

# ガイドデータを用いた多層ニューラルネットのオンライン学習に関する考察

A Study on an On-Line Learning for Multilayer Perceptron Using Guided Data

金田 祐也<sup>\*1\*2</sup> 趙 強福<sup>\*1</sup>  
Yuya Kaneda Qiangfu Zhao

<sup>\*1</sup>会津大学 <sup>\*2</sup>日本学術振興会特別研究員 DC2  
The University of Aizu JSPS Research Fellow DC2

We proposed an algorithm called decision boundary making (DBM) to induce a compact and high performance multilayer perceptron (MLP) model. This time, we consider a memory-less on-line learning for an MLP model which is obtained by the DBM algorithm. We propose an on-line learning using guided data to update a model stably. In this paper, we investigate the performance of the proposed algorithm through experiments.

## 1. 緒言

近年、スマートフォン等を始めとした携帯型端末が急速に発達し、多くの人が生活で使用している。また、スマートフォンの普及に伴い様々なアプリケーションが開発され、多くのユーザが多種多様なアプリケーションを利用している。我々は、ユーザの生活をサポートすることが可能な機械学習を基にした察知エージェントを作成し、スマートフォンのアプリケーション内で活用する事を考えている。機械学習を用いる事で、各ユーザに最適化する事ができ、その上でユーザの様々な状況を判断、有力となる情報をユーザに提供する事で、ユーザの意思決定をサポートする事が出来る。また、スマートフォンのアプリケーションを対象とする事で、前述の通りより多くのユーザが活用可能となる。

我々は、小型で高性能な機械学習モデルを構築する為の手法、判別境界作成 (DBM: Decision Boundary Making) アルゴリズムを提案し、携帯端末でも利用しやすい小型な機械学習モデルを設計した [2]。従来の高性能な機械学習モデルを利用すると、計算コストが高く、計算リソースに制限があり、バッテリーの問題がある携帯端末で活用する事は難しい。その為、計算コストを削減すべく我々は DBM アルゴリズムを提案した。本手法では、高性能な機械学習モデルとして知られているサポートベクターマシン (SVM: Support Vector Machine)[6] の判別境界を、小型な多層パーセプトロン (MLP: Multilayer Perceptron)[5] で再現する事で、小型化と高性能化の両立を図っている。過去の実験結果から、SVM と同等、もしくはそれ以上の精度を持つ小型で高性能な機械学習モデルが得られる事を確認した [2]。

本稿では、MLP のメモリレスなオンライン学習に着目し、ガイドデータを用いた手法を提案し、結果の考察を行う。提案した DBM アルゴリズムはオフライン学習に分類され、学習した後に得られたデータに適応する為には学習をし直す必要があり、計算コストが高い。その為、DBM アルゴリズムで学習した MLP モデルを、メモリレス、低計算コストで安定的に精度向上する事が可能なオンライン学習に焦点を当てる。なお、従来のオンライン学習の多くは初期モデルからモデルを学習する為の手法であるのに対し、我々は学習済みモデルを更新する事を目的とする。与えられた未知データのみを用いて学習する

と、そのデータに適応する為、データの到来順序によっては汎化性能を損なう事となる。我々のオンライン学習でデータ到来順序に偏りが起こると、既にオフライン学習でモデルを設計している為、モデルの精度を向上させたい目的に反してモデルの精度を低下させる要因となり得る。ガイドデータを設け、ガイドデータと未知データを用いてモデルの更新を行う事で、問題を回避する事を考えた。本稿では、公開されているデータベースを用いて実験を行い、提案手法の性能について調査する。

本稿の構成は、以下の通りである。2. 章では、ガイドデータを用いた MLP のオンライン学習法を紹介する。3. 章では、公開データベースを用いた実験について説明し、実験結果について考察する。4. 章は、本稿のまとめである。

