

SACLA における機械学習による故障予知・異常検知アプリケーションの試作 PROTOTYPES OF FAILURE PREDICTION AND ANOMALY DETECTION APPLICATIONS USING MACHINE LEARNING IN SACLA

佐藤悠史^{#, A, B)}, 清水俊吾^{A)}, 上條慎二^{A)}, 岩井瑛人^{B, C)}, 前坂比呂和^{B)}
Yuji Sato^{#, A, B)}, Shungo Shimizu^{A)}, Shinji Kamijo^{A)}, Eito Iwai^{B, C)}, Hirokazu Maesaka^{B)}

^{A)} CHUO ELECTRONICS CO., LTD.

^{B)} RIKEN SPring-8 Center

^{C)} Japan Synchrotron Radiation Research Institute (JASRI)

Abstract

The X-ray free-electron laser facility, SACLA, has a large number and variety of sensors, which are effectively used to ensure the stable operation of the facility. However, due to the large number of sensors, some data are not fully utilized. In addition, there are many analog gauges that must be read visually. We investigated some machine learning techniques to make use of such sensor data and instruments and to improve maintainability and inspection efficiency. We selected the following three tasks: (1) estimation of the remaining life of thyratrons, (2) estimation of the downtime after a suspension of operation, and (3) numerical reading of analog flowmeters. For (1), we applied Bayesian learning to the number of abnormal self-discharges and developed a tool to alert an end-of-life thyatron. For (2), the downtime was estimated from many status bits by using a dimensionality reduction and the decision tree algorithm. For (3), analog flowmeters were recognized by a convolutional neural network and the value was read by a rule-based algorithm. This paper presents the prototype applications and evaluation results of these efforts.

1. はじめに

X線自由電子レーザー施設 SACLA では、多岐にわたる大量のセンサーが設置されており、施設を安定して稼働するために有効利用されている。大部分のセンサーはデジタル化されており、それらの読み値やステータス値は、施設運転中に常時監視しつつ、時系列データとしてデータベースに記録している[1]。また、一部で用いられているアナログ計器についても、運転員による日常的な目視点検が行われている。これらのセンサーデータは閾値超過やステータスビットの監視といった古典的な異常検知システムと組み合わせることにより、アナログ計器の読み取り値は運転員の判断により、運転時のトラブル等、様々な場面での解析に役立てられている。また、長年の運転実績からそれらに関する多くのノウハウがある。

しかしながら、それらは膨大な点数であるため、十分には活用しきれていないものも存在している。例えば、閾値超過時に異常を発報するようなデータであれば、時系列データを活かして予兆を捉え、未然にトラブルの防止を図る等の改善に向けての取り組みの余地がある。

こういったデータやアナログ計器について、故障予兆検知や高度な異常検知を新たに実現することで、メンテナンス性の向上や点検の効率化につながり、施設の更なる安定稼働に貢献できる。この実現にあたっては、長年のノウハウと蓄積しているデータを照らし合わせたり、目視点検等を画像認識により代替したりという手法が考えられる。これらの手法は機械学習によるアプローチとの相性が良く、また、加速器以外への汎用的な活用が見込めるという利点もある。

そこで、施設内のセンサーデータやアナログ計器類に

関して、メンテナンス性の向上や点検の効率化のために機械学習を用いた手法を役立てられないか、調査、および検討を行った。その結果、(1)サイクロトンの余命推定、(2)装置運転停止時のユーザー待機時間の推定、(3)アナログ流量計の数値読み取りの三つの対象を見つけるに至った。

具体的には、以下の三つをテーマに取り組んだ。

- サイクロトンの自爆回数等にベイズ学習を適用して余命推定(故障予兆検知)することによる計画的なメンテナンスの実現
- 運転停止時のアラーム発報状況を基にした決定木回帰等によるユーザーへの待機予定時間の自動連絡
- 畳み込みニューラルネットワークを用いて画像認識したアナログ流量計の数値読み取りによる常時監視、および、点検作業の自動化

本稿ではこれらの取り組みに関して、はじめにそれぞれの取り組み方針を概説し、その取り組み途上で試作したアプリケーション、およびその試作したアプリケーションの評価結果について現状を報告する。

