

時系列解析によるエンジン主軸受の摩耗予測

釣谷 周平[†] 松原 靖子[†] 水谷 雅巳^{††} 佐藤 正彦^{††} 櫻井 保志[†]

[†] 大阪大学産業科学研究所 〒567-0047 大阪府茨木市美穂ヶ丘 8-1
^{††} 株式会社小松製作所 〒107-8414 東京都港区赤坂二丁目 3 番 6 号
 E-mail: †{shuhei.tsuriya88,yasuko,yasushi}@sanken.osaka-u.ac.jp,
 ††{motomi_mizugai,masahiko_satou}@global.komatsu

あらまし エンジン主軸受はエンジンの軸を支え耐久性を高める、エンジンにとって不可欠なコンポーネントである。エンジン主軸受の過度な摩耗は回転不良を引き起こし、最悪の場合エンジンの突発故障を引き起こす可能性がある。したがって、エンジンの適切なメンテナンスを実施するためにもエンジン主軸受の摩耗度の将来予測は重要な課題である。そこで、本研究では車両に備え付けたセンサから得られた多次元時系列データを用いて軸受の摩耗度を予測する手法を提案する。提案手法ではセンサから得られる時系列データから推定摩耗量を求め現時点の摩耗度を推定する。さらに、摩耗進行状態に応じて将来予測モデルを切り替えることで高速かつ高精度に将来の摩耗度を予測する。実データを用いた実験を行った結果、提案手法が効果的にエンジン主軸受の摩耗度を予測できることを確認した。

キーワード 時系列解析, 摩耗予測, PHM, 深層学習

1 ま え が き

近年軸受の故障予測や寿命予測を実現するための研究が盛んに行われている [1–5]。軸受はエンジンなどの回転機械において金属同士の摩擦を低減するための部品であり、軸受を用いることで機械の寿命を飛躍的に伸ばすことができる。ただし、軸受はしゅう動するにつれて徐々に摩耗していき、過度に摩耗が進行すれば焼付きが発生し、最終的には機器の故障を引き起こす。そこで、軸受の破損や焼付きによる機器の故障を防ぐためには、摩耗の進行が致命的になる前にメンテナンスを実施し、軸受の交換などの対処を実施する。ここで、適切なタイミングで機器のメンテナンスを実施するために、軸受の故障予測及び摩耗予測手法の研究が広く行われている。なかでも、エンジンのクランクシャフトに用いられるエンジン主軸受に関しては、その摩耗がエンジン本体の故障と密接に関連している。エンジン主軸受において摩耗進行により焼付きが発生するとエンジンの回転不良を引き起こし、最終的にエンジンが故障してしまう。エンジンは多くの車両、機器の中核的なコンポーネントであり、その故障は甚大な経済的かつ時間的損失をもたらす。例えばマイニング現場では、ショベルのエンジン主軸受摩耗によりエンジン故障が発生すると、エンジンの修理、交換にかかる経済的な損失に加えてショベルが稼働できないことによる現場のパフォーマンスの低下など多くの損害が生じる。このようにエンジン主軸受の摩耗予測はエンジン故障による損害を未然に防ぐために必要な課題であり、本研究ではエンジン主軸受の摩耗予測手法を提案する。

先行研究により、エンジン主軸受を含め多くの軸受ではその振動データが軸受の健康状態をよく説明するがわかっている [6, 7]。そのため、多くの先行研究では軸受の振動データを分析することによって軸受の摩耗予測を実現している。しかし、

そのような振動データを機器の稼働中常時得るためには機器に対して加速度センサを装備する必要がある。したがって、実際の車両でリアルタイムに摩耗予測を実施するにあたって、振動データを用いる手法は計測条件への制約が大きいアプローチと言える [1]。そこで、本研究では振動データを用いず、エンジン速度や平均燃費など車両に搭載されているセンサからのデータのみを用いて摩耗予測を実現する手法を提案する。車両から得られる多変量時系列センサデータから推定摩耗量を算出し、さらにそれを Gompertz 関数を用いて変換し現時点の摩耗度として推定する。

さらに、摩耗予測を用いて最適なメンテナンスのタイミングを判断するためには現時点の摩耗度の情報より将来時点の摩耗度の情報を得られる方が好ましい。したがって、本研究では現時点の摩耗予測に加え、求めた推定摩耗度を自己回帰的に将来予測し、将来時点の摩耗度を予測する手法を提案する。

