

AIの発達により我々の生活・産業が どのように変わるのか

東京大学 松尾 豊

東京大学 松尾研究室について



松尾 豊

- 1997年 東京大学工学部電子情報工学科卒業
- 2002年 同大学院博士課程修了。博士(工学)。産業技術総合研究所 研究員
- 2005年 スタンフォード大学客員研究員
- 2007年～ 東京大学大学院工学系研究科 技術経営戦略学専攻 准教授
- 2014年～ 東京大学 グローバル消費インテリジェンス寄付講座 共同代表・特任准教授
- 2015年～ 産総研AIセンター 企画チーム長
- 2017年～ 日本ディープラーニング協会設立。理事長。

- ◆人工知能、ディープラーニング、Webマイニングを専門とする。
- ◆論文数と被引用数に基づき科学者の科学的貢献度を示すh-Index=31(ウェブ・人工知能分野最高水準)であり、2013年より国際WWW会議Web Mining部門のチェアを務める。
- ◆2012年より、人工知能学会 理事・編集委員長、2014年から倫理委員長。
- ◆人工知能学会論文賞(2002年)、情報処理学会長尾真記念特別賞(2007年)、ドコモモバイルサイエンス賞(2013年)、文部科学省 科学技術への顕著な貢献2015、大川出版賞(2015年)、ビジネス本大賞審査員賞(2016年)等受賞。
- ◆経済産業省 産業構造審議会 新産業構造部会 委員、IoT推進コンソーシアム 運営委員、厚生労働省「働き方の未来 2035」懇談会メンバー、内閣府「人工知能と人間社会に関する懇談会」構成員、金融庁「フィンテック・ベンチャーに関する有識者会議」委員、総務省「ICTインテリジェント化影響評価検討会議」委員等。
- ◆近著に「人工知能は人間を超えるか?—ディープラーニングの先にあるもの」(角川 2015)。

<研究室の実績>

- ◆博士学生17人、修士・学部生10人が所属し、人工知能の基礎研究、ソーシャルメディアの分析、データ分析及びその実社会へのアプリケーションを多方面にわたって行っている。
- ◆これまでに、トヨタ、リクルート、マイクロソフト、CCC、経営共創基盤、ミクシィなどさまざまな企業と共同研究の実績がある。官公庁からも、経産省(アジアトレンドマップ等)、文科省(ビッグデータ活用)など相談多数。
- ◆卒業生の主な進路は、Google、DeNA、楽天、サイバーエージェント、光栄、ゴールドマンサックス、BCG、三井物産、電通など。起業した学生も多数。研究室からPKSHA technology, GunosyやREADYFORなどの企業を産み出した。

Google DeepMindの開発したアルファ碁がプロ棋士を破る (2016年3月, 2017年5月)

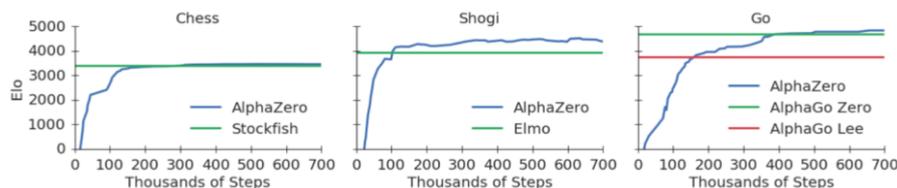
涙を見せた柯潔9段、「アルファ碁との対局、苦しかった」

Posted May. 29, 2017 09:04, Updated May. 29, 2017 09:06



囲碁世界ランキング1位の中国の柯潔9段の充血した両目には涙が浮かんでいた。カメラがクローズアップして柯潔9段を映すと、片手で顔を隠したが、泣いているのは明らかだった。27日午後1時頃、グーグル・デープ・マインド社が開発した人工知能(AI)囲碁プログラム「アルファ碁(AlphaGo)」と3回目の対局を行った柯潔9段。対局中に身動きが多かったが、3回目の敗北がほぼ確定した頃から銅像のように固まっていった。

- Googleが2014年に買収したDeepMind(英国ロンドン本社)が開発
- 韓国イ・セドル九段を4勝1敗で破る(2016年3月)
- 中国カ・ケツ九段を3連勝で破る(2017年5月)
- アルファ碁ゼロ(2017年10月)
 - プロ棋士の棋譜データなしで学習
 - それまでのアルファ碁よりさらに強い
- アルファゼロ(2017年12月)
 - 将棋、チェスでも既存のプログラム(名人より強い)を破る
 - ゼロから学習し、将棋は2時間、チェスは4時間



将棋電王戦



IBM ワトソン



ディープラーニング革命

- ILSVRCでの圧勝(2012)
- Googleの猫認識(2012)
- ディープマインドの買収(2013)
- FB/Baiduの研究所(2013)
- アルファ碁(2016)

機械学習

ウェブ・ビッグデータ

車・ロボット
への活用

自動運転
Pepper

統計的自然言語処理
(機械翻訳など)

検索エンジンへの活用

MYCIN(医療診断)
DENDRAL

エキスパート
システム

オントロジー

タスクオントロジー

ワトソン(2011)

LOD(Linked Open Data)

Eliza

対話システムの研究

Caloプロジェクト

Siri(2012)

bot

探索
迷路・パズル

プランニング
STRIPS

チェス(1997)
Deep Blue

将棋(2012-)
電王戦

囲碁

1956

1970

1980

1995

2010

2015

第一次AIブーム
(推論・探索)

第二次AIブーム
(知識表現)

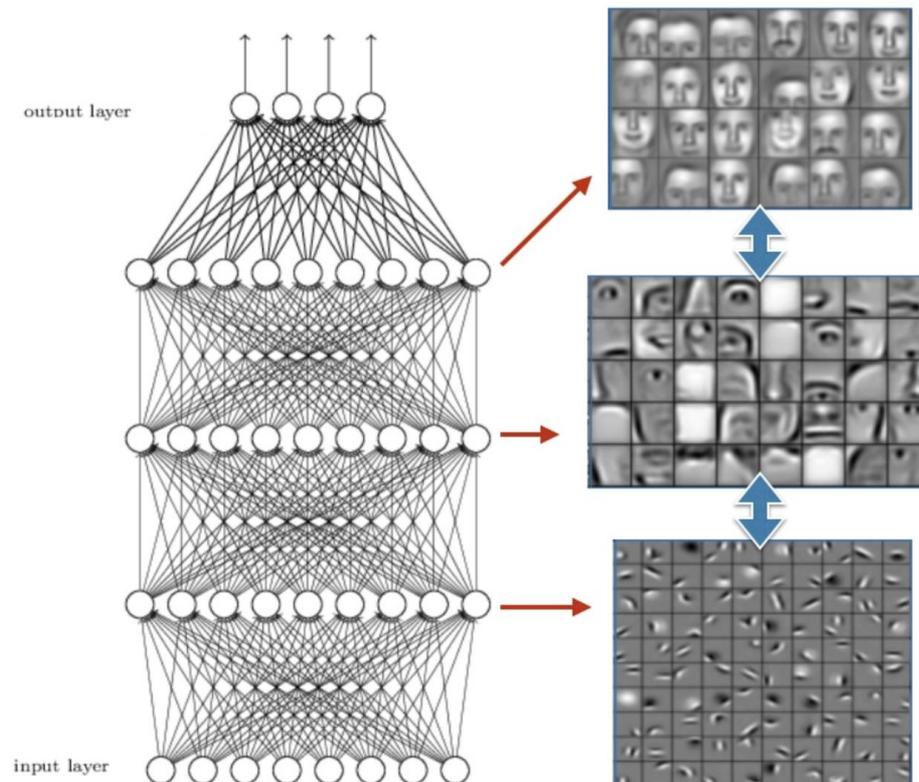
第三次AIブーム
(機械学習・ディープラーニング)

人工知能(AI)という言葉で指されるもの

- 1. IT系: 従来からあるIT技術の擬人化
 - フィンテック、IoT、RPA(ロボティックプロセスオートメーション)、...
 - AIの定義がないのでAIというのは嘘ではない。が、ITが重要というのと同義。
- 2. マシンラーニング系: 機械学習や自然言語処理を中心とする技術
 - ビッグデータ、ウェブ関連、コールセンターのサポート、与信
 - IBM ワトソン、日立 H、NEC the Wise、富士通 Zinrai
 - 1990年代からの技術。インターネット企業が活用しているイノベーション
- 3. ディープラーニング系: 「眼」の技術、画像処理と機械・ロボットの融合
 - アルファ碁、医療画像の診断、自動運転
 - 2012年ごろからの技術。世界が今まさに戦っている。
 - 日本は製造業との融合に大きなチャンス

ディープラーニングとは

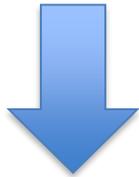
- 入力を出力に写像するために、簡単な関数の組み合わせで表現力の高い関数(「深い」関数)を作り、そのパラメータをデータから推定する方法
- 途中の階層には、入力を変換した「特徴量」が学習されている



ディープラーニング革命

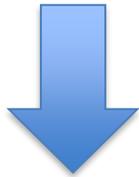
認識

「画像認識」ができる
(コンピュータができて以来、初めて！)



運動の習熟

ロボット・機械に
熟練した動きができる



言葉の意味理解

文の「意味」が分かる
(文と映像の相互変換ができる)

認識の難しさ



ネコ



イヌ



オオカミ

- これをコンピュータで見分けたい
 - 目が丸い→ネコ
 - 目が細長い、耳が垂れている → イヌ
 - 目が細長い、耳がとがっている → オオカミ

ところが...

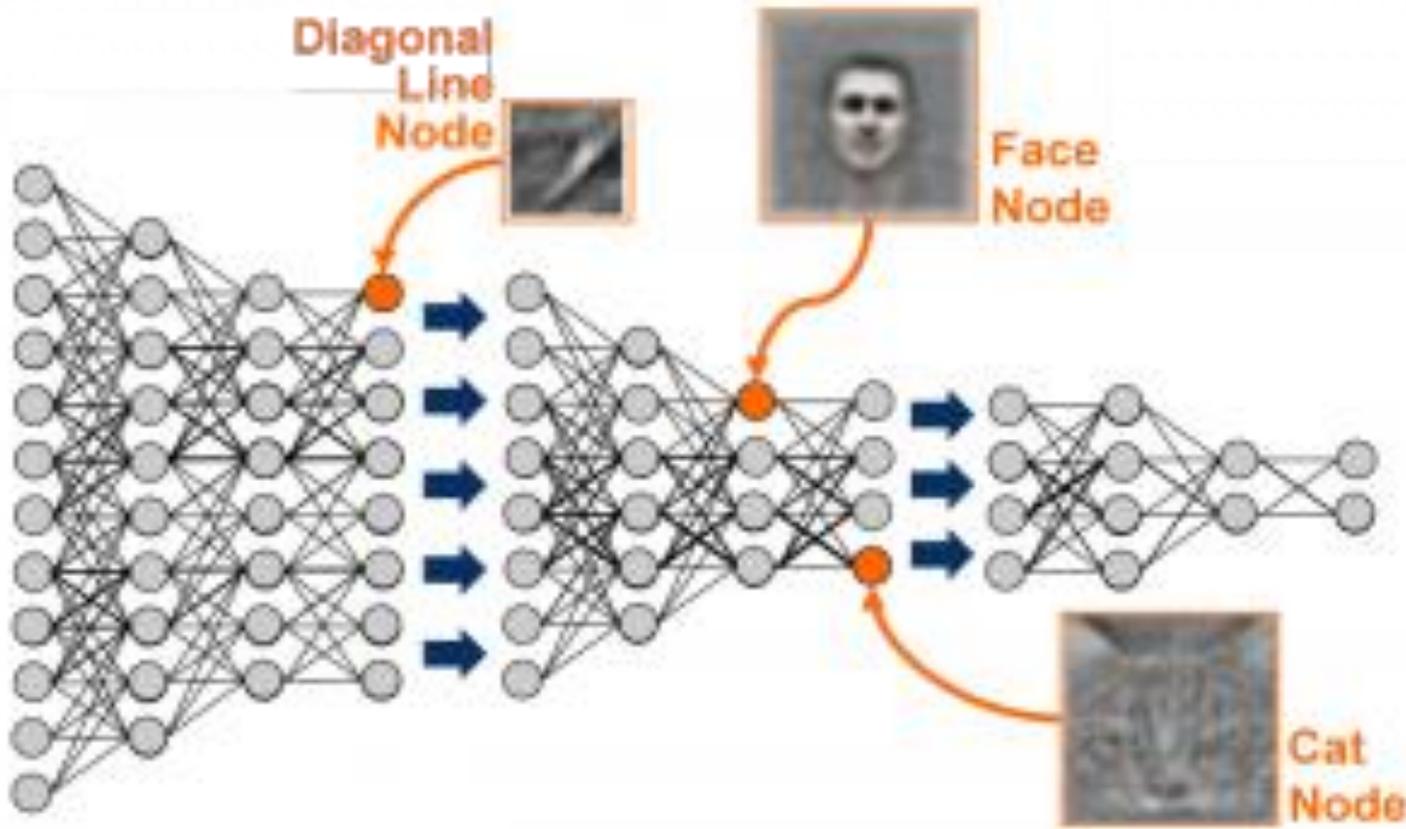


イヌ



結局、「耳が垂れている」「目が細長い」などの「特徴量」を人間が考えている限り無理。どんなに頑張っても、必ず例外がある。人間はなぜかうまくできる。

Googleの猫(2012)



- ・YouTubeから取ってきた大量の画像をニューラルネットワークに学習させることで、下位の層のニューロンには線や点といった単純な特徴量が、上位の層には、人の顔や猫といったより複雑な特徴量が学習される。
- ・人間の視神経のモデルとして知られているものと極めて近い。

認識：2012年以降のエラー率の変化

		Error
Before ディープ ラーニング	Imagenet 2011 winner (not CNN)	25.7%
	Imagenet 2012 winner	16.4% (Krizhevsky et al.)
	Imagenet 2013 winner	11.7% (Zeiler/Clarifai)
	Imagenet 2014 winner	6.7% (GoogLeNet)
After ディープ ラーニング	Baidu Arxiv paper:2015/1/3	6.0%
	Human : Andrej Karpathy	5.1%
	Microsoft Research Arxiv paper: 2015/2/6	4.9%
	Google Arxiv paper: 2015/3/2	4.8%
	Microsoft Research CVPR paper: 2015/12/10	3.6%
	ILSVRC 2016 winner	3.0%
	ILSVRC 2017 winner	2.3%

2015年2月に人間の精度を超えた

昔の画像認識と今の画像認識は全く別物。

The background features a network diagram with nodes and connecting lines. Several nodes are highlighted with a bright cyan glow. The text 'YOLO v2' is centered in a white, stylized font.

