

蒸留を用いた時系列分類モデル MC-MHLF の圧縮

玄行 朱里† 田村 慶一‡

広島市立大学情報科学部† 広島市立大学大学院情報科学研究科‡

1 はじめに

センサデバイスが取得した時系列のデータを分類することで機器の異常や状態を検出することができるため、深層学習を時系列データ分類問題へ応用する研究開発が盛んに行われている。そこで、実用化のためにエッジデバイスに組み込むことが可能なサイズの深層モデルを作成することが重要な研究課題となる。本研究では、時系列データの分類モデルのひとつである Multi-Channel MHLF (MC-MHLF) モデル[1]に対し、モデル圧縮の基本的な手法の一つである蒸留を試みる。MC-MHLF モデルは LSTM-FCN モデル[2]をベースとしており、LSTM-FCN モデルをベースとしたモデルの蒸留による圧縮性能についてはその評価が十分に行われていない。そこで、本稿では蒸留を用いたモデルの学習手法を示すとともに UCR アーカイブデータセット[3]を用いて行った圧縮の評価実験の結果を報告する。

2 MC-MHLF モデル

MC-MHLF モデルは Karim ら [2] によって提案されている時系列データ分類モデル LSTM-FCN をベースとした深層モデルの入力部分に、時系列データとその加速度にあたる MACD ヒストグラムをマルチチャンネル化するための変換層を新たに加えたモデルである。

3 モデルの蒸留

蒸留とは大きなサイズのモデルで習得した知識を小さなサイズのモデルの学習に使用するモデルの圧縮手法である。学習済みモデルを教師モデル、教師モデルの知識を継承する教師モデルより小さなサイズのモデルを生徒モデルと呼ぶ。生徒モデルの学習に教師モデルの出力とデータセットの正解ラベルを用いる。蒸留の1つ目の目的関数は、学習用データセットを入力したときの教師モデルの出力と生徒モデルの出力のクロスエントロピー L_{soft} (soft target loss), 2つ目の目的関数は、生徒モデルの出力とデータセットの正解ラベルとのクロスエントロピー L_{hard} (hard target loss) である。これらの目的関数の加重平均が、生徒モデル学習の際の損

失関数であり、通常、温度パラメータを用いた調整が行われる。

$$(1 - \lambda)L_{hard} + \lambda T^2 L_{soft} \quad (1)$$

T は softmax の温度パラメータである。 λ は L_{hard} と L_{soft} の重みパラメータである。

4 モデルの学習手法

本研究では、教師モデルとして MC-MHLF モデルを、また、生徒モデルとして、FCN モデルを用いる。FCN モデルと MC-MHLF モデルとの違いは、LSTM 層があるかないかである。モデルの新しい学習方法として、(a) 蒸留を行った後に生徒モデル単独での学習を行う (復習), (b) 生徒モデル単独で学習を行った (予習) 後に蒸留を行う, (c) 予習を行い、次に蒸留を行った後に復習を行うという3つの学習手法を提案する。

表1:生徒モデルのフィルタ数とパラメータ数

サイズ	畳み込み層 1 フィルタ数	畳み込み層 2 フィルタ数	畳み込み層 3 フィルタ数	およその パラメータ 数
①	16	-	-	550
②	32	-	-	1000
③	64	-	-	2000
④	128	-	-	4000
⑤	8	8	-	600
⑥	8	16	-	1000
⑦	16	16	-	1900
⑧	16	32	-	3300
⑨	32	32	-	6300
⑩	32	64	-	12000
⑪	32	64	32	22000
⑫	64	64	64	44000
⑬	64	128	64	85000
⑭	128	128	128	170000
教師	-	-	-	335000

5 評価実験

評価実験では、教師モデルを MC-MHLF モデル、生徒モデルを FCN モデルにしたときの蒸留の圧縮性能の評価と、蒸留を用いた生徒モデル学習の提案手法3つの比較実験を行った。

“Compression of Time Series Classification Model MC-MHLF using Knowledge Distillation”

†Gengyo Akari, Faculty of Information Sciences, Hiroshima City University

‡Tamura Keiichi, Graduate School of Information Science, Hiroshima City University

表 2: 蒸留を用いた場合, 蒸留を用いなかった場合の平均正解率 (学習回数 2000 回)

モデル サイズ	①	②	③	④	⑤	⑥	⑦	⑧	⑨	⑩	⑪	⑫	⑬	⑭
蒸留 あり	0.7918	0.8113	0.8249	0.8291	0.8281	0.8422	0.8538	0.8593	0.8643	0.8668	0.8722	0.8734	0.874	0.8729
蒸留 なし	0.7763	0.7952	0.8069	0.8185	0.821	0.8341	0.847	0.8524	0.861	0.8633	0.8724	0.8742	0.8755	0.8758

