

SAPT

第3回知能化分科会

一色 浩

(SAPT知能化分科会長)

2018.05.26

SAPT電子会議室C

目次

1. MathWoksのビデオ・Webセミナー
「MATLABによるディープ
ラーニング」
2. ニューラルネットワーク
「ニューラルネットワークの基礎
～バックプロパゲーション～」

1. 第3回のWebセミナーの概要

前半：知能化技術の現状

MathWoksのビデオ・Webセミナー

「MATLABによるディープ
ラーニング」

質疑応答

後半：ニューラルネットワーク

「ニューラルネットワークの基礎
～バックプロパゲーション～」

質疑応答

2. 知能化技術の現状

MathWoksのビデオ・Webセミナー

「**MATLAB** によるディープ・ラーニング」

- (1) イントロダクション
- (2) MATLABによるDeep Learning
- (3) Stackedautocoders
- (4) Convolutional Neural Network
- (5) CNNと転移学習
- (6) 必須なTool BoxとHardware
- (7) 質疑応答

3. ニューラルネットワークの基礎

～バックプロパゲーション～」

3.1. 前回の復習

3.2. MatLabによるニューラルネットワークのコード

3.3. ニューラルネットワークの学習, 検証, 試験

3.4. 質疑応答

資料: SAPT第2-3回資料(改訂版)

—BackPropagation.pdf

(SAPTのHPからダウンロード可能です)

2. 知能化技術の現状

MathWoksのビデオ・Webセミナー

「**MATLAB** によるディープ・ラーニング」

(1) イントロダクション (0'0")

ニューラルネットワークとは(脳にヒント)

(2) MatLabによるニューラルネットワーク
のコード (1'25")

バックプロパゲーション

MatLabによるDeep Learning
(Autoencoder
Convolutional Neural Network)

(3) Stacked autoencoders ... 積層自己符号化器 (12'30")

Step1~6: Autoencoderによるウェイトの学習 (14'40")

MatLabによる実演 (17'50")

(4) Convolutional Neural Network ... 畳み込みニューラルネットワーク (23'00")

畳み込みニューラルネットワークとは (23'00)

... Autoencoderは使わない

画像のカテゴリ分類 (23'30")

ILSVRC (ImageNet Large Scale Visual Recognition Challenge) (24'50")

... 驚くべき認識率の向上、自動運転に使われている

Convolutional Neural Network (畳み込みニューラルネットワーク) Neural Network Toolbox (27'00")

Convolution Layer (畳み込み層) / Pooling Layers (プーリング層) (28'20") ... 二次元データ + 畳み込み

畳み込みとは.

1次元の拡散:

$$\frac{du}{dt} + \kappa u = f(t)$$

インパルス応答関数:

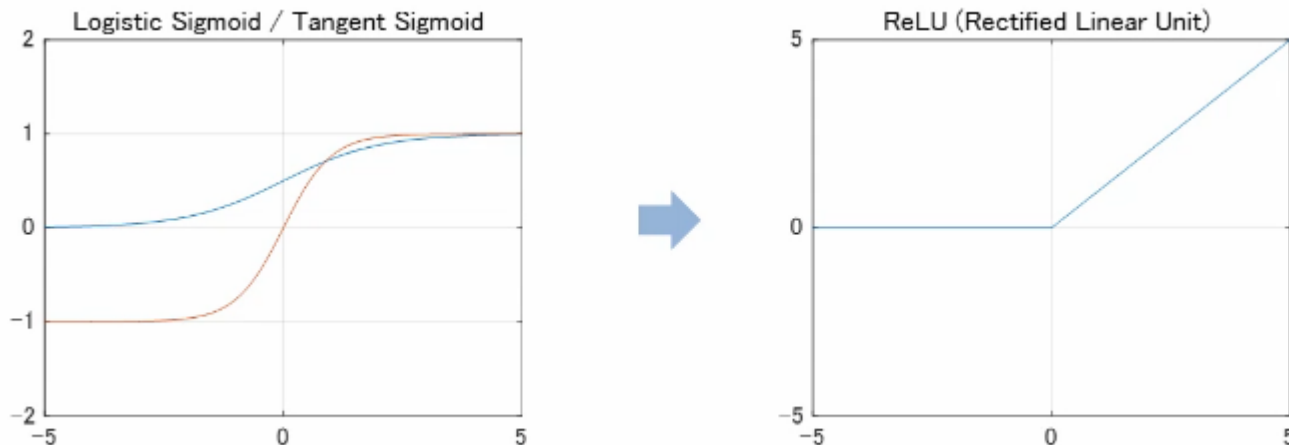
$$\frac{d\phi}{dt} + \kappa\phi = \delta(t) \quad \phi(0) = 0$$