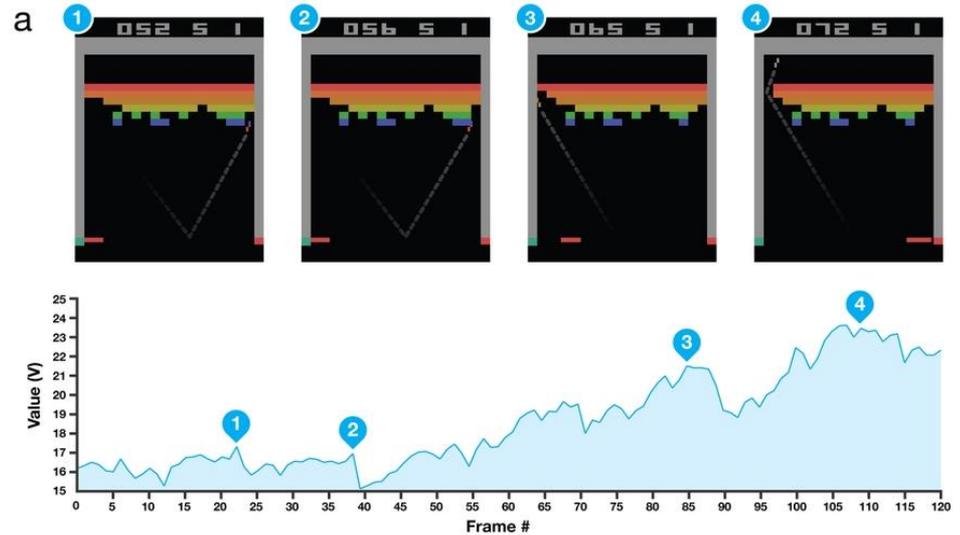
YOLO v2

<http://pureddie.com/yolo>

画像認識＋強化学習(2013-)

- 2013年 ATARIのゲームをプレイする人工知能をDeepMindが開発。人間よりうまくなる。
- 2015年 試行錯誤で部品の取付を習熟するロボットの開発(UC Berkeley)
- 2016年 試行錯誤でピッキングが上達するロボットの開発(Google)
- アルファ碁もこうした技術のひとつ

試行錯誤でゲームがうまくなる人工知能(DeepMind)



試行錯誤で作業学ぶロボット(UC Berkeley)



試行錯誤でピッキングが上達するロボット(Google)



Deep Reinforcement Learning

深層強化学習

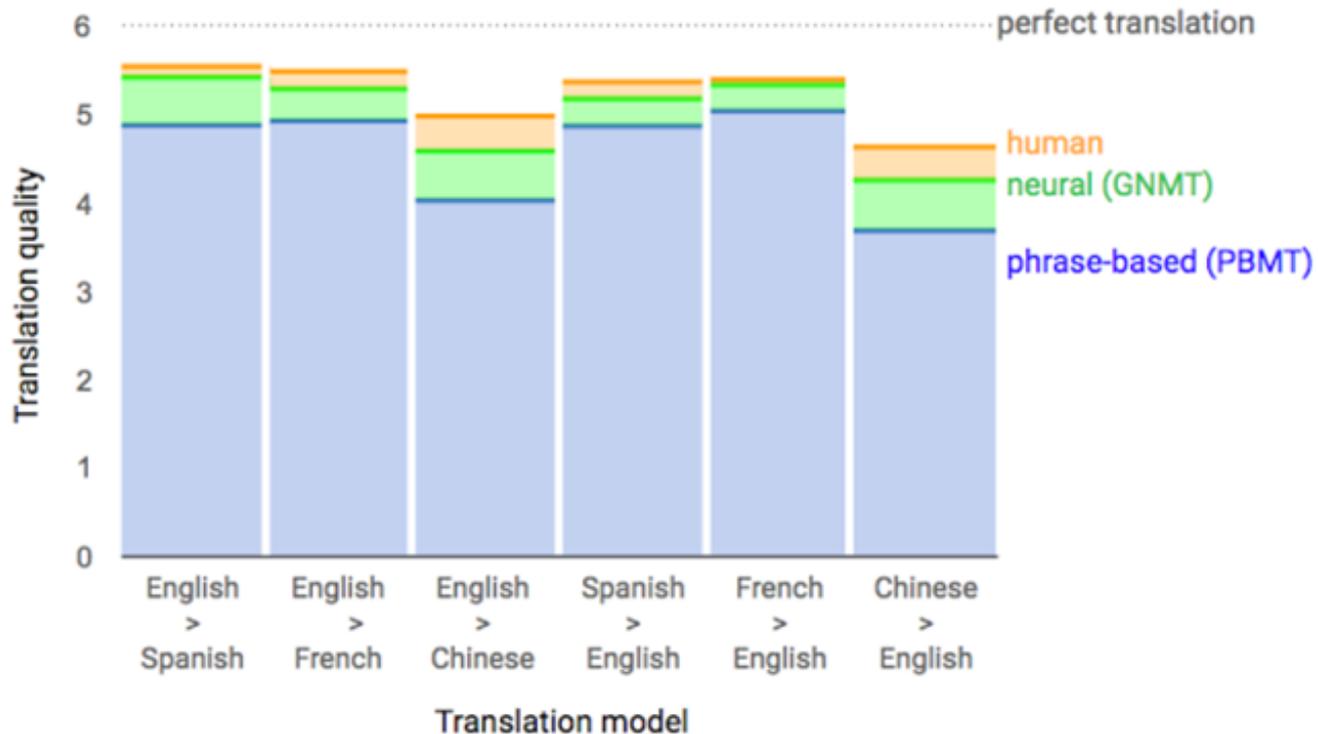
End-to-End Training of Deep Visuomotor Policies

Source: Peter Pastor



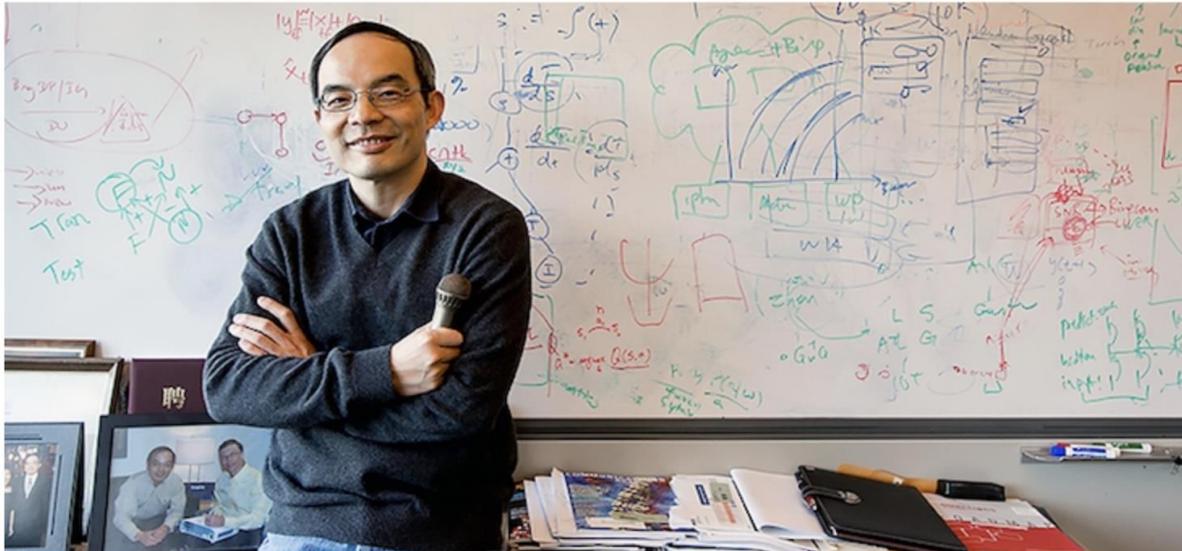
Google翻訳がDL方式に(2016.9)

- Google Neural Machine Translation (GNMT)
- 全部入り: 8層のbidirectional RNN (LSTM), Residual connection, Attention
- さらなる工夫: TPUの利用, Wordpiece
- 60%エラーを減らした。
- “two to three decimal orders of magnitudes bigger than the WMT corpora for a given language pair”