1.1 具 体 例

本節では提案手法を用いたエンジン主軸受の摩耗予測の具体例を示す。この例では、株式会社小松製作所が製造する大型マイニングショベルのエンジン主軸受の摩耗予測を実施している。まず、予測対象となる摩耗度を次のように定義する。エンジン主軸受は合金を複数層に重ねた多層構造になっているものが多く、摩耗の進行によって第一層のメッキや合金が剥がれて第二層の金属が露出する。ここで、エンジン主軸受の内第二層の金属が露出しているものの枚数を摩耗度として定義する。例えば、図 1 はショベルのエンジン主軸受の画像を示したものであるが、画像内の茶色の部分が第二層の銅合金が露出している部分である。したがって、この場合銅合金の露出が見える軸受の枚数を摩耗度とするため、図 1 の軸受の摩耗度は上段、下段でそれぞれ 6, 3 となる。

上記の摩耗度の定義に基づいて 10 台のショベルに対し摩耗





図 1: 大型マイニングショベルのエンジン主軸受




図 2: 提案手法を用いたエンジン主軸受の摩耗予測結果

予測を行った結果を図 2 に示す。図中の横軸はショベルの累計稼働時間を示し、縦軸はショベルのエンジン主軸受の摩耗度を示す。ここで、稼働時間は平均 0、分散 1 となるように標準化を施している。また、図中の実線は摩耗予測モデルが出力した各車両の 30 時点先の摩耗度の予測値であり、また実線と同色の下三角は同じ車両のメンテナンス時に計測した実際の摩耗度である。すなわち、実線がモデルによる摩耗度の推定値であり、下三角がその正解値である。ここで、教師データである摩耗度の正解値は車両のメンテナンス時にしか得られないイベントデータであるのに対し、モデルの出力である摩耗度の推定値は時系列になっている。摩耗度の教師データは数が少なくかつ非時系列的なデータであるにもかかわらず、提案手法では車両から得られる時系列センサデータを活用することで摩耗度の推定を時系列的に実行することができる。このように、提案手法を用いることでエンジン主軸受の将来時点の摩耗度を予測することが可能である。

1.2 本研究の貢献

本研究では、車両から得られる時系列センサデータを用いてエンジン主軸受の摩耗度を将来予測する手法を提案する。本手法は次の特徴を持つ。

- 軸受の振動データが入手できないような環境でも、車両に搭載されたエンジン関連のセンサデータを用いることで摩耗予測を実現できる。
- 現在時点の摩耗度に加え将来時点の摩耗度予測を行うため、将来時点の摩耗度から逆算して最適なメンテナンスのタイミングの判断に役立てられる。

- 摩耗進行状態に応じて将来予測モデルを切り替えることで高速かつ高精度に将来の摩耗度を予測できる。

2 関連研究

軸受の寿命予測. エンジン主軸受を含めその他のすべり軸受、転がり軸受の寿命予測、摩耗予測の研究が広く行われている。Zhang [2] らは振動データに対し主成分分析 (PCA)、隠れマルコフモデル (HMM)、劣化モデルの 3 つのコンポーネントを応用することで効果的に軸受の寿命を推定する手法を提案した。また、Zhai [3] らは軸受やバッテリー、LED などの劣化プロセスを Wiener 過程によってモデリングし、それらの寿命予測を実現する手法を提案した。Rai [4] らは軸受の振動データに対して EEMD、GMM、JRD を適用して軸受の寿命予測を行う手法を提案した。また、深層学習を用いて寿命予測を行う研究も行われている。Ni [5] らはベイズ最適化を用いて GRU のハイパーパラメータチューニングを自動で行い最適なモデルで軸受の寿命予測を行う手法を提案した。これら軸受寿命予測の手法の多くは振動データが得られることを前提としており、本研究で取り扱うような加速度センサにより振動データを入手できないような状況では用いることができない。また、多くの手法が振動データから健康指数を算出し、その健康指数が閾値を超える点までの時間を予測するアプローチをとっている。したがって、これらの手法ではあらかじめ対象の健康指数の閾値を設定する必要がある。本提案手法では軸受が故障するまでの時間ではなく摩耗度合いそのものを予測するため、健康指数の閾値を設定する必要がない。また、多くの健康指数は振動データに対して複雑な数学的、統計的処理を加えて得られるものであり、健康指数の値自体の解釈性は低い。これに対し提案手法では軸受の摩耗度合いを出力値としており、そのため健康指数に比べて高い解釈性を持つ。

