

12DVターボ振動調整における、機械学習を用いた最適調整点算出

Calculation of Optimal Adjustment Points Using Machine Learning in 12DV Turbo Vibration Tuning

岡田 一貴^{*1}
Kazutaka Okada

*1 エンジン事業部 生産技術部

要旨

ターボチャージャー生産ラインの生産性向上を目的に振動調整工程を改善し、初回調整合格率の向上を図った。調整量演算の不適切さが問題点とされたため、過去の生産データを活用し最適調整量を機械学習で予測するモデルを構築した。未調整品に対して予測結果を適用することにより初回調整合格率90%を達成し、一定の効果を確認した。今後は設備へのモデル実装を進めることで、刃具費や設備稼働費の低減が見込まれる。

キーワード：ターボチャージャー、振動調整、機械学習、XGBoost

Abstract

To improve the productivity of the turbocharger production line, we enhanced the vibration adjustment process and aimed to increase the initial adjustment pass rate. Inappropriate adjustment calculations were identified as an issue, so we constructed a model to predict the optimal adjustment amounts using machine learning based on past production data. By applying the prediction results to unadjusted products, we achieved a 90% initial adjustment pass rate and confirmed a certain level of effectiveness. Going forward, implementing the model into the equipment is expected to reduce tool costs and equipment operating costs.

Keywords: Turbocharger, Vibration Tuning, Machine Learning, XGBoost

1 はじめに

内燃機関自動車は燃費改善、排ガス削減が求められており、EVへの移行期間やインフラ整備の課題がある中、今後も引き続き必要とされることが予測される。自動車用のターボチャージャー（以下ターボ）は、エンジンの燃費性能を改善する目的で採用されており、より効果的な性能向上や環境負荷低減にも貢献が期待されている。

2 背景

エンジン重量に対してわずかな重さのターボを装着するだけで、出力を大幅に増大させることができるというメリットに対して、ターボ特有の振動（=異音）が発生し、ドライバーの乗り心地に影響を与えるというデメリットがある。

この振動を抑えるために、生産ラインの中には振動調整工程が設けられている。本工程のフローを図1に示す。まず、初期状態の振動を測定し、振動波形を取得する（図2）。続いて、測定された振動値[G]に応じてインペラ（IP）ナットと呼ばれる部品を用いて調整加工を実施する。その後、振動値[G]が規格を満たしたかを確認するために再度振動測定を実施する。規格は図2に示すように低速域・高速域にそれぞれ設けられており、その両方を

満足しなければならない。

本工程の出来高を示す値として直行率があり、計算方法は以下の通りである。

$$\text{直行率} [\%] = \frac{\text{調整OK数} [\text{台}]}{\text{投入数} [\text{台}]}$$

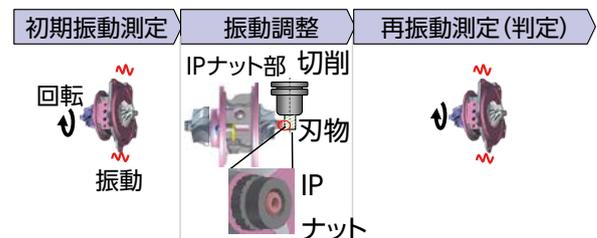


図1 振動調整工程フロー
Fig.1 Vibration Tuning Process Flow

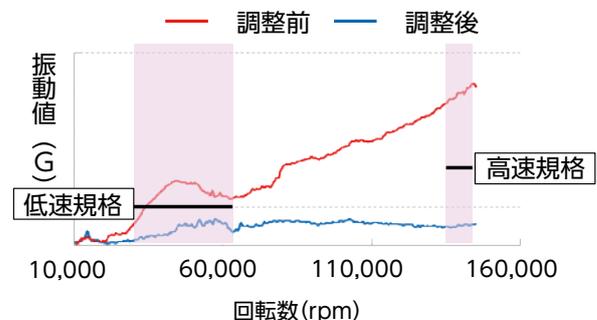


図2 振動波形
Fig.2 Vibration Waveform

3 問題の明確化

先述のIPナットを用いた振動調整は1回の加工で規格を満たすことが望ましいが、実際には約30%がNGとなる。そこで現状は、振動調整を繰り返すことで直行率の向上を図っている。ここで、すべての製品に対して必ず1回は調整を実施し、繰り返しの調整は最大3回までとする。