Microsoftの翻訳、中国語から英語に機械翻訳した品質は人間と同レベルに

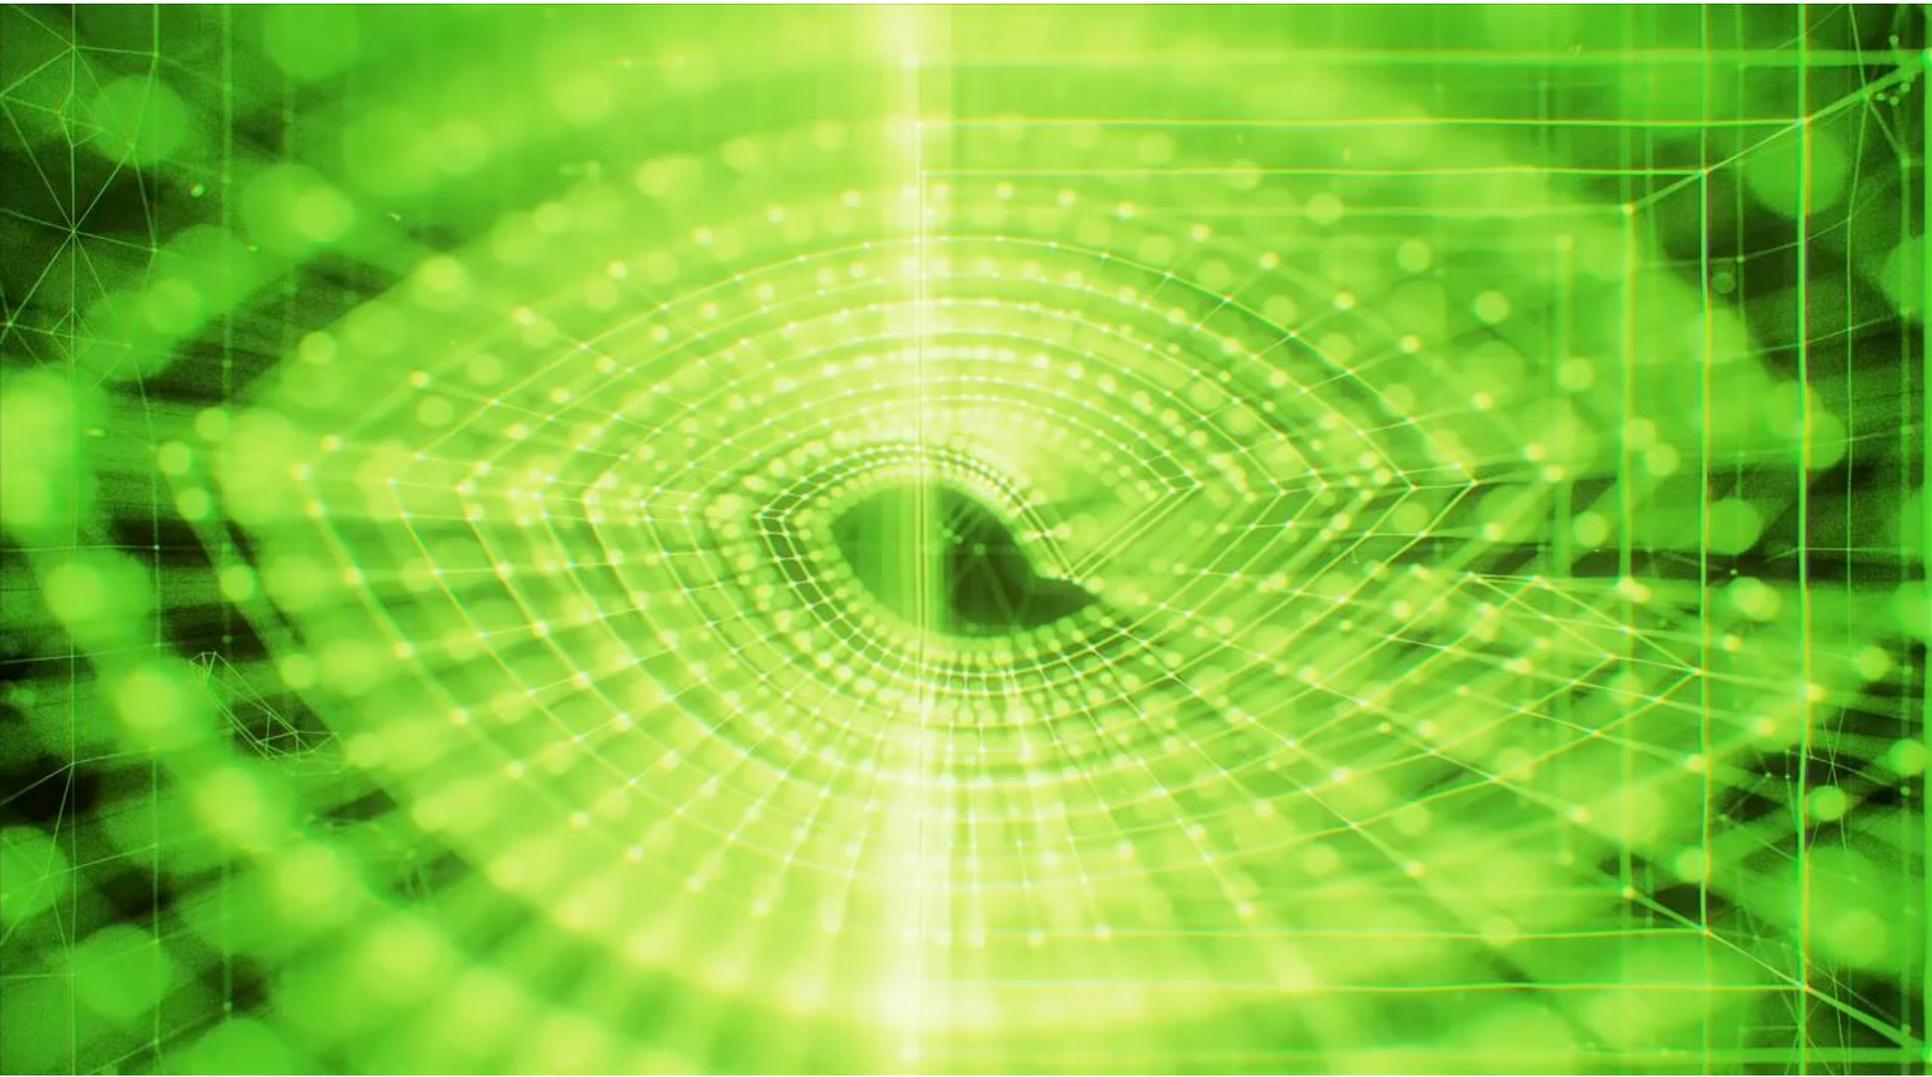
2018年3月15日 By 中橋 義博



fシェア 9 ツイート 0 はてブ 1

2018年3月14日、MicrosoftのThe AI Blogにて、中国語から英語に機械翻訳するシステムの精度が人間の精度と変わらないレベルを達成したと発表した。

翻訳のためのディープニューラルネットワークとして、Dual Learning（二重学習）、Deliberation Networks（審議ネットワーク）、Joint Training（共同訓練）、Agreement Regularization（合意正則化）といったAIトレーニング方法が使われたという。



High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs

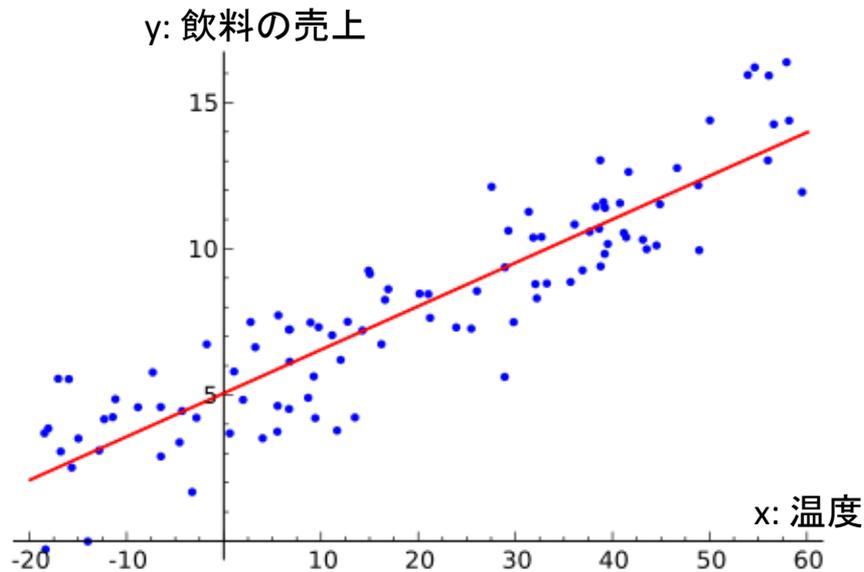
Ting-Chun Wang¹, Ming-Yu Liu¹, Jun-Yan Zhu², Andrew Tao¹,
Jan Kautz¹, Bryan Catanzaro¹

¹NVIDIA Corporation ²University of California, Berkeley

ディープラーニングをもう少し理解する

最小二乗法

- 測定で得られたデータの組を、1次関数など特定の関数を用いて近似するときに、想定する関数が測定値に対してよい近似となるように、残差の二乗和を最小とするような係数を決定する方法。



データを直線で近似

$$y' = a + bx$$

xの1次式でyが決まると仮定

$$J = \sum_{i=1}^n (y - y')^2$$

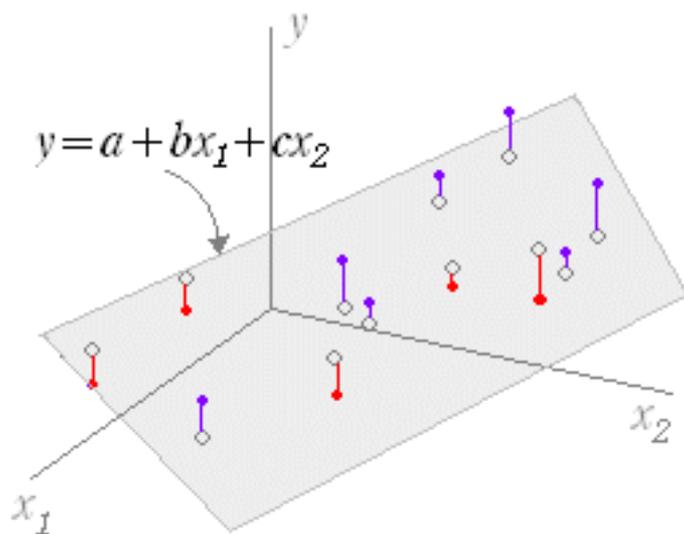
実際のyの値

推定したyの値

残差の2乗和を取る。
これが最も小さくなるように、
パラメータaやbを求める。

最小二乗法: 変数を増やす

- x ではなく、 x_1, x_2 の2変数



データを1次関数で近似

$$y' = a + bx_1 + cx_2$$

x_1, x_2 の1次式で y が決まると仮定

$$J = \sum_{i=1}^n (y - y')^2$$

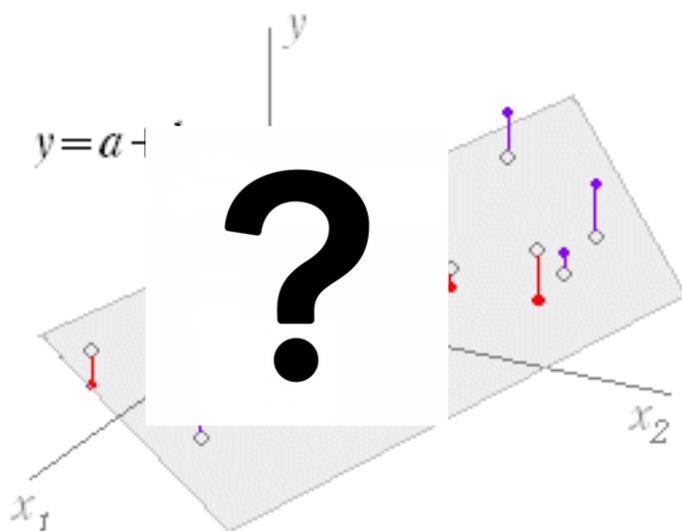
実際の y の値

推定した y の値

残差の2乗和を取る。
これが最も小さくなるように、
パラメータ a, b, c を求める。

最小二乗法：変数をもっと増やす

- x ではなく、 $x_1, x_2, \dots, x_{10000}$ の1万変数



データを1次関数で近似

$$y' = k_0 + k_1 x_1 + k_2 x_2 + \dots + k_{10000} x_{10000}$$

$x_1, x_2, \dots, x_{10000}$ の1次式で y が決まると仮定

$$J = \sum_{i=1}^n (y - y')^2$$

↑
実際の y の値

↑
推定した y の値

マーケティング等で用いられる「重回帰分析」
通常は10～数十変数

1万変数の問題なんて、現実にあるの？
あります！100×100の画像から猫かどうか判定する問題

残差の2乗和を取る。
これが最も小さくなるように、
パラメータ $k_0, k_1, \dots, k_{10000}$ を求める。

猫関数

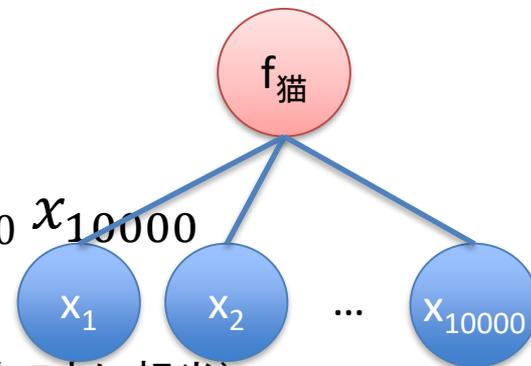
$$f_{\text{猫}}(x) = k_0 + k_1 x_1 + k_2 x_2 + \cdots + k_{10000} x_{10000}$$

- 100×100 の1万個の値から、猫か($y=1$)、猫でないか($y=0$)を出力する関数を求める問題
 - 基本的には、最小二乗法で求められる
 - たくさんの画像があり、それぞれが猫か猫でないかのデータがあれば、誤差が最も小さくなるように、 $k_0, k_1, \dots, k_{10000}$ のパラメータを求めればよい。
 - いったんパラメータが求まると、新しい画像に対して「猫」「猫でない」と判定できるようになる。
- 経済学やマーケティングでよく用いる「重回帰分析」と同じ。
 - マーケティングでは通常は変数の数が数個から数十個。
 - ディープラーニングの場合は、数万個から数億個。
- つまり、ディープラーニングは、最小二乗法のお化けのようなもの。
- 細かい補足
 - 回帰ではなく分類。損失関数として、最小二乗和ではなく、クロスエントロピーや対数尤度
 - 最適化は、解析的に求めるのではなく、繰り返し反復による勾配法

では、なぜ「ディープ」というのか？

猫関数を「深く」する

$$f_{\text{猫}}(x) = k_0 + k_1 x_1 + k_2 x_2 + \dots + k_{10000} x_{10000}$$



- 中間的な関数を介して、最終的な猫関数を定義する。(2層にしたことに相当)

- 中間的な関数

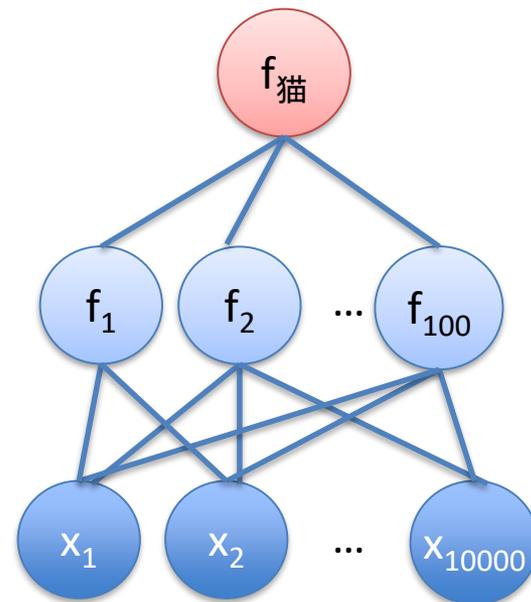
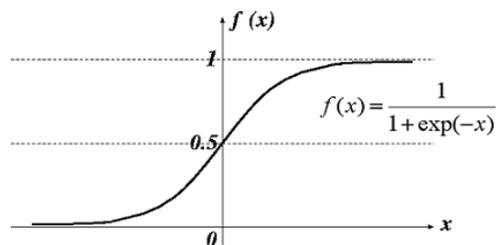
- $f_1(x) = \sigma(k_{01} + k_{11}x_1 + k_{21}x_2 + \dots + k_{10000,1}x_{10000})$
- $f_2(x) = \sigma(k_{02} + k_{12}x_1 + k_{22}x_2 + \dots + k_{10000,2}x_{10000})$
- $f_3(x) = \sigma(k_{03} + k_{13}x_1 + k_{23}x_2 + \dots + k_{10000,3}x_{10000})$
- ...
- $f_{100}(x) = \sigma(k_{0,100} + k_{1,100}x_1 + k_{2,100}x_2 + \dots + k_{10000,100}x_{10000})$

