

多変量時系列変数マルチチャネル変換画像分類における深層学習の適用

Proposition of Multimodal Time Series Data Analysis Framework by CNN based on Multi-Channel Image Conversion

蛭田 興明 ^{*1}
Komei Hiruta

梁木 俊冴 ^{*1}
Toshiki Hariki

高屋 英知 ^{*1}
Eichi Takaya

伊藤 千輝 ^{*2}
Kazuki Ito

荒牧 大樹 ^{*2}
Hiroki Aramaki

稲垣 隆雄 ^{*3}
Takao Inagaki

山岸 典生 ^{*4}
Norio Yamagishi

栗原 聡 ^{*1}
Satoshi Kurihara

^{*1}慶應義塾大学 大学院理工学研究科
Graduate School of Science and Technology, Keio University

^{*2}ネットワンシステムズ株式会社
Net One Systems Co., Ltd.

^{*3}トヨタプロダクションエンジニアリング株式会社
TOYOTA Production Engineering Co., Ltd.

^{*4}トヨタ自動車株式会社
TOYOTA Motor Co., Ltd.

In recent years, with the development of IoT and sensor technology, various data can be acquired. In this case, it is expected to establish analytical methods capable of extracting the characteristics of relevances of each variable of multimodal data. In this study, time series variables with different dimensions on the same time axis are converted to color change images as RGB which is the three primary colors of light, and Convolution Neural Network(CNN) is applied to this. Next, we propose a method to perform more effective feature extraction by converting the image using XYZ, Lab color space reflecting the color visual stimulus with RGB as the base. We compared accuracy with existing classification method and showed the effectiveness of the proposed method. Moreover, by converting time series in various color spaces. It is suggested that higher performance feature extraction can be realized than when processing each variable as independent.

1. はじめに

近年, IoT やセンサ技術の発展により, 多様なデータをリアルタイムで得ることが可能な世の中になってきている. 実際に現時点で採取することのできるデータは, 変数の種類が単一という場合は少なく, 二種類以上のデータを対象とする場合が殆どである. このような場合の分析は, 現状は各変数の種類に対して回帰分析や異常検知を行う等, あくまで独立した変数として処理する方法が殆どである. しかし, このような多次元データが得られる場合, それぞれの変数が独立に作用している場合だけでなく, 実際はある変数が変化するとある変数が変化するというように, 互いに関連し合い, 影響を及ぼしながら変化している場合が多い. しかし未だ多次元データの関連性を新たな特徴量として抽出する研究手法は確立されていない. したがって, 複数の多次元データが得られた際に, 変数の関係を維持できるような適切な前処理を行うことで各変数の関連性を特徴抽出し, より有効性の高い分析を行う手法の確立が期待されている.

2. 関連研究

多次元データ分析に関しては今日まで産業界, 学術界を問わず幾多の手法が提案されてきた. 深層学習による高い分類精度が明らかになって以来, 深層学習に基づく多次元データ, 特に時系列データに対する分析手法が近年数多く提案されている. Zheng ら [2] は, 複数の時系列データを各チャネルに変換し, それぞれのチャネルに対し個別の Convolutional Neural Network(CNN) により処理する手法を提案している. Wang ら

[3] は Deep Neural Network を用いた時系列分類のベースライン手法を提案している.

これらの手法はいずれも, 深層学習の特徴である多次元データより特徴量を自動的に抽出しているといった点では有効性があるものの, 複数の変数の関連性より新たな特徴量を抽出するといった領域までは踏み込めていない.

3. 提案手法

本研究では, 色の持つ物理的特性を効果的に活用する特徴抽出手法の提案を行う. はじめに, 3つの異なる次元を持つ変数をそれぞれ光の三原色である赤, 緑, 青に対応させ, 正規化を行い統合させ一つの色変化画像に変換し, それに対して畳み込みニューラルネットワークを適用することで, 高性能の特徴表現学習を行う分析手法の提案を行う. 色成分は赤, 緑, 青の各独立成分の線形結合で表せるため, 3つの変数を色変換する事で, 既存手法とは異なり, 変数間の関連性も抽出することができるメリットがある. しかし, 我々人間は RGB を一つの色として認識できるが, 計算機で処理する場合は, RGB 独自に処理されてしまう. そこで, 計算機でも人のように RGB を取り扱うために, RGB を基軸にした XYZ, Lab 色空間を利用した画像変換を行うことで, より効果的な特徴抽出を行うことを目指す. XYZ は人間の視覚刺激を反映した色空間となっており, RGB 系をベースとして次のような式で表現できる.

