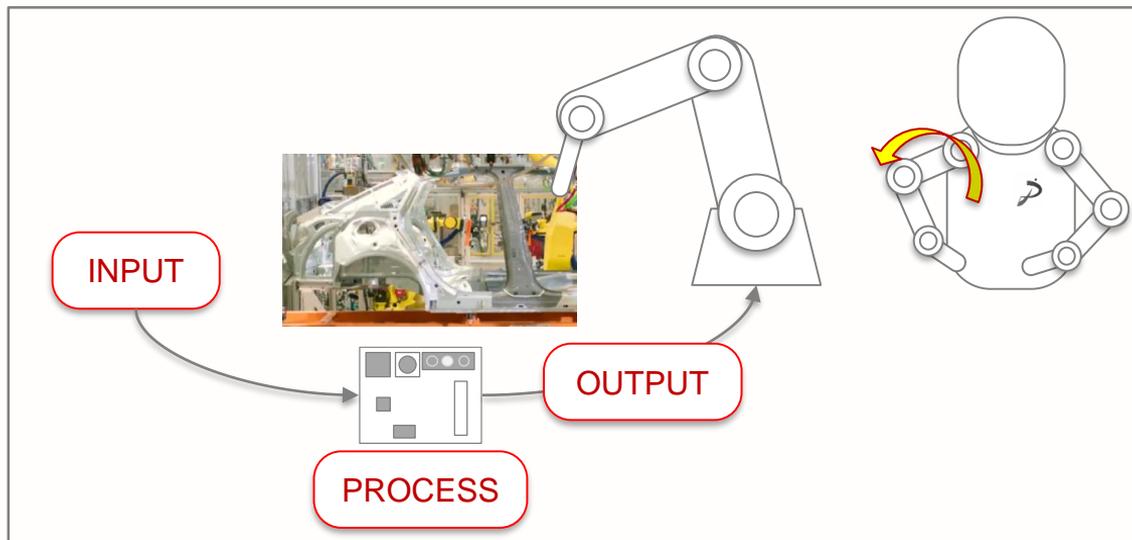


producing 2 million engines and 135 thousand cars in 2014.

高度な制御が行われている。しかし、対象が常に決まった位置にある
ために実現できている**目の見えないロボット**

FANUC ipari robotok az AUDI Hungariánál
<https://www.youtube.com/watch?v=NtQjQkDli-g>

一般的な産業用ロボット



INPUT

- 信号
(セット完了)

PROCESS

- プログラムに従った動作
(ティーチング)

OUTPUT

- 動作の実行
(モーターの制御)

センサーにより、所定の位置にセットされたことが検出されると、あらかじめ決められたプログラム通りに動作を行う。

- 常に同じ動作
- 作業結果のフィードバックは生じない

つまり、**視覚情報なしに動作**している。

アルゴリズムで記述が可能

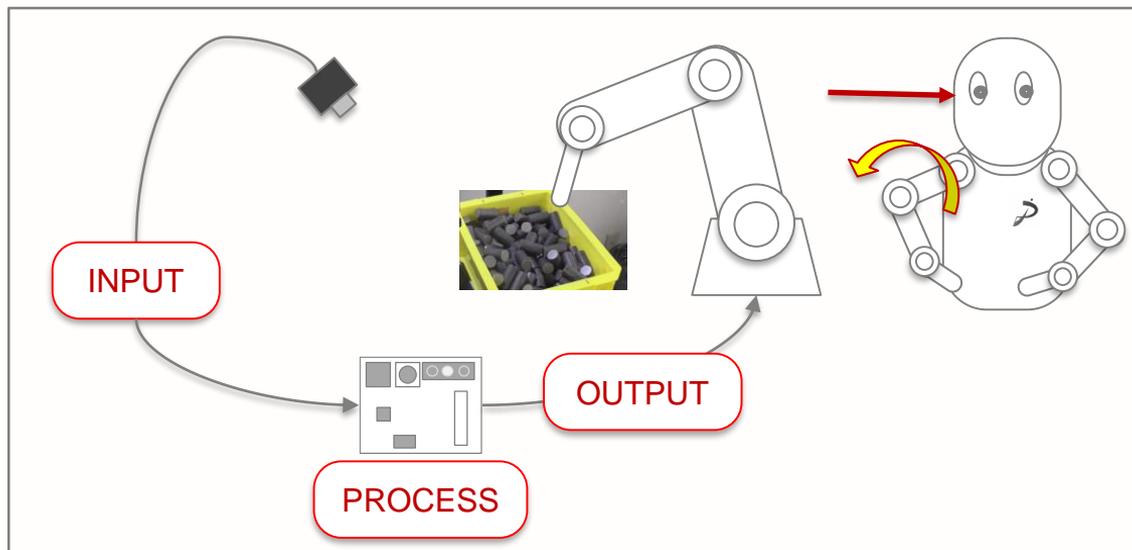
産業用ロボット（ばら積みロボット）



ばら積み(Random Pickup)では、事前に対象の位置を正確にプログラム（ティーチング）できないため、画像などに基づいたフィードバックと、動作計画をリアルタイムで実施する必要がある。つまり、**目が見える必要がある**

FANUC【バラ積みロボットの活用例】3Dビジョンセンサを用いた前段取りシステム
<https://youtu.be/qHeDW7ICC5A>

バラ積みロボット



INPUT

- 画像

PROCESS-1

- 対象の特定
- 位置の算出

PROCESS-3

- 成功・失敗の判断

PROCESS-2

- ピックアップの計画
- 動作のプログラム

OUTPUT

- 動作の実行
(モーターの制御)

画像から、自動的に対象群を認識し、そのなかからピックアップする対象を選択する。

対象をピックアップするためのシーケンスを生成し、これを実行する。トレーニング時には、画像から、動作が成功したかどうかを判断する。

- 変化する状態に合わせた、3次元情報を算出
- 対象をピックアップするためのシーケンスを生成
- 訓練時には、成功・失敗を認識し、精度を高めていく

つまり、**視覚情報に基づいて作業を行うが、画像認識するアルゴリズムが極めて難しい。**

(形、光、方向、などで画像が変わってしまう)

画像と音声を計算可能にする取り組み

コンピューターの二つの問題

- 現実的な時間で解けない問題がある

- 計算能力を増大させ続ける一つの要因

- ✓ ボードゲームは、可能な局面をすべて探索すれば必ず勝てるが、
まともにすべてを計算するとチェッカーで 3億年かかる計算 (10の14乗/秒)

