

J-PARC MLF ミュオン生成標的の回転振動成分解析

ANALYSIS OF ROTATIONAL AND VIBRATIONAL COMPONENTS OF MUON PRODUCTION TARGET AT J-PARC MLF

砂川光^{#, A, B)}, 的場史郎^{A, B)}, 河村成肇^{A, B)}

Hikaru Sunagawa^{#, A)}, Shiro Matoba^{A, B)}, Naritoshi Kawamura^{A, B)}

^{A)} Institute of Material Structure Science, High Energy Accelerator Research Organization

^{B)} Materials and Life Science Division, J-PARC

Abstract

The muon production target at the J-PARC MLF is rotating target to disperse radiation damage and heat load due to proton beam injection. The target is installed in a vacuum beam duct, and the target is driven by a rotary drive transmission system using a drive-line component. Data on the rotational torque and speed of the target are monitored, and the interlock is introduced to stop the rotation and beam in case of an anomaly. However, even if an anomaly is detected, it is difficult to replace or repair the target immediately in a high-radiation environment. Therefore, early detection and identification of the location of the abnormality are more important. We have confirmed that the vibration signal originating from the bearing of a rotary induction motor is included in the FFT analysis of the waveform data of rotational torque and rotational speed. Since multiple bearings are used in the drive-line component, it was confirmed that it is possible to identify the abnormal location of the bearing based on the difference in bearing frequency components. In addition, these vibrations are caused not only by bearing deterioration but also by misalignment during operation. We are currently designing a system introducing machine learning that enables cause estimation from vibration patterns in waveform, and in the future we plan to construct and operate a real-time hazard prediction system.

1. はじめに

J-PARC MLF のミュオン生成標的は陽子ビーム入射による放射線損傷および熱負荷分散のために回転方式の標的を使用している[1]。標的は真空ダクト内に設置されており、真空内への回転駆動は回転導入器を用いたシステムによって伝達されている。この回転導入器の寿命は内部のボールベアリングの寿命によって決定されているが、寿命はカップリングの取付不良やミスアライメント等によって変動する。ミュオン生成標的の回転トルクおよび回転速度のデータはモニタリングされており、異常時の場合は、回転動作を停止するようにインターロックが組み込まれているが、標的周辺は高放射線区域であり、交換及び修理を即座に行うことは厳しい。そのため、異常の早期発見および異常個所の特定が必要である。本発表では、回転駆動を伝達するモーターレゾルバから得られる軸回転トルクおよび速度のデータから、回転導入器内部のベアリング振動が特定できた例について報告し、現在開発中である機械学習を用いた異常原因推定システムについて紹介する。

2. ベアリング振動成分

ミュオン生成標的の回転駆動システムは大きく分けて、真空容器外に設置された回転駆動モーター、真空容器内に設置された回転負荷である標的シャフト、これらを連結する回転導入器の 3 つで構成されている(Fig. 1)。回転駆動モーターはワコー技研製 BNR006-D316、回転導入器はアネルバ社製の磁気結合型回転導入器を用い

ており、トルク及び速度の信号は回転駆動モーターレゾルバから取得している。KEYENCE 社製データロガー(NR-600)および三菱製 PLC(MELSEC-Q シリーズ)でモニターしている。PLC においては設定閾値を超える異常なトルク及び速度信号値を一定時間計測されると、回転停止およびビーム停止を実行するシーケンスが組み込まれている。一方で閾値以下の信号においては非常に遅い周期性を持っていることが確認されている。我々はこの




Figure 1: Rotation system of Muon Target.

[#] sunagawa@post.kek.jp

遅い周期性がボールベアリング由来であると推測し、回転機構に使用されているボールベアリングについて調査を行った。ミュオン生成標的の回転機構に用いられているボールベアリングは 4 種類あるが、その内訳は回転導入器内部に 3 種類(Fig. 2)、標的シャフトに 1 種類である。ボールベアリングは回転輪、固定輪、転動体、保持器




Figure 2: Drive-line components.

で構成されており、ベアリングが回転することによって生じる振動は複数ある[2]。これらはベアリングの内径及び外径、転動体の数が既知であれば容易に求めることが可能である。回転体が持つ基本振動成分として回転周波数 F_r があるが、ボールベアリング特有のものでは、保持器によって生じる保持器回転周波数 F_c があり、これは転動体がベアリング内部を周回する際の周期を表している。 D_w :転動体の玉径、 D_{pw} :転動体のピッチ径、 α :接触角としたとき、保持器回転周波数は以下の式で求められる。(内輪:回転輪、外輪:固定輪の場合)

$$F_c = \frac{1}{2} F_r (1 - \gamma) \quad (1)$$

$$\gamma = \frac{D_w \cos \alpha}{D_{pw}}$$

また、ベアリング特有の振動として転動体自身の自転による振動もある。転動体自転周波数 F_B として以下の式で求められる。

$$F_B = \frac{1}{2} \frac{D_{pw}}{D_w} F_r (1 - \gamma^2) \quad (2)$$

さらに固定輪、回転輪、転動体に損傷がある場合、特定の周波数で振動が発生する。これらは前述した周波数成分及び転動体個数により変動し、固定輪損傷周波

数 F_{sd} 、回転輪損傷周波数 F_{rd} 、転動体損傷周波数 F_{bd} として 4 種類の各ベアリングが有する特定周波数を Table 1 に明示した。

