

# J-PARC 加速器システムにおけるインバリエント分析技術の適用

## APPLYING OF SYSTEM INVARIANT ANALYSIS TECHNOLOGY (SIAT) TO J-PARC ACCELERATOR SYSTEM

相馬知也<sup>#, A)</sup>, 石井恒次<sup>B)</sup>, 福田靖行<sup>A)</sup>, 志賀正徳<sup>A)</sup>

Tomoya Soma<sup>#, A)</sup>, Koji Ishii<sup>B)</sup>, Yasuyuki Fukuta<sup>A)</sup>, Masanori Shiga<sup>A)</sup>

<sup>A)</sup> NEC Corporation, <sup>B)</sup> J-PARC/High Energy Accelerator Research Organization

### Abstract

It is considered that analyzing the correlation between data collected by the accelerator system in detail makes it possible not only to improve the performance of the accelerator but also to enable abnormality detection and failure signs. We will examine possibilities by applying predictive diagnosis technology of AI (artificial intelligence) and Big Data analysis to accelerator system, which have developed recently. In this research, we analyzed the data collected by the J-PARC accelerator using System Invariant Analysis Technology (SIAT) which is the AI engine developed by NEC. In this paper we report this progress course with discussion. We will also refer to the experimentally collected vibration data.

## 1. はじめに

ICT (Information and Communication Technology) の進歩により、近年、益々大容量のデータが蓄積されている。それに伴い、AI (人工知能) やビッグデータ解析と呼ばれる新しい分析技術が出現し、大容量データを容易に扱い、これまでの統計的手法では露わに出来なかった関係性や関連性を見つけ、実社会に活用されるようになってきた。加速器などの大型設備においても、これまで以上に、多種多様な時系列データを取得し、蓄積している。一方で、加速器設備の運転データは、その特性から短時間のサンプリングレートで取得されることが多い。このためデータ量は膨大になり、蓄積されたデータの分析を統計的な手法で行うには非常に時間がかかってしまう結果となっていた。明らかなことだが、AI (人工知能) やビッグデータ解析など、新たに発達してきた分析技術を、加速器設備で得られたデータに適用してみることは非常に興味深い。過去データを分析し、未知の関係性や関連性を見つけてビーム運転等に活用するだけでなく、過去データとリアルタイムデータを比較し、健全性を認識したり、故障を予知したりすることは、加速器を運用する上でとても重要であると考えられる。

J-PARC では、NEC が開発したデータ分析技術であるインバリエント分析技術 (System Invariant Analysis Technology : SIAT) [1] を活用した、加速器等の故障予兆検知と効率的な設備保全への適用について取り組んでいる。適用に当たっては、J-PARC MR (Main Ring) およびユーティリティの運転データに対して分析を実施した。詳細は後述するが、強い関係を持つものが多数抽出され、全体として同じ動きをするモデルが得られている。しかしながら、未知の関係性を見つけて出したり、故障予知を実現したりするまでには至っていない。一方、新しい取り組みとして、振動センサーやマイクを利用した異常予兆検知も実施した。こちらについては、実際に電源設備の故障が発生し、その状況を捉えることに成功した。本論文ではこれらの分析・試験結果について報告する。

## 2. インバリエント分析の概要

インバリエント分析技術は、システムの性能情報やプラントのセンサ情報として得られる数値の時系列から、それらの関係性を網羅的にかつ高速に抽出する機械学習技術である。学習したセンサ情報間の関係性を対象システムの稼働モデルとし、その関係性が変化した時刻と場所をリアルタイムに監視することで、異常兆候を早期に発見することができる (Fig. 1)。

大規模設備の運転監視に適用した場合、従来の閾値監視やベースライン監視では見つけづらかったサイレント障害 (監視制御システムで確認できない、閾値以下で発生している異常など) を検知できるため、障害影響が顕在化する前の早期対処により、計画外停止による損失を防止し、運用コストを低減することが可能となる。[2]



Figure 1: Invariant analysis technology overview.