- 必ずしもDeep Learningで取り組んではいけないが、計算量を減らすために利用されている

- その問題を解く明確な手順が必要

- 演繹的、アルゴリズムがかけないと解けない

- ✓ アルゴリズムから外れたものは、解けないか、誤った解を導く (汎化性能)
- ✓ 画像解析、音声認識、翻訳など

- Deep Learningによる取り組みが行われている領域

チェッカー	10の30乗
オセロ	10の60乗
九路盤囲碁	10の90乗
チェス	10の120乗
将棋	10の220乗
囲碁	10の360乗

Deep Learning とは？ : 摂氏から華氏への変換

Deep Learning

普通関数

仕様
入力: C
出力: F
ただし、FはCを華氏で表したもの

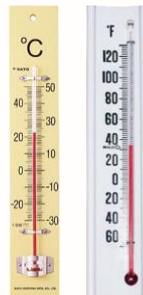
モデル $F = 1.8 * C + 32$

アルゴリズム

```
double c2f(double c) {  
    return 1.8*c + 32.0;  
}
```

**モデルが既知
アルゴリズムが
構成可能である必要**

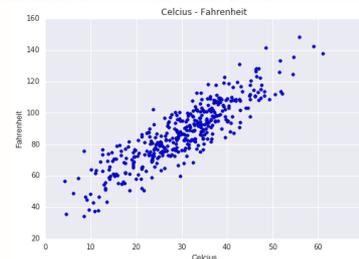
人が持つ
先験的知識



観測



訓練データセット

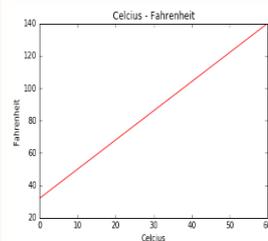


X

$$Y = f(X, \theta)$$

Y

モデル: 線形回帰式



**モデル・アルゴリズムが
未知でよい**

Deep Learningへの注目：画像認識に関するコンテスト - IMAGENET

Beach

An area of sand sloping down to the water of a sea or lake

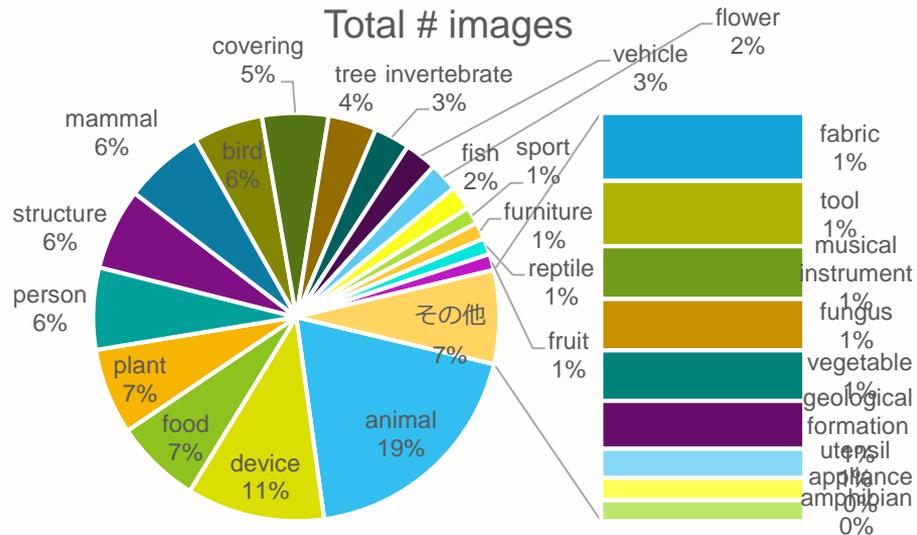
1713 pictures 97.48% Popularity Percentile Wordnet IDs

Numbers in brackets: (the number of synsets in the subtree).

ImageNet 2011 Fall Release (32326)
 plant, flora, plant life (4486)
 geological formation, formation (1):
 aquifer (0)
 beach (1)
 plage (0)
 cave (3)
 cliff, drop, drop-off (2)
 delta (0)
 diapir (0)
 folium (0)
 foreshore (0)
 ice mass (10)
 lakefront (0)
 massif (0)
 monocline (0)
 mouth (0)
 natural depression, depression (0)
 natural elevation, elevation (41)
 oceanfront (0)
 range, mountain range, range of relict (0)
 ridge, ridgeline (2)
 ridge (0)
 shore (7)
 slope, incline, side (17)
 spring, fountain, outflow, outpouring (0)
 talus, scree (0)
 vein, mineral vein (1)
 volcanic crater, crater (2)
 wall (0)

*Images of children synsets are not included. All images shown are thumbnails. Images may be subject to copyright.

Prev 1 2 3 4 5 6 7 8 9 10 ... 48 49 Next



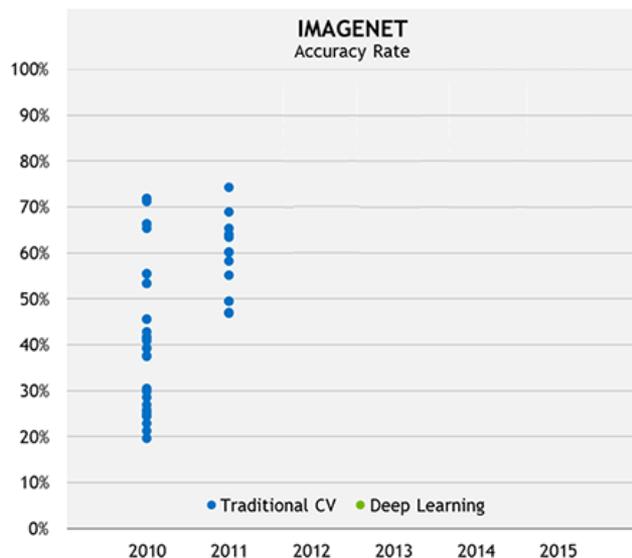
Total number of non-empty synsets	21,841
Total number of images	14,197,122
Number of images with bounding box annotations:	1,034,908
Number of synsets with SIFT features	1,000
Number of images with SIFT features	1.2 million