- 最終的な関数

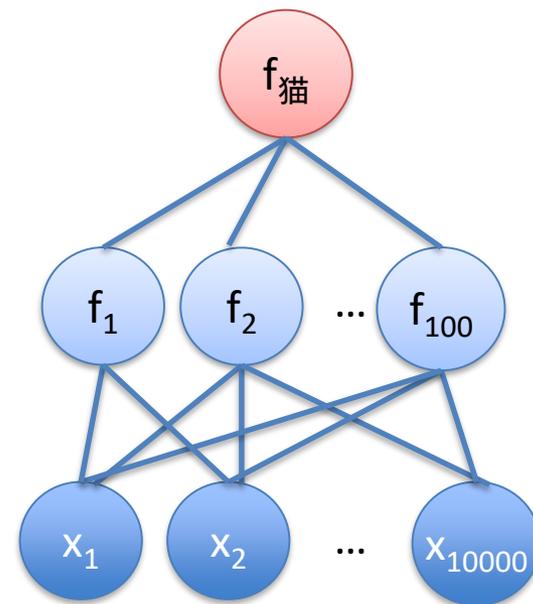
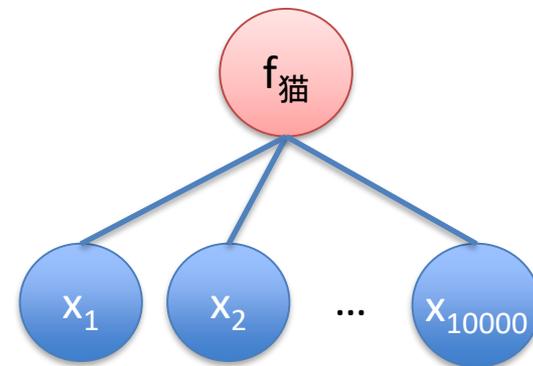
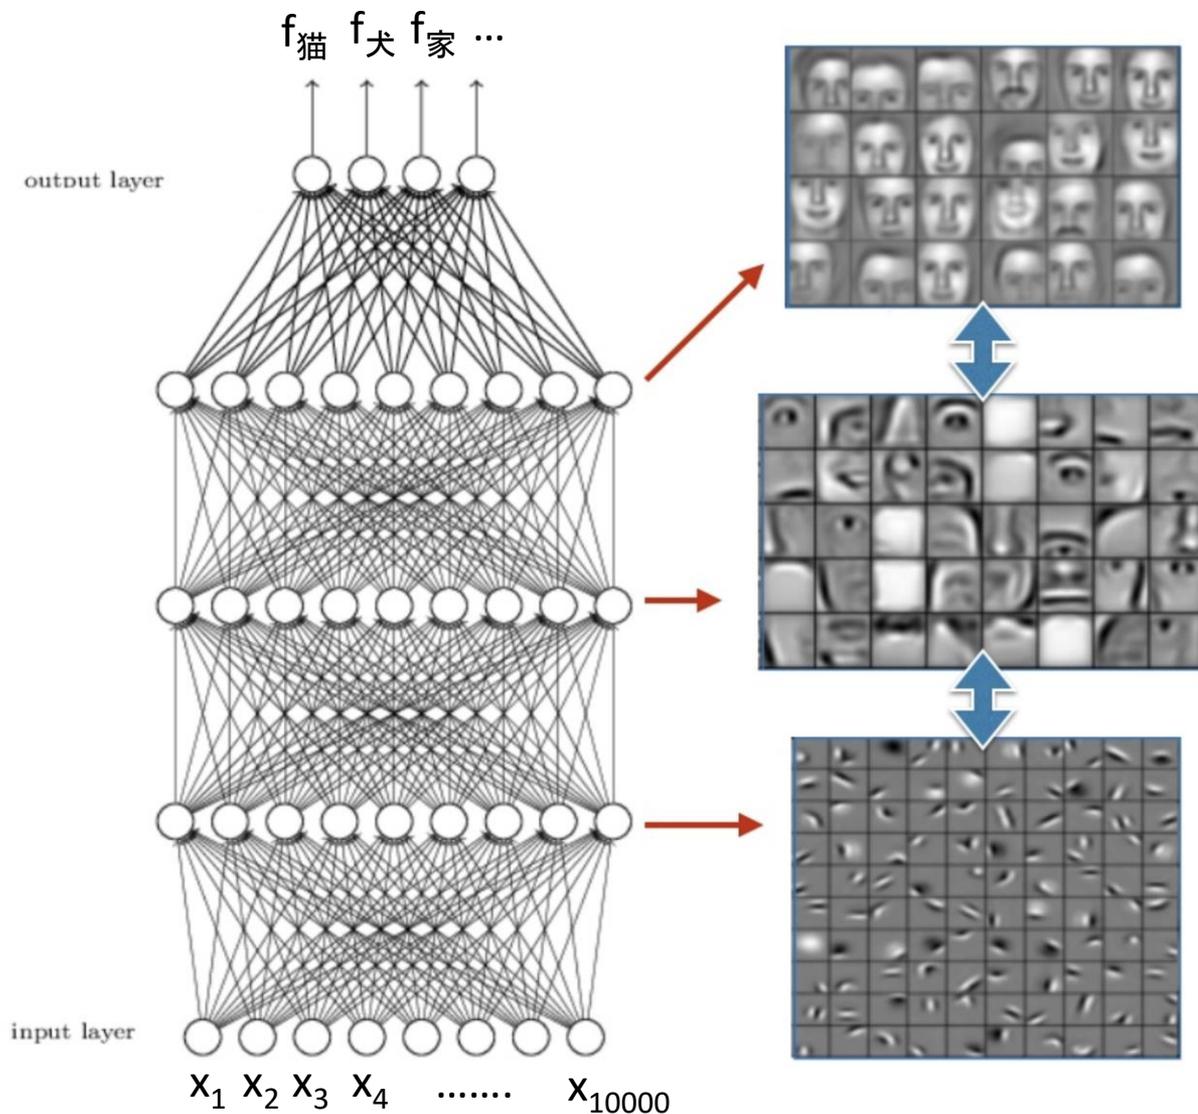
- $f_{\text{猫}}(x) = \sigma(k_0 + k_1 f_1(x) + k_2 f_2(x) + \dots + k_{100} f_{100}(x))$

- 非線形性を入れる。 σ :シグモイド関数

- ニューロンの発火を模擬。
- x が正のときは1、負のときは0
- それをなめらかにつなぐ



猫関数を「深く」する



なぜ深いことが重要か

- 1. 世界の階層性
 - エッジ→ヒゲ→猫の顔
 - 世界の構造がそもそも階層的になっているので、学習するモデルも、素性がフラットに並んだ線形のモデルのようなものよりも、階層性をもったモデルのほうが良い。
- 2. 表現力とパラメータのトレードオフ
 - 線形なモデルで切り取れる領域は、直線で囲める範囲である。
 - 我々が扱いたい概念(例えば猫)は、非線形でぐにゃぐにゃした部分空間を形成する。
 - 表現力が高い関数を使いたい。ところが、通常は表現力を上げるとパラメータの数が増える。
- 3. 階層を重ねることが効率的
 - 1層の隠れ層を持つニューラルネットワークを用いれば、任意の連続関数を任意の精度で近似できる(普遍性定理)が、場合によっては無限に多いニューロンの数が必要になる。
 - 階層を増やすことで、指数的に少ない数のニューロンで同等の表現力を持つ関数を作れる。
 - つまり、簡単な関数を深く重ねることで、パラメータが少なく、かつ表現力の高い関数を作れる。
- なので深くしたい！
- これがようやくできるようになったのは、計算機のパワーが上がったこと、データが増えたことが最も大きい要因。

大きく4タイプのDeep Learningの手法

- CNN (Convolutional Neural Network) : 画像を扱う
 - 畳み込みニューラルネットワーク
 - 画像分類、物体検出、セグメンテーションなど
- RNN (Recurrent Neural Network) : 時系列を扱う
 - LSTM (Long-Short Term Memory) というのが一般的
 - 音声認識、テキストの処理など
- 深層生成モデル : データの生成仮定をモデル化する
 - VAE (Variational Auto-Encoder、変分オートエンコーダ)
 - GAN (Generative Adversarial Network、敵対的生成ネットワーク)
 - 本物のような画像を生成するなど
- 深層強化学習 : 行動を学習する
 - 強化学習にCNN等を組み合わせる方法
 - DQN, Policy Gradient, A3C
 - アルファ碁、ゲームが上達する、ロボットを動かす

xとyの例

- 画像認識: x: 画像、y: クラス
- 物体検出: x: 画像、y: バウンディングボックスとクラス
- セグメンテーション: x: 画像、y: 領域とクラス
- 翻訳: x: 英語の文、y: 日本語の文
- 画像のキャプション生成: x: 画像、y: キャプション
- キャプションからの画像生成: x: キャプション、y: 画像
- アルファ碁: x: 盤面の状態(ほぼ画像と同じ)、y: 打つべき手
- Image Translation: x: 画像、y: 画像
- 顔認識: x: 画像、y: 人の名前(クラス)

ディープラーニングとは

- 入力を出力に写像するために、簡単な関数の組み合わせで表現力の高い関数を作り、そのパラメータをデータから推定する方法

1. x と y を決める。
2. 回路を決める。
3. 損失関数を決める。
4. データを集めて学習させる
(パラメータを最適化する)

すると、 x を入れると y が出るようになる。

- インターネット、トランジスタ、エンジン、電気などに匹敵する数十年に一度の技術
 - 原理は簡単。トランジスタが「信号を増幅する」ことと同じ。
 - トランジスタがIC, LSI, VLSIと集積度があがり、計算機、パソコン、携帯、スマホなどができたように、ディープラーニングでも技術変化・産業変化が起こる。
- 従来のマシンラーニングは「浅い」関数を使っていた。
 - ディープラーニングは「深い」関数を使う。違いはそれだけ。
 - それによって表現力が大きく上がる。人間の脳もおそらく同じ原理。

人工知能(AI)という言葉で指されるもの

- 1. IT系: 従来からあるIT技術の擬人化

- フィンテック、IoT、RPA(ロボティックプロセスオートメーション)、...
- AIの定義がないのでAIというのは嘘ではない。が、ITが重要というのと同義。

データから学習するものではない
最初から動作がプログラムされている

- 2. マシンラーニング系: 機械学習や自然言語処理を中心とする技術

- ビッグデータ、ウェブ関連、コールセンターのサポート、与信
- IBM ワトソン、日立 H、NEC the Wise、富士通 Zinrai
- 1990年代からの技術。インターネット企業が活用しているイノベーション

1層の「浅い」関数で学習

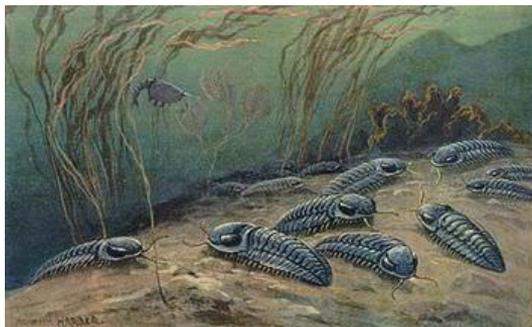
- 3. ディープラーニング系: 「眼」の技術、画像処理と機械・ロボットの融合

- アルファ碁、医療画像の診断、自動運転
- 2012年ごろからの技術。世界が今まさに戦っている。
- 日本は製造業との融合に大きなチャンス

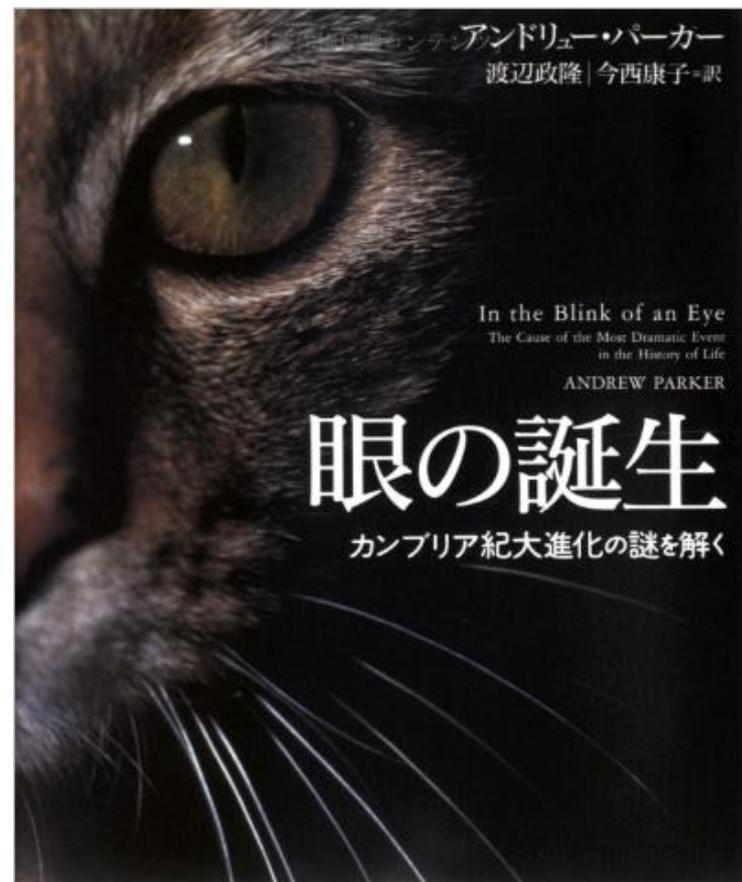
多層の深い関数で学習

眼の誕生

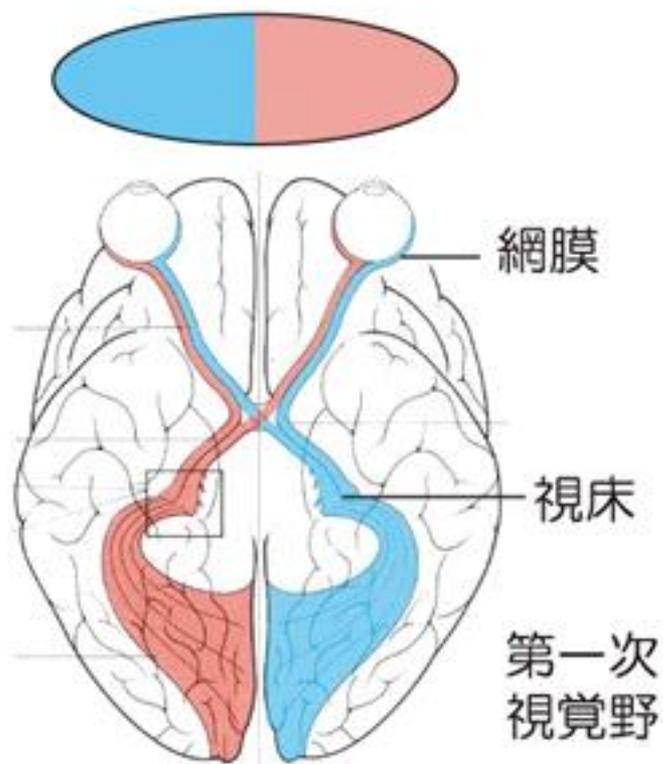
- カンブリア爆発
 - 5億4200万年前から5億3000万年前の間に突如として今日見られる動物の「門」が出そろった現象
 - 古生物学者アンドリュー・パーカーは、「眼の誕生」がその原因だったという光スイッチ説を提唱
- 「眼をもった機械」が誕生する
 - 機械・ロボットの世界でのカンブリア爆発が起こる
 - これを日本企業が取れるか？