2. 取り組み方針

2.1 サイクロトンの余命推定

サイクロトンは消耗品であるが高価な部品であるため、可能な限り長期間使用したいという要求がある。これまでも、寿命まで使い切りつつ故障や不調による運転中のトラブルを防ぐべく、様々な対策が取られてきている[2]。対策を講じる中で、故障の症状に関する知見が得られている。

このような背景があり、故障が近いサイクロトンの自爆回数やクライストロンへの出力電圧(Vk)等の傾向と、

[#] y-sato@cec.co.jp

SACLA に蓄積しているセンサーデータを基にした機械学習による余命推定について検討した。この問題には、ベイズ推定系アルゴリズムが適していると思われる。ベイズ推定により得られる確率分布から余命の期待値や信頼区間が求められるためである。

本取り組みはこのような余命推定モデルにより、計画的なメンテナンスの実現に貢献することが目的である。

2.2 装置運転停止時のユーザー待機時間の推定

加速器が何らかのトラブルにより運転停止した際に、復旧までの時間を自動連絡する仕組みがあれば、装置を利用している実験中のユーザーにとって有益である。ユーザーはその推定時間を基にスケジュールを検討できるため、ユーザビリティ向上につながると考えられる。

そこで、過去に発生した運転停止から復旧までにかかった時間と、停止していた期間のセンサーデータ記録を学習することにより、停止発生時のセンサーデータから停止時間を推定するモデルを構築することを検討した。SACLA では、閾値超過時のセンサー読み値やインターロック条件となるステータス値等はアラーム履歴として記録されている。実際に行われる復旧作業もアラーム発報状況から原因を特定していき、その後復旧までの見込み時間を推定するため、アラーム履歴と停止時間には相関があることが期待できる。

入力とするアラーム履歴は、前処理として埋め込み (embedding) 処理を行った後、回帰問題を解くアルゴリズムを適用する方針で検討を進めた (いずれも機械学習アルゴリズムを用いる)。埋め込み処理は、ステータスビットのような離散的なデータを連続的なデータにマッピングしつつ次元を削減し、機械学習を適用しやすい入力にする。

2.3 アナログ流量計の数値読取り

SACLA で目視点検が行われている重要なアナログ計器として流量計がある。また、加速器トンネル内のアナログ計器は運転中に目視点検することができない。この点検時の数値読取りを自動化できれば現場の作業を効率化したり、運転中のトンネル内の計器データを追加したりできる。

目視点検は画像認識により代替可能であると考えられるが、近年は機械学習を用いた手法で多くの実績があるため、本取り組みは機械学習による画像認識技術を活用することとした。最終的には、巡回ロボット等と組み合わせ、さらなる効率化についても想定している。

3. 試作アプリケーション

3.1 サイラトロン余命推定

サイラトロンの故障モードのひとつとして、寿命が近づくにつれて自爆の発生頻度が増加していき、最終的に寿命に至るものがあることが分かっている。この自爆発生頻度の増加傾向を検知することにより寿命が検知できると思われる。

そこで、サイラトロンの毎時自爆回数を観測データとし、事前分布をガンマ分布、尤度をポアソン分布とするベイズ推定モデルを適用した。モデルは次式で表される。

$$p(\lambda|x) \propto \text{Poisson}(x|\lambda)\text{Gamma}(\lambda|\alpha, \beta) \quad (1)$$

毎時自爆回数 x はポアソン分布に従うものとし、ベイズ更新するとサイラトロン毎に異なる平均発生回数 λ (ポアソン分布パラメータ) の事後分布 (ガンマ分布となる) が得られる。

さらに、このベイズ推定モデルでは、観測データは負の二項分布に従っており、また、その累積値も負の二項分布に従う。この確率分布から信頼区間が求められる[3]。

これらを基に、サイラトロンの寿命を検知するコンソールアプリケーションを試作した。はじめに、本アプリケーションは寿命の判定を行う前日 7 日分の自爆回数をデータベースから取得する。そこからベイズ更新によりユニットごとの毎時自爆回数の予測確率分布 (負の二項分布) を得る。判定を行うその日の累積毎時自爆回数が 95% 信頼区間を超過した場合、そのユニット名を出力する。