<http://looseleaf0727.hatenablog.jp/entry/2017/12/17/233709>

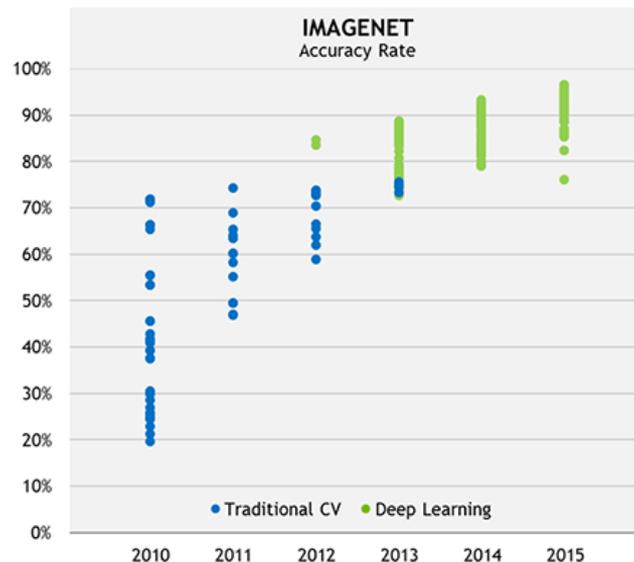
<http://www.image-net.org/about-stats>

Deep Learningによる画像認識のブレイクスルー (IMAGENET)

2015: A MILESTONE YEAR IN COMPUTER SCIENCE



2015: A MILESTONE YEAR IN COMPUTER SCIENCE



ロボットにおける 画像と音声・機能的プログラミングの利用

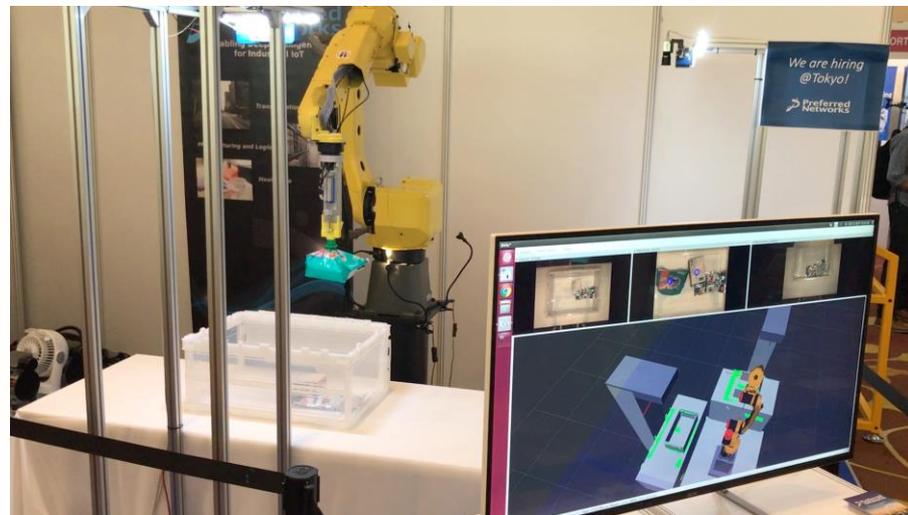
Deep Learningで帰納的に問題を解く

実験映像

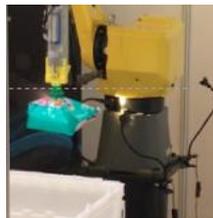
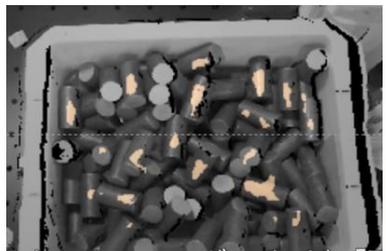


バラ積みされた円柱の取り出しを
0から自動的に学習する

ティーチングなしでバラ積みされた部品を取り出す。
8時間の学習で9割の取得率（熟練者のチューニングに匹敵）



トレーニングをしていない、多様な形状のものを取り出す
液体の入った袋のような、移動に伴って重心が変わるモノや、
初めてのモノでも、取り出すことができる（高い汎化性能）



Deep Learningを使って物体を認識する

実世界における インタラクティブな物体指示

羽鳥潤*, 菊池悠太*, 小林颯介*, 高橋城志*,
坪井祐太*, 海野裕也*, Wilson Ko, Jethro Tan

* Starred authors equally contributed

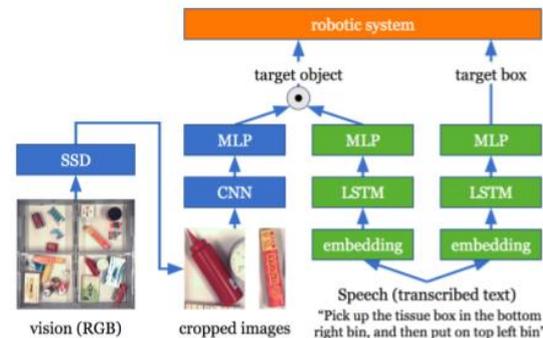
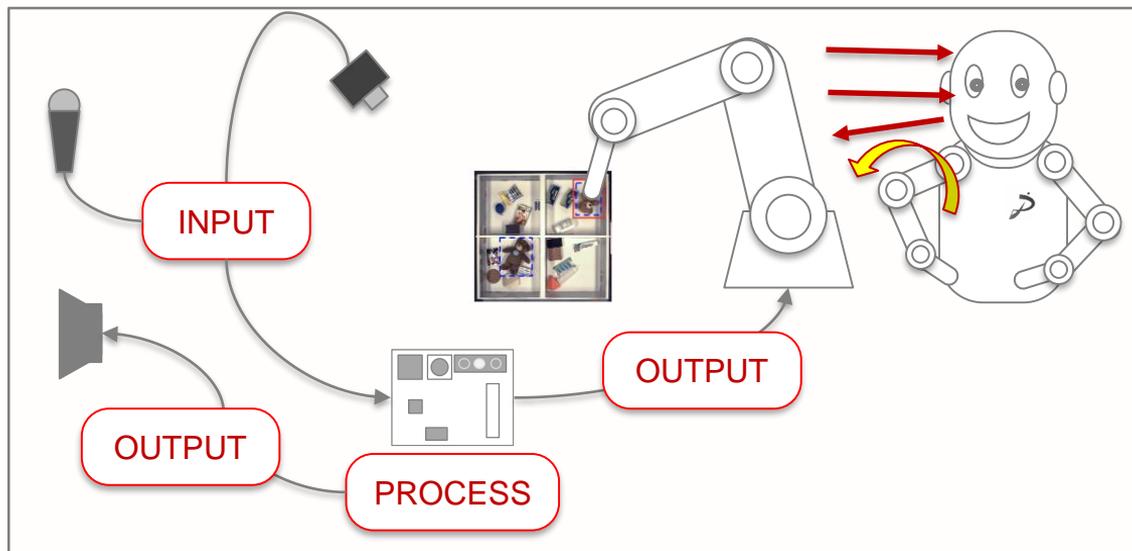


図3: 全体のネットワーク構成. 入力画像は SSD によって検出した物体ごとに切り抜き, CNN によって特徴情報を抽出し, 言語指示は LSTM によって同様に特徴情報を抽出する. 両者を使って対象物と移動先を推定する.

