



リザーバーコンピューティングによる食材刺突時の把持力に基づく食材判別の改善

Improvement of Classification of Food Materials Utilizing Reservoir Computing by Gripping Force in Piercing

坪倉 奏太¹⁾, 安藤 潤人²⁾, 北野 勝則²⁾, 野間 春生²⁾

Sota Tsubokura¹⁾, Mitsuhiro Ando²⁾, Masanori Kitano²⁾, and Haruo Noma²⁾

1) 立命館大学 情報理工学研究科 (〒525-0058 滋賀県草津市野地東 1-1-1, is0464pf@ed.ritsumei.ac.jp)

2) 立命館大学 情報理工学部 (〒525-0058 滋賀県草津市野地東 1-1-1, {anmitsu, kitano, hanoma}@fc.ritsumei.ac.jp)

概要: 本研究では周辺機器に依存せずリアルタイムで処理を行える食材判別器の作成を目指し研究を行った。センサとして圧力と剪断力の計測が可能である超小形 MEMS 触覚センサを使用した。このセンサをフォークの柄の裏に取り付け、食材刺突時において中指がフォークに及ぼす把持力を計測した。そして、判別モデルとしてリザーバーコンピューティングを採用し、新しく判別に変数選択法を導入した。k-分割交差検証を用いて検証した結果、識別精度 91.5%を達成した。

キーワード: MEMS 触覚センサ, ハプティクス, リザーバーコンピューティング

1. はじめに

近年、食事を考えるに際し健康を志向している人が多い[1]。利用の際のユーザの便益を考え、判別がリアルタイムかつ PC 等の周辺機器に依存せず行える食材判別器を実現するため、先行研究[2]ではまず MEMS 触覚センサ[3]を用いてフォークにて食材を刺突するときの把持力に対応する信号を計測した。そうして取得されたデータを基に、ディープラーニングなど計算機資源を多大に要する機械学習モデルではなくマイコン等に搭載可能な程に簡便な機械学習モデルによる判別を考えた。そこで、近年提案された低い学習コストと高い計算性能の両立を目指す機械学習モデルである「リザーバーコンピューティング(Reservoir Computing)」[4,5]を使用し判別を行った。リザーバーコンピューティングを用いた判別ではノード数を 2000 と、パラメータ数が 10000 個であった 1DCNN といったディープラーニングモデルより小さくした上で判別精度 80%を達成したが、1DCNN にて達成した精度 99%とは劣っていた。そこで、本研究では先行研究に加え変数選択による過学習のさらなる抑制を図ることで判別精度の改善を目的とし研究を行った。

2. 測定デバイスと MEMS 触覚センサ

2.1 MEMS 触覚センサ

今回、使用した MEMS 触覚センサ[3](図 1)は、3つのマイクロカンチレバーをエラストマで覆った構造を有している。MEMS 触覚センサに力が加わればカンチレバーの傾き、さらに電気抵抗が変化し、これを計測することで加え

られた力に対応する電気信号を取得する。本研究では、MEMS 触覚センサをフォークの柄の裏に搭載することで食材を刺突する際の把持力を計測した。

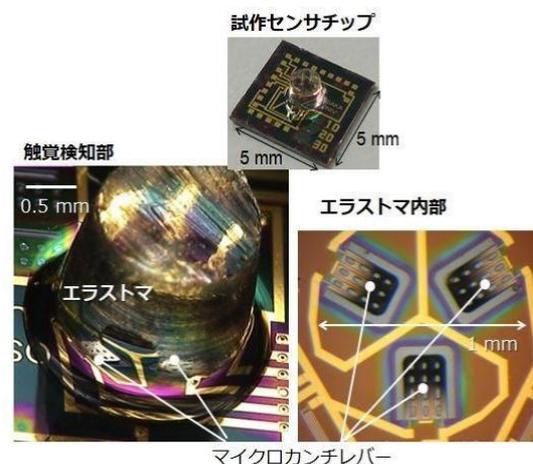


図 1 超小型 MEMS 触覚センサの構造[3]