Table 1: Frequency of Bearing

	Inner-Shaft 1	Inner-Shaft 2	Outer-Rotor	Target-Shaft
F_c [Hz]	0.055	0.1	0.15	0.096
F_B [Hz]	0.155	0.59	0.995	0.508
F_{sd} [Hz]	1.36	1.35	1.996	0.77
F_{rd} [Hz]	0.39	0.90	1.534	1.23

3. FFT スペクトログラム検知

周期性をもつ連続した信号データから、その周期性を特定する方法としてフーリエ変換がよく知られている。ある一定の区間の離散信号が無限に続いているという前提で、これらの信号を有限個の周波数の波に分解する手法が高速フーリエ変換(FFT)である。本解析では、サンプリング周波数 100Hz、時間長 300s で FFT スペクトル解析を実施し、縦軸を周波数(Hz)、横軸を時間(Hour)、強度をカラーマップとしたスペクトログラムを1日ごとに作成した(Figure 3)。




Figure 3: FFT Spectrogram of bearing frequency.

スペクトログラムを用いて FFT の時間変化を確認したところ、10 時-11 時の約 30 分間、1.18 Hz 及び 1.35 Hz の振動成分が強く表れていることがわかった。回転導入器のインナーシャフト側ベアリング特有の振動成分が明確に表れている時間帯を発見することができた。これは、モーターレゾルバの信号にはベアリング特有の振動成

分が含まれており、FFT スペクトルの時間変化をモニターすることでベアリングの異常振動を検知することが可能であることを示唆している。

4. スペクトルクラスタリングの導入

3章にて、トルクデータの FFT スペクトログラムによって、各ベアリング特有の振動成分がモニターできることが示唆されたが見逃す可能性がある。また、各時間帯のデータにはベアリングの振動成分以外にも多くの振動成分が含まれており、各データの主振動成分の区別を人の目で判断することは難しい。そこで、機械学習を用いた FFT スペクトルクラスタリングを実施し、各時間帯のデータをラベルで位置づけることで異常振動を検知しようと試みた。機械学習を用いたクラスタリング手法は複数存在しているが、本手法では K-means++法を採用したクラスタリングモデルを作成した。K-means 法はデータの重心を求めることで分類するアルゴリズムであり、非常にシンプルな手法で、大量データへの適用が可能である。しかし、K-means 法はランダムに設定される初期値の重心点によって結果が変わってしまう恐れがあり、克服したモデルとして K-means++が知られている。クラスタリングモデル作成においては各 FFT スペクトルデータの特長量として使用した。Table 1 からベアリング特有の振動成分は 2Hz 以下であるため、FFT スペクトルデータの周波数範囲 5Hz(特長量:1500)を 2Hz(特長量:600)に削減した。しかし、このまま使用すると計算コストが非常に高いため、スペクトルデータに対して主成分分析(PCA)を用いて次元削減を行うことで特長量を 600 から 200 に削減し、これを前処理後の特長量データとした。さらにクラスタリングモデル作成時にはクラスタ数を指定する必要がある。これらのクラスタ数の最適化には、クラスタ内誤差平方和(SSE)やシルエットスコア分析などがよく用いられているが、各 FFT スペクトルデータには共通の振動成分が複数混ざっており、非常によく似ているデータとして扱われるため、これらの評価方法でクラスタ数を最適化することは難しいと考えた。そこで、クラスタリング時において各クラスタの平均 FFT スペクトルを導出し、平均 FFT スペクトルと同クラスタのスペクトルのコサイン類似度を算出し、各クラスタのコサイン類似度の平均値を指標としてクラスタ数の最適値を検討した。

さらに、本解析で検知しようとしているベアリング特有の振動は 2Hz 以下と非常に遅い周期成分であるため、この周期成分は信号の変調成分として表れていると考えられる。そのため、得られた全データトルク信号に対してヒルベルト変換処理を行い、エンベロープ波形信号を得た。実信号を $x(t)$ としてヒルベルト変換式は次のとおりである。

$$\hat{x}(t) = \frac{1}{\pi t} \int_{-\infty}^{\infty} \frac{x(\tau)}{x(t-\tau)} d\tau$$

