

機械学習の発展

独立行政法人産業技術総合研究所
知能システム研究部門

麻生 英樹

2015.3.27@日本太陽エネルギー学会
太陽光発電部会第13回セミナー

統計的機械学習とは？

- 機械学習 (Machine Learning)
= 機械 (コンピュータ) が学習する、
機械に知識を獲得させる
≠ 機械を使って学習する
(CAE, CAI, e-Learning)
 - 統計的機械学習
- 知識 = 確率モデル
 - 非統計的機械学習
- 知識 = if-thenルール、論理式、方程式
- 人工知能
Artificial Intelligence
の一分野として発足

なぜ機械に「学習」させるのか？

- 知的な情報処理システム（人工知能）の実現
 - 非明示的知識の実装
 - 多様な対象や環境への対応
- 人間の学習・知能の解明
 - 構成的な知能研究（認知科学）
- データの利活用への応用
 - データのモデリングと推測

機械学習技術の発展の超概略

- 1958/9 パーセプトロン、チェッカー
- 1960～ 文法学習、バージョン空間、数学定理発見、 ...
- 1980～ ニューラルネット・コネクショニズム
 - 誤差逆伝播学習、連想記憶モデル、自己組織化モデル、ボルツマンマシン
- 1980～ 帰納論理プログラミング
- 1985～ ベイジアンネットワーク
- 1992～ カーネル法
 - サポートベクトルマシン、カーネル主成分分析
- 2000～ パターン認識等への応用の展開、急速な進展
- 2000～ ベイズモデリング
- 2006～ Deep Learning

統計的機械学習研究の源流

- 学習するチェックカープログラム
 - Arthur Lee Samuel: Some studies in machine learning using the game of checkers, 1959
 - 対戦結果から盤面評価関数を学習して強くなる
 - 強化学習の源流
- パーセプトロン
 - Frank Rosenblatt: The Perceptron: A probabilistic model for information storage and organization in the brain, 1958
 - 脳の構造を模倣し、事例から学習する
パターン認識装置

パターン認識

- パターン情報：時間的・空間的に広がりを持つて分布する大量の情報
 - 画像、音声・音楽、動画
- パターン認識：パターン情報を分類・識別・認証・理解する情報処理
 - 文字認識、指紋認証、顔認識、表情認識、一般物体認識、自然言語理解
 - 音声認識、音楽理解
 - 動画理解

手書き数字認識



MNIST 手書き数字データ

パターン認識

- パターン認識はコンピュータには難しいタスク
 - 1950年代から研究
 - 手書き数字認識実用化 1980年代
 - 音声認識商用化 1990年代
 - 顔認識商用化 2000年代
- 人間は無意識のうちに簡単にやっているどうやっているのかは意識に登らない

→ プログラムが書けない

顔画像認識

- コンピュータに画像を認識させるプログラムを書くのは難しい

- 顔画像には、人の情報以外に膨大な情報が混在している

- 顔の向き、大きさ、傾き
- 表情
- 背景
- 光線のあたり方

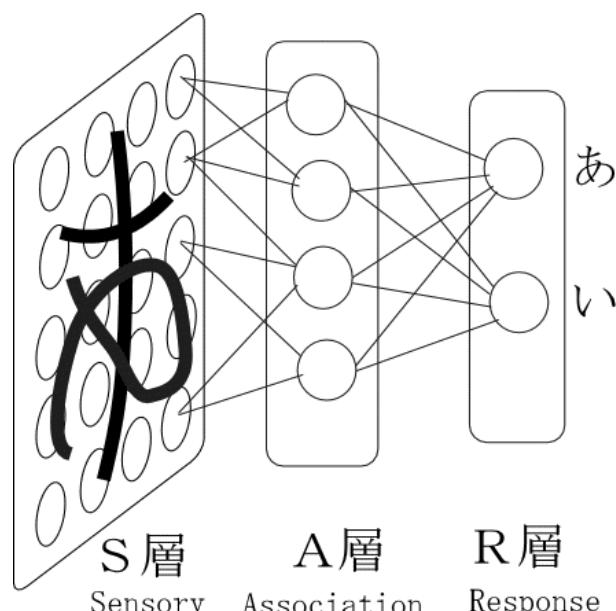
顔認識にとって雑音

雑音の中から
欲しい情報を抽出
する方法を
たくさんの例から
学習させる

パーセプトロン

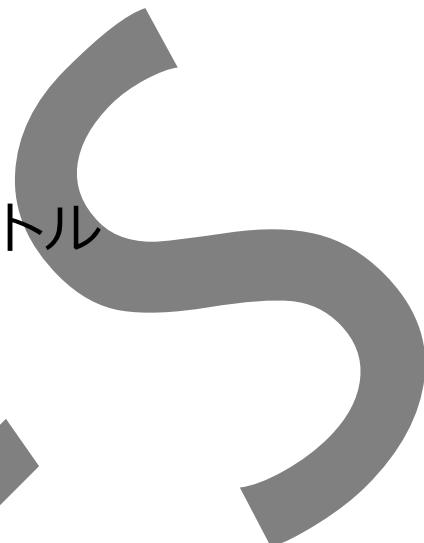
[Rosenblatt 1958]