## 2. ガイドデータを用いた MLP のオンライン学習法

我々のオンライン学習では、DBM アルゴリズムで得られた MLP モデルを、メモリレスかつ低計算コストで、性能が低下することなく安定的に精度を向上させる事が目的である。観測データを用いたモデル更新では、観測データに適応する為、観測データの到来順序によっては過学習を引き起こし、汎化性能が失われる為にモデルの精度が低下する可能性が高い。そのような学習を防ぎ、安定的にモデルを更新する為の方法として、ガイドデータを用いたオンライン学習法を提案する。

本手法では、DBM アルゴリズムで得られた SVM の判別境界を近似した学習データセットをガイドデータとし、ガイドデータに対する勾配と観測データに対する勾配の平均を更新量とする。観測データに対する勾配だけでなく、ガイドデータに対する勾配を合わせた平均値を更新量とする事で、観測データに対して適応しすぎる事なく、モデルが更新する事を目論んでいる。また、平均値を用いる為、モデルが急激に変化する可能性が低くなる。式 (1) に、本手法の更新式を示す。 $w^{(t)}$  は  $t$  時点における MLP の入力層と隠れ層、または隠れ層と出力層の間の重み、 $W$  は MLP の重み行列、 $\alpha$  は学習率、 $x_{observed}$  は観測データ、 $x_{guide,i}$  は  $i$  番目のガイドデータ、 $N_{guide}$  はガイドデータの個数、 $f(x, W)$  は  $x$  と  $W$  に対する目的関数である。観測データが得られる毎に、式 (1) によりモデルの更新を行う。

$$w^{(t+1)} = w^{(t)} - \alpha \frac{1}{N_{guide} + 1} \left( \sum_{i=1}^{N_{guide}} \frac{\partial f(x_{guide,i}, W^{(t)})}{\partial w} + \frac{\partial f(x_{observed}, W^{(t)})}{\partial w} \right) \quad (1)$$

モデル更新の計算コストを削減する為、k平均法 [3] を用いて近似学習データセットにクラスタリングを行い、各クラスタの中から無作為に抽出したデータをガイドデータとしている。全ての近似した学習データセットをガイドデータとして使用すると、1回のモデル更新に全てのデータに対しての勾配を計算する必要があり、使用するメモリ、及び計算コストが膨大化する。そこで、観測データ  $x_{observed}$  が属するクラスタ以外の  $k-1$  個のクラスタからそれぞれ1つずつデータを無作為抽出し、それをガイドデータとしてモデルの更新を行う。観測データ  $x_{observed}$  が属するクラスタからデータを抽出しない事で、あるクラスタに二重に適應する事を防いでいる。したがって、ガイドデータ数  $N_{guide}$  は  $k-1$  になり、観測データと合わせて  $k$  個のデータの購買平均値でモデルを更新する。即ち、 $k$  が増加すると、観測データの勾配が更新に与える影響力は反比例して減衰していく為、観測データに適應してモデルが急激に変化する可能性が低くなると言える。また、オンライン学習で得られたデータを、モデル更新後に対応するクラスタに追加し、ガイドデータを更新していく。

### 3. 実験

#### 3.1 実験設定

我々は、提案した手法により MLP の精度がどの様に変化するか確認する為、カリフォルニア大学アーバイン校の機械学習レポトリ [1] で公開されているデータベースを用いた性能評価実験を行った。本実験で使用したデータベースは、表 1 の通りである。

表 1: 各データベースの特徴

	クラス数 ( $N_c$ )	特徴数 ( $N_d$ )	データ数 ( $N_t$ )
Ozone Level Detection (Ozone)	2	72	2,536
QSAR Biodegradation (QSAR)	2	41	1,055
Seismic Bumps (Seismic)	2	18	2,584

提案手法を評価する為、以下に挙げる 3 つのメソッドを定義した。

- MLP: オフライン学習、オンライン学習共に誤差逆伝播 (BP: Backpropagation) アルゴリズムで学習した MLP
- DBM: DBM アルゴリズムでオフライン学習し、BP アルゴリズムでオンライン学習した MLP
- DBM-GD: DBM アルゴリズムでオフライン学習し、提案した手法を用いて BP アルゴリズムでオンライン学習した MLP