そこにある“何か”ではなく、それが何かを認識する

https://anlp.jp/proceedings/annual_meeting/2018/pdf_dir/C5-1.pdf

インタラクティブな物体指示



画像から、自動的に対象群を認識し、自然言語による曖昧な指示に従って移動する対象、移動先を認識し移動する。対象が特定できない場合は、問い合わせを行うことで、対象を特定する。対象群が、形状だけではなく、名称や特徴として認識されている。

INPUT

- 画像

PROCESS-1

- 物体検出
- 物体選択
- 移動先予測
- 指示の曖昧性判定と解消

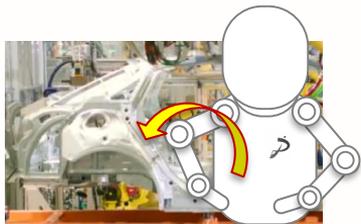
PROCESS-2

- ピックアップの計画
- 動作のプログラム

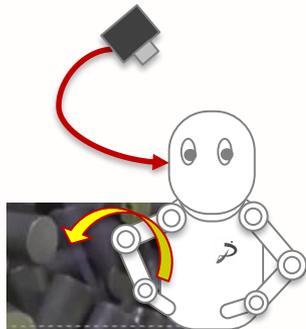
OUTPUT

- 動作の実行 (モーターの制御)
- 応答
- 指示の確認

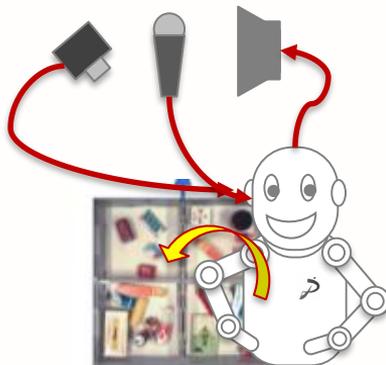
ロボットに見る 識別・認識・認知



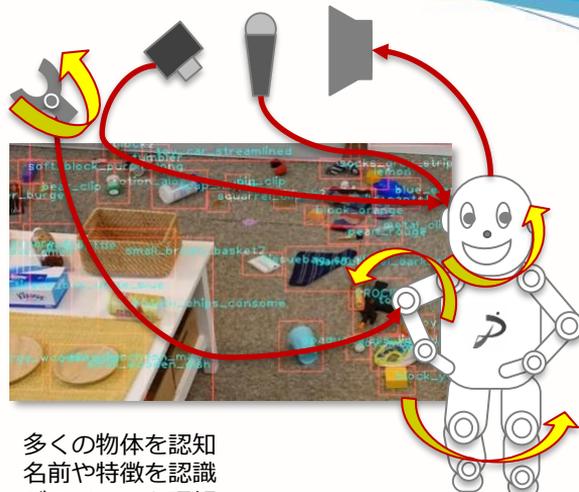
- 視覚を持たない
- 聴覚を持たない
- 発話をしない
- 計画をしない
- 移動しない (据え付け)



- 特定物体の形状を識別
- 名前や特徴を持たない
- 聴覚を持たない
- 発話をしない
- ピックアップを計画
- 移動しない (据え付け)



- 多くの物体を識別
- 名前や特徴を認識
- 音声の指示を理解
- 指示の不明瞭さを判断
- 指示の認識を応答
- 指示の不明瞭さの解決を促す
- 指示に基づいて、ピックアップと移動を計画
- 移動しない (据え付け)



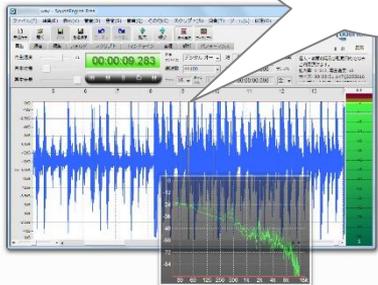
- 多くの物体を認知
- 名前や特徴を認識
- ゼスチャーを理解
- 音声の指示を理解
- 指示の不明瞭さを判断
- ゼスチャーとの組み合わせを理解
- 指示の認識を応答
- 指示の不明瞭さの解決を促す
- お片付けを計画
- 物体をピックアップし指定の場所に移動
- 移動し、自身の位置を把握する
- 物体の位置を記憶し相対的な位置を理解する
- 握る・圧力を感じる

音声における計算レベル・認識レベル



音声の例

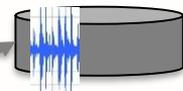
けん玉はどこ？



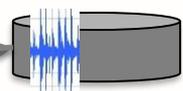
背景音と分離
抽出データ

ディクテーション
(聞き取り)

音データ



音声データ



テキストデータ

“ケンダムハドコ”

単語・文節の認識

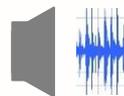
“ケンダム・ハ・ドコ”

意味の認識

“ケンダム (名詞) ・ハ (接
続詞) ・ドコ (副助詞) ”に
あるかを尋ねている

文脈の認識

“ケンダム”を認識 (認識できなければ質問)
“ケンダム”は部屋にひとつ (複数の場合は質問)
記録されている場所は (X,Y)
周辺で目印になる物体の選出 (“Z1”, “Z2”, “Z3”)



再生

計算できない

計算できる

単純な会話・指示

- 検索エンジンの入力
- カーナビの指示、音声案内

単純な会話・指示

- 自動翻訳、書き起こし
- チャットボット
- スマートスピーカー

単純な会話・指示

- お片付けロボット
- 高度な対話型のシステム

Deep Learningが必要とする膨大な計算資源

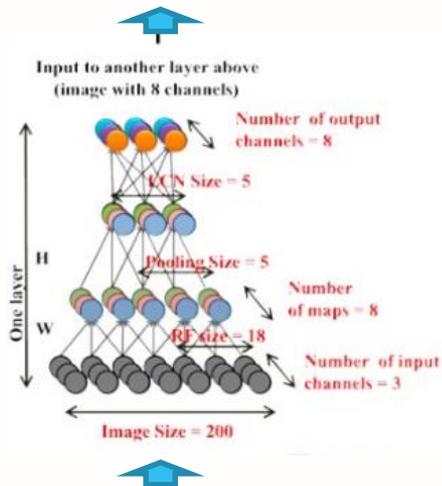
Deep Learning が必要とする計算リソース

汎用計算機構としての深層学習

代償： 暴力的な計算リソース

学習を1日で終わらせるのに必要な計算リソース

出力 (超多次元)



入力 (超多次元)

桁違いに多いパラメタ

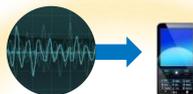
任意の多次元非線形関数を近似
→ 疑似的にチューリング完全!