- 脳の構造を模擬した、例から学習するパターン認識装置



統計的パターン認識

- 入力パターン
 - ↓ – 例：画像 = 1024x1024画素x256階調x3
- 前処理・正規化
 - ↓ – 位置や明るさの正規化
- 特徴抽出
 - ↓ – 数10～数100次元のベクトル
- 統計的識別
 - ↓ – 特徴ベクトルの識別
- 出力クラス



統計的パターン認識

- 統計的機械学習の最も成功している応用
 - 実用段階
 - 郵便番号読み取り、ナンバープレート読み取り、手書き漢字認識、顔認識、表情認識、指紋などの生体認証、音声認識、Spam Filter クレジットリスク診断、ネットワーク異常診断、各種製品検査、プロセス診断、GeneFinding、反応活性識別、自動走行車、音声Q&A、・・・
 - 研究段階
 - 音声対話、一般物体認識、一般行動認識、知的車椅子、盲人ナビゲーション、・・・

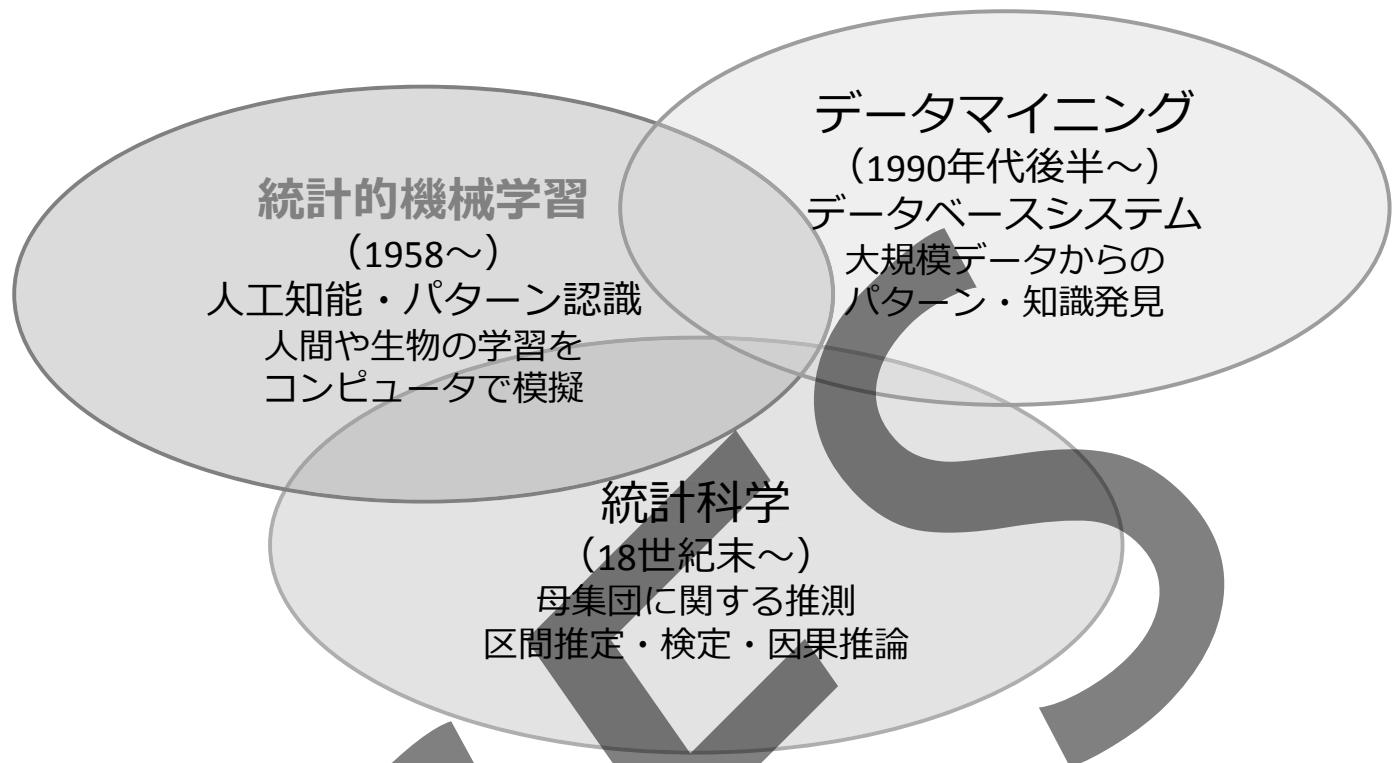
進歩の影にベンチマーク用データ

- ETL文字データベース
 - 印刷漢字、手書き漢字
- NIST手書き数字データ
- DARPA音声認識コンペティション
- RWC研究用音楽データベース
- Penn Tree Bank
 - 自然言語処理
- ImageNet
 - 一般物体認識