2.2 測定に使用したデバイス

先行研究[2]、及び本研究にて判別に使用したシステムの概略図を図 2 に示す。本システムは、与えられた把持力を MEMS 触覚センサにて計測し、把持力に対応するカンチレバーにおける抵抗の時系列的变化を取得、その信号をアンプ(LT1167)、Arduino Nano 搭載の AD コンバータを介して PC に取り込み、PC 上に構築したリザーバーコンピューティングモデルにて刺突した食材の判別を行う。

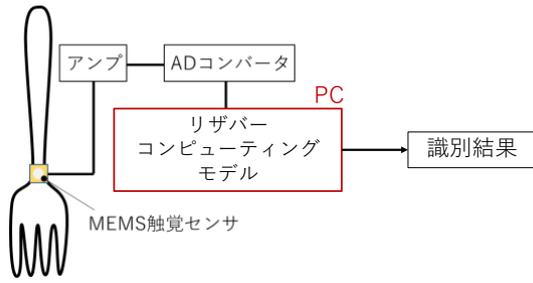


図2 構築したシステムの概略図

2.3 測定の対象と測定条件

本研究においては、先行研究[2]と同じデータセットを用いた。判別対象はマッシュマロ、グミ、かまぼこ、こんにゃく、キュウリの内側、キュウリの外側、ナスの7種類の食材とした。計測は3秒間隔において「刺す」、「抜く」という動作を繰り返してもらい、各動作20回の繰り返しを7セットとし、被験者1人につき2セット、計40回の計測から得られたデータからデータセットを構成している。被験者の構成は右利きである男性3名、ADコンバータのサンプリングレートは300Hz、分解能は10bitであった。実際に得られた波形データを図3に示す。

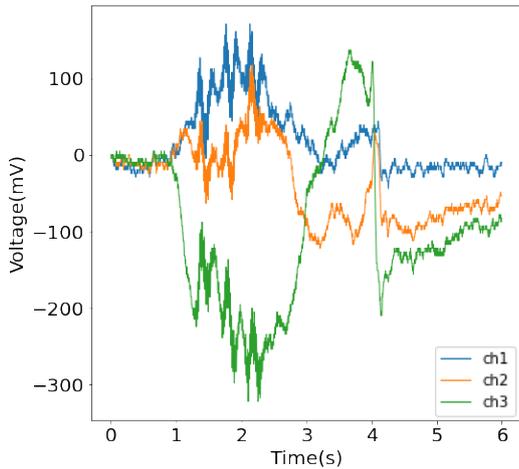


図3 実際に取得した波形データ

3. リザーバーコンピューティングによる判別結果

3.1 リザーバーコンピューティングの概要

リザーバーコンピューティング[4,5]とは、時系列入力データを高次元な時空間パターンに写像する「リザーバー」と「リザーバー」から特徴を抽出する「リードアウト」という二つの構造からなり、このうち「リードアウト」のみを学習の対象とすることで高速な学習と高い精度の両立を図る機械学習モデルである[4,5]。リザーバーコンピューティングモデルのうち信号予測や音声認識、画像認識にて応用されており本研究にも使用した「Echo State Network(ESN)」モデルの概略図を図4に示す。

リザーバーコンピューティングでは、「リザーバー」にて入力信号を高次元時空間パターンに写像することで「リードアウト」の学習を線形回帰など誤差逆伝播法に比べ簡便かつ高速な学習法で行うことを可能にする。

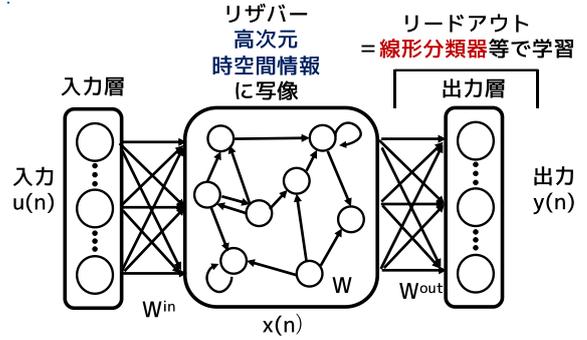


図4 リザーバーコンピューティングの概略図

3.2 先行研究でのリザーバーコンピューティングの構成

今回、先行研究[2]と同じく判別には入力データとしてそれぞれのカンチレバーの変化から得られた波形データをウェーブレット変換したパワースペクトルを用いた。1軸分の波形データをウェーブレット変換した結果を図5に示す。これは、激しい時系列変化をスペクトルに変換することで変化の強度を抑えることを目的にしている。図5に示したスペクトルにおいて、黄色の部分が高い強度を有する領域である。