時系列解析. また、時系列データを対象としたデータマイニングや将来予測も重要な研究課題である。自己回帰モデルや線形動的動的システムは代表的な時系列解析手法であり、多くの時系列予測の課題で応用されている。これらの手法はその単純さにもかかわらず高精度に時系列データをモデリングできるが、非線形の時系列データには適応できない。また、深層学習を用いた時系列解析手法としては RNN [8]、LSTM [9]、GRU [10] などが代表的である。これらの手法は非線形な時系列データに対しても適応可能であるが、モデルの学習に時間がかかるという問題がある。SplitCast [11] は大規模時系列テンソルに対する時系列予測手法であり、時系列データを複数のパターン（レジーム）に分割し、個々のレジームに対して固有の LSTM を用いて時系列予測を行う。時系列全体に対して 1 つのモデルを学習するのではなく、個々のパターンに対してモデルを学習する。これによりモデルを並列に学習させることが可能となり、深層学習の課題であるモデルの学習時間を短縮できる。また、各モデルが固有のパターンのみを集中的に学習するため結果として高精度な時系列予測を実現できる。

結論として、振動データを用いずエンジン速度や平均燃費な

どのセンサデータから将来時点の摩耗度を予測する手法はこれまでに存在せず、提案手法が初の試みである。

3 問題定義

本章では、本研究で取り組む問題の定義を行う。本研究の最終目的は、車両から得られる時系列センサデータを用いて将来時点のエンジン主軸受の摩耗度を予測することである。ここで、前提として以下に挙げる2種のデータが与えられていると仮定する。

- センサデータ $\mathcal{X}$ ：これは車両に搭載されたセンサから得られるエンジン速度や平均燃費などの時系列センサデータの集合である。本データは（車両，センサ，時刻）の3つ組で表現され、それぞれ w 台の車両， d 種のセンサ， n 個の観測点から構成される。したがってこのデータは $\mathcal{X} \in \mathbb{R}^{w \times d \times n}$ と3階テンソルの形で表現でき、 $\mathcal{X}$ の要素 $x_{ij}(t)$ は t 時点の i 台目の車両のセンサ j の計測値を示す。
- 摩耗データ $\mathcal{Y}$ ：これは車両がメンテナンスもしくは修理を行った際に得られるエンジン主軸受の摩耗度の正解値の集合である。本データは（車両，時刻）の組でセンサデータと同様に表現される。すなわちこのデータは $\mathcal{Y} \in \mathbb{R}^{w \times n}$ と2階テンソルの形で表現でき、 $\mathcal{Y}$ の要素 y_{ij} は j 時点で i 台目の車両に対して実施したメンテナンスの際のエンジン主軸受摩耗度を示す。なお、ここで摩耗度とは1.1節で述べたもの、すなわち全軸受のなかで摩耗により第二層の金属が露出しているものの枚数を意味する。また、センサデータは各時刻で値が得られる時系列データであるが、摩耗データはメンテナンス時にのみ値が得られるイベントデータ、すなわち疎なテンソルである。

以上の2つのデータが与えられている前提で、本研究で取り組む問題を以下のように定義する。

[問題] 摩耗予測の対象とする車両の現在時刻 t までのセンサデータ $\mathcal{X}(0:t)$ が与えられたとき、次式に基づいて l 時点先の摩耗度 $\mathcal{Z}$ を求める。

$$\mathcal{Z}(t+l) = F(\mathcal{X}(0:t)) \quad (1)$$

ここで、 F は提案手法を、 $\mathcal{Z}$ は摩耗度の予測値を示す。 $\mathcal{Z}$ はイベントデータである $\mathcal{Y}$ と異なり提案手法が予測する摩耗度の時系列である。与えられた摩耗データ $\mathcal{Y}$ はメンテナンス時に得られるイベントデータであるが、提案手法では時系列データであるセンサデータ $\mathcal{X}$ を活用することで摩耗度予測を時系列領域に拡張する。さらに、上記の問題は以下の2つの小問題に分解できる。