三葉虫: 史上初めて眼をもった生物



眼が見える仕組み



←イメージセンサ

←ディープラーニング
(CNN: 畳み込みニューラルネットワーク)

既存産業の発展

農業	収穫判定	トラクター、コンバインの適用範囲拡大、効率向上 選別調製等の自動化	自動での収穫 自動での耕うん
建設	測量	掘削、基礎工事、 外装内装作業等の 効率向上	多くの作業の 自動化・効率化
食品 加工	振り分け 確認	カット、皮むき等 の自動化 食洗機に入れる	多くの加工工程の 自動化
組み立て 加工	目視確認の 自動化	動作効率の向上	段取りの自動化 セル生産の自動化

⋮

A: 画像認識

B: 運動の習熟

C: 計画立案を伴う運動

眼をもった機械・ロボットの典型例 単独の製品から入る

- 農業: トマト収穫ロボット
 - トマトは市場規模も大きく、収穫の工数も大きい。
 - 現状の技術で、トマトの認識ができる。上手にもぎ取ることも可能。
 - 先進的な農場から試しに入れる。
- 建設: 自動溶接機械
 - 建設の工程(例えば溶接)を自動化する
 - 現状の技術で、接合面の状態等の認識ができる。上手に溶接することも可能。機械を当てれば熟練した人でなくとも熟練の人のような溶接ができる。
 - 一部の建設現場で試しに入れる。
- 食品加工: 食洗機にお皿を入れるロボット
 - 食品加工に関わる仕事、まずは食洗機にお皿を入れることを自動化する
 - 現状の技術で、お皿の位置、把持位置の認識ができる。まずは、食器が下げられたところから、食洗機に入れるところを自動化する。(混雑時に重要)
 - ファミリーレストラン等の一部の店舗で試しに入れる。

製品を一刻も早く市場に投入する

「認識」が人間から切り離され、
社会の必要なところに再配置される。

機械・ロボットのカンブリア爆発

- 介護施設や病院等での見守り・介護ロボット
- 医療（X線、CT、皮膚、心電図、手術ロボット）
- 警備、防犯技術
- 顔による認証・ログイン・広告技術、表情読み取り技術（サービス業全般に重要）
- 国家の安全保障、入国管理、警察業務、輸出入管理業務における活用
- 防災系（河川、火山、土砂崩れを見張る）
- 重機系（掘削、揚重）、建設現場系（セメント固め、溶接、運搬、取り付け）
- 農業系（収穫、選果、防除、摘花・摘果）
- 自動操縦系（ドローン、小型運搬車、農機、建機）
- 自動運転系、物流
- 産業用ロボット系（特に組み立て加工等）
- 調理系（牛丼、炊飯、ファミリーレストラン、外食全般）
- ペットロボット系
- 片付けロボット（家庭、オフィス、商業施設）
- 新薬発見や新素材の開発（遺伝子の認識・分析、実験ロボット）
- 廃炉系（深海や鉱山、宇宙も含めた極限環境）

農業・建設・食品加工だけでなく、製造、物流、介護なども。

ディープラーニングに関わる海外企業

- 医療画像: 全産業で最も早い
 - Deep Mind (英): DLの技術力をもった企業。DQNによるゲーム、アルファ碁。ロンドンのMoorfields Eye Hospital NHS Foundation Trustと連携。眼底検査。2011創業。Googleが2014に£ 400Mで買収。
 - Enlitic: レントゲン写真やCTスキャンから悪性腫瘍を見つけ出す。放射線医師が1人だけで肺がんを検出する精度を5割以上上回る。2014創業。
 - GEヘルスケア: DLによる医療画像の診断。
 - アルタリス (Arterys) 「DeepVentricle」は心室内の輪郭を写したMRI画像を分析し、患者の心臓が保持・拍出できる血液量を計算する。2017年1月にFDA(米国食品医薬品局)の承認。
 - Idx: 糖尿病網膜症の診断。医者が画像や結果を解釈しなくても検査結果を出すことをFDAが認可した初の製品である。2018年4月。
 - Infervision (中国): 北京が拠点。肺がんの診断をディープラーニングで行う。
 - ほかにもGoogle, IBMなども。
- 顔認証: 中国が急激に躍進
 - Emotient: 顔の表情を認識する会社。2012創業、6M調達後、Appleが2016買収。
 - Affectiva: 映画やTV番組のどこで表情が変わったのかを読み取る。2009創業、34M調達。
 - Sensetime: 中国国内に設置された1億7千万のCCTVカメラや新システムで撮影されたデータをSenseTimeは処理。フィンテック、自動車、スマートフォン、スマートシティ開発など)にまたがる700社以上の顧客。時価総額45億ドル以上。
 - Megvii: 中国で顔認証技術を代表する企業。顔認証ソフトウェアである「Face++」を開発。オンライン決済サービス「アリペイ」が導入。中国公安は、同技術をパトカーに搭載。無人カメラにより半径60m内で犯罪容疑者を探すことが可能。
- 製造業関連
 - ZenRobotics (フィンランド): ごみの選別ロボット。2007創業、17M調達。
 - Dyson: 掃除機に眼をつけたものを開発。インペリアル・カレッジにRoboticsラボ設立。
 - Kuka (独): 産業用ロボットへのDL適用。ピッキング等。
 - Mobileye (蘭): 車用の画像認識を提供。1999イスラエルで創業。2014年上場。時価総額10B。

海外の動きは早い

コマツとの協業を発表

今回のショーでは一大ニュースとして、世界の大手建設重機メーカーであるコマツと NVIDIA が協業し、エッジからクラウドまで対応した AI テクノロジーを導入することで、建設現場の安全性と生産性の向上を目指す計画が発表されました。高齢化に伴う労働力不足によって、現在の建設労働者約340万人のうち3分の1が今後10年間で離職することが予想される日本にとって、この発表は大きな意味を持ちます。

ブレインパッド、河川の護岸コンクリートの劣化検知をAIで支援 - 八千代エンジニアリングに「機械学習/ディープラーニング活用サービス」を導入 -

いいね! ツイート G+ B!ブックマーク

ブレインパッド、河川の護岸コンクリートの劣化検知をAIで支援
- 八千代エンジニアリングに「機械学習/ディープラーニング活用サービス」を導入 -

株式会社ブレインパッドは、大手総合建設コンサルタント会社の八千代エンジニアリング株式会社に、人工知能（AI）ビジネス活用を支援する「機械学習/ディープラーニング（*2）活用サービス」（*3）を導入し、同社が実施する河川コンクリートの劣化検知を効率化する支援を行ったことを発表いたします。

■本取り組みに至った背景

1960年代の高度経済成長期に整備された道路や橋、下水道、河川の護岸コンクリートなどの社会インフラには経年劣られ、その点検・改修が喫緊の課題となっております。

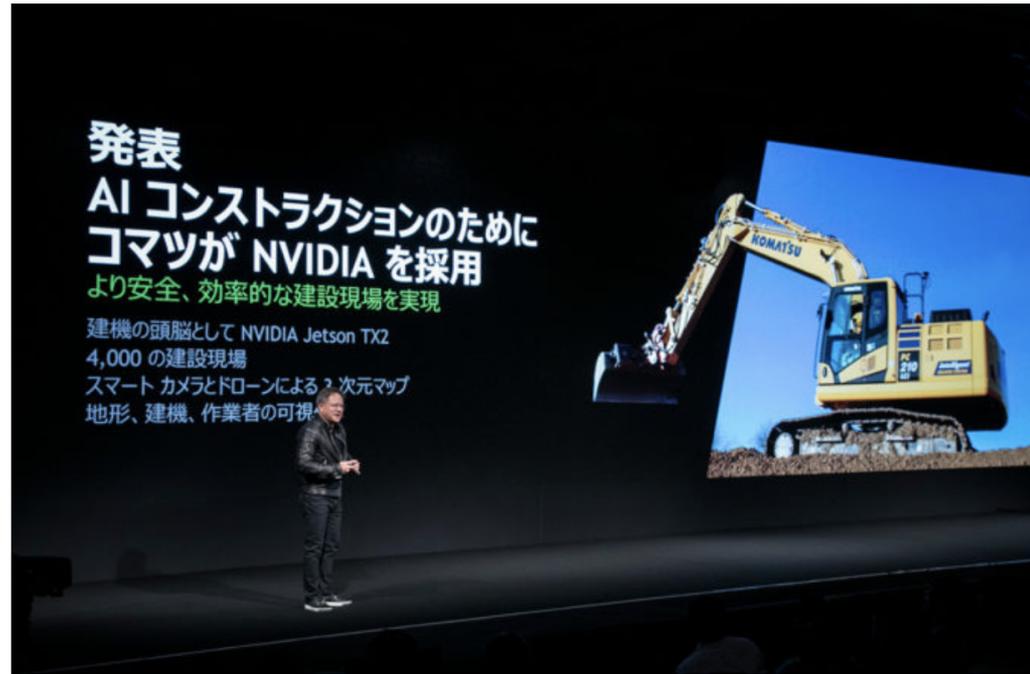
日本国内には、現在35,462本もの河川があると言われ（*4）、その周りには洪水などの災害対策として重要な役割をコンクリートが設置されておりますが、設置された時期や地域などによって整備形式が異なることから、これらの点検は熟練された技術が必要とされてきました。

国内有数の総合建設コンサルタント会社である八千代エンジニアリングは、これらの護岸コンクリートの維持管理に査・検討業務を請け負っており、現在は人間による目視主体で劣化状況を把握しております。しかしながら、長い河川数の人間が作業することとなるため、その手間やコストが膨大であること、劣化状況の判断基準が人によってさまざまが問題となっていました。

同社は、これらの問題を解決するため、ブレインパッドの支援のもと、画像処理によるコンクリートの劣化検知とそ

今回の支援対象となった河川の護岸コンクリートの写真 (八千代エンジニアリング提供)

劣化領域(赤色)を
画像処理で
自動的に検知



NVIDIA CEO のジェンスン ファンが世界の大手建設重機メーカーであるコマツとの協業を発表しました。

ファンは次のように述べています。「仮想現実と人工知能を駆使すれば、自律型マシンと人間を融合させることができます。世界の偉大な企業の1つであり、未来の自律型マシンの創造を目指すコマツと協業することができ、非常に光栄に思います。」

吉野家がアーム型ロボット導入 食器洗浄作業を短縮

牛丼チェーン大手の吉野家が、店舗の食器洗浄工程にアーム型ロボット「CORO」を導入した。産業用ロボットを製造・販売するライフロボティクスがこのほど発表した。画像AI技術を使って洗浄された食器を識別し、種類ごとに重ねて収納することで、作業時間を1当たり約0.5時間削減できるという。まず都内の1店舗に導入し、順次拡大する予定。



従業員が汚れた食器をコンベアに伏せて流すと、食器洗浄機が洗浄。洗浄機から出て濡れた状態の食器を、COROが内蔵カメラで読み取り、大きさや形など種類ごとに積み重ねて棚に収納する。食器をある程度積み重ねると、従業員に通知。安全のため、従業員がCOROに近付くとセンサーが検知して作業を一時停止する仕組みも備える。

原料検査の生産性が2倍に：

キューピーがAI導入、1日100万個以上のポテトをさばく「ディープラーニング」の威力 (1/2)

1日100万個以上のポテトを人力で見分けていく……キューピーの工場で行われている膨大な作業。その状況が今、「ディープラーニング」で大きく変わろうとしている。

膨大な原料検査にブレイクスルーを起こす「ディープラーニング」

キューピーは原料検査の基準を厳しく設定している。特にダイスポテト（さいの目状にカットされたジャガイモ）の場合、単なる変色など、食べても問題ないようなものでも、取り除くようにしている。そのため、スタッフには技術と高い集中力が必要になるのだという。

「害はなくとも、やや黒ずんだジャガイモが混じっていたらお母さんは心配に思いますよね。それは“安全”かもしれませんが、“安心”な商品とはいえません」（荻野さん）



黒く変色したジャガイモは原料として使わないのだという

しかし、当時採用していた画像認識システム（マシンビジョン）では、精度やコスト面で折り合いがつかない。そこで荻野さんが目を付けたのが人工知能（AI）だった。自律的に精度を高めることで問題を解決できるのではないかと考えたためだ。