画像/
映像認識



10P (画像) ~ 10E (映像) Flops
学習データ：1億枚の画像 10000クラス分類
数千ノードで6ヶ月 [Google 2015]

音声認識



10P ~ Flops
1万人の5000時間分の音声データ
人工的に生成された10万時間の
音声データを基に学習 [Baidu 2015]

機械学習、深層学習は学習データが大きいほど高精度になる
現在は人が生み出したデータが対象だが、今後は機械が生み出すデータが対象となる

各種推定値は1GBの学習データに対して1日で学習するためには
1TFlops必要だとして計算

バイオ・ヘルスケア



100P ~ 1E Flops
一人あたりゲノム解析で約10M個のSNPs
100万人で100PFlops、1億人で1EFlops

自動運転



1E ~ 100E Flops
自動運転車 1台あたり1日 1TB
10台 ~ 1000台, 100日分の走行
データの学習

ロボット/ドローン



1E ~ 100E Flops
1台あたり年間1TB
100万台 ~ 1億台から得られた
データで学習する場合

P: Peta
E: Exa
F: Flops

10PF

100PF

1EF

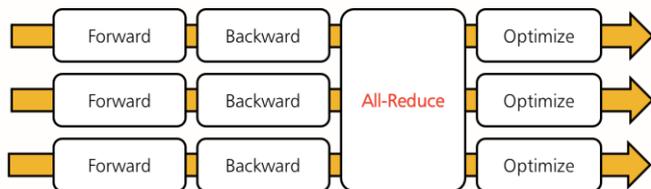
10EF

100EF

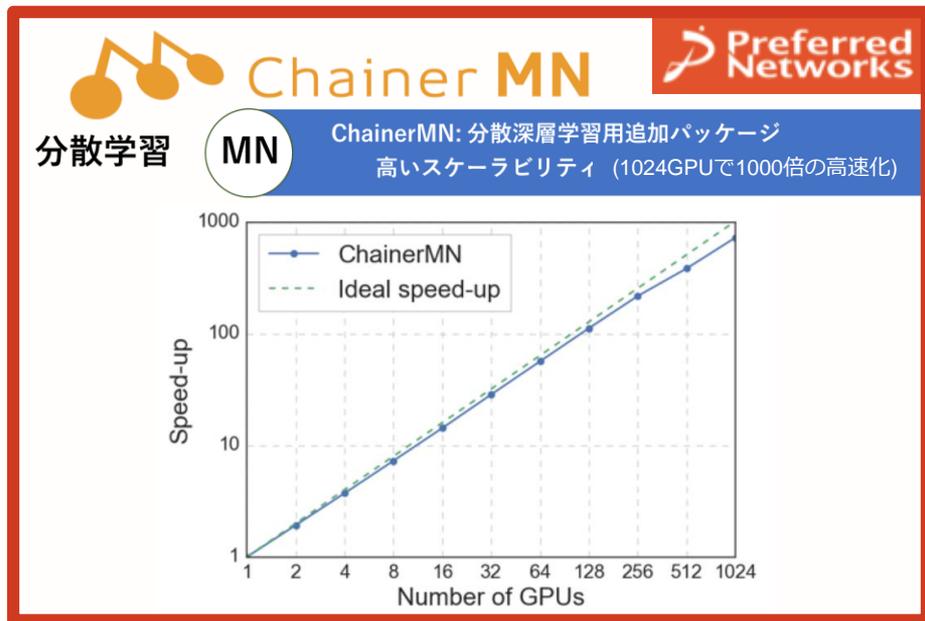
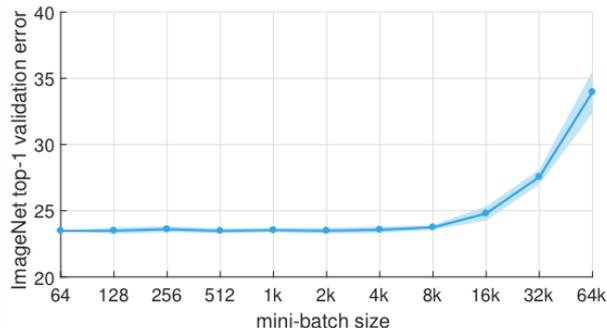
高速化・大規模化：分散学習の大規模を支える技術

- GPUとバッチサイズを増やせば高速化 \leftrightarrow モデル同期頻度が減るので精度悪化
- パラメータ調整、NVIDIAライブラリの有効活用、Infiniband等の高速通信…

GPUとデータセットを並列にしAll-Reduceで勾配情報の共有



各GPUの毎回の処理数 = バッチサイズが大きすぎると破綻



MN-1: The GPU cluster behind 15-min ImageNet

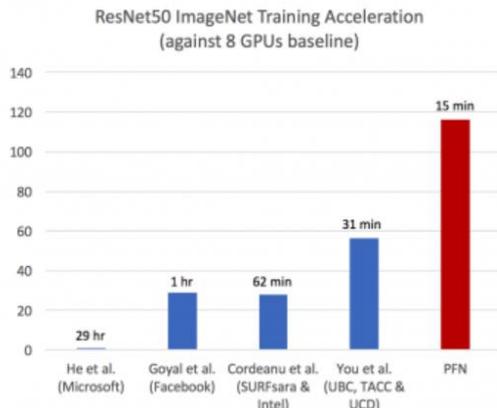
<https://preferredresearch.jp/2017/11/30/mn-1-a-gpu-cluster-behind-15-min-imagenet/>

深層学習の学習速度において世界最速を実現

大規模な並列コンピュータを活用し、分散学習パッケージ ChainerMNでImageNetの学習を15分で完了

株式会社Preferred Networks（本社：東京都千代田区、代表取締役社長：西川徹、プリファードネットワークス、以下、PFN）は、大規模な並列コンピュータ「MN-1^{※1}」を活用し、深層学習（ディープラーニング）の学習速度において世界最速を実現しました。

深層学習モデルの精度を向上させるため、学習データのサイズやモデルのパラメータ数が増加し、それともなっていくと計算時間も増大しています。1回の学習に数週間かかることも稀ではありません。複数のコンピュータを連携させて学習を高速化することは、新たなアイデアの試行錯誤や検証に要する時間を圧縮し、素早く研究成果をあげていくために非常に重要です。