機械学習とデータマイニング

- 機械学習 (1959～)
 - 人工知能・パターン認識からの発想
 - コンピュータに学習させる
 - ゲームの学習、経験（観測データ）からの学習
 - 潜在変数を含む複雑なモデルの獲得を志向
 - 人間の学習のモデル化
 - いろいろなアプローチ⇒確率的アプローチに収束
- データマイニング (1990～)
 - データベースからの発想
 - データに内在する規則性・知識・法則の発見
 - 大量データのオンライン・リアルタイム処理志向
 - 条件を満たすデータやルールの枚挙が基本

統計科学・機械学習・ データマイニング



統計的機械学習の問題設定

- 知的な情報処理の主要な問題は
観測可能・容易な変数から
観測不能・困難な変数を推測すること
 - 外観から食べられるか否かを推測する
 - 顔画像や指紋から人のIDを識別する
 - 音声信号から発話しようとした言葉・意図を推測する
 - テストの結果から能力を推測する
 - アンケート情報から嗜好を推測する
 - 抜き取りサンプルから製品の不良率を推定する
 - 過去の情報から未来を予測する
 - 外観や特徴から対象を分類する
 - 受信符号から送信情報を推定する

統計的機械学習の問題設定

- なぜ推測できるのか？
 - 観測可能変数の値と観測不能変数の値の間に制約関係がある
- 変数間の制約関係 = 知識
 - 決定論的アプローチ:
制約 = 知識をルール(if-thenなど)、関数、論理式、方程式、プログラム等で記述する
 - 確率統計的アプローチ:
制約 = 知識を確率分布で記述する
(決定論的アプローチ + 雜音モデル)

決定論 ⊂ 確率論

17

確率統計的な情報処理

- X : 観測可能な変数
- Y : 観測困難な変数 (隠れ変数・潜在変数)
- 知識 : 同時確率分布や条件付き確率分布
 $p(x, y) = p(X = x, Y = y)$
- 隠れ変数の推測 :

変数 X の値 x が観測されたときの
Y の値 y の事後確率分布の計算

ベイズの定理

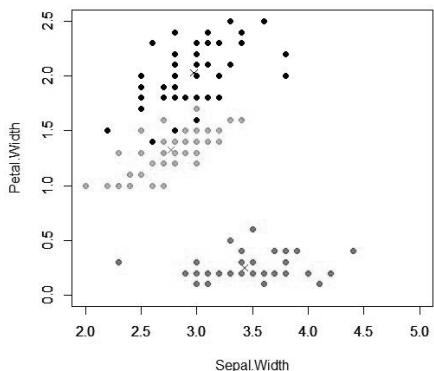
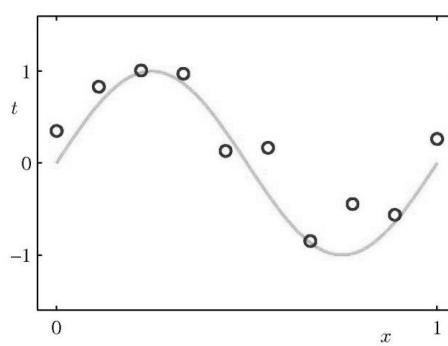
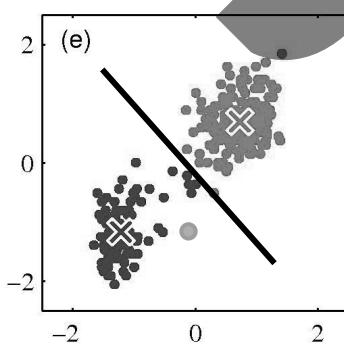
$$p(y | x) = \frac{p(x, y)}{p(x)} = \frac{p(x, y)}{\sum_{y'} p(x, y')} = \frac{p(x | y)p(y)}{\sum_{y'} p(x | y')p(y')}$$

生成モデルと識別モデル

- 生成モデル：データの生成過程のモデル $P(X|Y)$ と事前確率 $P(Y)$ をモデル化して、 $P(Y|x)$ を推定
 - ナイーブベイズモデル
 - 混合正規分布モデル
 - 隠れマルコフモデル (HMM)
- 識別モデル：条件付き確率 $P(Y|x)$ あるいは $P(Y|x)$ を最大にする $y = f(x)$ を直接モデル化
 - 線形回帰、ロジスティック回帰
 - ニューラルネットワーク
 - サポートベクターマシン

統計的機械学習の問題設定

- 教師あり学習 (Supervised Learning: 予測)
 - 識別問題 (出力が離散クラス) : パターン識別
 - 回帰・予測問題 (出力が連続値)
- 教師なし学習 (Unsupervised Learning: 分類)
 - 分類・クラスタリング
 - 次元圧縮、スパースモデリング



[C. Bishop: Pattern Recognition and Machine Learning, 2006] より引用

統計的機械学習の問題設定

- 半教師あり学習
- 報酬学習・強化学習
- Transductive Learning
- 転移学習
- 構造的学習
- 公正配慮学習
- . . .