表 3: 各手法, 各サイズ生徒モデルの平均正解率 (学習回数 200 回)

モデル サイズ	①	②	③	④	⑤	⑥	⑦	⑧	⑨	⑩	⑪	⑫	⑬	⑭
(a)	0.6665	0.7031	0.7272	0.7471	0.7383	0.7660	0.7890	0.7969	0.8136	0.8215	0.8502	0.8541	0.8518	0.8549
(b)	0.5795	0.6215	0.6506	0.6762	0.6554	0.683	0.7142	0.7351	0.7621	0.7722	0.8214	0.8350	0.8397	0.8474
(c)	0.6563	0.6890	0.7129	0.7341	0.7055	0.7337	0.7685	0.7757	0.7908	0.8157	0.8376	0.8456	0.8382	0.8389
蒸留 のみ	0.6439	0.6743	0.7000	0.7212	0.7201	0.745	0.7806	0.7904	0.8116	0.8212	0.8521	0.8558	0.8593	0.8591
蒸留 なし	0.6324	0.6710	0.6913	0.7136	0.7124	0.7416	0.7692	0.7859	0.8057	0.8098	0.8470	0.8573	0.8578	0.8621

5.1 生徒モデル FCN のパラメータ

FCN モデルの層数, フィルタ数を変化させた, パラメータ数の異なる 14 種類のモデルを作成した. パラメータ数が小さくなるほどモデルのサイズは小さくなる. 全ての生徒モデルは, データをマルチチャンネル化する変換層の後, 生徒モデルサイズに応じた 1~3 枚の畳み込み層, Global Average Pooling (GAP) 層を持つ構成となっている. 全ての畳み込み層には Batch Normalization と, 活性化関数として Rectified Linear Unit (ReLU) 関数を用いる. 生徒モデルの層数と各層のフィルタ数を表 1 に示す. 表 1 内のモデルサイズ⑤~⑧はそれぞれモデルサイズ①~④の 1 層 FCN モデルと同等のパラメータ数を持つ 2 層 FCN モデルである. 最終行には教師モデルのパラメータ数を示す.

5.2 蒸留モデルの評価実験

評価実験に用いた UCR アーカイブデータセットには 85 個の時系列データセットがあり, それらは訓練データと検証データを含む. 実験では, 訓練データを教師モデル, 生徒モデルの学習に用い, 各学習モデルの検証データに対する正解率を比較する.

評価実験では, 蒸留を用いて学習した生徒モデル, 蒸留を用いずに学習した生徒モデルの比較を学習回数 2000 回で行い, その後, 提案する各学習手法とそれらの手法を用いなかった場合の比較を学習回数 200 回で行った. それぞれの結果を表 2 と表 3 に示す. 表 2 には学習に蒸留を用いた場合, 蒸留を用いなかった場合の生徒モデルにおける, 全データセットでの平均正解率を示す. この結果から, 1 層または 2 層 FCN において, 蒸留を用いることで正解率が向上していることが分かった. 表 3 には表 2 と同様に, 提案手

法を用いた場合, 提案手法を用いなかった場合の生徒モデルの平均正解率を示す. (a), (b), (c) の行には 4 章で説明した 3 手法を用いた場合, 蒸留のみの行には単純に蒸留のみ用いた場合, 蒸留なしの行には蒸留を用いなかった場合の結果を示す. この結果は, 1 層または 2 層 FCN において, (a) 蒸留を行った後に復習を行うという提案手法は, 他の方法より分類精度が高くなることを示している.

6 まとめ

本研究では MC-MHLF モデルを様々なサイズの FCN モデルに蒸留し, その分類精度を示すとともに, 蒸留を用いた新たな学習手法を提案した. 評価実験の結果として, 1, 2 層 FCN で蒸留が有効であり, 学習回数 200 回の限定的な条件下では, 提案手法の (a) 蒸留の後に復習が有効であることが分かった. 今後の課題として, 蒸留の効果がなかったデータセットにおける生徒モデルの検討や, 予習と復習の学習法の改良が必要だと考えられる.

謝辞

本研究の一部は, JSPS 科研費 JP18K11320 により行われた.

参考文献

- [1] 橋田修一, 田村慶一. Multi-Channel MHLF を用いた時系列データの分類手法, 情報処理学会論文誌: 数理モデル化と応用, Vol. 13 No. 2, pp. 22-35 (Aug. 2020).
- [2] F. Karim, et al. Lstm fully convolutional networks for time series classification. IEEE Access, Vol. 6, pp. 1662-1669, 2017.
- [3] Hoang Anh Dau, et al. The ucr time series classification archive, October 2018.