[P1] 現在時刻 t までのセンサデータ $\mathcal{X}(0:t)$ が与えられたとき、次式に基づき時刻 t の摩耗度を推定する。

$$\mathcal{Z}(t) = G(\mathcal{X}(0:t)) \quad (2)$$

ここで、 G は提案手法の中で現在時刻の摩耗度を推定するコンポーネントを示す。

[P2] P1 で求めた時刻 t までの摩耗度 $\mathcal{Z}(0:t)$ を用いて l 時

点先の摩耗度を求める。

$$\mathcal{Z}(t+l) = H(\mathcal{Z}(0:t)) \quad (3)$$

ここで、 H は提案手法の中で将来時点の摩耗度を予測するコンポーネントを示す。

次章では P1, P2 のそれぞれの問題を解くための提案手法について説明する。

4 提案手法

提案手法は以下の2つのアルゴリズムで構成される。

- [P1] 現在時刻の摩耗度を推定：車両から得られた時系列センサデータ $\mathcal{X}$ から現在時刻の摩耗度 $\mathcal{Z}(t)$ を求めるアルゴリズム。まず摩耗推定式に基づいて推定摩耗量 W を算出する。次に、 W に対して Gompertz 関数を適応して本問題で求めたい摩耗度へ写像する。ここで、Gompertz 関数のパラメータは W と摩耗データ $\mathcal{Y}$ を用いて学習する。
- [P2] l 時点先の摩耗度を予測：[P1] で求めた摩耗度 $\mathcal{Z}(0:t)$ を用いて l 時点先の摩耗度 $\mathcal{Z}(t+l)$ を求めるアルゴリズム。このアルゴリズムはさらに次の (a), (b) の2つのモジュールで構成される。
 - (a) CubeMarker：階層的な隠れマルコフモデルを用いて $\mathcal{Z}$ に対して時系列セグメンテーションを行う。これにより各車両の摩耗進行状態がセグメントとして自動で分類可能になる。
 - (b) SplitCast：CubeMarker で得られたそれぞれの時系列パターン（レジーム）に対し固有の GRU モデルを学習する。複数の小さな予測モデルを並列で学習するため既存の深層学習モデルよりも高速に学習でき、また各モデルがそれぞれ固有の時系列パターンを集中的に学習するため、全体的に高精度な将来予測が可能となる。

図3に提案手法の全体的な流れを示す。

4.1 [P1] 現在時刻の摩耗度の推定

軸受の寿命予測では多くの場合振動データが用いられるが、実際の現場での運用を考えるとこれは計測条件への制約が大きいアプローチといえる。そこで、提案手法では振動データを用いず車両のセンサデータから摩耗量を推定する。軸受の摩耗量を推定する際に広く用いられている手法に Archard の法則 [12] がある。これは実験的に得られた知見から摩耗量の推定式を定めたもので、次式の形で摩耗量を計算する。

$$W = K \times P \times V \times T \quad (4)$$

ここで、(4) 式の各記号の意味は下記の通りである。

W ：推定摩耗量

K ：比摩耗量。擦り合う金属同士の材料の組み合わせによって決まる定数である。

P ：軸受にかかる面圧。




図 3: 提案手法の概要

V : 軸受のしゅう動速度.

T : 軸受が稼働した時間.

ここで、実際に車両が稼働している環境では P , V は時間と共に変化する時系列データである。したがって、時刻 t における単位時間あたりの推定摩耗量、面圧、しゅう動速度をそれぞれ $W(t)$, $P(t)$, $V(t)$ とするとこれらの時系列変化を考慮した摩耗量の計算式は以下のようになる。

$$W_t = \sum_{i=1}^t W(i) = \sum_{i=1}^t (K \times P(i) \times V(i)) \quad (5)$$

ここで、 W_t は現在時刻 t までの累積の推定摩耗量である。このように、車両に搭載されたセンサからエンジン主軸受にかかる面圧としゅう動速度の時系列データが得られれば (5) 式に基づいて摩耗量を計算できる。

ただ、ここで求めた W は摩耗の絶対的な総量であり、本提案手法で求めたい摩耗度を示すものではない。摩耗度はエンジン主軸受のうち第二層の金属が露出しているものの枚数であるため、これを求めるには推定摩耗量 W を摩耗度へと写像する必要がある。ここで、推定摩耗量から摩耗度への写像には Gompertz 関数 [13] を用いる。Gompertz 関数は Sigmoid 関数の一種で、生物の人口増加や癌腫瘍の成長過程のモデリングに用いられており [14, 15]、以下の数式で定義される。

$$f(t) = ae^{-e^{-b(t-c)}} \quad (6)$$

この Gompertz 関数を (5) 式で求めた W に対して適用することで推定摩耗量を摩耗度に変換する。Gompertz 関数を用いた推定摩耗量から摩耗度への写像に関する考察は 5.3 節の実験で後述するが、Gompertz 関数を通すことで高精度に摩耗度を推定することが可能である。なお、Gompertz 関数には a, b, c の 3 つのパラメータが存在するが、これらのパラメータは摩耗データ y と推定摩耗量 W を用いて学習する。

まとめると、アルゴリズム [P1] は次式のようになる。

$$Z(t) = f(W_t) = f\left(\sum_{i=1}^t (K \times P(i) \times V(i))\right) \quad (7)$$

4.2 [P2] l 時点先の摩耗度の将来予測

アルゴリズム [P1] によって現在時点の摩耗度 $Z(t)$ を得ることができた。しかし、車両メンテナンスの最適なタイミングを判断するためには、現在時点ではなく将来時点でどの程度摩耗が進行しているかを知る必要がある。そこで、本研究ではアルゴリズム [P1] で求めた $Z(0:t)$ を用いて l 時点先の摩耗度 $Z(t+l)$ を求めるアルゴリズム [P2] を提案する。アルゴリズム [P2] ではまず、(a) 摩耗度 Z に対して CubeMarker [16] を用いて時系列セグメンテーションを行う。続いて、(b) SplitCast を用いて各レジームに対してそれぞれ時系列予測モデルを学習し、データが属するレジームに応じて予測モデルを切り替えながら将来時点の摩耗度を予測する。