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.576669 & 0.185558 & 0.188229 \\ 0.297345 & 0.627364 & 0.075291 \\ 0.027031 & 0.070689 & 0.991338 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (1)$$

XYZ 系の各成分は色の三原色である赤, 緑, 青の線型結合で表せるので, 各色成分に対応させた変数間の関連性を特徴抽出

連絡先: 蛭田興明, 慶應義塾大学大学院理工学研究科,
T 223-8522 神奈川県横浜市港北区日吉 3-14-1,
Email: komei1582@gmail.com

することができる。加えて、XYZ 色空間の導入により、人間が見て異なる色同士を異なる情報として扱うことが可能となる。

加えて、この XYZ 系を改良させ、より色差を正確に表現できる CIELAB 系も同時に採用した。Lab は XYZ をベースとして、次のような式で表せる。

$$f(t) = \begin{cases} t^{\frac{1}{3}} & (t > 0.008864) \\ \frac{9.66^3 t + 16}{116} & (\text{otherwise}) \end{cases} \quad (2)$$

$$L^* = 116f(Y/Y_n) - 16$$

$$a^* = [f(X/X_n) - f(Y/Y_n)]$$

$$b^* = [f(Y/Y_n) - f(Z/Z_n)]$$

(X_n, Y_n, Z_n は正規化定数)

これらの二つの色空間と通常の RGB による時系列色画像を作成し、画像分類精度の比較を行うことで色相変換による特徴表現能力の向上を試みた。

4. 時系列の折りたたみ画像作成による効果

本研究では、時系列を色相変換することで色の特性を生かした特徴抽出を行うだけでなく、時系列データを画像に置き換える際に、従来のように時系列を一行にするのではなく、時系列ウィンドウ単位で変換させたデータを横に複数並べて一つの正方形の画像とした。これによって、より広範囲の時系列パターンを表現学習を試みた。図 5 で示すような画像変換を行うことで、隣接する時間と離れた時間の両方を畳み込むことが可能となる。これによって、多様な時系列データ変化の特徴表現学習を行うことが可能となる。




図 1: 時系列折りたたみによる作成画像イメージ

5. 実験

本研究では、上述した 2 種類の色空間によって表現される色覚刺激や色同士の差を多次元データ同士の関連性や違いに対応させることで、特徴表現能力の向上を試みた。

今回の研究で使用した CNN アーキテクチャは LeNet[8] をベースに構築した。今回の提案手法の概要を図 3、図 4 に示す。本実験では、データセットとして UCI Machine Learning Repository の Heterogeneity Activity Recognition Data Set を用いた。これはスマートフォンの加速度センサデータであり、9 人の被験者が多様な行動をする際の x, y, z 軸の 3 方向の加速度




図 2: 提案手法の全体像 (1 列画像の場合)




図 3: 提案手法の全体像 (折りたたみ画像の場合)

の時間変化の記録である。被験者が取り得る行動は、「立つ」、「座る」、「歩く」、「階段を登る」、「階段を降りる」、「自転車に乗る」の 6 種類である。人間の各動作の周期は約 1 秒間により、本研究では時系列ウィンドウサイズを 1250ms にし、1 ウィンドウを特定の間隔 (5ms, 10ms, 50ms, 100ms) でスライドさせ画像を作成した。これらを入力とし、行動分類モデルの学習を試みた。精度確認のため、訓練データ：バリデーションデータの比率を 8:2、バッチサイズ 70、エポック数 50 とした。

6. 結果

提案手法の評価のため、比較手法として既存の多次元データ分類手法である SVM, K-NN, RandomForest(RF), LSTM によるモデルを作成し、これと各色相空間上で画像変換した提案手法の精度 (Precision), 再現率 (Recall), F1 値 (F1-score) を求め比較した。その結果を表 1 に示す。加えて、時系列データを折りたたむことによる効果を確認するために、同一のウィンドウ間隔における精度比較を行った結果を表 2 に示す。