3.2 装置運転停止時のユーザー待機時間の推定

主成分分析 (PCA) およびオートエンコーダー (AE) を埋め込み処理アルゴリズムとし、決定木回帰モデルを組み合わせて運転停止時間を推定するモデルをそれぞれの組み合わせで構築した。学習データは、SACLA 電子銃のビーム射出トリガの ON/OFF から停止時間 (出力) を求め、その期間に発生していたアラーム履歴 (入力) をデータベースから計 570 件収集した (2021 年 5 月 6 日から 12 月 13 日)。すべての設備のデータを対象とすると取り扱う問題として複雑であるため、本件では対象とする設備はアラーム履歴に出現する頻度が高い C バンド加速器に関するものに限定した。

学習データは以下の条件とした。

- 整数型にパックされたビットフィールドデータは 1 要素あたり 1 ビットのベクトル表現にする。データにより最大ビット長が異なるため、最大ビット長 (24 ビット) に揃えた。また、ユニットごとに信号数が異なるため、最大信号数 (159 本) に揃えた。その後、対象ユニット (38 機) の信号データすべてを連結して 1 本のベクトルとした。これにより 145008 (24×159×38) 次元のデータとなった。また、ユニットによって存在しない信号は 0 で埋めた。
- 上記連結後のデータを主成分分析したところ、主成分数 20 で累積寄与率が 0.75 でほぼプラトーとなったため、次元削減後は 20 次元のデータとした。オートエンコーダーにおいても次元削減後は 20 次元とした。ニューラルネットワークの構造は、エンコーダー 4 層、デコーダー 4 層、活性化関数は ReLU とした。
- 停止時間は短時間の事象の頻度が大きいいため、対数変換することで事象の密度をある程度均一にするとともに、外れ値の影響を抑えることとした。
- 1000 秒を超える停止データは極小数であり、うまく学習ができない要因となるため、1000 秒以内のデータのみを学習データとした。

上記の学習データの内 2 割をテストデータとして決定木回帰モデルで学習した。主成分分析を用いた方は、学習データとテストデータそれぞれの決定係数は 0.983、0.957 となり、RMSE は 0.223 だった。オートエンコーダーの方は、決定係数はそれぞれ 0.983、0.968 となり、RMSE は 0.195 だった。わずかながらオートエンコーダーを使った方は性能が高いようである。

上記の停止時間推定モデルを組み込み、推定停止時間および要因となっている設備を Web ブラウザ上で表示するアプリケーションを試作した (Fig. 1)。SACLA 電子銃の出射トリガステータスを監視し、停止を検知したとき、その時にアラーム発報されているデータを取得する。そのデータから推定停止時間と原因ユニットを表示する。

停止時間推定 (PCA)							
稼働状態							
停止日時: 2021/06/17 14:41:43				稼働中の推定時間: 100P			
サブグループ状態							
xfel_rf_cb01_1	xfel_tf_cb01_2	xfel_rf_cb01_3	xfel_rf_cb01_4	xfel_rf_cb02_1	xfel_tf_cb02_2	xfel_rf_cb02_3	xfel_rf_cb02_4
xfel_rf_cb03_1	xfel_tf_cb03_2	xfel_rf_cb03_3	xfel_rf_cb03_4	xfel_rf_cb05_1	xfel_tf_cb05_2	xfel_rf_cb05_3	xfel_rf_cb05_4
xfel_rf_cb06_1	xfel_tf_cb06_2	xfel_rf_cb06_3	xfel_rf_cb06_4	xfel_rf_cb07_1	xfel_tf_cb07_2	xfel_rf_cb07_3	xfel_rf_cb07_4
xfel_rf_cb08_1	xfel_tf_cb08_2	xfel_rf_cb08_3	xfel_rf_cb08_4	xfel_rf_cb09_1	xfel_tf_cb09_2	xfel_rf_cb09_3	xfel_rf_cb09_4
xfel_rf_cb10_1	xfel_tf_cb10_2	xfel_rf_cb10_3	xfel_rf_cb10_4	xfel_rf_cb11_1	xfel_tf_cb11_2	xfel_rf_cb11_3	xfel_rf_cb11_4
xfel_rf_cb12_1	xfel_tf_cb12_2	xfel_rf_cb12_3	xfel_rf_cb12_4	xfel_rf_cb13_1	xfel_tf_cb13_2	xfel_rf_cb13_3	xfel_rf_cb13_4
xfel_rf_cb14_1	xfel_tf_cb14_2	xfel_rf_cb14_3	xfel_rf_cb14_4	xfel_rf_cb15_1	xfel_tf_cb15_2	xfel_rf_cb15_3	xfel_rf_cb15_4
xfel_rf_cb16_1	xfel_tf_cb16_2	xfel_rf_cb16_3	xfel_rf_cb16_4	xfel_rf_cb17_1	xfel_tf_cb17_2	xfel_rf_cb17_3	xfel_rf_cb17_4
xfel_rf_cb18_1	xfel_tf_cb18_2	xfel_rf_cb18_3	xfel_rf_cb18_4				

