

機械学習によるベータトロン振動波形のリアルタイム解析

REAL-TIME ANALYSIS OF BETATRON OSCILLATION WAVEFORMS USING MACHINE LEARNING AT THE NewSUBARU STORAGE RING

藤井将[#], 渡部圭佑, 橋本智

Hitoshi Fujii[#], Keisuke Watanabe, Satoshi Hashimoto

Laboratory of Advanced Science and Technology for Industry, University of Hyogo

Abstract

At the NewSUBARU synchrotron radiation facility, the betatron oscillation waveform is constantly monitored in order to deal with the dependence of the betatron tune on the stored current and the gap value of insertion device, and fluctuations during acceleration and deceleration of the stored energy. By correcting the tune value in real time, the stability of the electron beam is improved. In order to correct the tune value in real time, it is necessary to quickly and accurately evaluate the tune value from the waveform containing noise. Previously developed correction systems have used complex algorithms that combine many thresholds and conditions. However, this program cannot handle various operation modes. Also, it is difficult to maintain and update since there are many conditional branches. Therefore, we have investigated the application of tuned waveform analysis methods using various machine learning techniques (e.g., local outlier factor method, logistic regression, deep learning, etc.). So far, we have developed a Python code that can analyze tune waveforms in real time with high accuracy, and confirmed that it works correctly in tests. In the future, we plan to implement it in the tune correction system and verify it in actual operation. In this paper, we will introduce the specific application results of each machine learning method.

1. はじめに

蓄積リングを周回する電子は閉軌道の周りを水平・垂直方向にわずかに振動しながら周回している(ベータトロン振動)。リング一周あたりの振動数であるチューンの値は様々な要因(蓄積電流値、挿入光源のギャップ値、蓄積電子エネルギーの加減速等)で変動し、適切な値から外れると電子ビーム寿命の低下やビーム電流の削れが発生する。そのため兵庫県立大ニュースバル電子蓄積リングでは、運転中にチューンの値を常に監視し、水平および垂直方向の最適値 $\nu_x/\nu_y = 6.29/2.23$ を保つようにリアルタイム補正を行い電子ビームの安定性を高めている。チューン値はベータトロン振動の周波数スペクトルに対してピーク抽出を行うことによって得ることが出来、その値を用いて四極電磁石に巻いた補助コイルの電流値を自動調整することでリアルタイム補正が行われる。この際、常に綺麗なスペクトルが得られる訳ではなく、何らかの理由によりスペクトルデータの質が悪化することがある。その場合、誤ったチューンの値が抽出される可能性がありチューン補正が失敗する。そのため、実際にチューン補正を行う前に、補正して良いスペクトルかどうか、つまり、スペクトルから得られるチューンの値が十分信頼できるかどうかを判断する必要がある。現行の補正システムではスペクトルのピークの高さや半値幅、およそその位置等、多数の閾値を設けた複雑なアルゴリズムによりその判断を行なっている。

しかし、このシステムでは、運転状況の変化や装置の更新等により得られるスペクトルデータが変化した場合、その都度、全ての閾値を人の手で再調整する必要が生じ、柔軟性に欠ける。そこで本研究ではディープニューラルネットワークを用いて、ベータトロン振動スペクトルの「信頼度」を判定し、良いスペクトルの場合にはそのスペクトルからチューンの「ピーク位置」を同時に予測するネットワークを構築する方法を提案する。

2. 教師データ

2.1 ベータトロン振動スペクトル

図1に今回の学習で用いたベータトロン振動のスペクトルの例を示す。スペクトルデータは後で学習しやすいように、周波数の範囲を固定して1,800点の一次元の配列データにしている。図1の縦軸はスペクトラムアナライザの信号強度であるが、横軸は周波数ではなく、配列データのインデックスとなっている。ピーク位置の学習はこのインデックスに対して行われる。インデックスからベータトロン振動の周波数、また、チューンへの変換は容易である。

2.2 自動アノテーション

ディープラーニングのネットワークを学習させるためには、大量の教師データが必要となる。教師データとは特徴量(記述子)と目的変数となる正解の値のセットのことである。目的変数は1つの場合が多いが、今回のように複数の場合もあり得る。今の場合、特徴量はスペクトルデータそのものであり、目的変数は「信頼度とピーク位置(水平方向成分と