Agrobot



Deep30

- Deep 牛: 牛丼が世界を制す。ゼロオペの牛丼チェーンを運営する会社
- Deep ラーメン: ゼロオペのラーメン店。
- Deep 片付け: 片付け業務の自動化。片付けロボットの設計・開発・生産、リース・運用保守ならびに片付け業務のサービス提供業。
- Deep Toilet: トイレをいつでもきれいに。自動のトイレ掃除ロボットの開発／トイレ管理サービス業
- Deep 顔認証: オフィスの入退室管理、会員へのおもてなし、本人認証。
- Deep Beauty: 美をDLで科学する会社。化粧品、美容院等へ展開。
- Deep 建設: 建設業務におけるDL活用。重機、建機、溶接、コンクリート等の工程の自動化
- Deep 化工: 化学プラントにおけるDL活用。
- Deep アグリ: 農業の収穫、間引き、防除等を行う。
- Deep 魚市場／畜産市場: 魚の仲買人の目利きをDL化し、グローバルな市場での価格設定、取引を行う会社
- Deep Annotation: 専門家を集めてひたすらアノテーションする会社
- Deep 違反: 交通違反、法律違反、会社規定違反等の違反状態のチェックサービス。インフラに組み込む型。

Deep30

- Deep 万引き: 違反系をお店の万引き防止から入るパターン。
- Deep 調剤薬局: 眼をもった機械による調剤業務の自動化。ならびに薬の配送管理全般を請け負う。薬に関するミスをゼロに。
- Deep 労務管理: 従業員に過度なストレスを与えていないか、勤務時間などのチェック。さらに快適に労働生産性を上げるためのDL活用。
- Deep 採掘。鉱山の採掘業務(先端の掘削業務)の自動化。深海での採掘。
- Deep 医療画像: 医療画像のDL。CT/MRI/レントゲン、細胞診、皮膚病、眼底。ややレッドオーシャン気味。
- Deep 縫製: 眼をもった機械による中国等で大量にやっている縫製業務の自動化。
- Deep モビリティ: パーソナルモビリティを提供する会社。特に自動運転車に積み込むことのできる、また、オフィス等でも通れる超小型自動運転車を開発。
- Deep Embed: 組み込み用のDLのチップ、学習工程などの設計・運用
- Deep 街づくり: DLをベースに、街におけるおしゃれスコアを上げることで街の不動産価値を向上させる。ディベロッパーに対するサービス提供。
- Deep 安全確認: お客様の安全、作業員の安全を常時確認する認識業務。

Deep30

- Deep 衛星画像: 衛星画像ないしは超望遠レンズによって高精細な画像を取り、認識できるさまざまなことを認識して提供する会社。防衛、セキュリティに近い。
- Deep 植物: 植物の生育状況を認識し、水や肥料等の量を最適化する栽培管理ソリューションの提供。
- Deep 搬入: コンビニ等の搬入、受取、陳列をロボットで自動で行う会社。
- Deep カフェ: ゼロオペのカフェ。
- Deep 表情: 超高速度カメラでひとの表情を撮影し、深層心理も読み取る技術をベースに、商品開発、コンテンツ開発、サービス評価、与信、犯罪捜査などに活かす。
- Deep 物流: 特に私有地内のトラックの自動運転。バンニング、デバンニング。
- Deep ガソスタ: ガソリンスタンド、電気の補給、車体整備の自動化。
- Deep 店番: 深夜帯等に最低限の接客・監視業務だけを行うことで店を開けておけるようにするサービス。

グローバルな食のプラットフォームの可能性

- 外食産業に調理機械、調理ロボットが普及する。
 - 日本の外食産業が世界に出ていきやすくなる。
- 調理ロボット用の「レシピの配信ビジネス」ができるようになる。
 - メキシコ料理でも、ブラジル料理でも、日本からレシピを開発し配信する。
- 顧客の嗜好データを取れる：胃袋をつかむ
 - 顔認識、表情認識で、その人の好み・味付けに。
- 日本は食文化を高め続けることで勝ち続けられる。
 - 日本は消費者のレベルが高い。みんな食にうるさい。(極めて重要な資産)
 - ミシュランの星が一番多い。B級グルメもおいしい。
- 潜在的には超巨大市場。これを取ればいいのではないか。
 - 1000兆円以上のという超巨大産業。突出して巨大。
 - これまでは自動化が甚だ難しかった。
 - 食を中心として、農業や水産業、レベルの高い物流、健康医療などともつながっている。

データをどう作るか

- x, y をどう決めるかで学習されるものが異なる。
- 例えば、
 - x : 医療画像、 y : 診断名
 - x : 医療画像、 y : 専門医に見てもらったほうがいいかどうか(Yes/No)
 - x : 医療画像、 y : 性別・年齢
 - ...
- x と y を何にするのかは、工夫次第。
 - x を集めるだけであればそれほど難しくない。
 - 例えば、病院と提携して医療画像を入手する
- y をコストをかけて「作る」必要がある。アノテーションの作業。
 - 医療画像に、適切な「タグ」をつける。
 - 専門家の集団を雇う必要がある。クラウドソーシングがよく使われる。

データをどう作るか

- トマトの収穫判定
 - x: トマト画像、y: トマトが収穫してよいかどうか
 - x: トマトの葉や茎の画像、y: そのトマトがどのくらい元気か(1-5段階)
 - → トマトの収穫判定や栽培管理に
- 不審者判定
 - x: 人の画像、y: 不審者かどうか
 - x: 人の映像、y: 不審な動きかどうか
 - → 防犯や監視のシステムに
- 表情判定
 - x: 人の顔の画像、y: 笑顔か怒っているか悲しんでいるか
 - → お店での顧客の満足度判定に

日本の戦略:ものづくりとディープラーニングの組み合わせ

ものづくり

- ・自動車
- ・産業用ロボット
- ・家電
- ・農業機械
- ・建設機械
- ・医療機器
- ・食品加工機器
- ・.....



ディープラーニング
「眼」の技術



作業の自動化

- ・自動運転
- ・組立加工の自動化
- ・外観検査の自動化
- ・家事労働の自動化
- ・介護の自動化
- ・農作業の自動化
- ・建設作業の自動化
- ・画像診断の自動化
- ・食の自動化
- ・.....

大企業中心
ベテラン技術者が戦力
ものづくりの知識・ノウハウ
「設計」
部品や素材などの強さ
年功序列

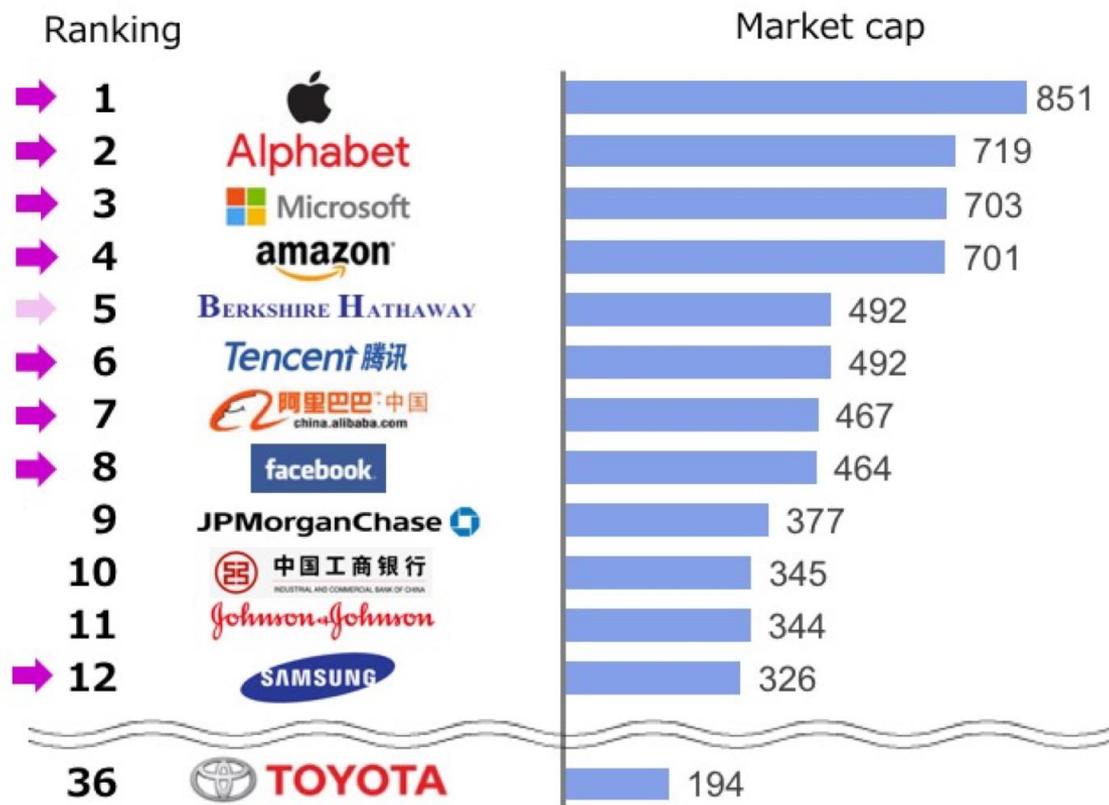


ベンチャー中心
新技術を学んだ若い人が戦力
ディープラーニング・ITのスキル
「学習」
データの量
20代が最強

地方での活用が可能
人手不足の作業
今後さらに増える作業
熟練が減っていく現場
日本の強みのある現場

世界の企業 時価総額ランキング

(10億ドル)



資料: 時価総額 World Stock Market Cap by Think 180 around (Mar 2018)、純利益 各社IR資料より

上位は軒並み創業年の若いウェブ系企業

日本なりのプラットフォーム戦略

- 「眼のある機械」は、データの継続的収集が不可欠
 - 製品からデータが戻るようにしないと、継続的な品質向上につながらない
 - つまり、製品がネットワークに接続されることがほぼ確定している
- すると、眼のある機械の「稼働」に対して課金できるようになる
 - 「学習ずみモデル」の品質が上がれば、価格を上げることができる
 - 内部コストを下げれば、利益を上げることができる
 - モノ売りからサービス売りへの転換が容易にできる
- さらに、眼のある機械を起点とする「場」全体のプラットフォーム化へ
 - 製品が置かれるオフィス、家、商業施設、工場、農場、建設現場など、製品が取得するデータ・提供するサービスを起点として、その周りのお金・情報の流れに広げ、事業チャンスをとっていくことができる。
- それを世界展開し、日本品質でサービスを提供する
 - 「学習ずみモデル」は日本で作り続け、競争力を維持し続ける

眼のある機械の市場投入→サービス化→周辺を含んだプラットフォーム化
→海外へ大きく展開という流れが王道

ディープラーニング時代のプラットフォームとは？

• 1. 熟練の「眼」のスコア化

- 収穫物の品質のスコア化
- 美のスコア化
- 建設作業の検収
- 製造業の外観検査
- 食品の盛り付けチェック、品質チェック

2. 中心的な作業の自動化

- トマトの収穫作業
- 重機の自動操縦
- 組み立て加工
- 食品の盛り付け
- ...

• 3. 現場全体のフローの最適化／自動化、横展開

- 中心的な作業の周りのデータが集まってくる
- 全体の作業工程(オペレーション)の最適化ができる
- サービス化: 横展開によるオペレーションのノウハウの共有、リスクの共有。
- ここからさまざまなマネタイズ手段が出てくる。

一見して、ITや人工知能と遠そうに見える、労働集約的な産業こそ、大きな変革がある。

DLの人材

ディープラーニング関連の主要1500論文 (国際会議ICLR/NIPS/ICML/ICCV/CVPR/ACL/...)



タイトル	引用数	出版年	備考
ImageNet Classification with Deep Convolutional Neural Networks	17892	2012	ILSVRC2012の画像認識の大きさ
Very Deep Convolutional Networks for Large-Scale Image Recognition	7874	2014	ILSVRC2014の勝者。VGG。1
Caffe: Convolutional architecture for fast feature embedding	6153	2014	フレームワークのCaffe
ImageNet: A large-scale hierarchical image database	5543	2009	
Adam: A Method for Stochastic Optimization	5459	2014	ADAM
Going Deeper with Convolutions	5387	2015	ILSVRC2014のGoogLeNet。2
Deep Residual Learning for Image Recognition	5138	2016	ILSVRC2015の勝者。ResNet
Deep learning	5084	2015	3氏によるNature論文
Dropout: A simple way to prevent neural networks from overfitting	4516	2014	Dropout
Rich feature hierarchies for accurate object detection and semantic segmentation	4166	2014	物体認識・セグメンテーション
Imagenet large scale visual recognition challenge	4160	2015	ImageNetデータ
Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups	3482	2012	音声認識
Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift	3144	2015	バッチ正規化
Fully Convolutional Networks for Semantic Segmentation	2994	2015	CVPR2015準ベスト。セグメンテーション
Visualizing and Understanding Convolutional Neural Networks	2855	2013	
Sequence to Sequence Learning with Neural Networks	2678	2014	Seq2seq
Representation Learning: A Review and New Perspectives	2670	2013	
Rectified linear units improve restricted boltzmann machines	2534	2010	
Neural Machine Translation by Jointly Learning to Align and Translate	2501	2014	ニューラル機械翻訳の提案
Improving neural networks by preventing co-adaptation of feature detectors	2345	2012	Dropout
Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks	2283	2015	Faster R-CNN
TensorFlow: Large-scale machine learning on heterogeneous distributed systems	2199	2016	TensorFlow
Deep Learning in Neural Networks: An Overview	2188	2015	ディープラーニング概観
Human-level control through deep reinforcement learning.	1900	2015	AtariのNature論文
Mastering the game of Go with deep neural networks and tree search	1874	2016	Atariの記事
Generative Adversarial Nets	1857	2014	GAN
Learning phrase representations using RNN encoder-decoder for statistical machine translation	1852	2014	RNNエンコーダ、デコーダ
OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks	1811	2013	
DeepFace: Closing the gap to human-level performance in face verification	1797	2014	
Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification	1788	2015	4.9%。人間を上回る。PRELU
Microsoft COCO: Common Objects in Context	1748	2014	