まとめ

- 機械学習 = 機械に学習させる
 - 非明示的知識の獲得
 - ロバストで適応的な情報処理
 - 人間の学習のモデル化
 - データの利活用
- 統計的機械学習
 - 知識を確率分布で表現する
 - データの背後に確率分布を想定する
 - 生成モデルと識別モデル
 - 様々な分野での応用

機械学習技術の発展の超概略

- 1958/9 パーセptron、チエッカー
- 1960～文法学習、バージョン空間、数学定理発見、…
- 1980～ニューラルネット・コネクショニズム
 - 誤差逆伝播学習、連想記憶モデル、自己組織化モデル、ボルツマンマシン
- 1980～帰納論理プログラミング
- 1985～ベイジアンネットワーク
- 1992～カーネル法
 - サポートベクトルマシン、カーネル主成分分析
- 2000～パターン認識等への応用の展開、急速な進展
- 2000～ベイズ統計モデリング
- 2006～Deep Learning

Deep Learning (深層学習)

- 層の数が多い（深い）ニューラルネットワークを用いた機械学習
- 抽象度の高い特徴量や内部表現を大量の生データから学習

なぜ今話題になっているのか？

- パターン認識タスクを中心に、従来の方式よりも大幅な性能向上を達成した
- 音声認識
 - 連続音声認識での単語誤り率 23.6% → 16.1% (2011)
- 画像認識
 - 1000クラスの一般物体画像認識で Top-5 誤り率 26%程度 → 15.3% (2012) → 4%台 (2015)
- Science, Nature に論文が出た [Hinton+ 06, Mnih+ 15]
- Google, Microsoft, Facebook, Baido が強くコミット

ニューラルネットワーク

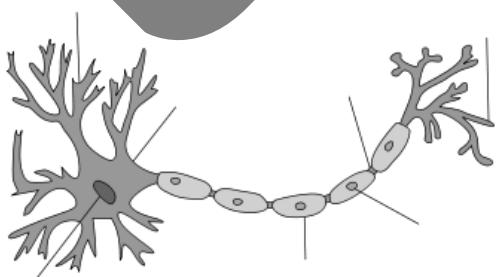
- 生物の神経回路網のモデル
- 脳は生物の進化が生んだ、とても優れた情報処理装置
- 脳の情報処理方式を模擬した情報処理方式の研究

脳の情報処理原理

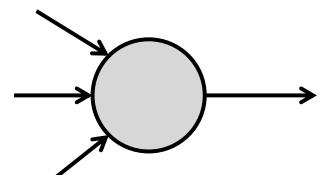
- 脳：神経細胞（ニューロン）のネットワーク
- 神経細胞：多入力 1 出力の情報処理素子
- コラム構造：特定の情報に対して選択的に活動するモジュール
- 階層構造：異なる機能の領野が階層的に構築されている
- 脳の学習：細胞間の結合部位（シナプス）での信号伝達効率の変化
 - クラスタリング、識別、強化学習、 . . .

ニューラルネットワーク

- 脳を模擬した、経験から学習する並列・分散パターン情報処理システム
- 単純な情報処理をするニューロンモデルのネットワーク
- ニューロンモデル間の結合重みの変化で学習