[#]hfujii@lasti.u-hyogo.ac.jp

垂直方向成分) 」となる。スペクトルデータは簡単に集めることができるが、問題は目的変数で、集めたスペクトル全てに対し信頼度とピーク位置という正解ラベルを付与する作業 (アノテーション) が必要となる。これを手作業で行うのは骨が折れるので、スペクトルからピークの位置を自動的に判定するピーク抽出プログラム (GFit) を作成した[1]。これは自動アノテーションのためのものなので、高速に判定を行う必要はなく、人間の判断と同程度に高精度であれば良い。GFit はパラメータフリーのガウシアンフィッティングプログラムで、スペクトルデータを混合ガウスモデル、つまり、頻度分布と見做してクラスタリングを行うというアイデアに基づいている。この混合ガウスモデルに対して EM アルゴリズムや変分ベイズ法[2]などを使ってガウス分布の数 (ピークの数) と位置 (チューンのピーク位置) を推定する。スペクトルの信頼度 (これを t_0 とする) は、このガウシアンフィッティングの結果から判断する。つまり、ベータトロン振動の周波数ピークは水平方向成分と垂直方向成分 (これを t_1, t_2 とする) の 2 つとわかっているのので、フィッティングの結果、ピーク数が 2 つと判定されれば $t_0 = 1$ 、それ以外の数であれば $t_0 = 0$ とする。ここで、信頼度が 0 と判断されるような (フィッティングが失敗する) 質の悪いスペクトルデータに対してピーク位置を与えることは人間の目を持ってしても不可能なので、 $t_0 = 0$ の場合はダミーとして $t_1 = 0, t_2 = 0$ の値を与えるものとする。このように GFit を用いた自動アノテーションを行うことで 9,103 個の教師データを準備した。(信頼度 1 のデータ 6,112 個、信頼度 0 のデータ 2,991 個)




Figure 1: An example of betatron oscillation spectrum. The vertical axis is signal intensity and the horizontal axis is frequency index; frequency is represented by the index number of the array for simplification.

3. ディープニューラルネットワーク

3.1 信頼度付損失関数の定義

スペクトルの信頼度とピークの位置を同時に判定

するネットワークを学習するために、以下のような信頼度付損失関数を用いた。

$$L = -t_0 \ln y_0 - (1 - t_0) \ln(1 - y_0) + \alpha t_0 [(t_1 - y_1)^2 + (t_2 - y_2)^2] \quad (1)$$

ここで y_0 はディープラーニングによる信頼度の推定値、 y_1, y_2 はベータトロン振動の周波数ピークの水平方向成分と垂直方向成分の推定値である。第一、第二項はバイナリ交差エントロピー誤差であり、第三項は残差平方和の和である。 α は第一、第二項と第三項との大きさのバランスを取るためのハイパーパラメータで、本研究では $\alpha = 0.001$ を用いた。

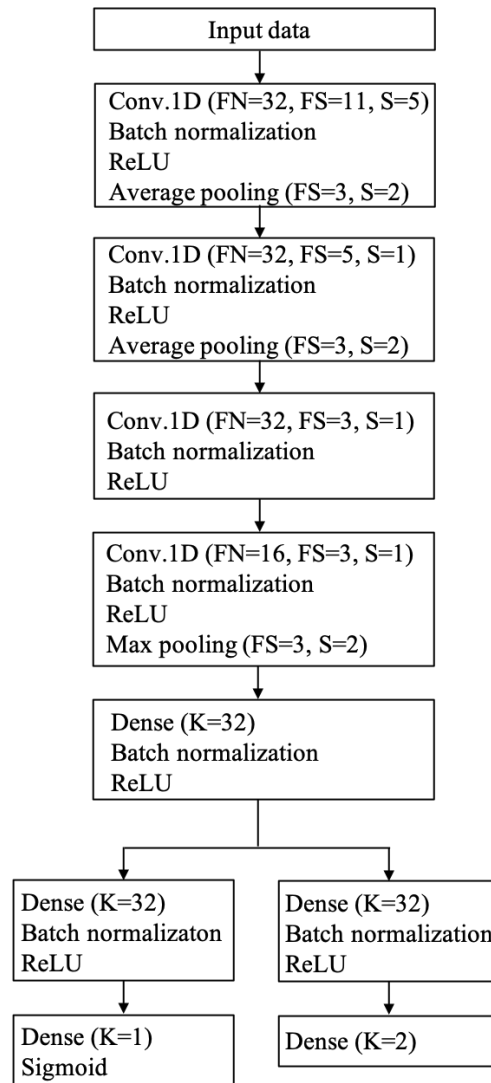


Figure 2: Illustration of the architecture of our network. FN, FS, and S mean the number of filters, filter size, and stride size, respectively. The left-hand side of the output layer gives an estimation value for certainty and the right-hand side gives estimation values for peak positions.