ディープラーニング関連の主要人物 トップ10

冬の時代も研究を続けた
3人の先生(カナディアンマフィア)
ヒントン・ベンジオ・ルカン

1	2012年以降の主要論文の引用件数代表作				略歴	
2	 Yoshua Bengio	6770.288029	28648	40	DLのNature論文、表現学習のレビュー、ニューラル言語モデル、2007年のディープネット、NMT共著、積層オートエンコーダ、GAN共著、Theano共著、DL本、語の表現、show-attend-tell共著、maxout共著、素性の転移、カリキュラム学習、さまざまな理論的検証	1964生まれ。McGill大学で博士。MITでM. Jordan氏のもとポストドク、AT&Tベル研。U. Montreal教授。
3	 Geoffrey Hinton	5972.279715	57069	25	バックプロパゲーション共著、2012年の画像認識の論文共著、2006年のDBN、DLのNature論文、Dropout、t-SNE共著、2012年の音声認識、ReLU、DBM、分散表現、蒸留	1947年生まれ。ケンブリッジで学資、エジンバラ大でLonguet-Higgins氏のもの博士。サセックス大、UCサンディエゴ、CMUなどを経て、UCLのGatsby神経科学ユニットを作る。U. Toronto教授。同時にGoogle。
4	 Ilya Sutskever	3591.211495	32242	20	2012年の画像認識の論文。Seq2seq。Word2vec共著。Dropout共著。Tensorflow共著、Alpha碁共著、ダチョウに騙す共著。	2012年にトロント大のヒントン研で博士。A. Ngのグループでポストドク。DNNresearchを作り、Google Brainに。OpenAI
5	 Yann LeCun	2534.844966	17799	19	文書認識の勾配法、DLのNature論文、手書き文字認識、OverFeat共著、1990年代のCNN、MNISTデータベース、中間的な素性の学習	1960年生まれ。パリのUniversité Pierre et Marie Curie大で博士。トロント大のヒントン研でポストドク。AT&Tベル研。プリンストン大のNEC institute。NYU教授。同時にFacebook AI研究所ディレクター。
6	 Oriol Vinyals	1955.811852	9563	20	Seq2seq共著、TensorFlow共著、Decaf共著、show-and-tell、蒸留共著、GNMT共著、ニューラル会話モデル、Wavenet共著、poiter net	2013年にUCBで博士を取得。DeepMind
7	 Quoc V. Le	1700.048823	8006	19	Seq2seq共著、word2vec、Googleネコ論文共著、2011年の音声認識、キャプション共著、翻訳共著、最適化、ニューラル会話モデル共著	2013年にスタンフォードでAndrew Ngのもと博士を取得。Google Brain
8	 Ruslan Salakhutdinov	1483.974393	7620	17	2006年のヒントンの次元削減共著、ドロップアウト共著、確率的行列因子分解、Show-attend-and-tell共著、DBM、ベイズ確率行列因子分解、セマンティックハッシュ、LSTMによる動画の教師なし学習共著	2009年にトロント大のヒントン研で博士。MITでポストドク、トロント大助教、CMU准教授。同時にAppleのAI研究所ディレクター。
9	 David Silver	1457.703674	9444	15	ATARIゲーム共著、アルファ碁、A3C共著、DDPG共著、POMDPにおけるモンテカルロ探索、協調的バス探索、Double Q学習共著、優先経験リプレイ共著、DPG。	1997年にケンブリッジ卒、一度ゲーム会社を創業した後、2004年にアルバート大に戻り、博士。UCL講師。DeepMindに初期から関わり、2013年にフルタイムで参加。
10	 Honglak Lee	1403	3721	23	スパースコーディング、コンボリユショナルDBN、マルチモーダルDL共著、CNNの教師なし学習、ロボット把持共著、	2010年にスタンフォードでAndrew Ngのもと博士。ミシガン大で助教の後、ミシガン大准教授。同時にGoogle Brain
11	 Kaiming He	1381.095218	13246	12	ResNet、Faster R-CNN共著、ガイド付きイメージフィルタリング、2015年の4.9%、DCGAN、SRのCNN共著	2011年に清華大学で博士を取得、MSRAを経て、Facebook AI Research

10位～20位

12		Trevor Darrell	1294.602642	8551	14	Caffe共著、R-CNN共著、全CNN共著、DeCaf共著、キャブ ショニングRNN共著	1996年にMITで博士号。Interval Research Corporationで働いた後、2008年までMITのファカルティ。その後、UCB教授。BAIRディレクター。Berkeley DeepDriveディレクター。
13		Christian Szeged	1269.487692	13319	11	GoogLeNet、バッチ正規化共著、インセプション、ダチョウ 論文、SSD共著、DeepPose、Inception-v4	ボン大卒業。Cadence Design SystemsでVLSI CADの設計。Googleでソフトウェアエンジニア・研究者。
14		Sergey Levine	1256.588238	2166	27	ロボットのend-to-end学習、TRPO、GPS	<u>2014年にスタンフォードで博士。UCB助教。</u>
15		Jian Sun	1123.432241	12621	10	ResNet共著、R-CNN共著、2015年の4.9%共著	2003年上海交通大学博士。MSRA。Magvii (Face++)
16		Kyunghyun Cho	1101.126696	8420	12	NMT共著、Show-attend-and-tell共著	<u>2014年Aalt大博士。モントリオール大でベンジオ研ポスドク。NYU助教、同時にFAIR研究員。</u>
17		Ross Girshick	1084.434876	9719	11	Caffe共著、R-CNN、Fast R-CNN、Faster R-CNN共著、 MS-COCO共著、YOLO共著	<u>2012年シカゴ大博士。UCB、MSRを経て、FAIR研究員。</u>
18		Volodymyr Mnih	1079.666615	8095	12	ATARIゲーム、アテンション、A3C	<u>2013年トロント大ヒントン研で博士。DeepMind研究員。</u>
19		Alex Graves	1077.824661	6874	13	ATARIゲーム共著、音声認識、RNNによる系列生成、CTC、 DRAW共著、ニューラルチューリングマシン、手書き文字認 識	<u>2008年スイスIDSIAのJürgen Schmidhuber研で博士。トロント大ヒントン研でポ スドク。現在、DeepMind</u>
20		Tomas Mikolov	1075.641204	14284	9	word2vec、RNNによる言語モデル	<u>2012年チェコのBrno University of Technologyで博士。Google Brainを経て、 FAIR研究員。</u>
21		Ian Goodfellow	1012.365547	5229	14	GAN、DL本、Tensorflow共著、Theano共著、Maxout、ダ チョウ論文共著、Pylearn2	スタンフォード卒、 <u>2014年モントリオール大ベンジオ研で博士。Google Brainを 経て、OpenAIを創設。その後、Google Brainに戻る。</u>

20位～30位

23		Alex Krizhevsky	968.5122612	26056	6	AlexNet、ドロップアウト共著、ロボット強化学習共著	2012年ごろトロント大ヒントン研で博士。Google Brain
24		Karen Simonyan	967.0289551	11545	9	VGG、動画認識、空間トランスフォーマーネットワーク共著、Wavenet共著	2014年ごろOxfordで博士。DeepMind
25		Jeff Donahue	954.5512034	14237	8	Caffe共著、R-CNN共著、Decaf共著、敵対的素性学習	2017年UCBで博士。DeepMind
26		Jimmy Ba	938.562731	8809	10	Adam共著、Show-attend-and-tell共著、Do deep learning really need to be deep。ただし同姓同名の影響も。	2017年にトロント大ヒントン研で博士。トロント大助教。
27		X Wang	852.7156619	2516	17	顔認識共著、顔関係多数	2009年にMITで博士。香港大学准教授。NVIDIA Cuda香港研究所ディレクター
28		Richard Socher	827.9516894	10711	8	ImageNet論文共著、Glove共著、意味的構成性の深層モデル、再帰的オートエンコーダ	2014年スタンフォードで博士。MetaMind創業し、2016年セールスフォースに売却。セールスフォース主席研究員、スタンフォード客員教授
29		Samy Bengio	792.8934355	3720	13	show-and-tell共著、devise共著、Torch共著	1993年にモントリオール大で博士。IDIAP Research Instituteを経て、2007年からGoogle。ベンジオ氏の弟
30		Shaoqing Ren	770.6043083	12119	7	Resnet共著、Faster R-CNN、2015年の4.9%論文共著、顔アライメント	2015年ごろ中国科技大で博士。MSRA自動運転のスタートアップmomenta.aiを共同創業
31		Koray Kavukcuoglu	713.5712999	7956	8	ATARI共著、アルファ碁共著、Torch7共著	ニューヨーク大ルカン研で2011年に博士。NEC米国研究所を経てDeepMind
32		Durk Kingma	697.2861679	7597	8		2017年にアムステルダム大博士。

	X Chen	421.1650508	905	14	
58	C Gulcehre	417.0755327	2718	8	
59	J Wang	413.2602086	1186	12	
60	J Bruna	413.0205806	2106	9	
61	J Schmidhuber	409.1258975	3416	7	
62	R Kiros	408.6465465	3408	7	
63	J Deng	398.3767061	9919	4	
64	L Deng	396.263801	6281	5	
65	M Jordan	388.1443031	2354	8	
66	Y Zhang	378.8561732	443	18	
67	L Li	377.9550238	5714	5	
68	J Yosinski	377.5288068	2227	8	
69	M Mathieu	364.9410911	2718	7	
70	J Wu	360.0888779	2026	8	
71	M Yang	350.6422678	4918	5	
72	Y Jia	350.4868043	13649	3	
73	R Urtasun	345.2998697	1863	8	
74	M Welling	331.3970428	1716	8	
75	J Shlens	315.5693268	1556	8	
76	M Mirza	306.9201851	3768	5	
77	R Fergus	306.4049608	1916	7	
78	A Torralba	295.8918721	1368	8	
79	A Karpathy	291.2473176	3393	5	
80	JB Tenenbaum	287.9374932	2303	6	
81	Z Ghahramani	284.5136201	1652	7	
82	RK Srivastava	279.5621577	1595	7	
83	A Mohamed	276.9025099	3067	5	
84	N Jaitly	276.202824	1192	8	
85	P Vincent	272.7178029	2975	5	
86	S Ioffe	270.8209741	4584	4	
87	N Heess	269.7554448	1137	8	
88	Y Kim	268.5963514	2004	6	
89	S Han	264.4295747	1427	7	
90	H Su	264.1817556	4362	4	
91	Y Teh	258.156929	7405	3	
92	K Xu	257.5849374	2654	5	
93	A Geiger	256.7586415	2637	5	
94	K Gregor	254.129888	1318	7	
95	R Collobert	247.4368606	2449	5	
96	CR Rogers	246.3818175	15176	2	
97	T Schaul	245.9817066	747	9	
98	S Wang	241.2488342	481	11	
99	X Tang	238.0420131	1574	6	
100	N Kalchbrenner	237.8907312	1572	6	
101	D Yu	233.2102056	6043	3	

397	P Pinheiro	44.45222154	494	2	
398	J Pouget-Abac	44.31703961	1964	1	
399	A Huang	44.01136217	1937	1	
400	L Sifre	44.01136217	1937	1	
401	B Chen	43.9886349	215	3	
402	J Jia	43.9886349	215	3	
403	X Huang	43.78355856	213	3	
404	H Lu	43.68065934	212	3	
405	H Kim	43.08131846	116	4	
406	Y Yuan	42.42640687	200	3	
407	N Wang	42.28474902	447	2	
408	E Grave	42.21374184	198	3	
409	TY Lin	42.09513036	1772	1	
410	J Hays	42.09513036	1772	1	
411	J Hoffman	41.91658383	1757	1	
412	K Kawaguchi	41.56921938	108	4	MITの博士課程の日本人
413	Y Ganin	41.47288271	430	2	
414	A Nair	41.35214626	190	3	
415	A Perelygin	41.27953488	1704	1	
416	J Chuang	41.27953488	1704	1	
417	A Acero	41.24318125	1701	1	
418	E Ilg	41.18252056	424	2	
419	P Hausser	41.18252056	424	2	
420	J Tompson	41.18252056	424	2	
421	R Arora	41.03656906	421	2	
422	L Guibas	40.59556626	103	4	
423	A Sharif Razav	40.48456496	1639	1	
424	H Azizpour	40.48456496	1639	1	
425	J Sullivan	40.48456496	1639	1	
426	S Shetty	40.42276586	1634	1	
427	M Ren	40.24922359	180	3	
428	P Pastor	40.19950248	404	2	
429	J Foerster	40.19950248	101	4	
430	D Sontag	40.09987531	402	2	
431	O Tuzel	40.02499219	178	3	
432	C Doersch	39.91240409	177	3	
433	C Summerfield	39.84971769	397	2	

ディープラーニング人材

- 若い。
 - 教祖の3人(カナディアンマフィア)を除いて、ほとんど20代後半～30代前半
 - 彼らが大きなインパクトをもたらしている
- 人材の争奪戦
 - 300位前後でも、年収が50万ドル
 - 30位以内だと、年収が数百万ドル
 - トップ5レベルだと、年収が数千万ドル
 - DeepMindにはこういう人が100人、GoogleやFacebookも数百人いる。
 - 中国のテンセント、アリババなども急速に人材を集め、自動運転や医療画像の分野にも進出。
- 松尾研の例
 - 人材獲得
 - 卒業生