また、現状の調整量演算は調整前の振動波形より低速・高速域のピーク点をそれぞれ抜き取り、その両方が規格を満たすようIPナットの切削部Aを決定する(図3)。

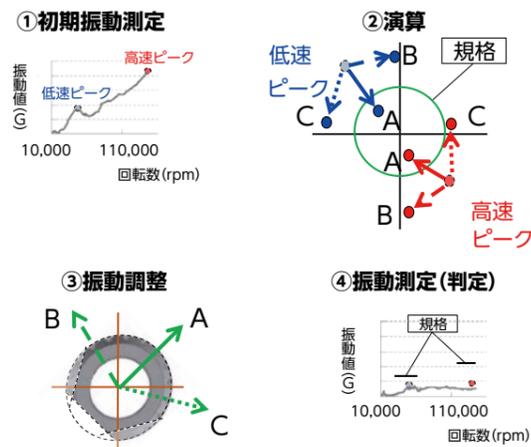


図3 現状の調整量演算
Fig.3 Current Adjustment Computation

上述の振動調整を繰り返すことで、12DVターボの直行率は90%程度にまで向上するが、機種Xの場合は直行率99%以上を達成している。また、調整NGの10%に関しては分解・再組付し、再度振動調整を実施するため、労務費や部品費が*** (円/月)増加している。

1~3回の調整を繰り返すことによる、直行率の推移を図4に示す。機種Xは、1回目の振動調整で全体の90%を直行できるのに対し、12DVの場合は70%に留まり、機種Xと比較して20ポイント低いことが問題点である。

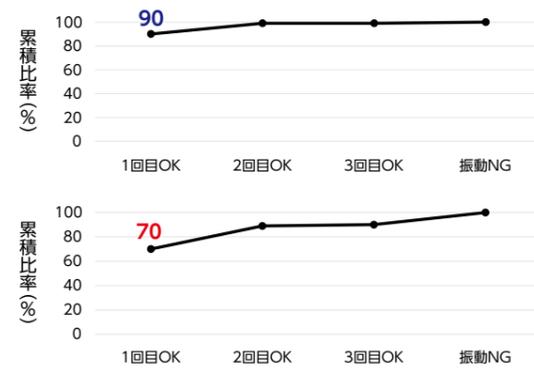


図4 直行率の推移(上:機種X, 下:12DV)
Fig.4 Transition of Direct Ratio (Top: Model X, Bottom: 12DV)

4 目標設定

現状把握をふまえて、12DVターボ振動調整の1回目直行率を2023年12月末までに20ポイント向上させることを目標に設定した。

5 要因解析

現状把握で設定した問題点に対して、4M(設備、人、材料、方法)を切り口になぜなぜを繰り返して2つの真因を特定した(図5)。

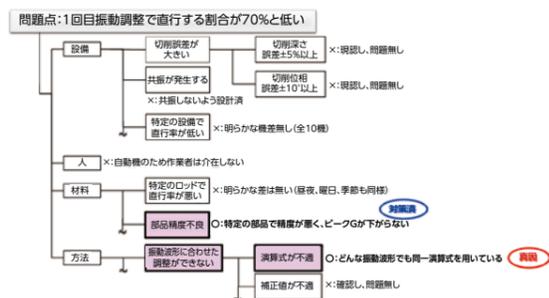


図5 要因解析
Fig.5 Factor Analysis

1つ目に、「部品精度不良」である。組付けられる部品1つ1つに着目し、直行率との相関を調査すると、特定の部品で精度が悪く低速・高速域のピーク点を下げられないことが判明した。対策実施後は直行率が安定している。

2つ目に、「調整量演算が不適」である。3章で述べたように、現状の調整量演算は低速・高速域のピーク点をそれぞれ抜き取るため、ピーク点以外の振動値[G]や位相[°]を考慮することなく切削量を決定している。