Figure 1: Application screen of user standby time estimation.

3.3 アナログ流量計の数値読み取り

アナログ流量計を物体検出するモデルの作成には YOLOv3[4]を用いた。SACLA 棟内で撮影した約 3400 枚分のアナログ流量計画像を用意し、それらにアノテーションして学習データを作成した。本モデルからアナログ流量計を切り出した画像が得られる。

アナログ流量計の浮き位置は物体検出により切り出した画像の輝度値を横方向に積分して求めた。浮きは黒色のため、輝度の積分値が最小となる点を浮き位置とした。アナログ流量計の窓部分の上端を 100 分率の 100、下端を 0 とし、浮き位置を数値化した。

これらの要素技術を組み合わせたアプリケーションを搭載したカメラ機器を作成した。エッジ PC として NVIDIA 製 Jetson AGX Xavier、Web カメラはロジクール製 C920n を使用した。Figure 2 にアプリケーション画面を示す。画面には、カメラ映像からアナログ流量計を物体検知した位置 (四角枠) と 100 分率の浮き位置読み取り結果を表示している。

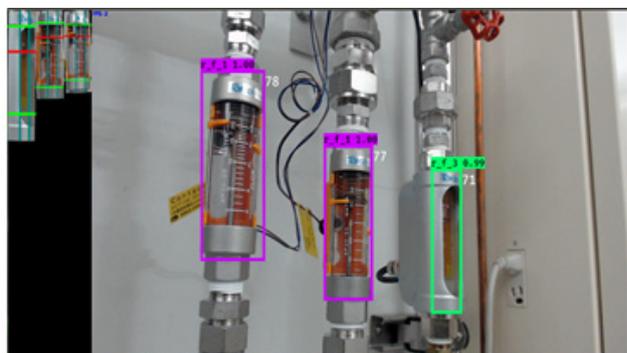


Figure 2: Application screen of analog flowmeter reading numerical values.

4. 評価結果

4.1 サイラトロンの余命推定

2022 年 4 月から 8 月までの SACLA 運転期間 (2022 年 4 月 11 日から 27 日まで、および、5 月 9 日から 8 月 1 日まで)、試作したアプリケーションを連日動作させて検知にかかったユニットを記録し (Table 1 に記録の抜粋を示す)、寿命となったサイラトロンを運轉作業記録から確認した。全 74 ユニット、途中の交換を含めてサイラトロンの総数は 86 本が対象となった。

期間中に検知した 123 件の内、寿命を迎える前に検知できたのはのべ 10 件で、ユニットとしては 3 ユニットであった (別日での検知を含むため、件数には重複がある)。寿命前に検知できた 3 ユニットについて、交換時の状況は以下であった。

- CB11-4: クライストロン電圧不出力、および、サイラトロングリッドからの反射が大きいため 5/16 に交換
- CB17-3: クライストロン電圧不出力、および、自爆多発により 7/11 に交換
- CB18-1: リザーバ過電流により 7/24 に交換

Figure 3 に検知後に寿命を迎えたユニットの累積自爆回数、および、95% 区間のグラフを示す。自爆回数の増加傾向は検知できており、上記 3 ユニット以外にも同様に増加傾向を検知することはできていた。しかしながら、直近 2 週間以内では寿命を迎えない検知が 123 件中 113 件と大半を占める結果となった。