4.2.1 (a) CubeMarker

CubeMarker は多次元時系列テンソルをセグメンテーションし、部分時系列の集合に要約する手法である。ここで、CubeMarker によって分類された個々の部分時系列をセグメントと呼び、また各セグメントが属する固有の時系列パターンをレジームと呼ぶ。CubeMarker は摩耗度 $Z(0:t)$ を入力として受け取り、そのセグメンテーション結果 $C = \{m, r, S, \mathcal{F}, \Theta\}$ を出力する。 C の各項目の内容は以下のとおりである。

m : セグメントの総数

r : レジームの総数

S : セグメントの集合 $S = \{s_1, \dots, s_m\}$. s_i は i 番目のセグメントを示し、(車両, セグメントの開始点, セグメントの終了点) の 3 つ組で表される。

$\mathcal{F}$: セグメントのラベルの集合 $\mathcal{F} = \{f_1, \dots, f_m\}$. $f_i (0 \leq f_i \leq r)$ はセグメント s_i が属するレジームのラベルを示す。

Θ : レジームのモデルの集合及びレジーム間の遷移行列

$\Theta = \{\theta_1, \dots, \theta_r, \Delta_{r \times r}\}$, θ_i は i 番目のレジームのモデルを示し, $\Delta_{r \times r}$ はレジーム間の遷移行列を示す。

各レジーム θ_i は隠れマルコフモデル (Hidden Markov Model, HMM) を用いて表現される。HMM は隠れ状態を持ったマルコフ過程を示した確率モデルであり, 音声処理や言語処理などの分野で広く活用されている [17, 18]。また, CubeMarker では 1 つのレジーム θ_i を HMM における 1 つの隠れ状態とみなした, 階層的な HMM を用いてレジーム間の遷移をモデリングする。すなわち, それぞれが HMM である各レジーム θ_i が下階層の HMM であり, 上階層の HMM は r 個の隠れ状態 $\theta_1, \dots, \theta_r$ を持つ。ここで, 上階層の HMM における状態遷移確率が $\Delta_{r \times r}$ である。

上記のような構造を持った CubeMarker は, 次に示す工程で時系列データをセグメンテーションする。

1. Θ を初期化する
2. Θ を用いて入力時系列データ $\mathcal{Z}(0:t)$ をセグメンテーションする。ここで, セグメンテーションには階層的な Viterbi アルゴリズムを用いる。Viterbi アルゴリズム [19] は時系列データと HMM が与えられた時に, 最も尤度が高くなるような HMM の隠れ状態系列を出力するアルゴリズムである。したがって, 階層的な HMM である Θ に対して (階層的な) Viterbi アルゴリズムを適用すると, 尤度が最大となるようなレジーム θ_i の系列, すなわちセグメンテーション結果が出力される。階層的な Viterbi アルゴリズムは階層的 HMM モデル Θ 及び時系列データ $\mathcal{Z}(0:t) = \{z_0, \dots, z_t\}$ が与えられた時, 次式により最大尤度 $P(z_t|\Theta)$ を動的に求める。

$$P(z_i|\Theta) = \max_{1 \leq j \leq r} \{ \max_{1 \leq k \leq k_j} \{p_{j;k}(i)\} \} \quad (8)$$

$$p_{j;k}(i) = \max \left\{ \begin{array}{l} \max_l \{ \delta_{li} \cdot \max_v \{ p_{l;v}(t-1) \} \cdot \pi_{j;k} \cdot b_{j;k}(z_i) \} \\ \delta_{jj} \cdot \max_w \{ p_{j;w}(i-1) \cdot a_{j;wk} \} \cdot b_{j;k}(z_i) \end{array} \right\} \quad (9)$$

ここで, $p_{j;k}(i)$ は z_i がレジーム j の隠れ状態 k に属する確率である。 δ_{ij} は $\Delta_{r \times r}$ の i 行 j 列目の要素であり, レジーム i からレジーム j へ遷移する確率である。 $\pi_{j;k}$ はレジーム j における隠れ状態 k の初期確率, $b_{j;k}(z_i)$ はレジーム j の隠れ状態 k が値 z_i を出力する出力確率, $a_{j;wk}$ はレジーム j において隠れ状態 w から k へ遷移する遷移確率である。このように最大尤度を求め, その最大尤度となるとき隠れ状態 (レジーム) の系列から $\mathcal{S}, \mathcal{F}$ を求める。