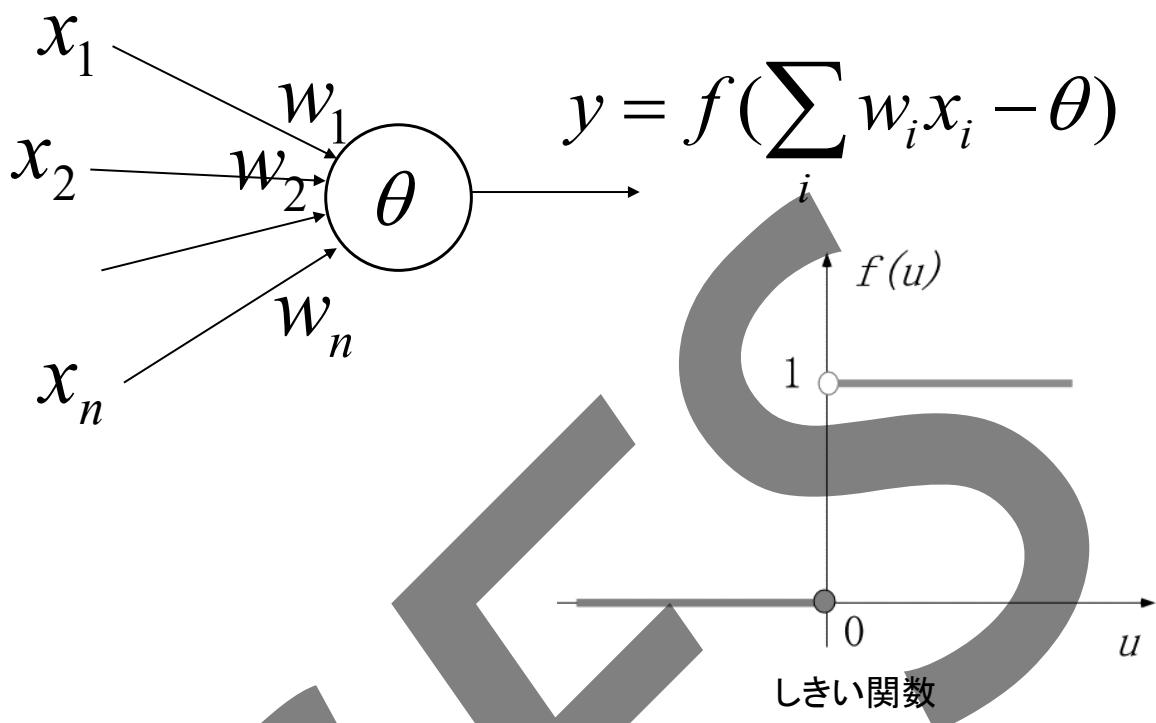


Wikipedia より



モデル化

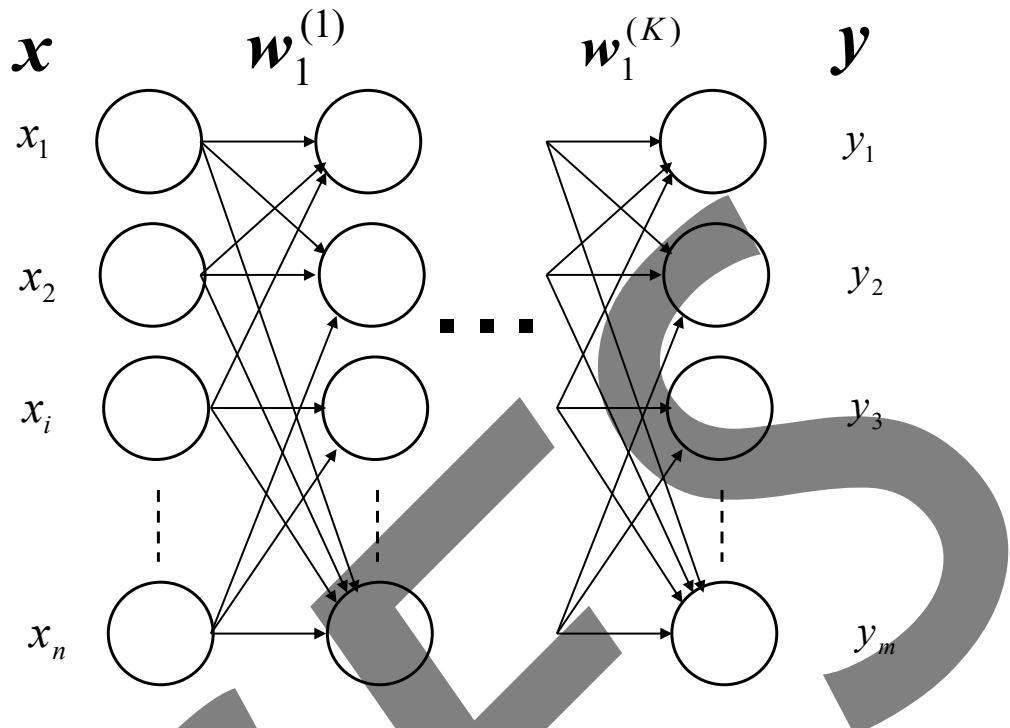
神経細胞の数理モデル



ネットワークの構造

- 階層型
 - ニューロンが複数の層に分かれている
 - 入力層から出力層に向かう結合
- 相互結合型・再帰結合型
 - ニューロン間が相互に結合している

階層型ニューラルネット



階層型ニューラルネットの学習

- 教師あり学習：入力に対して、正解に近い出力を出すように結合の重み w やしきい値 θ を調整する
- 誤り訂正学習（パーセプトロン学習）
(1958)
- 誤差逆伝播学習 (1986)