Preferred Networksのプライベート・スーパーコンピュータがTop 500リストのIndustry領域で国内1位に認定

© 2017年11月14日 ■ タグ: MN-01, supercomputer 👤 By preferred

株式会社Preferred Networks（本社：東京都千代田区、代表取締役社長 最高経営責任者：西川 徹、以下PFN）が占有利用するプライベート・スーパーコンピュータ「MN-1」が、LINPACK^{※1}性能測定の結果、約1.39ペタFLOPS^{※2}を記録しました。これにより、2017年11月のスーパーコンピュータ性能ランキングを示すTOP500リスト (<http://www.top500.org>) において、産業領域 (Industry Segment) のスーパーコンピュータにおける世界12位、国内1位として登録されました。研究用等の全てのスーパーコンピュータを含むランキングにおいては、世界91位、国内13位となります。

PFNのプライベート・スーパーコンピュータMN-1の概要^{※3}

MN-1は、NTTコミュニケーションズ株式会社（本社：東京都千代田区、代表取締役社長：庄司 哲也、以下NTT Com）と株式会社NTTPCコミュニケーションズ（本社：東京都港区、代表取締役社長：田中 基夫、以下NTTPC）の高速演算処理 (GPU) プラットフォームを採用し、計算ノードにはNVIDIA^(R) Tesla^(R) P100GPUを1,024基搭載しています。

MN-1は、Mellanox社製 Infiniband インターコネクトを活用することで、PFNが開発する分散深層学習パッケージChainerMN（チェイナー・エムエヌ）による高速な分散深層学習^{※4}が可能です。

PFNはMN-1を使って、特に多くの計算機資源を必要とする交通システム、製造業、バイオ・ヘルスケア分野をはじめとしたさまざまな分野での深層学習の研究開発を、より一層加速させます。

<https://www.preferred-networks.jp/ja/news/pr20171114>

Google AI Open Images – Object Detection Track

Preferred Networks, Inc.
 作成者: 坂口 弓 (?) · 9月8日 8:13 · 3

表示: 日本語 ▾

【発表】世界454チームが参加したKaggle物
 Open Images – Object Detection Trackで準備

コンペにはチーム「PFDet」として参加。今
 V100 32GB 512基の大規模クラスター「MN-

た。
 惜しくも0.023%という僅差のスコアで2位となりましたが、コンペでの

開発成果はChainerMN、ChainerCVの新機能として活用します。

<https://www.preferred-networks.jp/ja/news/pr2018>

解法論文はこちらで公開しています。

<https://arxiv.org/abs/1809.00778>

Object Detection Track

Object detection is a central task in computer vision, with applications ranging across search, robotics, self-driving cars, and many others. As deep network solutions become deeper and more complex, they

- 170万枚上の500オブジェクトクラス、1200万の境界ボックスのアノテーション
- 複数のオブジェクトを含む複雑なシーンの画像-平均7ボックス/画像
- “fedora” や “snowman” 等の新しいブランドオブジェクトを含む非常に多様な画像
- イメージのクラス間の関係を反映する階層。

項目	MN-1	MN-1b	MN-2	MN-1bとMN-2の性能比
計算用CPU Core 総数	2,048	2,304	5,760	150 %UP
計算用GPU 総数	1,024	512	1,024	100 %UP
計算用GPU 性能※1	19.1 ペタフロップス	57.3 ペタフロップス	128 ペタフロップス	123 %UP

GPU Node 1台あたりの主な性能

GPU	モデル	NVIDIA P100 PCI-e	NVIDIA V100 PCI-e	NVIDIA V100 SXM2	-
	相互接続帯域幅	32 GB/s	32 GB/s	300 GB/s	837 %UP
Network	Ethernet	1 GbE	10 GbE	100 GbE x 4	-
	InfiniBand	FDRx2 (112Gbps)	EDRx2 (200Gbps)	なし	-

Takuya Akiba @twit Following ▾

明日からの CEATEC JAPAN 2018 で全自動お片付けロボットシステム」を展示します！ChainerMN は勿論、先日の Open Images Challenge 準優勝の成果物も早速活用しており、この激すごデモに少しでも貢献できたことを誇りに思います。明日は僕も会に居ります。

Takuya Akiba @twit Following ▾

09.00778] PFDet: 2nd Place Solution to Open Images Challenge 2018 Object Detection Track <https://arxiv.org/abs/1809.00778> Open Images Challenge で準優勝を獲得した PFDet のアプローチをまとめたものを tv で公開しました。しれっと書いてありますが、1度の学習に 512 GPU で 33 時間。

10:47 AM - 5 Sep 2018

NVIDIA Tesla V100 x 512

PREFERRED-NETWORKS.JP

www.preferred-networks.jp

Exai kltus

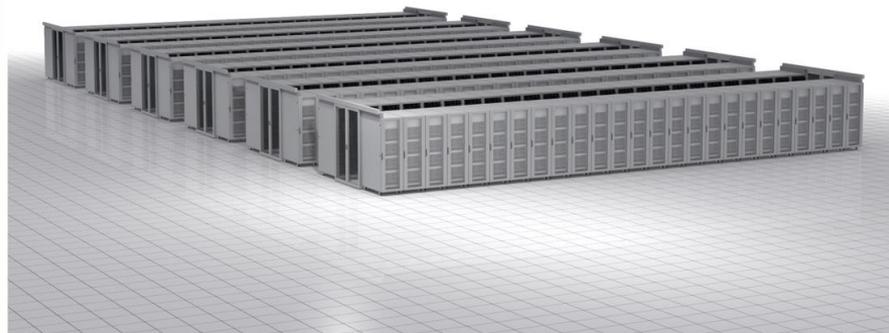
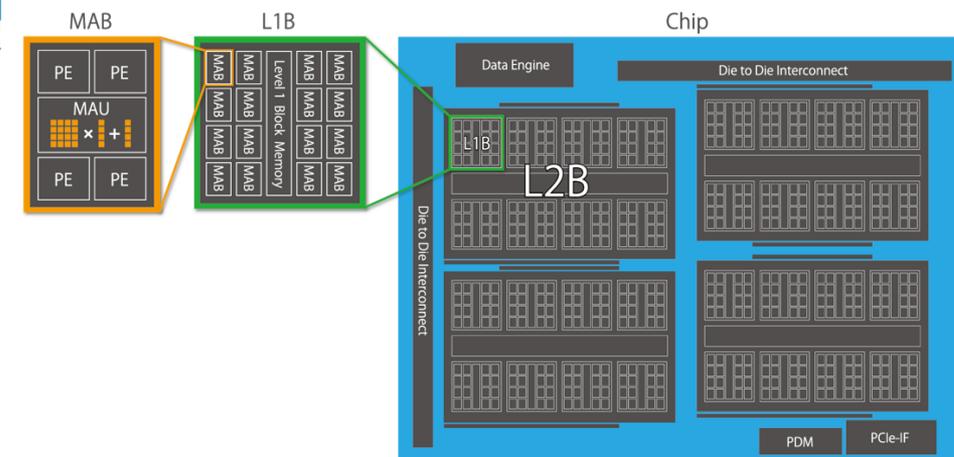
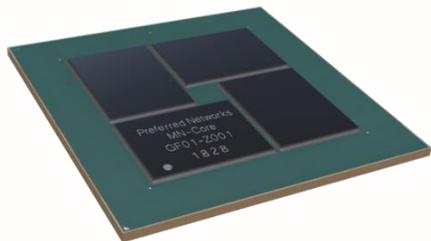
MN-2 (2019/03)