3. セグメンテーション結果である $\mathcal{S}$ 及び $\mathcal{F}$ を用いて Θ のパラメータを更新する。各レジーム θ_i のパラメータである HMM の初期確率 $\pi = \{\pi_1, \dots, \pi_k\}$, 状態遷移確率 $A = \{a_{ij}\}_{i,j=1}^k$, 出力確率 $B = \{b_1(x), \dots, b_k(x)\}$ は Baum-Welch アルゴリズム [20] を用いて推定する。また, $\Delta_{r \times r}$ の各遷移確率 δ_{ij} (レジーム i からレジーム j に遷移する確率) は次式のように求められる。

$$\delta_{ij} = \frac{N_{ij}}{\sum_{s \in \mathcal{S}_i} |s|} \quad (10)$$

ここで, N_{ij} はレジーム i からレジーム j に遷移した回数を表し, $\mathcal{S}_i$ はレジーム i に属するセグメントの集合を表す。すなわち, $\sum_{s \in \mathcal{S}_i} |s|$ はレジーム i に属する全セグメントの長さの総和を表す。

4. 上記の 2., 3. をモデルの「良さ」が収束し, それ以上改善しなくなるまで繰り返す。CubeMarker では $\mathcal{C} = \{m, r, \mathcal{S}, \mathcal{F}, \Theta\}$ のモデル選択指標として最小記述長 (Minimum Description Length, MDL) に基づいたスコアを定義しており, このスコアが小さければ小さいほど良いモデルとしている。2., 3. の工程を繰り返すことでこのスコアは減少していくが, 最終的にスコアは収束し, 収束した時点のモデルとセグメンテーション結果を CubeMarker の最終出力とする。

上記の工程で摩耗度 $\mathcal{Z}(0:t)$ をセグメンテーションし, セグメンテーション結果である $\mathcal{S}, \mathcal{F}$ を用いて次の SplitCast で摩耗度予測モデルを構築する。

4.2.2 (b) SplitCast

SplitCast では l 時点先の摩耗度を予測する時系列予測モデルを構築する。摩耗度 $\mathcal{Z}(0:t)$ に対して CubeMarker を適用した結果得られた各レジーム θ_i それぞれに対して 1 つの時系列予測モデル $\mathcal{M}_i$ を学習する。通常の時系列予測手法では時系列全体 $\mathcal{Z}(0:t)$ に対して 1 つの時系列予測モデルを学習させるが, SplitCast では各モデルが個々の時系列パターンを集中的に学習できるため, より高精度に時系列予測を行うことができる。また, $\mathcal{M}_1, \dots, \mathcal{M}_r$ の複数の時系列予測モデルを並列に学習するため, 既存手法に比べてより高速にモデルを学習できる。

SplitCast は学習時には摩耗度 $\mathcal{Z}$ 及び CubeMarker によるセグメンテーション結果 $\mathcal{S}, \mathcal{F}$ を入力として受け, r 個の時系列予測モデル $\mathcal{M} = \{\mathcal{M}_1, \dots, \mathcal{M}_r\}$ を出力する。また, 推論時には学習したモデル $\mathcal{M}$, 摩耗度 $\mathcal{Z}$ 及びセグメンテーション結果 $\mathcal{S}, \mathcal{F}$ から l 時点先の摩耗度 $\mathcal{Z}(t+l)$ を予測する。SplitCast によるモデルの学習と摩耗度予測の工程を以下に示す。

- モデルの学習: この工程では学習用センサデータ $\mathcal{X}_{train}$, 摩耗データ $\mathcal{Y}_{train}$ を用いてアルゴリズム [P1] から得られた摩耗度データ $\mathcal{Z}_{train}$ と, $\mathcal{Z}_{train}$ に対してセグメンテーションを行った結果の $\mathcal{S}_{train}, \mathcal{F}_{train}$ を用いて時系列予測モデル $\mathcal{M}$ を学習する。まず $\mathcal{Z}_{train}$ を同じレジームのセグメントごとに $\mathcal{Z}_{train;1}, \dots, \mathcal{Z}_{train;r}$ と分割する。 $h(z)(z \in \mathcal{Z}_{train})$ を z が属するレジームであるとする, この分割は次式のように定義される。

$$\mathcal{Z}_{train;i} = \{z \in \mathcal{Z}_{train} | h(z) = i\} \quad (11)$$

次に, $\mathcal{Z}_{train;i}$ を学習データとして時系列予測モデル $\mathcal{M}_i$ を学習する。なお, 本研究ではこの時系列予測モデルに GRU を採用した。GRU は深層学習モデルである RNN をメモリユニットと呼ばれるモジュールを用いて拡張した深層学習モデルである。LSTM と比べて高速に学習が