実験時の各パラメータについては、次の通りである。評価方法として、20 回の 5 分割交差検定を行い、その平均値で比較した。

また、全てのデータに対し、各特徴の範囲が  $[-1, 1]$  となるよう特徴毎に拡大縮小を行う正規化を行った。SVM は、ソフトマージン SVM を用い、逐次最小問題最適化法 [4] により学習を行い、カーネル関数は放射基底関数 ( $\kappa(x_1, x_2) = \exp(-\|x_1 - x_2\|^2)$ ) を使用した。学習の際に用いたパラメータは、 $C = 1$  とした。MLP については、隠れ層が 1 層の計 3 層からなるネットワークを使用した。BP アルゴリズムの学習については、学習率  $\eta$  が 0.5、入力ニューロン数は特徴数  $N_d$ 、隠れニューロン数は 10、出力ニューロン数は 1 とした。オフライン学習時は学習サイクル数を 1,000 回に設定し、オンライン学習時はデータが 1 つ得られる毎に 1 回学習を行った。DBM アルゴリズムにおいては、 $N = 10$ 、 $\epsilon = 0.1$ 、 $\delta_{DB} = 0.1$ 、 $\delta_{outlier} = 0.2$  に設定した。提案手法については、 $k = 2, 3, 5, 10$  とし、 $k$  による性能の変化を確認した。

#### 3.2 実験方法

提案手法の目的は、オフライン学習で得られた MLP モデルを、安定的に精度向上させる為のオンライン学習である。その為、交差検定の 1 回の試行の中で、オフライン学習とオンライン学習の為の 2 つのデータセットが必要である。学習データをオフライン学習様データ  $U_{off-line}$  とオンライン学習データ  $U_{on-line}$  に分割し、実験を行う。始めに、 $U_{off-line}$  を用いてオフライン学習し、その後  $U_{on-line}$  から 1 つずつデータを取り出しオンライン学習を行う。今回、 $U_{off-line}$  として 100 個、500 個のデータを割り当て、残りを  $U_{on-line}$  に割り当てる 2 種類の実験について結果を考察する。

#### 3.3 実験結果と考察

表 2: Ozone データベースにおける学習後の各精度

データサイズ	精度 (%)		オフライン 学習
	オンライン学習 100	オンライン学習 500	
MLP	95.9	96.3	96.1
DBM	<b>97.0</b>	<b>97.0</b>	96.7
DBM-GD(k=2)	96.9	96.9	
DBM-GD(k=3)	96.9	96.9	
DBM-GD(k=5)	96.9	96.9	
DBM-GD(k=10)	96.9	96.9	

表 3: QSAR データベースにおける学習後の各精度

データサイズ	精度 (%)		オフライン 学習
	オンライン学習 100	オンライン学習 500	
MLP	79.4	80.0	86.8
DBM	82.4	85.6	86.8
DBM-GD(k=2)	82.5	85.8	
DBM-GD(k=3)	82.5	85.8	
DBM-GD(k=5)	<b>82.6</b>	<b>85.9</b>	
DBM-GD(k=10)	<b>82.6</b>	85.8	

表 2-4 は、各メソッドのオンライン学習後の精度を、オフライン学習時の精度と合わせて示したものである。太字は、 $U_{off-line}$  のデータサイズ毎の最も良い精度を意味している。図 1-6 は、各データベースにおける、オンライン学習による各メソッドの精度変化の平均値を表したものである。

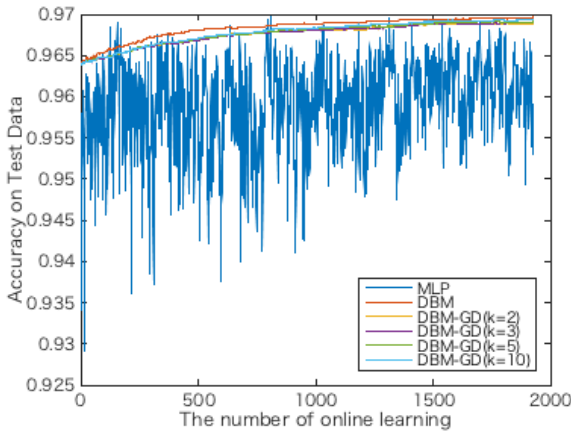


図 1: Ozone データベースにおける各オンライン学習後の精度推移 ( $U_{off-line}$  のデータサイズ: 100)




