

電子蓄積リングにおける閉軌道補正への機械学習適用の試み —あいち SR での試験例—

PILOT APPLICATION OF MACHINE LEARNING TO COD CORRECTION FOR THE ELECTRON STORAGE RING AT AICHI SYNCHROTRON RADIATION CENTER

石田孝司^{A)}, 高嶋圭史^{A)}, 保坂将人^{A)}, 持箸晃^{A)}, 真野篤志^{A)}, 大前良磨^{B)}, 大熊春夫^{C)}
Takashi Ishida^{A)}, Yoshifumi Takashima^{A)}, Masahito Hosaka^{A)}, Akira Mochihashi^{A)}, Atsushi Mano^{A)},
Kazuma Omae^{B)}, Haruo Okuma^{C)}

^{A)} Nagoya University Synchrotron Radiation Center

^{B)} Graduate School of Engineering, Nagoya University

^{C)} Japan Synchrotron Radiation Research Institute

Abstract

We have started a project to introduce artificial intelligence into control system for accelerators at Aichi SR. To test its feasibility, we developed a rudimentary neural network which corrects COD (closed orbit distortion) of electron beam circulating in a storage ring using data measured by beam position monitors and steering magnets. After training with results of calculation based on SVD (singular value decomposition), our neural network successfully corrected COD. The accuracy of correction was consistent with what SVD has. We also discuss possible improvement and application examples.

1. 目的

あいちシンクロトロン光センター[1]は 50MeV の直線加速器、1.2GeV のブースターシンクロトロン、周長 72m の電子蓄積リングを備えている。これらの高度化のひとつとして我々は制御系へ機械学習の手法を取り入れる試みを始めた。加速器科学の分野において機械学習が適用できる可能性のある場面はいくつか考えられるが、現在までその報告例は非常に少なく、また、当施設ではまだその実績がない。そこでまずは機械学習の加速器制御への適用可能性を探りたい。なかでも、おおまかな挙動はシンプルではあるが、精密な制御を実現するためには取り組むべき課題の多い電子蓄積リング内を周回する電子ビームの軌道補正に対して、機械学習の手法の有効性を検証することを試みた。現在我々は BPM (beam position monitor) により電子ビームの軌道を測定し、特異値分解法によってステアリング電磁石に流すべき電流値を計算によって求め、基準軌道からのずれが小さくなるよう補正を行っている。我々の最初の目標は、軌道のずれと特異値分解法が与える解の組み合わせを複数用意し、それを初歩的な人工ニューラルネットワークに学ばせ、それが正しく学習を行い、実際に特異値分解法と同等の制御が可能かどうかを検証することである。

2. 人工ニューラルネットワーク

2.1 概要

今回の目的は 32 台ある BPM によって測定された、電子蓄積リング内を周回する電子ビームの水平方向の位置情報から 16 台あるステアリング電磁石に流すべき電流値の組み合わせを求めることである。そこで 32 入力、16 出力の人工ニューラルネットワーク[2]を構成する。人

工ニューラルネットワークは、ある同じ手順によって計算を行う構成要素が複数集まり、その入出力が互いに結合したものの集合である。以下の節でその詳細を述べる。

2.2 パーセプトロン

人工ニューラルネットワークを構成する最小単位はパーセプトロン、ニューロン、ノード、ユニットなどと呼ばれ、Figure 1 左の青い円によって模式的に示したように、多数の入力から1つの出力を出す演算を行う。




Figure 1: Schematic description of perceptron.

入力値は平等ではなく、それぞれに対して決まった重み乗じられ、まずその和が計算される。さらにそこから定数である閾値を引いたものがユニットへの総入力となる。すなわち、各入力値を z_i ($i=1 \sim I$)、それらに対応する重みを w_i ($i=1 \sim I$)、閾値を θ とすると総入力 u は

$$u = \sum_{i=1}^I w_i z_i - \theta \quad (1)$$

と表すことができる。ここで値が常に-1 であるような 0 番目の入力値 z_0 を導入し、閾値 θ を改めて w_0 とおけば、上式は

$$u = \sum_{i=0}^I w_i z_i \quad (2)$$

のように簡略化できる。さらに出力は総入力 u を変数とした関数の値となり、この関数は活性化関数と呼ばれる。活性化関数については次節で述べる。

2.3 順伝搬型ニューラルネットワーク

パーセプトロンを複数組み合わせることで Figure 2 のようなネットワークを構成することができ、これを順伝搬型ニューラルネットワークと呼ぶ。




Figure 2: Feed forward neural network.

縦に並んだ組を“層”と呼び、第 1 層・第 2 層・第 3 層、あるいは、入力層・中間層・出力層と呼ぶ。あいち SR 電子蓄積リングには BPM が 32 台、ステアリング電磁石が水平・垂直用にそれぞれ 16 台備え付けられている。今回は水平方向の COD 補正を行うため、BPM からの信号を第 1 層への入力とし、水平方向補正用ステアリング電磁石の電流値を第 3 層で出力するため、第 1 層は 32 の、第 3 層は 16 のユニットで構成し、中間層をなすユニットの数は 24 とした。さらに第 2 層の活性化関数 $f(u)$ は標準的に用いられている

$$f(u) = \frac{1}{1 + e^{-u}} \quad (3)$$

なるロジスティックシグモイド関数とし、第 3 層については恒等写像、すなわち

$$f(u) = u \quad (4)$$

とした。

2.4 最適化

人工ニューラルネットワークの学習には、擬似的に乱数を用いて生成した基準軌道からのずれと、そのずれを補正するためのステアリング電磁石の電流値を特異値分解法によって求め、それらの組を学習データとして用いた。設計した人工ニューラルネットワークの出力が適切か