$$\phi \approx E(t)e^{-\kappa|t|}$$

畳み込み表現:

$$u(t) = \int_0^t \phi(t-\tau)f(\tau)d\tau \approx \int_{\tau-\Delta}^{\tau+\Delta} \phi(t-\tau)f(\tau)d\tau$$

ReLU層 (Rectified Linear Unit) (29'00") ...
Logistic Sigmoidなどの値が飽和する関数より,
ReLUの方が学習が早く進む



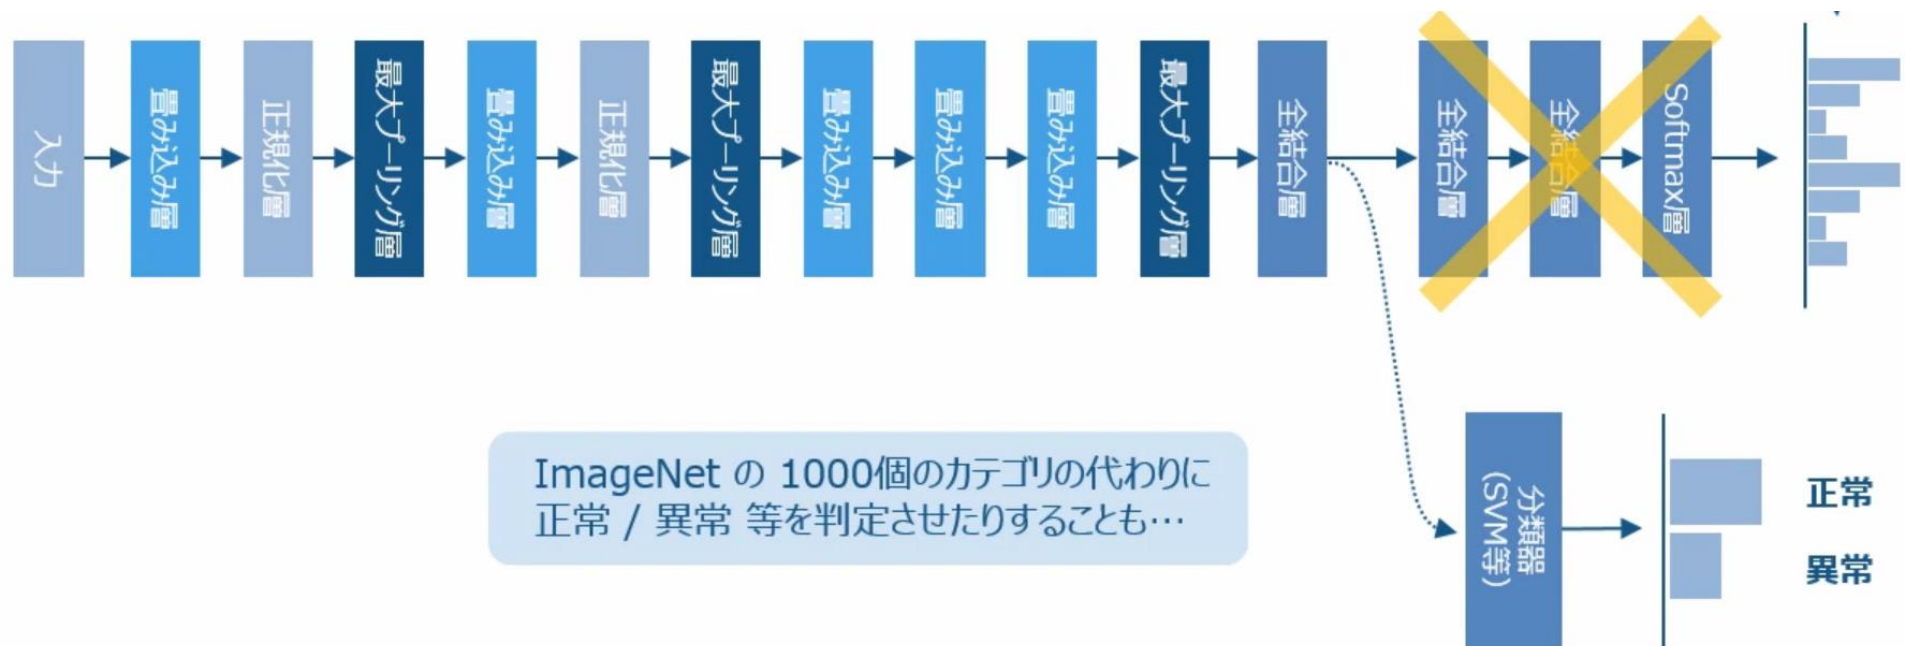
畳み込みニューラルネットワークのMatLabでの
実習 (30'10") ...