Star by Rhys A. Right: the house by anita

<https://www.kaggle.com/c/google-ai-open-images-object-detection-track>



MN-Core



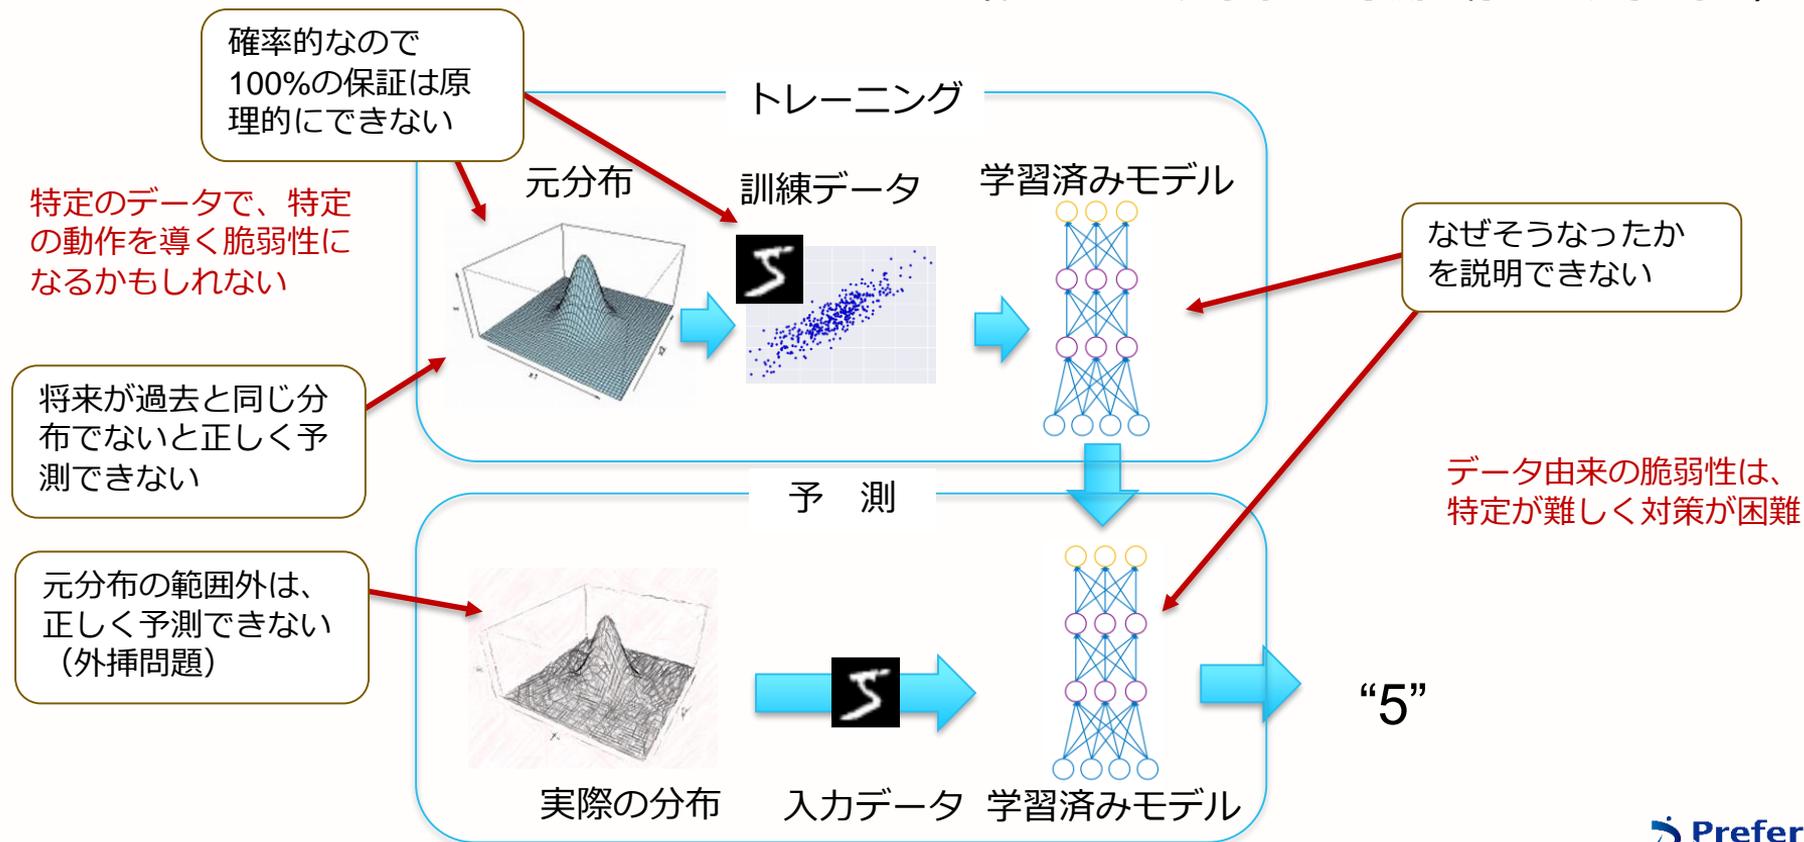
•MN-Coreチップのスペック

- 製造プロセス：TSMC 12nm
- 消費電力 (w、予測値)：500
- ピーク性能 (TFLOPS)：32.8 (倍精度) / 131 (単精度) / 524 (半精度)
- 電力性能 (TFLOPS / W、予測値)：0.066 (倍精度) / 0.26 (単精度) / 1.0 (半精度)