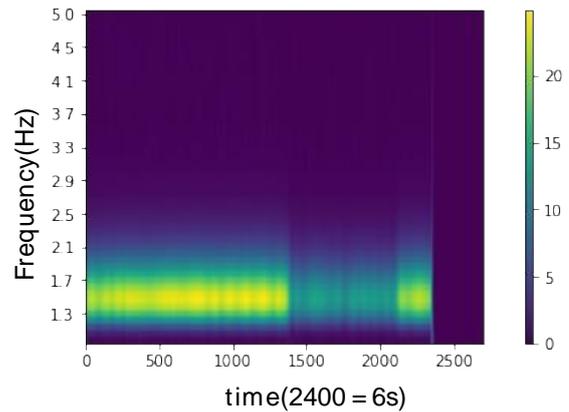


図5 波形データをウェーブレット変換した結果

また、リザーバーのノード数やリザーバー間の結合重みなど想定される各ハイパーパラメータを総当たりすることによってリザーバーの性質を調整した。リードアウトの学習方法として、リッジ回帰を採用した。リッジ回帰とはL2ノルム正則化項を加え、パラメータの大きさに制限を加えることで過学習を抑え込める線形回帰の方法である。先行研究にて判別に際し構築したモデルの概略図を図6に示す。

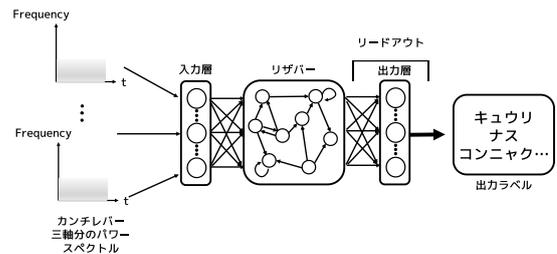


図6 先行研究にて構築したリザーバーの概略図

3.3 本研究での変数選択の導入

本研究では先行研究に加え、所謂「次元の呪い」を減少させることによる過学習の抑制や行列の大きさに比例する計算コストの省力化を図った。リッジ回帰によるリードアウトの学習の際にリードアウトにおけるリザバーと出力層の各ノードの接続をランダムに剪定する形で変数選択を導入した[6]。(図 7)つまり出力層の各ノードに接続されるべきリザバーのノードをランダムにサンプリングしそれをリッジ回帰によるリードアウトの学習に利用することでリードアウトの学習に対し変数選択を導入した。ここでの「変数」とはリードアウト導出の際に対象となる各時刻のリザバー状態を変数として扱ったベクトルを指す。

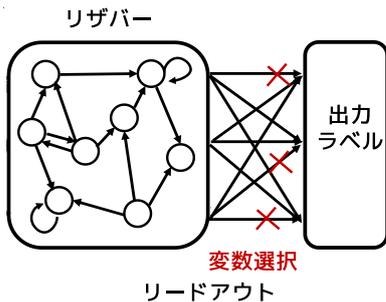


図 7 リードアウトの学習における変数選択

3.4 リザバーコンピューティングモデルの検証

リードアウトの学習及び判別精度の検証は、1組のリザバーのノード数の大きさなどといったハイパーパラメータと変数選択における方法の組み合わせに対し、10回訓練用データ、検証用データを変更し、それぞれ学習・判別・検証を行った(k-分割交差検証)。各学習・検証におけるデータセットは全体のデータのうち9割を訓練用データ、残りをテスト用データとした。なお、訓練用データは全てリザバーに入力した後、全体の順番をシャッフルしもう一度入力した。リードアウトの学習はリザバーに入力され、変換された全訓練データ分の高次元時空間パターンと、全訓練データにおける教師信号を対象にリッジ回帰にて行い、そうして求めたリードアウトを検証用データにて検証した。本研究におけるデータセットの構成、および学習の流れ