図 3: QSAR データベースにおける各オンライン学習後の精度推移 ( $U_{off-line}$  のデータサイズ: 100)




図 2: Ozone データベースにおける各オンライン学習後の精度推移 ( $U_{off-line}$  のデータサイズ: 500)




図 4: QSAR データベースにおける各オンライン学習後の精度推移 ( $U_{off-line}$  のデータサイズ: 500)

表 2 から Ozone データベースに結果について確認すると, MLP はオフライン学習時よりオンライン学習後の精度が下回る事があったが, DBM, DBM-GD の精度に関してはオフライン学習で得られた精度を僅かに上回る結果となった. オンライン学習によって, 精度向上が出来たと言える. また, 図 1-2 を確認すると, MLP の精度は増加向上の振動が激しく, 安定的に精度向上出来たと言いが, DBM, DBM-GD 共に振動がほとんどなく, 安定的に精度向上出来たと言える. DBM においてはオンライン学習初期に DBM-GD よりも僅かに精度が高くなったが, 回数を重ねていくと DBM の精度はその後増加せず, 最終的に DBM-GD と同等の精度となった. DBM-GD については,  $k$  による差は確認できなかった.

QSAR データベースにおいては, 表 3 の結果から DBM-GD が最も良い精度を示していた. しかしながら, オフライン学習時の精度に達してはなかった. 図 3-4 から, このデータベースにおいても MLP はオンライン学習による精度の振動が激しいと言える. 一方, DBM, DBM-GD においてはそのような振動はあまり見られなかった. DBM, DBM-GD の精度推移に注目すると, DBM は精度が低下する事があり, その結果とし

て DBM-GD の方が最終的に結果が高くなったと言える. その為, DBM-GD はより安定的にオンライン学習による精度向上が行えたと考えられる.  $k$  による DBM-GD の精度変化は, 表 3 から  $k = 5, 10$  あたりが最も精度が良かったが, 他と比べると僅かな差であり, 大きな変化は確認できなかった.

Seismic データベースでは, 表 4 から DBM, DBM-GD の方が MLP よりも精度が高く, また図 5-6 から MLP の精度は振動が激しく, DBM, DBM-GD は安定的に学習が行えたと言える. また, DBM, DBM-GD 共に  $U_{off-line}$  のデータサイズが 500 の時は, オフライン学習時と同等の精度が得られていた. しかし, 図 5-6 を確認すると, データサイズが 100 の時は徐々に精度が高くなっていったのに対し, データサイズが 500 の時は初期からあまり変わらなかったと言える. 即ち, オフライン学習で十分な精度を得るには, 500 個程度で十分であった可能性がある. また,  $k$  の違いによる DBM-GD の精度差はあまり確認できなかった.

今回の実験結果から, DBM-GD はオンライン学習により安定的に精度向上できる可能性が高い事を確認できた. しかしながら, オフライン学習時の精度に到達しない事があり, より精

表 4: Seismic データベースにおける学習後の各精度

データサイズ	精度 (%)		オフライン学習
	オンライン学習		
	100	500	
MLP	90.6	91.2	92.5
DBM	<b>92.3</b>	<b>93.0</b>	93.0
DBM-GD(k=2)	92.1	<b>93.0</b>	
DBM-GD(k=3)	92.2	<b>93.0</b>	
DBM-GD(k=5)	92.2	<b>93.0</b>	
DBM-GD(k=10)	<b>92.3</b>	<b>93.0</b>	