6 対策立案

目指す姿は、調整量演算を適切な状態にすることで、1回目直行率を90%にすることである。これを実現するため、現在までに蓄積されている設備データをもとに、最適な調整量を機械学習手法を用いて予測する。

図4より、今回取組の12DVは3回の振動調整を経てようやく直行率90%を達成していることが分かる。そこで、2回目および3回目の振動調整で直行する製品を、1回目で直行させることができれば目標を達成できると考えた。そのためには、1回目で調整成功するための教師データが必要になるため、下記の考え方をを用いた。

例えば、2回目の振動調整で直行した製品において、IPナットの実加工データを確認すると、図6のように2か所の切削部A,Bが確認できる。切削部A,Bはそれぞれ切削量・切削位相の情報を持つ。これらの情報からベクトル合成により切削部Cを求めることができる。合成後、切削部Cが持つ情報を総切削量・総切削位相と定義する。原理原則に基づけば、総切削量・総切削位相を用いて振動調整を実施することで、1回の調整加工で直行するという仮説が立てられる。

上記の要領で、2回目および3回目の振動調整で直行した製品の切削部情報を合成することにより、機械学習のための教師データを作成する。ここで、1回目調整で直行した製品の切削部情報はそのまま総切削量・総切削位相として利用する。また、3回目調整でも直行しない製品は、正解の切削部情報が存在しないためデータセットに含めない。

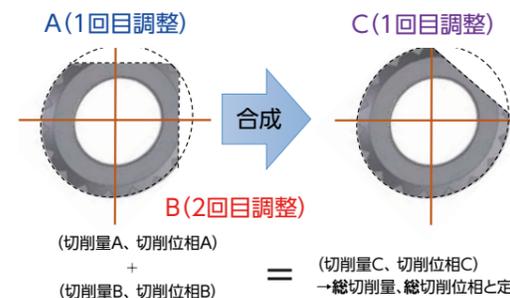


図6 教師データ取得の考え方
Fig.6 Approach to Obtaining Training Data

7 対策実施

6章の考え方を織込んだ機械学習モデル作成を

以下のように実施した。

説明変数

従来の低速・高速域のピーク点のみならず、今回は振動波形全体を説明変数として用いる。また、振動値[G]の取得と同時に位相[°]データも取得される。図2に示したような振動波形は、回転数300[rpm]毎にデータを取得しているため、1度の測定で900列のデータとなる。ここで、データ圧縮およびセンサのノイズ除去を目的として、振動値[G]・位相[°]それぞれで10点平均処理の加工を施す。これにより900列の説明変数を90列に縮小する。

さらに設備固有のパラメータである、ゲイン(2列)・オフセット(2列)を加えた計94列を説明変数とする。

目的変数

6章で述べた通り、総切削量[mm]・総切削位相[°]を目的変数とする。ただし、総切削位相[°]についてはX成分・Y成分に分解するため、総切削量・総切削位相X・総切削位相Yの計3列を目的変数とする。

XGBoost

上述のように作成したデータセットに対し、XGBoost (eXtreme Gradient Boosting) 回帰を実施した。本手法は重要度可視化、結果の解釈性、非線形データへ対応可能なことより選定した。データ行数は9,200行であり、訓練データとテストデータの比は7:3、二乗平均平方根誤差(RMSE)を最小にするためのハイパーパラメータ調整は5-fold cross-validationにより実施した。

テストデータにおける予測結果を図7、図8に示す。図8については、総切削位相X・総切削位相Yを総切削位相[°]に合成している。また、図8中に赤丸で示す箇所については、±180°同士で切削位相[°]が等しいため180°反転してRMSEを計算している。