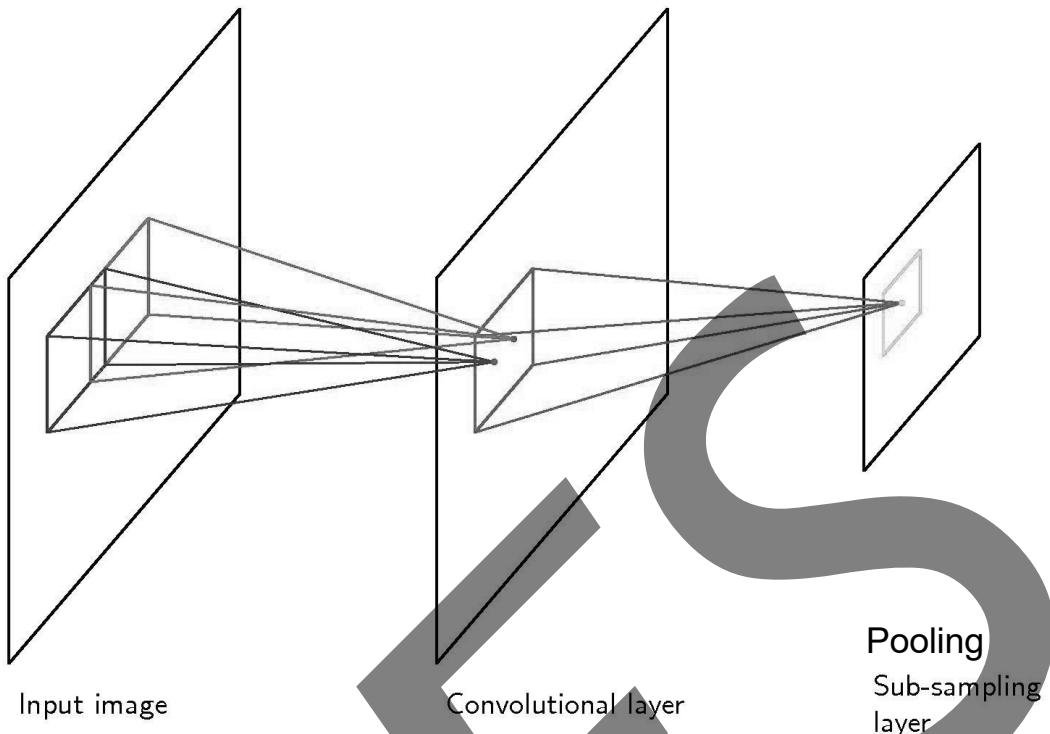
ニューラルネットの発展の超概略

- 1943年 マッカロー・ピツのニューロンモデル
- 1949年 ヘブの学習則
- 1958年 パーセプトロン [Rosenblatt]
- 1969年 「パーセプトロン」 [Minsky + Papert]
- 1970年頃 小脳パーセプトロン説
- 1982年 連想記憶モデル [Hopfield]
- 1983年 ボルツマン・マシン [Hinton]
- 1986年 誤差逆伝播学習法 [Rumelhart]
- (1992年 サポートベクトルマシン [Vapnik])

Deep Learning

- Deep=多層のニューラルネットワーク
 - 能力は高いが学習が困難
 - 特に誤差逆伝播学習は層が増えると困難
 - 局所収束+学習の遅さ
- ブレークスルー (2006～)
 - 1) 問題に適した構造を予め組み込む
 - 置込みネットワーク
 - 2) 層ごとの教師無し事前学習
 - Restricted Boltzmann Machine
 - Stacked Auto Encoder

畳み込みネットワーク



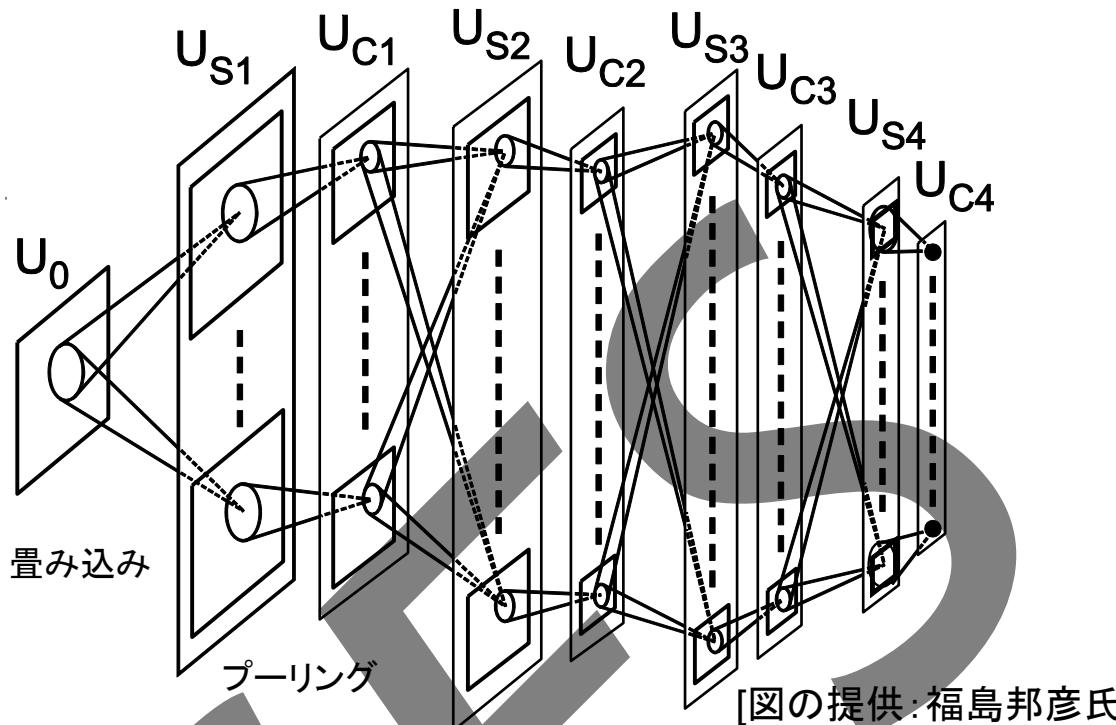
[C. Bishop: Pattern Recognition and Machine Learning, 2006] より引用