インバリエント分析技術は、基本的に数値の時系列であれば分析の対象とできるため、例えばポンプやモーターなどの振動計測データや、設備の性能データなどの情報をまとめて分析 (クロスドメイン分析) し、管理体制に応じた障害の一次切り分けを迅速に行うことができる。更に、設備建屋内の温度や、外気温、冷却水温などのさまざまな状態や、設備運転データとの関係性を発見することで、より広範囲な知見の見える化やシミュレーションへの応用も可能となる。

# t-soma@vx.jp.nec.com

### 3. 運転データ分析

J-PARC MR 加速器は稼働 10 年以上を経過し、システムのセンサ数は、モニター等のビーム診断系も含め、MR だけでも 1 万点を超える。データ自体は、大型加速器で頻繁に用いられる制御システム EPICS (Experimental Physics and Industrial Control System) に則したレコードの形で収集／蓄積されている。

サンプルデータによる分析結果は報告[3]で示した通り、センサ間のインバリエントには強い相関関係を持つものが非常に多かった。これは過去に経験した他の設備と比べても強い関係性が多い。このままの分析では、注目するインバリエント数が膨大で、故障予知するにも、未知の関係性を抽出するにも、埋もれてしまって露わには出来ない。

今回は前処理としてグループを作り、グループ内で適当な関係性の強さを持つものを抽出、抽出したセンサをグループ横断させて分析を実施した。Figure 2 にグループ横断のインバリエントモデル例を示す。図は最大 1.0 として算出される関係性の強さ Fs (Fitness Score) が 0.6 以上 1.0 未満のときのものである。黒い点がセンサを表し、センサ間の線の太さが Fs の大きさを示している。左上の赤で囲った部分がグループを表し、図の場合は入射機器のセンサ群である。赤枠以外のセンサはグループを横断して Fs が高いものを残している。グループ横断で残っているセンサは温度や電力などが多い。残念ながら興味深い、未知の関係性は今の所見つかっていない。また残っているセンサ間のインバリエントは、依然強い相関関係を持つものが多かった。まだ前処理が適切になっていない可能性が強く、今後グループの細分化や Fs 値の最適化を検討している。




Figure 2: Invariant model.

強い相関関係が多く存在することから、その相関関係自体が何を意味しているのかを検討してみた。Figure 3 に入射機器センサ、Figure 4 にインフラ電気機器センサの時系列データ(インバリエント分析への入力データ)1 日分を示す。9 時～19 時の間はメンテナンスのため機器オフとなっており、分析からは外してある。Figure 3 の入射機器センサは、運転オン・オフに完全同期している。

一方、Figure 4 にインフラ電気機器センサも加速器運転のオン・オフに同期しているが、それ以外の運転中の動きも見て取れる。分析したいのは、あるセンサの運転中の動きが、他のセンサの運転中の動きとどれぐらい関係があるかである。横断グループで高い相関関係を持つセンサを眺めると、電力パワー等を含めた温度を起源にしたものが数多く見受けられる。これは、運転のオン・オフのようなゼロ・イチデータを除くと、加速器施設が熱に支配されている様子を抽出しており、いわば正しく関連性を抽出していると考えられる。




Figure 3: MR Injection Sensors (Input data).

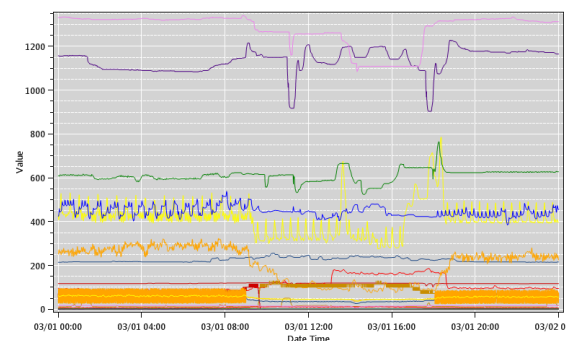


Figure 4: Electric Utility Sensors (Input data).