CNNと転移学習 (35'00")

転移学習とは

→ 学習済のネットワークを他のタスクに転用

→ 新しく付けた分類器のみ学習



[例題] タンポポとフキタンポポの分類 (36'50")

Alex Netをベースにした転移学習により、2種類のたんぽぽを見分けたい




[例題] 転移学習を使った応用例 (44'00")

監視カメラ等への応用



オプティカルフロー：
動画像の中から動いている物体の
速度ベクトルを計算する



対象領域の抽出：
ベクトルの大きさが一定値以上の
ところを対象領域として抽出



画像の認識：
対象領域にある物体を識別する

Deep Learningに必要なToolboxとHardware (47'30")

MATLAB

← CNNではR2016a以降が必須

Neural Network Toolbox

← 必須

Parallel Computing Toolbox

← CNNでは必須 →

Statistics and
Machine Learning Toolbox

← 転移学習に必要

Image Processing Toolbox

Computer Vision System

学習データセットの処理に必要




NVIDIA® のチップを搭載したGPU
(Compute Capability 3.0以上)

3. ニューラルネットワークの基礎

～ バックプロパゲーション～」

3.1. 前回の復習

ニューラルネットワークの構造

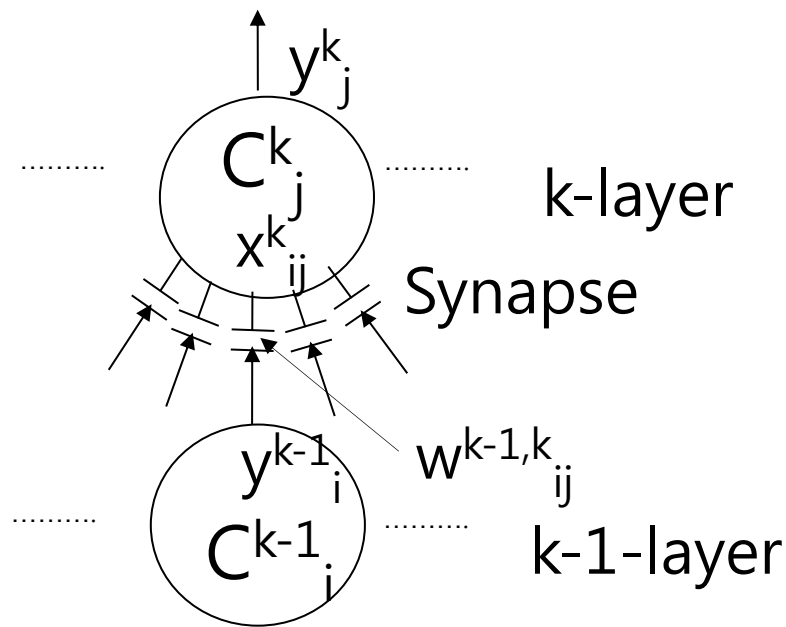


ネットワークの構造

Output

Hidden

Input



ニューロンの入出力
と伝達路の重み

バックプロパゲーションのアルゴリズム

信号伝達

$$x_j^k = \sum_i^{N_{k-1}} x_{ij}^k = \sum_i^{N_{k-1}} w_{ij}^{k-1,k} y_i^{k-1} \quad y_j^k = f(x_j^k) = \frac{1}{1 + e^{-x_j^k}}$$