畳み込みネットワーク

- 同一の局所的フィルタを画像全体に適用
- 結合の値が共有されている
=パラメータ数が小さくなる
- プーリング（固定結合）で
近傍ニューロンの出力を集約
=平行移動に不变な処理結果
- 画像認識（平行移動不变なタスク）に
適したネットワーク構造

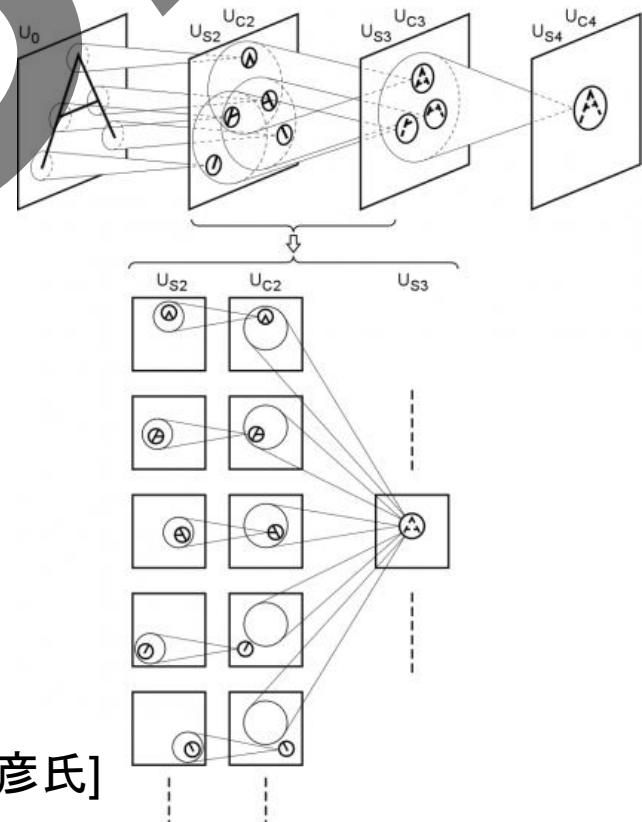
畳み込みネットワーク

- ・ネオコグニトロン [福島 1981]



多層化の効果

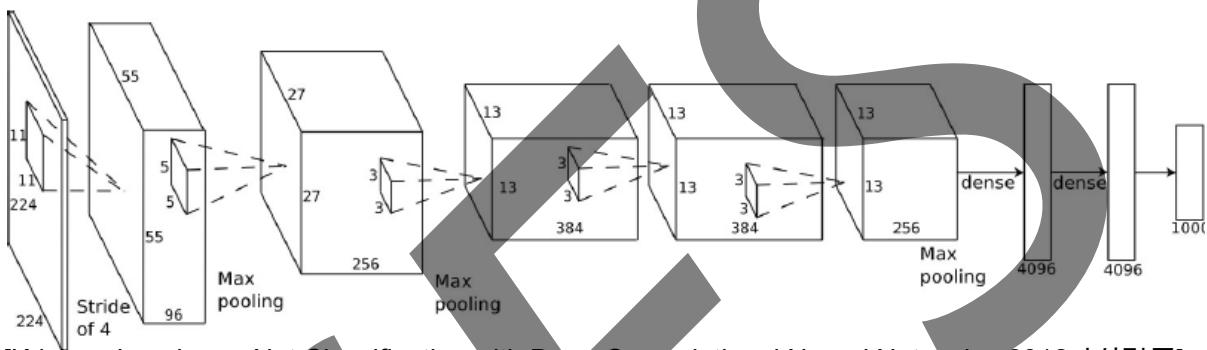
- ・入力に近い層では、局所的特徴を抽出
- ・深い層では、より大域的・抽象的な特徴が抽出される