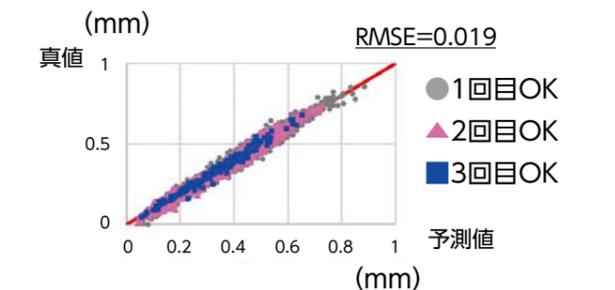


図7 総切削量の予測
Fig.7 Prediction of Total Cutting Volume

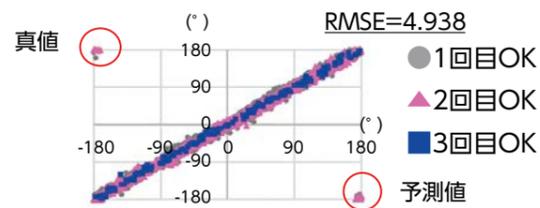


図8 総切削位相の予測
Fig.8 Prediction of Total Cutting Phase

図7、図8より、データ加工無し1回目直データおよびデータ加工した2、3回目の直データについて、総切削量[mm]・総切削位相[°]共に精度良く予測ができていたことが分かる。ただし、図7中の0.8~1.0[mm]の範囲においては、教師データ不足により精度が落ちる可能性がある。

8 効果確認・評価

7章にて作成した機械学習モデルの効果確認のため、新規に初期振動測定のみを実施した製品を30台用意し、従来の調整量演算と機械学習モデルとの比較を実施した。

比較結果を図9、図10に示す。

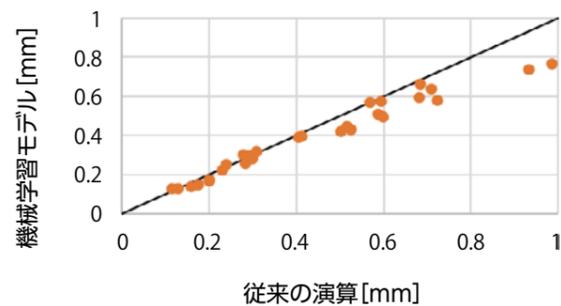


図9 総切削量の比較
Fig.9 Comparison of Total Cutting Volume

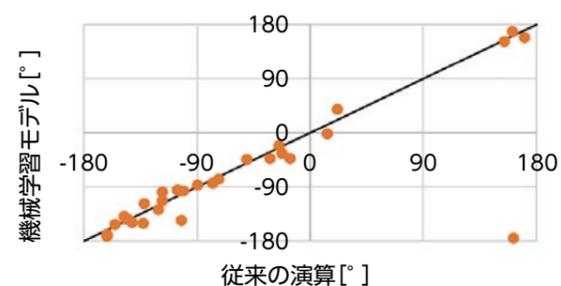


図10 総切削位相の比較
Fig.10 Comparison of Total Cutting Phase

図9より、総切削量0.4[mm]以下において、機械学習モデルは従来手法と同様の結果を示す。一方で、総切削量0.4[mm]を超えると機械学習モデル

は従来よりも小さい値を返すことから、総切削量が大きな場合は従来の演算はIPナットを削りすぎていと推測できる。

図10より、ほぼ全ての製品において、機械学習モデルは従来と同様の結果を示しており、総切削位相については従来の演算も正しいと考えられる。

続いて、図9で考察した総切削量について、推測が正しいか確認する。教師データ中の2回目の振動調整で直行した製品において、IPナットの実加工データを確認すると2か所の切削部が確認できる。2か所の切削部が180°反対側に位置する場合、1回目調整でIPナットを削りすぎているため、2回目調整で削り戻しが必要である(図11)。これに対し、切削部が同位相である場合、1回目調整でIPナットを削り足りないため、2回目調整で重ね削りが必要である(図12)。2回目直データの切削部位相の確認結果を図13に示す。