誤差, 評価関数

$$\delta_j^m = y_j^m - t_j \quad E = \frac{1}{2} \sum_j (\delta_j^m)^2$$

ウェイトの修正 (再急降下法または山下り法)

$$\Delta w_{ij}^{k-1,k} = -\varepsilon \frac{\partial E}{\partial w_{ij}^{k-1,k}} \quad \left[w_{ij}^{k-1,k} \right]_{\text{new}} = \left[w_{ij}^{k-1,k} \right]_{\text{old}} + dw_{ij}^{k-1,k}$$

逆伝播法による誤差の計算

$$\delta_j^k = \begin{cases} y_j^k - t_j & \text{if } k = m \\ \sum_{l=1}^{N_{k+1}} \delta_l^{k+1} y_l^{k+1} (1 - y_l^{k+1}) w_{jl}^{k,k+1} & \text{if } k = m-1, \dots, 2 \end{cases}$$

ウェイトの修正

$$\Delta w_{ij}^{k-1,k} = -\varepsilon \delta_j^k y_j^k (1 - y_j^k) y_i^{k-1}$$

信号の流れ：下層→上層

誤差の計算：上層→下層

⇒ 名前の由来

3.2. MatLabによるニューラルネットワークのコード

プログラムの構成

- (1) 入力データと教師データの作成または読み込み
- (2) 学習データ, 検証データ, 試験データに振り分け
検証データの役割: 過学習の防止
試験データの役割: 汎化能力の確認
- (3) 学習データと検証データによる学習と検証
学習の打ち切り: 検証データが上昇に転ずる所
- (4) 試験データによる汎化能力の確認
正解率(誤差確率)の計算
- (5) 結果の表示と記録

別資料によるコードの説明

別資料による簡単な例題 $y=x1 * x2$ の説明

3.3. 質疑応答

SONY

Neural Network Libraries / Console

ニューラルネットワークを直感的に設計、学習・評価を快適に実現するディープラーニング・ツールです。11月には、クラウドサービスのオープンベータ版を無料公開。アカウントを作成するだけでディープラーニングを体験できるので、ぜひお試しください。

[サインイン](#)

https://dl.sony.com/ja/?gclid=CjwKCAjwopTYBRAzEiwAnU4kb2oW
W_Ilxbpq8WWQqXVy9IsdhrqQ2vS6iyh786JpIrhj0PSbVCvVLhoCR
9sQAvD_BwE

Neural Network Console

ニューラルネットワークを直感的に設計。
学習・評価を快適に実現するディープラーニング・ツール。

[クラウドではじめる](#)[Windowsアプリではじめる](#)

三菱電機:車内音声通話の雑音除去技術

精密な音声モデルを構築し、機械学習技術を確立

雑音には無数の種類が存在するため、全ての雑音を詳細に表現できるモデルを開発することは大変困難です。本技術では声帯・呼気・声道により構成される人の音声生成メカニズムに着目して音声モデルを構築。例えば、“ま”という音声は肺から出る呼気の強さや声帯の振動で決まる周波数と声道の形で決まる音韻特性の組み合わせで規定することができます。これら音声固有の特徴は雑音のパターンと異なることを利用して、雑音が付加された音声入力から人の音声に対応する信号のみ抽出し、残りの信号を雑音として除去する機械学習技術(ニューラルネットワーク)を確立しました。

雑音を96%除去し、聞き取りやすい音声を実現

音声モデルの構築により、定常雑音だけでなく、これまで除去が難しかった非定常雑音も効率よく除去することができ、聞き取りやすい音声通話の実現に貢献します。大量の実データを用いた音声モデルの学習により、実際に車を運転する際に含まれる様々な雑音、例えば走行音・エアコン音などの定常雑音のみならず、ウインカー音・ワイパー音・対向車の走行音などの非定常雑音にも対応可能です。実環境で収録された車内雑音が混じった音声入力を用いた実験では、雑音の96%を除去することを実証しました。