可能であり、また予測の精度も高い。GRU を時系列予測モデルに採用することで、非線形で複雑な構造を持った時系列データも正確にモデリングすることができる。

- モデルによる予測（推論）：この工程ではテスト用センサデータ $\mathcal{X}_{test}$ 、摩耗データ $\mathcal{Y}_{test}$ を用いてアルゴリズム [P1] から得られた摩耗度データ $\mathcal{Z}_{test}$ と、 $\mathcal{Z}_{test}$ に対してセグメンテーションを行った結果の $\mathcal{S}_{test}$ 、 $\mathcal{F}_{test}$ と、学習した時系列予測モデル $\mathcal{M}$ を用いて l 時点先の摩耗度を予測する。 $z(i) \in \mathcal{Z}_{test}$ の l 時点先の摩耗度 $z(i+l)$ を予測するとき、GRU のウィンドウ幅を w としてウィンドウ $z(i-w:i)$ のレジーム $h(z(i-w:i))$ を調べる。多くの場合 $h(z(i-w:i))$ は単一の値となるが、ウィンドウがセグメントの切り替わりを含んだ場合などは複数の値となる。ここで、 $h(z(i-w:i))$ の中で要素数が最大のものを m とすると、 $z(i+l)$ は以下のように求められる。

$$z(i+l) = \mathcal{M}_m(z(i-w:i)) \quad (12)$$

以上のように、提案手法では (7) 式による現在時点の摩耗度推定、CubeMarker による摩耗度データのセグメンテーション、SplitCast による時系列予測を活用することで最終的に l 時点先の摩耗度予測を実現する。

5 評価実験

本研究では提案手法の有効性を検証するため、実データを用いた実験を行った。実験は 512GB のメモリ、NVIDIA RTX A6000 48GB の GPU を搭載した Linux マシン上で実施した。

5.1 データセット

実験で使用したデータセットは株式会社小松製作所にて、同社が製造する大型マイニングショベルの稼働データを集計したものである。本データセットは実験的な環境でショベルを稼働させて得たものではなく、製品が実際のマイニング現場でユーザーの手によって稼働させられた際に得られたデータである。そのため、本データセットはマイニング現場の地質、ユーザーの運転状況、ショベルの稼働時間、エンジンへの負荷のかかり方など様々な要素が異なる複数台のショベルの稼働データで構成されている。結果として、本データセットはそれぞれのショベルにおいて摩耗度や摩耗の進行速度が異なる多様なデータセットとなっている。

本データセットは大型マイニングショベルに搭載されたセンサから得られたセンサデータ $\mathcal{X}$ 及びそれらショベルのメンテナンス時に得られた摩耗データ $\mathcal{Y}$ で構成される。センサデータ $\mathcal{X} \in \mathbb{R}^{w \times d \times n}$ は 32 台のショベルから得られ ($w = 32$)、それぞれのショベルからエンジン速度、稼働時間、位置座標など計 53 項目のセンサの計測値が得られる ($d = 53$)。また、各センサの計測値は稼働時間に対して一定間隔で得られ、観測点の個数 n は $440 \leq n \leq 1730$ の範囲で分布している。センサデータ $\mathcal{X}$ には前処理として、各項目の計測値の標準化及び欠損値の線形補完を施した。

上記の 32 台のショベルはそれぞれの観測において最後の観測値が得られたタイミングでメンテナンスを実施し、エンジン主軸受の摩耗度を計測している。すなわち、 i 台目の車両から得られた計測点が n_i 個だとすると、 n_i 個目の計測点が得られたタイミングで i 台目の車両に対してメンテナンスが実施され、そのエンジン主軸受の摩耗度 y_{in_i} が得られる。すなわち、摩耗データ $\mathcal{Y}$ は 32 個の摩耗度 y_{in_i} で構成される。

また、提案手法ではアルゴリズム [P1] において、(7) 式を用いて現在時点の摩耗度を計算するのに比摩耗量 K 、軸受にかかる面圧 P 、軸受のしゅう動速度 V が必要になる。本実験ではこれら 3 つの値を上記の 53 項目のセンサ計測値を用いて次のように定めた。 K : 定数。 P : 最大ブースト圧力 [kPa] $\times$ 平均燃費 [L/h] $\div$ 最大エンジンオイル温度 [$^{\circ}\text{C}$]。 V : 平均エンジン速度 [rpm]。

また、本実験は特に記述のない限り $l=30$ として 30 時点先の摩耗度予測を行った。これは本データセットのショベルの稼働の場合では、予測結果からメンテナンス計画を調整できる十分な猶予を持った将来予測である。