図11 1回目調整で削りすぎの場合
Fig.11 In Case of Over-cutting in First Adjustment

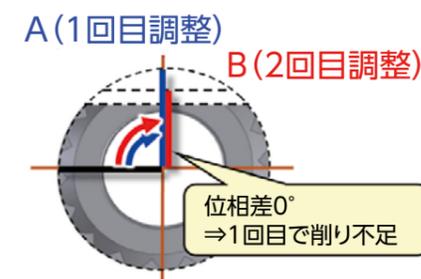


図12 1回目調整で削り不足の場合
Fig.12 In Case of Under-cutting in First Adjustment

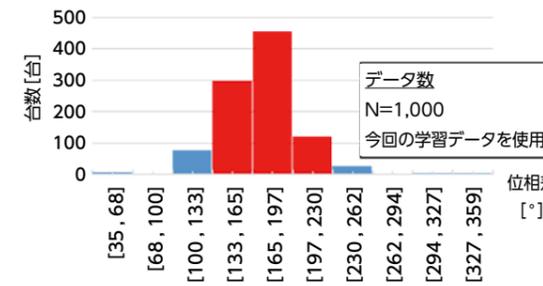


図13 2回目直データの切削部位相
Fig.13 Cutting Phase Difference in Second Direct Data

図13より、赤で塗りつぶした部分は切削位相が180°反対側付近にあることを示しており、全体の88%が含まれる。これより、従来の演算ではIPナットを削りすぎているという推測が正しいと言え、また、機械学習モデルが従来の演算と比較して小さい値を返すことを裏付ける。

次に、実際の設備にて、機械学習モデルの予測通りに調整加工および再振動測定を実施し、直行率推移を確認する(図14)。

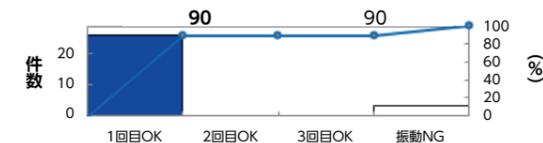


図14 機械学習モデルによる直行率推移
Fig.14 Transition of Direct Ratio Using Machine Learning Model

図14より、1回目直行率は目標通りに90%を達成することができた。しかし、2回目および3回目の振動調整で直行した製品は無く、全体の直行率は90%に留まった。

また、直行率は日々変動する値であり、バラツキを含めて評価するには今回の30台では不足している。そのため、今後は台数を増やして効果確認を進めるが、今回は評価の直前・直後に生産された製品各30台の直行率推移(図15)と比較する。なお、これらは従来の調整量演算にて振動調整を実施している。

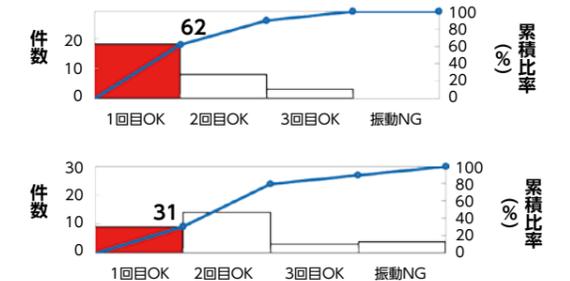


図15 直行率の推移(上:評価前、下:評価後)
Fig.15 Transition of Direct Ratio (Top: Before Evaluation, Bottom: After Evaluation)

図15より、評価前後に生産された製品の1回目直行率は評価前_62%、評価後_31%と今回目標の90%に大きく未達である。一方で、中間に生産された機械学習モデルによる振動調整でのみ90%を達成している(図14)。これより、今回の機械学習モデルにより一定の効果を得られたと考えられる。

効果額は、調整加工回数が減ることによる刃具費低減:*** (円/月)、測定回数が減ることによる設備稼働費低減:*** (円/月)、CO₂低減量:*** (kg-CO₂/月)の見込みである。

9 まとめ

機械学習モデルを用いた振動調整手法が従来の調整手法に比べて、直行率や生産効率の向上に有効であることが実証された。これにより刃具費や設備稼働費、環境負荷などの低減効果が期待できる。

今後は設備違い等の多様な条件下でのデータを収集し、データセットを拡充することで持続可能で競争力のある生産体制を構築していく。

■ 著者紹介 ■



岡田 一貴

開発の経緯と開発者の思い

ターボチャージャーにおける振動問題とその改善策へ深い関心を持って取り組んだ。技術開発において、非直行ワークに対して調整回数を増やすことによる振動調整では、直行率が向上する可能性はあるが成功率が低くラインの生産性を損なう恐れがあった。そこで、工程の特徴を生かした発想の転換で1回目直行率向上という手段を考案し、機械学習モデルの仕様に落とし込むことで一定の成果を得られたと考える。