階層型ニューラルネットワークを用いた 独立成分分析による信号分離と未学習音声への適応評価

久木原 健介 和久屋 寛 伊藤 秀昭 福本 尚生 古川 達也

佐賀大学大学院工学系研究科

1. はじめに

心理学の分野において、人間が持つ高度な信号分離能力として“カクテルパーティー効果”が知られており、これを工学的に模倣する技術の一つとして、独立成分分析 (Independent Component Analysis : ICA) がある⁽¹⁾。

カクテルパーティー効果が生体脳における情報処理に基づくと考えれば、ニューラルネットワークによって同等の効果が得られそうである。これまでに、3層構造の階層型ニューラルネットワークに構造刈り込み学習を適用し、入力層と出力層との間で恒等変換を学習して実現する手法が提案されている⁽²⁾。また、その適用事例の報告もある⁽³⁾⁽⁴⁾。しかし、従来は信号分離を実現する学習法に関するものが中心であり、獲得された分離行列の活用法、特に未学習音声への適応評価に関する議論は乏しかったようである。そこで、この点に着目した検討を行う。

以下本稿では、まず2.で構造刈り込み学習に基づくICAの計算手法について紹介し、3.で先行研究の概要を述べる。また、4.で未学習音声の信号分離に関する計算機シミュレーションを行い、最後に5.で結論を述べる。




Fig. 1. ICA-based signal separation with a layered neural network.

$$h_k(t) = \tanh(y_k(t)) \quad (2)$$

$$z_j(t) = \sum_{k=1}^K w_{jk} h_k(t) - \theta_{kj} \quad (3)$$

ここで、 θ_{ik} と θ_{kj} はニューロン $h_k(t)$ 、 $z_j(t)$ の閾値を表している。また、ICAの実現にあたっては、前処理として観測信号に中心化と標準化を施して、入力層へ与えることも多い。

Personal Identification by EEG Using ICA and Neural Network

Authors

[Authors and affiliations](#)

Preecha Tangkraingkiij, Chidchanok Lursinsap, Siripun Sanguansintukul, Tayard Desudchit

Conference paper

1

Citations

637

Downloads

Part of the [Lecture Notes in Computer Science](#) book series (LNCS, volume 6018)

Abstract

The problem of identifying a person using biometric data is interesting. In this paper, the uniqueness of EEG signals of individuals is used to determine personal identity. EEG signals can be measured from different locations, but too many signals can degrade the recognition speed and accuracy. A practical technique combining Independent Component Analysis (ICA) for signal cleaning and a supervised neural network for classifying signals is proposed. From 16 EEG different signal locations, four truly relevant locations F_7 , C_3 , P_3 , and O_1 were selected. This selection can identify a group of 20 persons with high accuracy.



理研、並列計算で感覚情報を分解するアルゴリズムを開発--“脳型コンピュータ”実現

へ一歩

<https://japan.zdnet.com/article/35085719/>

NO BUDGET 2016年07月16日 07時16分

いいね! 6

G+

B! 0

Pocket 26

印刷

メール

ダウンロード

クリップ

理研に論文送付を依頼したが応答なし。

PR | 生産性向上は企業の至上命題--明日の働き方を考え、デジタルで未来を切り開く

PR | 「頭おかしいぞ!」はイノベーションの瞬間かも? 記事まとめを読んで考えよう!

理化学研究所（理研）は6月29日、脳科学総合研究センター神経適応理論研究チームの豊泉太郎チームリーダーらの研究チームが、人の脳を模した“脳型コンピュータ”とも言える神経回路型ハードウェア（神経細胞を模倣した計算素子が互いに結合したネットワークからなる計算装置）を用いて複数の感覚入力を独立した成分に分解するためのアルゴリズムを開発したと発表した。

飲み会の代わり...自由討論

分科会運営方法に関するコメント

最近の世相，時代の潮流

夢：遠隔地音楽アンサンブル

時間遅れをどう克服するか？

音楽合奏に関する鍋島さんの経験