AI応用領域に求められる セキュリティ

統計的機械学習の本質的限界

統計的機械学習は、トレーニングと予測は独立したフェーズとして構成される。
(トレーニングしながら予測を行うわけではない)



AI応用領域に求められるセキュリティ

IT環境のセキュリティ

AI応用製品のセキュリティ

Trusted AI Lifecycle

- (Traditional) SDLの展開
- Secure DL Engineering等の適用
- データ要件フレームワーク
- データ検証フレームワーク
- トレーニングフレームワーク
- 検査手法フレームワーク
- Trustレスポンスフレームワーク
- DL Software StackのSDL
- 教育とトレーニング

Threat Modeling for Trusted AI

- STRIDE for Trusted AI
- Factors Influencing Uncertaintyをベースにした、脅威モデルの構築
- Safety, Privacyの組み込み

CERT/CSIRT for AI

- 脆弱性全般のハンドリング
- CERT/CSIRTとの連携
 - 主にシステム領域
- DL Software Stack
 - 脆弱性等ハンドリング
 - ベストプラクティス
 - Incident/Accident事例
- データレピュテーション
 - トレーニングデータ
 - トレーニング済モデル

Security Product / Solution with AI

- AIを使ったセキュリティ製品ソリューション

Data Security

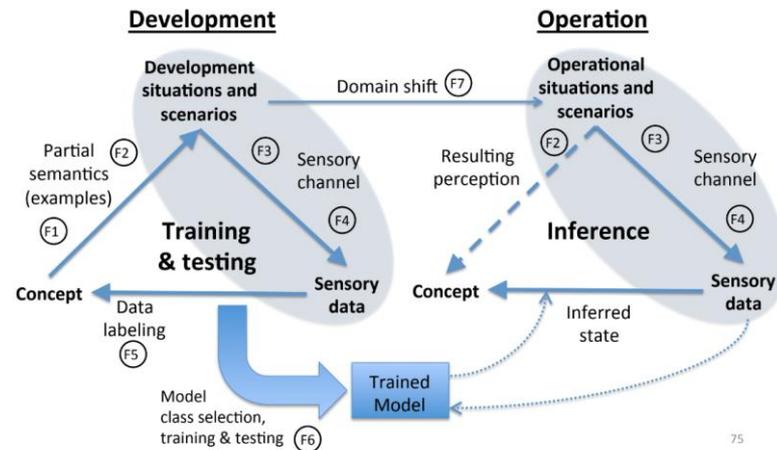
流通するデータのセキュリティ

脅威分析に不確定性を取り入れてみてはどうか？

STRIDE



FIU: Factors Influencing Uncertainty



不確かさに影響を与える要因（画像認識）

● F1: コンセプトの不確かさ

- 歩行者とサイクリストの区別
- 標準的なオントロジーの確立が必要

● F2: 開発シナリオのカバレッジ

- 様々な格好をした人々
- どれだけのデータが必要か：正解/不正解、ニアヒット/ニアミス

● F3: シーンの不確かさ

- 範囲、スケール、オキュレーションレベル、可視性、照明、集合・混雑レベル
- テストセットの正確性と出力の確かさをこれらの指標で評価する必要がある

● F4: センサーのプロパティ

- 成熟した工学的ディシプリン：モード、範囲、解像度、感度、配置、等
- ML アルゴリズムとセンサ特性の相互作用

● F5: ラベルの不確かさ

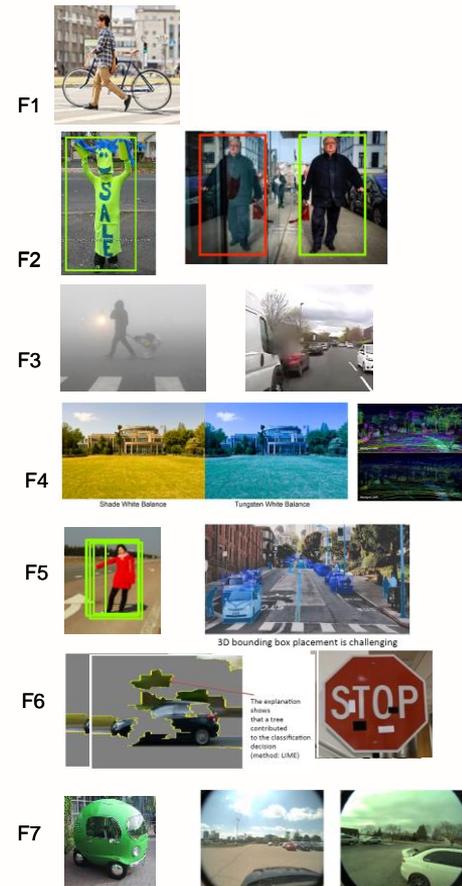
- 専門家のレビューとラベラーの不一致

● F6: モデルの不確かさ

- 説明手法、堅牢性評価、ベイズによる検証

● F7: 運用ドメインの不確かさ

- 新しい歩行者のポーズ、車の形状の新しいタイプ、カメラミスキャリブレーション
- 稼働時の新規状況の評価、インパクトレベル、センサーパラメータの評価



むすび

AI応用技術とセキュリティ

- AI応用技術は確実に利用が広がっている
 - これまでのロジックでは現実的な解がなかった領域に、現実的な解をもたらしている
 - 「現実世界を計算可能にする」ための取り組みが進んでいる
- AI応用技術は膨大な計算リソースを必要としている
 - 総合的な計算資源の強化が求められている
- AI応用技術のセキュリティを体系化することが求められている
 - ITレベルのセキュリティ
 - 製品レベルのセキュリティ
 - データレベルのセキュリティ



Retail

Using big data from diverse devices, we recognize customers' interests and attributes through analysis of their in-store behavior.



Advertising

Our technology provides an advanced O2O solution by integrating online and offline data for prediction of consumer behaviors and attributes.



Manufacturing

We automate manufacturing operations to maximize production efficiency and recommend counteractions in emergency situations.



Network Security

Using our distributed and collaborative computing methods, we provide advanced attack detection and threat avoidance.



Health Care

Our framework enables early detection of disease, through analysis of genomic, vital signs, environmental, and infectious disease trends data.



Life Science

Our integrative, multi-purpose system detects and predicts new phenomena, advancing developments in biotechnology, drug discovery, and health care.



Public Safety

Powered by deep learning, our leading-edge video analytics system provides real-time threat detection for any environment.



Transportation

We automate vehicle and transportation operations through computer vision and collaborative, real-time analysis of multiple types of data.