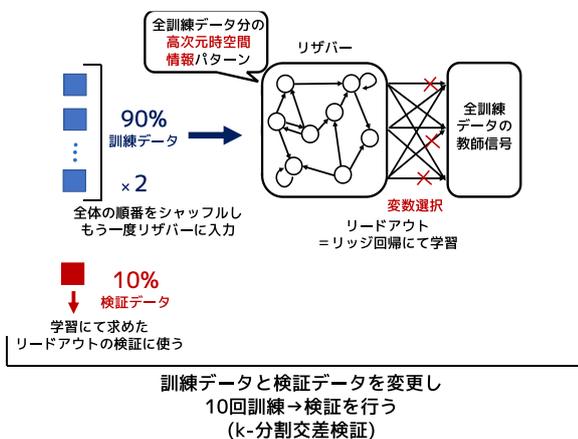


図 8 データセットの構成及び学習の流れ

れを図 8 に示す。なお各訓練、検証にてリザバー及びリードアウトはそれぞれ初期化される。

3.5 リザバーコンピューティングによる判別結果と考察

図 9 に本研究で得られた、変数選択を導入した上でリードアウトの学習を行い検証した結果について示す。なお図はリザバーのノード数を除いたハイパーパラメータを固定し 5 回変数選択の方法を変更した上で k-分割交差検証を行い、最も高い判別精度を出力した場合の最高精度、最低精度、平均値、標準偏差による平均値からの誤差について記載している。各精度の分類は変数選択前のリザバーのノード数を基準とし、またリザバーのノード数ごとに最も高い精度を出した時におけるサンプル数を記載している。

変数選択前のリザバーのノード数 3000 の時、かつリザバーのサンプリング数が 2250 だった時、選択前のリザバーのノード数が 2500、サンプリング数が 1750 だった時、そして選択前のリザバーのノード数が 1500、サンプリング数が 1000 だった時に最高精度 91.5%を達成した。これは先行研究[2]で得られた精度 80%と比べて向上している。ただし、各学習・検証によって精度が大きく変化していることは注意が必要である。これは、用いたメモリ等の計算機資源の限界により、判別結果が十分に一般化されるような大きさの学習データを構築できなかったことが原因として考えられる。リザバーにおける状態の時間発展が初期値に依存しないという性質である Echo State Property(ESP)[5]が満たされていないことも原因として考えられる。

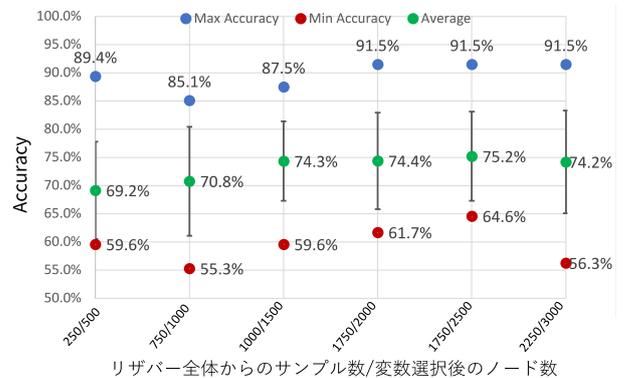


図 9 リザバーコンピューティングによる判別結果

また、学習に要する計算コストに関しても、先行研究では学習の対象となるリザバーのノード数が 2000 であるのに対し、変数選択を導入した今研究では 1750 と 4 分の 3 に減っていることから省力化に成功している。1DCNN と比較しても、用いるモデルのパラメータ数(ノード数)を 1 桁削減した上で 8%下がった程度の判別精度を維持している。そして、リザバーのノード数 500、サンプリング数 250 で精度 89.4%を達成した。これは、リザバーコンピューティングの「ディープラーニングと比べ出力精度は低い傾向にあるが、用いるネットワーク構造や計算コストが小さい」という特徴を示す。

4. おわりに

4.1 まとめ

本研究では、ディープラーニングに比べて精度が不十分であった先行研究[2]における判別手法を改善することをその目的とした。過学習の抑制や処理に要する計算コストの省力化を図るため出力層のノードごとに学習の対象となるリザーバーのノードをそれぞれランダムにサンプリングする形で変数選択を導入し判別精度の改善を図った。結果として、リザーバーのノード数 2000・サンプリング数 1750 などにて最高精度 91.5%を達成した。これは先行研究[2]にて得られた精度である 80%より大幅に改善されており、また変数選択による計算コストの省力化も達成できた。ただし、各試行により判別精度は大きく変化した。これはリザーバーに入力したデータの量、及びリザーバー自体が ESP を満たせていないという原因が考えられる。