ここで第三項に信頼度の正解の値 t_0 が乗せられているのがポイントで、これがゲートとして働き、質の悪いスペクトルデータが来た場合にピーク位置に関する学習をスキップさせることができる。つまり、正解を与えることが不可能な質の悪いデータが教師データに含まれている場合でも、とりあえずダミーの数値を入れておいて、この信頼度付損失関数を使って、そのダミーを上手く回避して効率よく学習を進めることができるようになるのである。

3.2 一次元畳み込みネットワーク

図 2 にネットワークの詳細を示す。基本構造は画像認識のために提案された AlexNet [3]と同型であるが、二次元畳み込みではなく一次元の畳み込み層を用いている。また、各畳み込み層の直後にバッチ正規化を行い、1 ブロック目と 2 ブロック目の最後には Max pooling ではなく Average pooling を行なっている。出力層は信頼度に関するものとピーク位置に関するものの 2 つに分岐させている。つまり、信頼度の予測のためのネットワークをピーク位置の予測に流用させている。これにより、2 つの全く独立なネットワークを構築するよりも効率が良くなり、また、一般に、出力を分岐することにより過学習が抑制されるという効果も期待できる。

4. 学習結果

Keras [4]という python のパッケージを用いて信頼度付損失関数を実装し、一次元畳み込みネットワークを構築し学習を行なった。9,103 個の教師データを 4:1 に分割して、7,283 個を訓練データとして学習を行い、その結果を、残りの 1,820 個をテストデータとして用いて検証を行なった。テストデータの内、 $t_0 = 1$ (質の良い) データは 1,210 個、 $t_0 = 0$ (質の悪い) データは 610 個であった。ネットワークのウェイト (学習されるパラメータ) の総数は 33,843 個で、学習のために要したトータルの時間はデスクトップパソコン (iMac) で 6 分程度であった。 $t_0 = 1$ のデータに対するピーク位置の予測の結果として二乗平均平方根誤差 (RMSE) は y_1 , y_2 それぞれで 7.189, 2.482 程度となった。これは、与えられた範囲において、ピーク位置の予測誤差が約 1% 程度ということの意味し、かなりの精度でのピーク抽出が出来ていることがわかる ($t_0 = 0$ のスペクトルに対する RMSE には意味がない)。また、信頼度の予測の結果 (正答率) を表 1 にまとめた。

Table 1: Success Rate for Estimation of Certainty

	$t_0 = 1$	$t_0 = 0$
$y_0 > 0.5$	0.969	0.100
$y_0 \leq 0.5$	0.031	0.900

正答率とは例えば $t_0 = 1$ のスペクトルに対し $y_0 > 0.5$ という予測値であれば正解、 $y_0 \leq 0.5$ という予測値であれば失敗と、それぞれの数をデータ総数で割ったものである。当然、この閾値 0.5 を増減させ

ることで、正答率も変化する。この閾値がこのシステムの唯一のハイパーパラメータであり、現行のシステムに比べて遥かに少ない。表 1 において、左下の数値は質の良いスペクトルデータであるにもかかわらず質が悪いと誤判断された割合を示しており、これは運用上問題の少ない間違いである。しかし、表 1 右上の数値は、本当は質の悪いスペクトルであるにもかかわらず質が良いと誤判断した割合であり、これは運用上あってはならない間違いである。この誤判断が 10%もあるため、このネットワークをそのままの形で運用するのは危険であると思われるかもしれないが、これは GFit でのスペクトルの質 (信頼度) の判断を厳しくしているためであり、実際に誤判断されたスペクトルを見てみると、それほど悪いスペクトルでなく、そのスペクトルから予測されたピーク位置を使って補正をしても何の問題もないと考えられる。

5. まとめ

信頼度付損失関数を用いた比較的浅い一次元畳み込みニューラルネットワークにより、ベータatron 振動スペクトルからスペクトルの信頼度とピーク位置の予測を同時に高精度に行うことが可能であることを示した。信頼度判定の閾値は 0.5 としているが、実際に運用する際はこれをもっと大きく (例えば 0.9 くらいに) することで信頼度の正答率をさらに上げることが可能である。また、隠れ層を追加し、パラメータの最適化を行うことで、容易にネットワークの表現力を上げることが可能である。このようなことは現行の多数の閾値を設けた複雑なシステムでは不可能である。また、スペクトルデータの大きさを規格化してから学習・予測しているため、運転状況の変化や、装置の更新等により、得られるスペクトルデータが変化した場合でも、基本的にはこのネットワークをそのまま使えるはずであるし、もし仮に精度が落ちることがあっても、新しい教師データを用いて再度学習してやれば、簡単に対応することが出来るのも利点である。今後、このディープニューラルネットワークを実際のチューン補正システムに組み込み、検証を行う予定である。本研究で提案した信頼度付損失関数は、正解ラベルを付与できないような質の悪いデータが混在する場合の学習に汎用的に適用可能な手法であり、様々な分野への応用が期待される。

参考文献

- [1] <https://github.com/Hitoshi-FUJII/GFit>
- [2] C. M. Bishop, "Pattern Recognition and Machine Learning", Springer (2006).
- [3] A. Krizhevsky, I. Sutskever and G. E. Hinton, Communication of the ACM 60 (6): 84-90 (2017).
- [4] <https://github.com/fchollet/keras>