エンベロープ波形信号に対しても同様に FFT スペクトル

解析を実施し、次元削減とクラスタリングモデル作成を実施した。Figure 4 は縦軸をコサイン類似度の平均値、横軸をクラスタ数として、ヒルベルト変換処理前後のクラスタリングモデルでの分類結果を比較した結果を示す。

エンベロープ信号データで作成したモデルがより少な

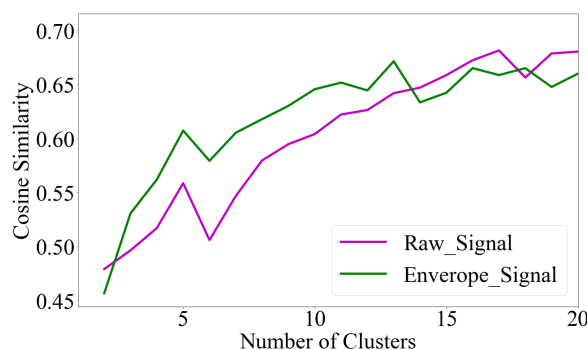


Figure 4: Cosine similarity of cluster model.

いクラスタ数で類似度が大きいことがわかる。これは、ヒルベルト変換することによってデータとして不要な高周波成分が除去され、クラスタリング精度が改善されたと考えられる。この結果から、本解析においてはエンベロープ信号データの特長量としたモデルを採用した。クラスタ数を大きくすると類似度は上昇し、徐々に緩やかになっていくが、これはデータのクラスタリングがほぼ完了しており、すでに完了しているクラスタをさらに分割しようとしているためである。そこで Fig. 4 のグラフから上昇が緩やかになったクラスタ数 11 を最適値として採用することにした。採用モデルを用いたクラスタリングから各クラスタの平均トルク値を Table 2 に示した。

平均トルク値が大きいクラスタ(No.0,1,5)と小さいクラスタ(No. 4)の平均 FFT スペクトルを Fig. 5 に示す。Figure 5(a)に示すクラスタ No. 0 においては回転基本周波数 0.25 Hz の n 次成分が基本周波数より大きい状態が確認されている。これはベアリングの回転体の摩擦によりベアリング固定輪と回転輪の間に隙間ができていないことにより、回転体の軸ブレが生じているものだと考えられる。Figure 5(b)に示すクラスタ No.1 の FFT スペクトルから 0.1 Hz のピークが確認されており、Table.1 で示したインナーシャフト下のベアリング特有振動成分と一致する。近い値として、標的シャフト側のベアリング特有成分があるが、この振動成分は別のクラスタで n 次成分と共に分類されているため、クラスタ No.1 がインナーシャフト下のベアリング由来である可能性が高い。Figure 5(c)に示すクラスタ No.4 においてはほぼ振動していない状態である平均 FFT スペクトルが得られており、トルク値が小さいこととも一致する。Figure 5(d)に示すクラスタ No.5 においては最もトルク値が高い振動状態であり、FFT スペクトルから 0.15 Hz 及びその n 次成分のピークが確認され、またそれ以外のピークは 0.15 Hz の n 次周波数でシフトしており、複数の振動状態を含んでいることがわかる。0.15 Hz の周波数は Table 1 で示したアウターロータのベアリング振動成分と一致しており、この振動成分はアウターリング側ベアリング由来であることが示唆された。

Table 2: Torque of Cluster Number

Cluster No.	No.0	No.1	No.4	No.5
Torque	6.27	6.32	5.68	6.45




Figure 5(a): FFT spectra of Cluster No.0.




Figure 5(b): FFT spectra of Cluster No.1.




Figure 5(c): FFT spectra of Cluster No.4.




Figure 5(d): FFT spectra of Cluster No.5.

5. 結論

本データは 2021 年 3 月~2021 年 7 月までのデータであり、回転導入器は使用開始からすでに 1 年以上経過しているため、単純な FFT スペクトル比較でベアリング劣化程度を確認することはできなかった。

しかし、FFT スペクトログラムによってベアリングの振動成分が確認できたことから、モーターレゾルバ信号からベアリング異常の早期発見及び交換箇所の特特定が可能であることが示唆された。本解析で用いられた FFT スペクトルクラスタリング手法においては、正解データがないため精度を評価する方法が難しいが、スペクトルのコサイン類似度がクラスタ数最適値推定手法として有効であった。非常に遅い周期成分においてはヒルベルト変換処理をした信号データを用いると精度がより良くなることが判明した。しかし、クラスタリング手法では 3 章で特定したベアリング振動成分はデータ数としては非常に少なく、データの重心を利用する K-means++法では分類できなかったと考えられる。今後は別のクラスタリングモデルを用いた分類を試みる。

参考文献

- [1] S. Makimura *et al.*, proceedings of PASJ2018, Nagaoka, Japan, Aug. 2018, FROM02.
- [2] T. Igarashi, H. Hamada, 日本機械学会論文集(C 編)47 巻 422 号(1981).