7. 結論および今後の方針

3 次元加速度センサデータを RGB に対応させ、多様な色相空間で画像変換し、その画像の多クラス分類による行動認識を行った。表 1 より全ての比較手法より提案手法が最も高い性能




図 4: 多次元データの色画像変換手順

表 1: 色相効果の評価実験の結果

ウィンドウスライド 5ms における結果

手法	精度 (Precision)	再現率 (Recall)	F 値 (F-score)
SVM	85.92 %	85.89 %	85.79 %
KNN	85.50 %	85.59 %	85.49 %
RF	85.68 %	85.78 %	85.68 %
LSTM	50.29 %	90.72 %	64.63 %
RGB+CNN	92.85 %	92.57 %	92.68 %
XYZ+CNN	91.30 %	91.31 %	91.21 %
Lab + CNN	91.43 %	91.76 %	91.53 %

を示すことが確認できた。しかし、色相変換による効果が現れる場合も存在したが、色相変換によって必ずしも分類性能が向上するわけではないことが判明した。この原因として、今回の加速度データは必ずしも各成分が関連性を持って変化しているわけではないことが考えられる。加えて、時系列を一系列の画像として処理する場合と比較して、折りたたみ画像に変換することによって、わずかなではあるが分類精度の向上が確認された。この結果より、時系列画像を折りたたむことで、多様な時系列変化を特徴表現学習できていることが期待される。

今後は、より多様なデータ分析手法との比較により、提案手法の有効性を示す。また、加速度データ以外にも心電図、脳波など、多様なデータに対しても性能を評価する。加えて、本手法では多次元データを直接色変換するため、現状では次元数が 4 以下の場合にしか対応できない。より汎用性を高めるために、次元数が 5 以上の場合にも色相変換により変数間の関連性を抽出できる手法の確立に努めていく。

表 2: 折りたたみ画像の評価実験の結果

ウィンドウスライド 5ms における結果

色相+画像形式	精度 (Precision)	再現率 (Recall)	F 値 (F-score)
RGB+CNN 1d	92.85 %	92.57 %	92.68 %
XYZ+CNN 1d	91.30 %	91.31 %	91.21 %
Lab + CNN 1d	91.43 %	91.76 %	91.53 %
RGB+CNN 2d	92.90 %	93.06 %	92.94 %
XYZ+CNN 2d	92.20 %	92.32 %	92.26 %
Lab + CNN 2d	86.92 %	86.86 %	86.83 %

参考文献

- [1] 総務省:平成 28 年度情報通信白書,2016
- [2] Yi Zheng, Qi Liu, Enhong Chen, Yong Ge, J. Leon Zhao, *time series classification using multi-channels deep convolutional neural networks*, International Conference on Web-Age Information Management, 2014.
- [3] Zhiguang Wang, Weizhong Yan, Tim Oates *time series classification from scratch with deep neural networks a strong baseline*, arXiv:1611.06455, 2016.
- [4] Zhengping Che, Sanjay Purushotham, Kyunghyun Cho, David Sontag, Yan Liu *Recurrent Neural Networks for Multivariate Time Series with Missing Values*, arXiv:1611.06455, 2016.
- [5] Nijat Mehdiyeva, Johannes Lahanna, Andreas Emricha, David Enkeb, Peter Fettke, Peter Loosa *Time Series Classification using Deep Learning for Process Planning: A Case from the Process Industry*, Procedia Computer Science archive Volume 114 Issue C, November 2017 Pages 242-249
- [6] Nima Hatami, Yann Gavet, Johan Debayle *Classification of Time-Series Images Using Deep Convolutional Neural Networks*, arXiv:1710.00886, 2017
- [7] Fazle Karim, Somshubra Majumdar, Houshang Darabi, Samuel Harford *Multivariate LSTM-FCNs for Time Series Classification*, arXiv:1801.04503, 2018
- [8] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner *Gradient-based Learning applied to document recognition*, Proceedings of the IEEE, 86(11), 1998
- [9] 日本色相学会 カラーテクノロジー, 朝倉書店, 2008