しかしながら、未知なる関係を探し出すには、この熱起源の動きはノイズにしかならない。さらに温度が上がれば、冷やそうとインフラ関連の装置が稼働し、結果として複雑な温度の動きをすることになる。タイムラグも伴って、Fs としては 1.0 未満だが十分に関係性強いインバリエントを持つモデルが形成されているのではないかと推察している。

あまりにも多くの、温度に関連するインバリエントが抽出されているため、発見したい関係性が埋もれて見えなくなってしまう。もう 1 段深いところの関係性をあぶり出すため、データ処理方法に更なる工夫が必要と感じている。

### 4. 振動センサ/音での異常検知

前章の運転データ分析で述べた通り、加速器の既得データとしては熱起源のものが多く、インバリエント分析ではその関係性が多く抽出される結果となっている。発



生じた熱は、冷却水や空調などによって冷やされ、その能力の限界がくるまで、一定温度を保とうとフィードバックしながら稼働・停止を繰り返す。機器故障の予兆検知という観点からは、観測された温度はインフラのフィードバックが入っているため、はっきりとした情報にはなっていない。そこで今回、大型施設で導入実績のある振動(音)センサを試験的にJ-PARC MR 加速器に導入し、異常予兆検知の検証を行った。

加速器施設に於いては、電源設備の維持・管理が最も重要な役割の一つとなっている。J-PARC MR 加速器の D3 電源棟に振動センサと集音マイクを設置して、データ収集を行った。なお、一般的にインバータやトランスなどの異常は音として現れることが多く、保全の現場でも音を頼りに異常を検知することが多い。このため、音とその発生源である振動に着目する。



Figure 5: Installation of vibration sensor.




Figure 6: Installation of Microphone.

電源設備は非常に高電圧かつ高電流を扱う機器であるため、機器本体にセンサを取り付けることは非常に困難である。また高電流が短い間隔で脈打つように流れる(パターン運転)のため、機器からはうなりのような音が発生する。この特性に着目し、機器の収納されている盤に振動センサを取り付け、音の発生源である振動を捉えるようにした。一方で J-PARC 電源棟のような大規模設備では、振動センサだと膨大な数が必要で、計測システム

も大掛かりなものになってしまう。このため広範囲の振動を少ない数のセンサで収集できる方法として「音」によるセンシングの検討も行った。計測の様子を Figure 5 及び Figure 6 に示す。振動の計測は盤の外側に広帯域振動センサを張り付けて行った。また音は IC レコーダーを用いて計測を行った。

#### 4.1 振動/音の計測とモデル作成

収集されたデータをもとにインバリエントモデルを作成した。モデル作成に当たっては振動/音それぞれの 1 つのセンサのデータを FFT により周波数分解し各周波数帯間のインバリエントを生成することとした。通常 FFT による振動解析は、特定の異常には特定の周波数帯が正常時と違う動作をすることに着目して行いが、過去の知見がない状態での異常検知にこの方法は使えない。FFT による周波数帯域間の関係性は、いつもの状態では関係性を保つことが過去の我々の経験からわかっている。この特性を生かして MR のような脈動する動きの振動や音をモデル化した。




Figure 7: FFT result of RF power supply sound.



Figure 8: Invariant model.

加速空洞用の RF 陽極電源での音 FFT 変換結果を Figure 7 に示す。周波数幅は 10Hz で分解を行った。このデータをもとに、インバリエントモデルを作成した。作成されたモデル図を Figure 8 に示す。モデル図を見ると各周波数帯間の関係性は比較的強い関係が構築されており、音によるモデル作成は今回検証で行ったモデルパラメータを利用することで異常検知用モデルとして有効に使えることを確認した。

## 4.2 音による異常検知

2018年5月中旬頃よりRF陽極電源の調子が悪かったため、異常検知のテストケースとしてレコーダーによる音の常時収集を行った。レコーダー設置3日後の5月28日に陽極電源にて異常が発生し、その様子をレコーダーで記録することができた。この事象をもとに異常発生を事前にとらえることが可能であるか検証を行う。障害発生は5月28日の17:39頃で破裂音が記録されていた。データ取り始めの周辺雑音が少ない時間帯を利用してモデルを作成し、障害発生の前及び復旧(故障電源のみ稼働停止)後の時間帯にて異常検知検証を行い、異常度(As: Anomaly Score)の推移を確認した。




Figure 9: Time table in abnormality detection verification.

Figure 9 に取得データのタイムテーブルを示す。異常が発生していないと思われる、十分時間が離れた5月26日 16:45~17:45 をモデル期間に選定し、インバリエントモデルを作成した。このモデルを利用し、27日から破裂音がした28日 17:39 付近までを異常検知期間と設定して確認を行った。通常状態時のAsは、時間帯によって環境音が異なるため幅が見られるが、高くとも10程度で安定しており、通常時として問題のない動きである(Figure 10, 11)。




Figure 10: Anomaly score under normal condition.