[図の提供: 福島邦彦氏]

SuperVision [Krizhevsky, Sutskever, Hinton, 2012]

- タスク：一般物体認識、検索（ImageNet Competition）
 - 224x224 RGB画像 ⇒ 1000 カテゴリ
- ネットワークアーキテクチャ：
 - 12層（学習する隠れ層は7層）
 - 入力層 – 5つの畳み込み層 – 2つの全結合層 – 出力層
 - 出力ニューロン数 1,000個
 - 全ニューロン数 65万個、全パラメータ数 6千万



[Krizhevsky+: ImageNet Classification with Deep Convolutional Neural Networks, 2012 より引用]

過学習を防ぐ工夫

- データの水増し
 - 256x256画像から 224x224画像を切りだし
 - 学習用データの枚数を増やす
- Drop Out 学習
 - 学習データごとにランダムに半分のニューロンを消去（マスク）して学習する
 - 学習が終わったらすべての重みを 1/2 にする
 - 複数のモデルを並行的に学習して、それらの平均を取ること（Bagging）を近似的に実現

層ごとの事前学習

- 今回の Deep Learning 研究の源となったアイデアのひとつ
- 全体を教師あり学習するのが難しい
 - 層ごとに学習させる
 - 各層に何を学習させればよいか不明
 - 教師無し学習させる
- アイデア自体はこれも古くからあった例：ネオコグニトロン [福島 1981]

層ごとの事前学習の方法

- 制限つきボルツマンマシン
Restricted Boltzmann Machine (RBM)
を使う方法 [Hinton+ 2006]
- 誤差逆伝播学習を使う方法
[Bengio+ 2007]
- 競合学習を使う方法 [福島 1981]

Deep Learning の成功

- 画像認識・理解・修復
 - 手書き文字認識、一般物体認識、道路標識認識、顔認識、医療画像認識、歩行者検出、・・・
- 音声認識
 - Google音声認識、MS音声認識、・・・
- 自然言語処理
 - 語彙タグづけ、感情認識、類似文検索、機械翻訳、画像や動画の言語化
- 薬物活性予測
- 高分子エネルギー計算（量子化学）
- 囲碁の盤面評価
- 強化学習（昔のコンピュータゲーム）

まとめ：Deep Learning

- 多層のニューラルネットワークモデルによる抽象度の高い、情報圧縮された良い内部表現の発見
- 大量のデータでの（層ごとの）効率のよい学習法と実装
- 教師あり学習（パターン認識や関数近似）で高い性能向上

研究・応用の展開

- 高精度化・高速化・省電力化
 - 領域固有知識の導入、大規模化、多層化
 - アンサンブル化
 - 並列実装、GPU, FPGAの利用、チップ化
 $16 \text{ core CPU} \times 1000 \times 3 \text{ days} \rightarrow (2 \times 4 \text{ core CPU} + 4 \times \text{GPU}) \times 16 \times 3 \text{ days}$
- 新アルゴリズム開発 Drop Out, Max Out, ...
- 理論基盤研究
 - 理論的性能保証、手法間の関連性
- 新しい問題への適用
 - 求人票の給与予測、コンピュータゲーム、画像・動画の言語化、機械翻訳、...

参考文献

- c. ビショップ：パターン認識と機械学習（上下），シュプリンガー・ジャパン(2007,2008)
- 杉山将：イラストで学ぶ機械学習，講談社サイエンティフィク, 2014
- 谷口忠大：イラストで学ぶ人工知能，講談社サイエンティフィク, 2014
- 人工知能学会誌 連続解説「深層学習」, 2013/5～（隔月）
- 岡谷貴之：深層学習，講談社サイエンティフィク, 2015/4（予約受付中）

参考文献

- G. Hinton and R. Salakhutdinov: Reducing the dimensionality of data with neural networks, Science, 2006
- Y. Bengio+: Greedy layer-wise training of deep networks, Advanced in Neural Information Processing Systems 19, 2007
- Y. Bengio+: Representation learning: a review and new perspectives, arXiv:1206.5538, 2012
- A. Krizhevsky+: ImageNet classification with deep convolutional neural networks, NIPS 2012, 2012

参考文献

- Le+ : Building High-level features using large scale unsupervised learning, ICML 2012, 2012
- Taigman+: Deep Face: closing the gap to human-level performance in face verification, 2014
- O. Vinyals+: Show and Tell: a neural image caption generator, arXiv:1411.4555, CVPR 2014, 2014
- I. Sutskever+: sequence to sequence learning with neural networks, arXiv:1409.3215, 2014
- V. Mnih+: Human-level control through deep reinforcement learning, Nature 14236, 2015