Table 1: Excerpts of Abnormal Thyratrons Detected by Failure Prediction

Date	Units over 95% interval
2022/4/18	CB11-2
2022/4/27	CB03-2, CB11-4
2022/7/4	CB03-1, CB17-3
2022/7/12	CB03-1, CB17-3, CB18-1
2022/7/31	CB16-2

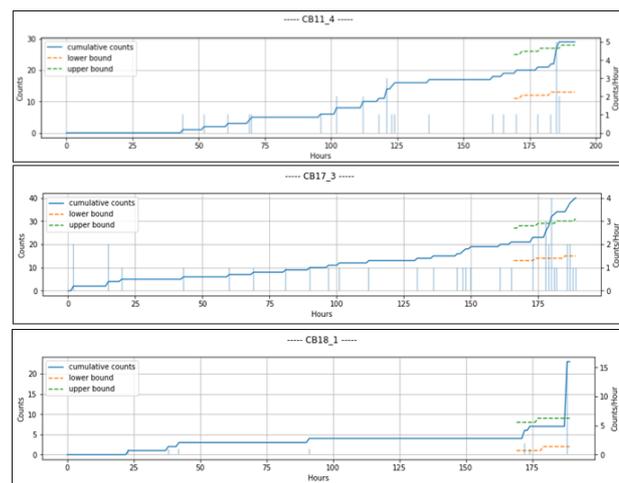


Figure 3: Cumulative counts of abnormal self-discharges and 95% interval.

4.2 装置運転停止時のユーザー待機時間の推定

2022年4月20日から試作アプリケーションの動作を開始し、運転停止時間実測値と予測値との比較を行った。運転停止を検知する毎に、発生時刻、停止時間推定値、および停止時間実測値をCSVログに記録した。推定値と実測値の散布図をFig. 4に示す。正確な誤差の検証は現在確認している状況だが、実測値300秒以上で予測値との乖離が大きくなってしまっていることを確認した。

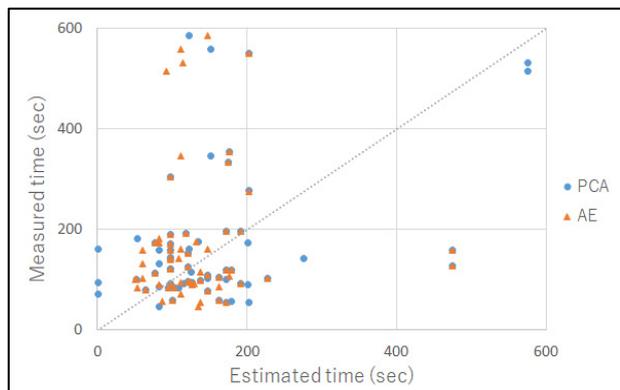


Figure 4: Scatter plots of estimated time (second) and measured time (second).

4.3 アナログ流量計の数値読取り

2022年4月21日より試作アプリケーションを搭載したカメラ機器一式をSACLAクライストロンギャラリー内に設置し、数値読取り精度の検証を実施した。机にエッジPC、光源、およびWebカメラを固定し、流量計3台を撮影して読取り結果をログに記録した(Fig. 5)。

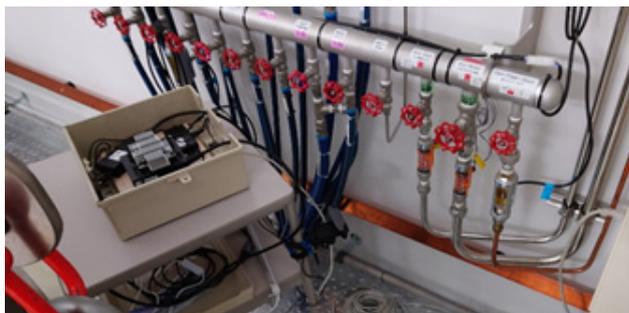


Figure 5: Camera equipment installed near the flow meters in the SACLA klystron gallery.