Figure 11: Anomaly score under normal condition.

次に異常発生期間の直前から復旧までの時間帯の検証を実施した。障害の直前(Figure 12)ではこれまでに見られた低いレベルでのAsの変化と異なり、10~30程度の全体的に高いレベルでAsが推移している。また、17:32頃からはAs=30周辺を中心とするさらに高いレベルに変化している。



Figure 12: Anomaly Score just before failure.




Figure 13: Anomaly score at failure occurrence.




Figure 14: Anomaly score after disaster recovery.

その状態が続き、17:39に破裂音とともに障害が発生(Figure 13)、Asは大きな振れとなっている。障害が復旧したのち(Figure 14)はAsが通常時の状態と同じような動きに戻っている。これにより、作成されたインバリエントモデルの精度についても異常検知に問題のないレベルであることが確認できた。

なお運転記録によると、2018年5月28日10:10頃から17:10頃まではビーム調整を行っており、連続ビーム運転は行っていない。ビーム調整時は、1時間に数発程度のビームを出しており、全機器は常に稼働状態である。しかしながら、RF陽極電源はビームを加速する空洞にパワーを入れる電源であり、ビームの状況に直結している。すなわちビーム有無で電源の振動音が変わることが知られている。したがって、Figure 12以降に見られるAs値で10~20程度のものはビーム有無を表している可能性がある。これはFigure 14の障害復旧後のAs値が10程度以下に下がった時間と、連続ビーム運転が開始した時間との一致により推定される。

一方、As 値 30 を超える振れは、電源の振動音変化を捉えている可能性がある。As 値の変化だけでなく、どのような周波数帯のペアにおけるインバリアントの破壊が起きているのか、深く分析してみたいと考えている。また知見を蓄積することも重要と考えている。今回の故障はインバータの破裂であったことがわかっている。様々な異常原因とそれに対する異常音が結び付けることができたから、正常復旧への時間短縮だけでなく、原因究明や故障対策にも貢献できるものと期待している。

## 5. まとめと今後

本稿では、既得済み運転データの分析と、新たに収集した振動音データの分析を行い、その結果を報告した。運転データの分析は未だ道半ばで、未知の関係性抽出や故障予兆の検知可能性について、有効な道筋は今のところ得られていない。知見としては、我々が持っている加速器施設のデータは、熱起源のデータが主であることを再認識した。今後の課題として、一歩深く分析を進め、有意義な関係性を抽出するために、さらに分析方法・手段を模索する必要があると考えている。

振動音データの収集については、首尾よく故障時のデータを取得することができた。分析の結果、予兆を捉えているかどうかは、最初のイベントということもあり、明らかではない。周波数帯の情報とハードウェアの情報を突き合わせたりして、精度を上げる必要がある。同時に、データの蓄積を行い、故障イベントを数多く蓄積する必要がある。今後、継続的な振動音のデータ取得はぜひとも実現したい。一方で、どのような形でデータを蓄積するかには課題も残っている。運転データとして蓄積するには EPICS に則したレコードとするのが適当と考えるが、全ての音声 RAW データを残すのはデータ量的に現実的でないだろう。分析後の As 値のみを蓄積するので良いかは議論がある。下手をすれば、故障情報を取りこぼしてしまう可能性がある。このあたりを意識しながら、今後知見を蓄積し、加速器の安定運転に貢献したいと考えている。

## 参考文献

- [1] T.Soma *et al.*, “Big Data Analytics in the Cloud - System Invariant Analysis Technology Pierces the Anomaly –”, NEC Technical Journal Vol.9 No.2 2014;  
<http://www.nec.com/en/global/techrep/journal/g14/n02/pdf/140218.pdf>  
<http://jpn.nec.com/techrep/journal/g14/n02/pdf/140219.pdf>
- [2] 相馬知也, “運転中のリアルタイム検査を実現するビッグデータ解析技術の活用”, 機関誌「非破壊検査」2016 年 10 月.
- [3] 相馬知也、石井恒次、吉岡正和、高城真弓“インバリアント分析技術を活用した加速器システム等の異常に対する予兆検知・診断”, 第 14 回日本加速器学会年会, 2017, 8.