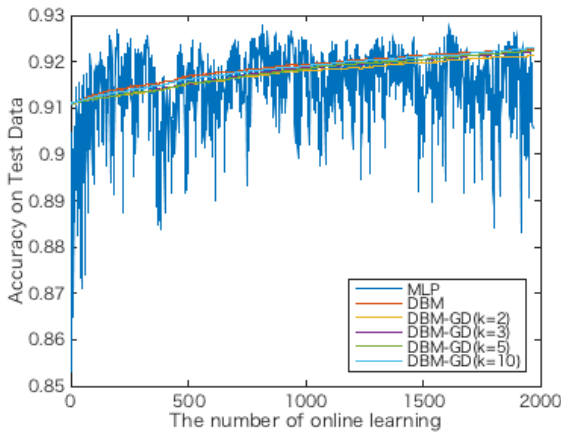


図 5: Seismic データベースにおける各オンライン学習後の精度推移 ( $U_{off-line}$  のデータサイズ: 100)

度向上できる方法を考えていく。改善可能な点としては、ガイドデータの生成方法、ガイドデータの追加条件の設定などが考えられる。これらの点について、より良い方法を模索していく。また、オンライン学習時のデータ到来順序について、偏りを設定していなかった。偏りがある場合、今回の結果とはまた異なる結果となり得る。その点を含め、実験方法についても考えていく。今回は、 $k$  の値による DBM-GD の精度にあまり変化が見られなかった。 $k$  の値の範囲を広げ、計算コスト、及びメモリコストの事も含めてどの程度の値を設定すべきかを検証していきたい。

#### 4. まとめ

本稿では、オフライン学習によって得られたモデルをより高精度にすべく、ガイドデータを用いたオンライン学習法を提案し、実験によりオンライン学習による精度変化を確認、検証した。提案手法では、ガイドデータは DBM アルゴリズム中で得られた新しい学習データを対象とし、 $k$  平均法で更新に用いるデータ数を削減する事で、計算コストの増加を回避した。実験結果から、提案手法によるオンライン学習では、急激に精度が増加、及び低下する事はなく、BP アルゴリズムによる MLP、及び DBM のオンライン学習に比べてより安定的に精度向上を行う事ができる可能性が高い事を確認できた。しかしながら、オフライン学習時の精度と比べて低い事があり、より高い精度となるよう学習を行える方法を模索していきたい。

その他の検証点としては、次の通りである。今回、実験に用




図 6: Seismic データベースにおける各オンライン学習後の精度推移 ( $U_{off-line}$  のデータサイズ: 500)

いたデータベース数は 3 つだけである為、他のデータベースについても検証を行う。また、オンライン学習時のデータ到来順序について、偏りのある場合等について検証する必要がある。どの偏りを定義するかも含めて実験方法を定めていきたい。更に、今回の実験では  $k$  の設定による変化がほとんど確認できなかった為、 $k$  の値の範囲を広げ、より効果的な  $k$  の設定方法について模索していく。

#### 謝辞

本研究は、JSPS 特別研究員奨励費 15J10477 の助成を受けたものである。

#### 参考文献

- [1] "K. Bache and M. Lichman". UCI machine learning repository, 2013.
- [2] Yuya Kaneda, Yan Pei, Qiangfu Zhao, and Yong Liu. Improving the performance of the decision boundary making algorithm via outlier detection. *Journal of Information Processing*, Vol. 23, No. 4, pp. 497–504, 2015.
- [3] J. MacQueen. Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*, pp. 281–297, Berkeley, Calif., 1967. University of California Press.
- [4] John Platt. Sequential minimal optimization: A fast algorithm for training support vector machines. Technical Report MSR-TR-98-14, Microsoft Research, April 1998.
- [5] David E. Rumelhart, Geoffrey E. Hinton, and Ronald J. Williams. Learning representations by back-propagating errors. *Nature*, Vol. 323, No. 6088, pp. 533–536, 10 1986.
- [6] Vladimir N. Vapnik. *Statistical learning theory*. Wiley, 1 edition, September 1998.