どうかを定量的に判断するために、以下の誤差関数 E を定義する。

$$E = \frac{1}{2} \sum_{k'=1}^K (z_{k'}^{(3)} - y_{k'})^2 \quad (5)$$

ここで z は出力値を、 y は目標値を表す。 z に付く上付きの添え字は第 3 層からの出力であることを示し、 z と y に付く下付きの添え字は何番目のユニットからの出力に対応するものであるかを示す。 K は出力層のユニットの数である。上式で定義した誤差関数 E は二乗誤差の和の半分であり、この値が小さいほどより望ましい値に近くなる。これを最適化する方法として、確率的勾配降下法を用いた。すなわち、はじめに乱数で重み w を初期化しておき E を各重みで偏微分した量に正の定数 ε を乗じたものを w から引くことで重みを順次更新していく。現在の値を $w^{present}$ とすると、更新後の値 w^{new} は

$$w^{new} \leftarrow w^{present} - \varepsilon \frac{\partial E}{\partial w} \Big|_{w^{present}} \quad (6)$$

と表すことができる。今回は学習の元となる入出力のデータ対を 10000 個用意し、各データ対について上式の更新を 50 回行った。

Figure 3 に学習の様子を示す。横軸は学習に用いたデータの数、縦軸は誤差関数 E の値を示している。なお縦軸はログスケールになっている。




Figure 3: Transition of the error function against the number of data used for learning.

図から学習はデータ数がおおよそ 2000 のあたりでほぼ終わり、その後はわずかずつか学習が進行しないことが分かる。

3. 実験結果

実際に電子蓄積リングを周回する電子に対して水平方向の軌道を補正する実験を行った結果を Figure 4 に示す。

横軸はある COD に対する補正回数(ただしゼロは補正前の値)で縦軸はカイ二乗誤差、すなわち各 BPM で測定した mm 単位での基準軌道からのずれをそれぞれ 2 乗したものの合計である。青い三角形(ただしそれらの多くは、のちに説明する赤い丸が上に重なっている)は特異値分解法を用いた従来の方法によって補正した値




Figure 4: Chi-square against the number of corrections.

を示している。繰り返し補正することで電子の軌道が基準軌道に近づき、4 回程度の補正によってほぼ横ばいになることが分かる。赤い丸は学習済みの人工ニューラルネットワークに特異値分解法の場合と同じ補正前の軌道データを入力し、出力として得られたステアリング電磁石電流値によって補正した結果であり、特異値分解法を用いた場合と同様の傾向を示していることが分かる。このことから、今回作成した人工ニューラルネットワークが正しく特異値分解法を学習しており、従来と同等の精度で電子ビームの軌道を補正できることが分かった。

4. 展望

今回は計算によって求めた値を学習データとして用いたが、実際のデータを学習データとすれば、従来の解析的手法では取り込むことが難しいより現実的な特性を学習させることができるはずである。現在は、あるステアリング電磁石が軌道に与える影響は線形であり、また各ステアリング電磁石による効果は重ね合わせが成り立つと仮定しているが、そうではない効果を取り込むことが可能である。また理想的には電子ビームの水平方向と垂直方向の挙動は独立であるが、ステアリング電磁石を含むその他の電磁石や BPM のアラインメントの誤差によりそれらの独立性は厳密には成立していない。そこで水平方向・垂直方向の両方の BPM の値を入力すれば、これらの効果も比較的容易に取り込むことができると思われる。さらに電子蓄積リングが設置されている室内の複数個所での気温、電磁石の冷却水の温度データなど、異なる物理量も入力に加えれば、一層精度の高い制御が可能になることが期待される[3]。

人工ニューラルネットワークがこれまでに述べてきた軌道補正以外にも応用可能と考えられる例をひとつだけ挙げておく。Figure 5 は電子蓄積電リングに電子を蓄積していく時の蓄積電流の時間変化を示したもので、横軸は時刻、赤線は蓄積電流を示し、値は左の縦軸に対応する。

赤線から、はじめは蓄積電流値がゼロであったが 8 時 17 分頃に入射が始まり、およそ 20 分後には通常運転時の 300 [mA] に到達している。青線はその時間微分、すなわち入射効率に比例する値で、




Figure 5: Ring current and its derivative against time.

数値は右の縦軸に対応する。青線の推移から入射効率ははじめは低く、徐々に上昇することが分かる。これは電子蓄積リングや入射器などのパラメータを手動で微調整したことによるものである。今後、入射効率が良い時および悪い時のデータを蓄え、それを学習させることによって、自動的に最適なパラメータを導くことができないか検討している。また Figure 5 の青線が示す蓄積電流の増分が一旦は 0.3 [mA/s] 以上に達しているものの、その後、瞬間的に値が低下しているところが複数見られる。この直接の原因は不明であるが、入射効率を悪化させない、あるいは高める条件を、これも機械学習によって発見し、常に高い入射効率を維持することが可能な制御系を開発できないかを検討しており、さらなる高度化の実現を迫っているところである。

参考文献

- [1] <http://www.astf-kha.jp/synchrotron/>
- [2] T. Okatani, “深層学習”, 講談社, 2015.
- [3] T. Goto, “あいちシンクロtron光センターにおける電子ビーム起動変動の研究”, School of Engineering, Nagoya University, 2016.