Figure. 6に最終的な読取り結果を示す。読み値は100分率の値である。当初は左端の1台のみで実験を開始し、アプリケーションの改修(読取り台数の追加、読取り結果の安定化等)をさみつつ、最終的には読取りのぶれ幅は100分率で±3となった。読取り値と記録画像の目視値との差を確認したところ、目視で変動が無かった2台(左端、真ん中)は1時間ごとの平均値と残差のRMSがそれぞれ0.94、0.83であった。また、目視で74~80%の範囲で変動があった1台(右端)については、約2%の範囲内で変化に追従できていた。

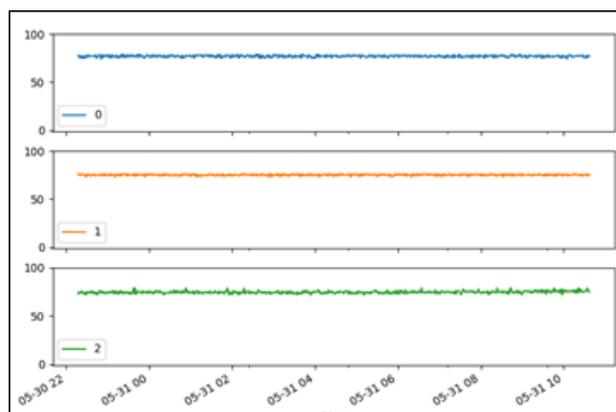


Figure 6: Trend graphs of flow meter readings.

5. まとめと今後

SACLA施設内のセンサーデータやアナログ計器類に関して、メンテナンス性の向上や点検の効率化を目的に、機械学習を用いた故障予知・異常検知アプリケーションを3種試作した。

サイクロトンの自爆回数にベイズ学習を適用した余命推定については、故障の前兆動作である自爆回数の増加傾向を捉えることができた。ただ、検知後2週間以内に故障に至ったサイクロトンは少なく、正確な余命推定の達成にはさらなる改善が必要である。これには、過去に寿命となったサイクロトンの自爆回数データも含めて傾向を分析し、適切な閾値を求めて精度を向上させることを考えている。

運転停止時のアラーム発報状況を基にした決定木回帰による停止時間推定は、主成分分析およびオートエンコーダーによる次元削減を用いることで多次元データの効率的な学習を行い、停止時間を推定するモデルを構築できた。しかし、長時間の推定には課題が残る結果となった。今後は現状の精度改善に加え、重篤な長時間停止(1~2時間や半日にわたるもの)の予測への対応を目指す。継続して停止発生時のアラーム発報状況は収集しているので、学習データ追加による精度改善を見込んでいる。加えて、疑似的な学習データの作成が考えられる。運転停止はそもそもの発生件数が少ないが、さらに希少である重篤な長時間停止への対策ともなると考えている。

畳み込みニューラルネットワーク(YOLOv3による物体検知)を用いて画像認識したアナログ流量計の数値読取りでは、固定カメラであれば今回得られた読取り精度(2%)で異常検知に用いることは可能と判断している。ただ、最終形は巡回ロボットと組み合わせた利用も想定しているので、その場合はカメラと流量計お互いの位置関係の考慮やARマーカの利用等の検討が必要となる。

現状の試作したアプリケーションは取り組み途上であり、実用化に向けて各取り組みは継続する予定である。具体的な要件定義をする中で実用上の要求も定まってくるので、その達成に向けては、上記に挙げた課題解決に加え、他の機械学習モデル(例えば、学習に使うセンサーデータの変更、次元削減アルゴリズムの変更等)について比較検討を考えている。

謝辞

本件では、SACLA 関係者の皆様より大変多くのご助力をいただきました。皆様に心より感謝申し上げます。

参考文献

- [1] K. Okada *et al.*, “SPRing-8/SACLA 加速器ログデータベース利用環境の構築”, Proceedings of the 18th Annual Meeting of Particle Accelerator Society of Japan, August 9 - 12, 2021, QST-Takasaki Online, Japan, pp. 524-527.
- [2] S. Nakazawa *et al.*, “SACLA でのサイラントラブルと対策”, Proceedings of the 14th Annual Meeting of Particle Accelerator Society of Japan, August 1-3, 2017, Sapporo, Japan, pp. 1000-1004.
- [3] 須山敦志(2017), 『ベイズ推論による機械学習入門』, 講談社, pp. 85-87.
- [4] <https://pjreddie.com/darknet/yolo/>