4.2 展望

本研究の展望としては、まずできる限り判別精度を保った上で時間計算量や空間計算量の大きさに関わるリザーバーのノード数の大きさをさらに削減することが挙げられる。その方法としては、主成分分析を用いてリザーバーの特徴を圧縮し次元数を削減、その圧縮された特徴ベクトルを対象にリードアウトの学習を行うという方法[7]が考えられる。また、リザーバーコンピューティングにおいてはできる限り少ないノードにて「大雑把な処理」を行い、その出力をマルチレイヤーパーセプトロンにて処理することで使用する計算コストを最大限に抑えた上で精度を保つことも考えられる。計算コストを抑えた上で学習・検証を行うことにより、学習データをかさますことなどによりリザーバーコンピューティングによる判別の一般化をさらに進めることが考えられる。

また、処理に必要な計算コストを削減されたリザーバーコンピューティングを用いた機械学習モデルを、ハードウェアに搭載して判別器のリアルタイム性や独立性を確保することも考えられる。ディープラーニングに比べ構造、および学習法が単純であるリザーバーコンピューティングモデルはハードウェア実装に適している。現在、このためにパルスカウントをベースとしたハードウェアニューロンの設計も進めている[8]。

そして、将来的な展望として今回構築した MEMS 触覚センサから得られた情報に基づきリザーバーコンピューテ

ィングモデルにて判別を行うモデルを他のタスクに応用することが考えられる。特に、触覚情報は高次元である上に激しく時系列的に変化するという特徴がある。そのような触覚情報をハードウェア上に構築したリザーバーコンピューティングモデルにて圧縮し、利用することで例えばモノを器用に掴めるロボットハンドの開発や、安全性の高い義手等の開発につなげることが考えられる。

参考文献

- [1] https://www.jfc.go.jp/n/findings/pdf/topics_210318a.pdf, 「食の志向 低下傾向にあった健康志向が上昇に転じる」, 日本政策金融金庫ニュースリリース, 2022 年 7 月 12 日閲覧
- [2] 坪倉奏太, 安藤潤人, 北野勝則, 秋田純一, 野間春生, MEMS 触覚センサを用いたフォークの把持力に基づく食材判別への リザーバーコンピューティングの応用, 第 28 回ハプティクス研究会(2022)
- [3] 橘弘人, 釜鳴志朗, 美馬達也, 寒川雅之, 金島岳, 奥山雅則, 山下馨, 野田実, 野間春生, 樋口誠良, 3 方向カンチレバーを用いた多軸触覚センサの作製と基礎特性. 電気学会論文誌 E(センサ・マイクロマシン部門誌), Vol. 130, No. 6, pp. 223-229(2010)
- [4] Jaeger, Herbert, The “echo state“ approach to analyzing and training recurrent neural networks-with an erratum note'. Bonn, Germany: German National Research Center for Information Technology GMD Technical Report. 148(2001)
- [5] 田中剛平, 中根了昌, 廣瀬明著, リザーバーコンピューティング 時系列パターン認識のための高速機械学習の理論とソフトウェア, 森北出版(2021)
- [6] X. Dutoit, B. Schrauwen, J. Van Campenhout, D. Stroobandt, H. Van Brussel, M. Nuttin, Pruning and regularization in reservoir computing, *Neurocomputing*, Volume 72, Issues 7-9(2009)
- [7] Løkse, S., Bianchi, F.M. & Jenssen, R. Training Echo State Networks with Regularization Through Dimensionality Reduction. *CognComput* 9, 364-378(2017).
- [8] 青木雅典, 土橋喜真花, 安藤潤人, 寒川雅之, 秋田純一, 野間春生, MEMS 触覚センサ向け機械学習のための FPGA による SNN パーセプトロン実装, 第 26 回日本バーチャルリアリティ学会大会論文集(2021)