日本の問題点

- 古い
 - ディープラーニング(2012年以降急速に進展)についていけない
 - 人工知能への投資と叫びつつ、結局、昔ながらの分野への投資になっている
- 遅い
 - 製造業はチャンスが大きい、大企業は軒並み意思決定できていない。
 - 消極的全張り: AIの部署を作る、AIベンチャーへの出資、シリコンバレーに人を送る、etc を薄くやる
 - (一部のオーナー企業では動きが早いところがある)
- 人への投資になっていない
 - 結局、最後、スーパーコンピュータを買っている
 - 若くて優秀な人の争奪戦ということが分かっていない
 - 大学等での人材育成も時代に追いついていない

松尾研による東大でのディープラーニングの講義(2015-)

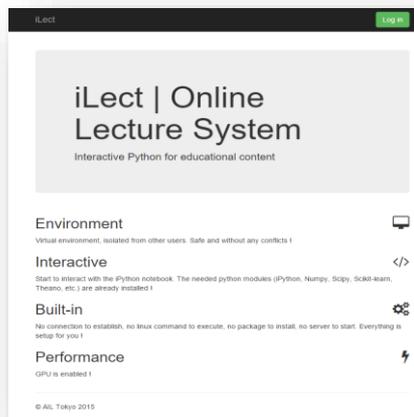
先端人工知能論I(または、Deep Learning基礎講座):

ニューラルネットワークの基礎から始まり、徐々にDeep Learningの核心的技術や最新トピックが学べるように設計された、高度なプログラムを提供します。「Practice makes perfect」の考えに基き、演習を通じての技術習得を目指します。演習では、ブラウザ上からGPUを利用したPythonコーディングが可能な開発環境「ilect.net」を提供しており、前提知識やGPU開発環境など多くの要素を必要とするDeep Learning技術の学習においても、本題のみに集中して学習できるように講義を設計しています。

先端人工知能論II:

Deep Learningの基礎的な知識とモデルを構築する能力を持つ者を対象に、より実践的な研究開発能力を身につけることを目的としたプロジェクト形式の授業を提供します。「Practice makes perfect」の考えに基き、演習を通じての技術習得を目指します。

独自に開発した講義システム



iLect | Online Lecture System
Interactive Python for educational content

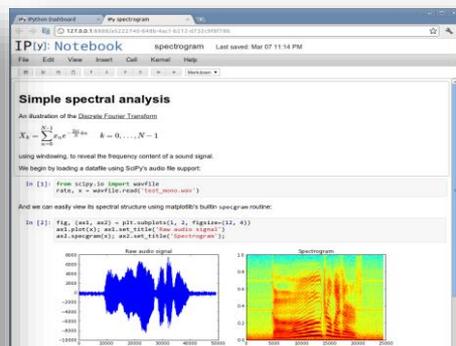
Environment
Virtual environment, isolated from other users. Safe and without any conflicts!

Interactive
Start to interact with the IPython notebook. The needed python modules (Python, Numpy, Scipy, SciKit-learn, Theano, etc.) are already installed!

Built-in
No connection to establish, no linux command to execute, no package to install, no server to start. Everything is setup for you!

Performance
GPU is enabled!

© All Tokyo 2015



IPython Notebook
spectrogram Last saved: Mar 07 11:14 PM

Simple spectral analysis

An illustration of the Discrete Fourier Transform

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j2\pi kn/N} \quad k = 0, \dots, N-1$$

Using windowing, to reveal the frequency content of a sound signal.
We begin by loading a datafile using SciPy's audio file support.

```
In [1]: from scipy.io import wavfile  
        data, sr = wavfile.read('test_audio.wav')
```

And we can easily view its spectral structure using matplotlib's builtin spectrogram routine.

```
In [2]: fig, (ax1, ax2) = plt.subplots(1, 2, figsize=(12, 4))  
        ax1.plot(data); ax1.set_title('Raw audio signal')  
        ax2.spectrogram(data, sr, ax2); ax2.set_title('Spectrogram')
```

一人一台の仮想サーバ
環境構築不要
ブラウザでコーディング
宿題アップロード
Leaders Board
GPUでの実行

(工学部の講義でも活用)

H27年度

Deep Learning基礎講座(自主講義、70名受講)

H28年度

情理講義 先端人工知能論1(61名受講)

情理講義 先端人工知能論2(33名受講)

Deep Learning基礎講座(NEDOから支援、
学部生・社会人向け、85名受講)

H29年度

情理講義 先端人工知能論1(222名受講希望、128名受講)

Deep Learning基礎講座(NEDOから支援、
学部生・社会人向け、149名受講希望、116名受講)



8社からの支援:トヨタ、ドワンゴ、オムロン、パナソニック、野村総研、DeNA、みずほFG、三菱重工

松尾研からのスタートアップ

- 優秀な卒業生ほど、大企業で働くより起業を選択。
- インターネットが出たときと同じ。「なんでもいいからインターネットをやること」が大事だった。いまのインターネット企業の中心にいる人たちは、この時期にいち早くやった人。



社名	概要
PKSHA technology (パークシャテクノロジー)	松尾研卒業生が起業。ネット企業や製造業に対しての機械学習・ディープラーニングの提供
Gunosy (グノシー)	ニュースアプリ。創業者3人のうち2人が松尾研。
READYFOR (レディフォー)	松尾研関連の企業からスピンアウト。クラウドファンディングで国内最大手。
DeepX (ディープエックス)	松尾研学生による起業。製造業に対してのディープラーニング提供。
MICIN (マイシン)	医療系の人工知能技術の提供。松尾研卒業生がCTO。
他数社	

個人にとって：職業の変化

- 10年～20年で、日本の労働人口の49%が人工知能やロボット等で代替可能に(NRI調べ、2015年12月)
- 新しい仕事が出てくる。

人工知能やロボット等による代替可能性が高い100種の職業（50音順、並びは代替可能性確率とは無関係）

※職業名は、労働政策研究・研修機構「職務構造に関する研究」に対応

IC生産オペレーター	こん包工	電子計算機保守員（IT保守員）
一般事務員	サッシ工	電子部品製造工
鋳物工	産業廃棄物収集運搬作業員	電車運転士
医療事務員	紙器製造工	道路パトロール隊員
受付係	自動車組立工	日用品修理ショップ店員
A V ・通信機器組立・修理工	自動車塗装工	バイク便配達員
駅務員	出荷・発送係員	発電員
N C 研削盤工	じんかい収集作業員	非破壊検査員
N C 旋盤工	人事係事務員	ビル施設管理技術者
会計監査係員	新聞配達員	ビル清掃員
加工紙製造工	診療情報管理士	物品購買事務員
貸付係事務員	水産ねり製品製造工	プラスチック製品成形工
学校事務員	スーパー店員	プロセス製版オペレーター
カメラ組立工	生産現場事務員	ボイラーオペレーター
機械木工	製パン工	貿易事務員
寄宿舎・寮・マンション管理人	製粉工	包装作業員
CADオペレーター	製本作業員	保管・管理係員
給食調理人	清涼飲料ルートセールス員	保険事務員
教育・研修事務員	石油精製オペレーター	ホテル客室係
行政事務員（国）	セメント生産オペレーター	マシニングセンター・オペレーター
行政事務員（県市町村）	繊維製品検査工	ミシン縫製工
銀行窓口係	倉庫作業員	めっき工
金属加工・金属製品検査工	惣菜製造工	めん類製造工
金属研磨工	測量士	郵便外務員
金属材料製造検査工	宝くじ販売人	郵便事務員
金属熱処理工	タクシー運転者	郵便事務員
金属プレス工	宅配便配達員	有料道路料金収受員
クリーニング取次店員	鍛造工	レジ係
計器組立工	駐車場管理人	列車清掃員
警備員	通関士	レンタカー営業所員
経理事務員	通信販売受付事務員	路線バス運転者
検収・検品係員	積卸作業員	
検針員	データ入力係	
建設作業員	電気通信技術者	
ゴム製品成形工（タイヤ成形を除く）	電算写植オペレーター	

人工知能やロボット等による代替可能性が低い100種の職業（50音順、並びは代替可能性確率とは無関係）

※職業名は、労働政策研究・研修機構「職務構造に関する研究」に対応

アートディレクター	児童厚生員	バーテンダー
アウトドアインストラクター	シナリオライター	俳優
アナウンサー	社会学研究者	はり師・きゅう師
アロマセラピスト	社会教育主事	美容師
犬訓練士	社会福祉施設介護職員	評論家
医療ソーシャルワーカー	社会福祉施設指導員	ファッションデザイナー
インテリアコーディネーター	獣医師	フードコーディネーター
インテリアデザイナー	柔道整復師	舞台演出家
映画カメラマン	ジュエリーデザイナー	舞台美術家
映画監督	小学校教員	フラワーデザイナー
エコノミスト	商業カメラマン	フリーライター
音楽教室講師	小児科医	プロデューサー
学芸員	商品開発部員	ペンション経営者
学校カウンセラー	助産師	保育士
観光バスガイド	心理学研究者	放送記者
教育カウンセラー	人類学者	放送ディレクター
クラシック演奏家	スタイリスト	報道カメラマン
グラフィックデザイナー	スポーツインストラクター	法務教官
ケアマネージャー	スポーツライター	マーケティング・リサーチャー
経営コンサルタント	声楽家	マンガ家
芸能マネージャー	精神科医	ミュージシャン
ゲームクリエイター	ソムリエ	メイクアップアーティスト
外科医	大学・短期大学教授	盲・ろう・養護学校教員
言語聴覚士	中学校教員	幼稚園教員
工業デザイナー	中小企業診断士	理学療法士
広告ディレクター	ツアーコンダクター	料理研究家
国際協力専門家	ディスクジョッキー	旅行会社カウンター係
コピーライター	ディスプレイデザイナー	レコードプロデューサー
作業療法士	デスク	レストラン支配人
作詞家	テレビカメラマン	録音エンジニア
作曲家	テレビタレント	
雑誌編集者	図書編集者	
産業カウンセラー	内科医	
産婦人科医	日本語教師	
歯科医師	ネイイル・アーティスト	

雇用の変化

- まずは「作る国」にならないといけない
 - インターネットで我々の生活は便利になったが。。
 - iPhone、検索、ソーシャルネット、アマゾン、全部米国。
 - 自動車立国になったから、自動車関連の産業が広がり、雇用が増えた
 - 人工知能を「作る国」か「使うだけの国」かで大きく異なる。
- 人工知能・ロボットを使う仕事
 - 人工知能・ロボットの開発・運用
 - ハードウェアの設計や製作
 - 人工知能部分の設計や製作
 - 学習データづくり
 - 遠隔での操作、保守・メンテ等のオペレーション
- 対人間のコミュニケーションは高付加価値に。
 - 低付加価値のサービスは機械化・ロボット化
 - 高付加価値のサービスは人間が行う
 - コミュニケーション力や人間力、教養は時代を超えて重要

人間の人間性を考える

- 知能の仕組みは工学的に実現できる。人間の人間性は変わらない。
- 人間 : 知能 = 鳥 : 飛ぶこと
 - いずれも、生命にとって重要な競争力を構成する機能。
- 飛ぶことの原理を解明し、工学的に実現すると飛行機になる。
 - しかし、飛行機は、朝になると鳴いたりしないし、巣を作ったりもしない。
- 同じように、知能の原理を解明し、工学的に実現するとさまざまなことを可能にする人工知能になる。
 - しかし、人工知能はおいしいものを食べたいとは思わない。
- 人間の「知能を除いた人間性」とは何か？
 - 長い年月を経た進化による人間の人間性は変わらない。
 - 感情、本能は元をたどれば生存確率の向上という進化的な原因がある(と思われる。)
 - 特に人間は、「集団を作って敵と戦う」ということを専らの競争力にしてきた。
 - したがって、仲間を助けるし、ルールを破った味方に制裁を加える。
- 人文社会系の学問も改めて重要に。
 - 哲学、政治学、社会学、法学、心理学、経済学など。

人間の(知能を除いた)人間性とは何か。

働き方に関して

- いまでも、第一次産業から第二次産業、第三次産業とシフト
 - 食べていだけならほとんど働かなくてもよいはず。ほとんどの労働は機械がやっている。
 - それでも「付加価値」の部分を作り続けている
- 人間は人間性にしたがって、集団を形成し、味方を作り、敵と戦うということを、(現代の文脈で) やり続ける。
 - 会社組織は、ある意味で、「部族」間の争いが形を変えたもの。人間にとって面白い。部族のなかでは、独自のルールや派閥などが大変大事。
 - 余裕ができると組織はすぐ部族ごっこを始める。危なくなると、正気に戻る。(合理的な組織のほうが不自然。)
- AIが進展すると、生産と仕事はますます関係ないものになる。
 - 生産は、ロボットとAIがやる。
 - 再分配は、人間のルールで決める。それは人間にとって面白く、かつ苦しいもの。それを仕事という。
 - いまでもすでに近い状態にある。
- 科学技術と文明の進展は、人間の行動の制約をなくし、自由度を上げる。
 - 例えば、「社会主義思想」は新しい技術でどう変わっていくのか。中国の行末は？

我々はどのような社会を作りたいのか。

ディープラーニング×ものづくり：日本の新たな産業競争力へ

- 日本の社会課題
 - 農業従事者、建設・物流、介護、廃炉、熟練工の後継者、etc
 - 少子高齢化しており、労働力が不足している
 - 地方にも影響が大きい
- ディープラーニングとものづくりの掛けあわせによる「眼をもった機械」
 - 眼をもった機械：認識や運動の習熟ができる機械・ロボット
 - 日本にも大きなチャンス：ものづくりの強さ、社会課題の大きさ
 - ものづくりと相性がよく、日本の強みを活かせる。素材や駆動系も強い
- グローバルに勝つための課題
 - いか「ディープラーニング」に投資するか
 - いか「人」に投資するか：若者の力を解放する必要
 - 事業展開をいかにスピード感をもって行うか