5.2 l 時点先の摩耗度予測の評価

図 2 に提案手法を用いた将来摩耗予測の具体例を示した。また、図 4 に提案手法を用いた摩耗予測の性能評価の結果を示す。ここでは、正解データである 32 件の摩耗データ $\mathcal{Y}$ に対して、その予測値との平均絶対誤差 (Mean Absolute Error, MAE) を性能評価指標とした。また、実験は一つ抜き交差検証を用いて評価を行った。提案手法の他にも複数の回帰モデルを用いて比較を行った。図中に示した比較手法では推定摩耗量 W や推定摩耗度 Z を用いずにセンサデータ $\mathcal{X}$ から直接摩耗度 $\mathcal{Y}$ を回帰するようにモデルを学習した。具体的には、比較手法は i 台目の車両の t 時点のセンサデータ $x_{ij}(t)$ を用いて l 時点先の摩耗度 $y_{i(t+l)}$ を回帰する (j は最大ブースト圧力、平均燃費、平均エンジン速度、最大エンジンオイル温度、累計稼働時間の 5 項目)。実験の結果より、提案手法は他手法と比較して高精度に将来時点の摩耗度を予測できることがわかった。

また、上記のような将来摩耗予測を異なる予測幅にて精度比較した結果を図 5 に示す。横軸は予測幅 l を示し、 $l=15, 30, 45, 60$ として実験を行った。図より、どの予測幅でも提案手法が最も高精度な摩耗予測を達成していることがわかる。また、比較手法は予測幅に対して予測精度のばらつきが大きいのに対して、提案手法は予測幅に関わらず常に安定した性能を示している。これは、比較手法が 1 時点の瞬間的な情報しか扱えないのに対し、提案手法ではエンジン主軸受の経時的な劣化を捉えられるためである。

5.3 [P1] 現在時刻の摩耗度推定の評価

次にアルゴリズム [P1] による現在時刻の摩耗度推定の評価を行う。まず Gompertz 関数による推定摩耗量から摩耗度への変換に関する評価の結果を図 6 に示す。図 6a は Gompertz 関数による推定摩耗量の摩耗度への変換の結果を示す。また、Gompertz 関数以外の手法による結果も図中に示している。こ




図 4: エンジン主軸受摩耗度予測の性能評価




図 7: 現在時刻の摩耗度推定の性能評価




図 5: 異なる予測幅での摩耗予測の性能評価




図 6: Gompertz 関数による摩耗度変換の評価

こで、図中の横軸、縦軸、青点はそれぞれ推定摩耗量、摩耗度、摩耗データを示す。また、図 6b は各手法における推定摩耗量から摩耗度への変換の性能を示している。推定摩耗量から摩耗度へ変換した際の誤差の大きさを MAE を用いて評価している。これら図 6 の結果より、Gompertz 関数が最も高精度に摩耗度への変換を達成できることが示された。また、図 7 には現在時刻の摩耗度推定の性能比較の結果を示す。図中の”Proposed”は提案手法のアルゴリズム [P1] による現在時刻の摩耗度推定の性能 (MAE) を示す。他の比較手法では図 4 での実験と同様、センサデータ x から直接摩耗度 y を回帰している。図より、アルゴリズム [P1] により他手法と比較して高精度に摩耗度を推定できていることがわかる。

5.4 [P2] l 時点先の時系列将来予測の評価

次にアルゴリズム [P2] による時系列将来予測の評価を行う。

図 8 に時系列将来予測の実行例を示す。図 8a は 3 台のショベルの摩耗度 y に対して CubeMarker を実行した結果である。横軸は時間、縦軸は摩耗度を示す。図のように CubeMarker を用いることで自動で摩耗進行状態を健康状態 (レジーム #1)、摩耗初期状態 (レジーム #2)、摩耗後期状態 (レジーム #3)、摩耗収束状態 (レジーム #4) にセグメンテーションすることができる。また、図 8b は図 8a のセグメンテーション結果を用いて SplitCast で時系列将来予測を行った結果である。図中の青線が正解値、赤線が SplitCast による予測値を示す。また、図 9 に時系列将来予測の性能評価の結果を示す。図より、提案手法は比較手法よりも高精度な将来予測を達成している。提案手法では予測モデルとして GRU を用いているが、時系列セグメンテーション結果を応用して各 GRU モデルが個々のレジームを集中的に学習することによって、素の GRU と比較して精度を向上させている。さらに、図 10 に提案手法における GRU モデルの学習にかかる時間の評価結果を示す。図より、提案手法を導入することで素の GRU を用いるより高速な学習が実現できていることがわかる。これは、時系列セグメンテーションにかかるオーバーヘッドよりもモデルの並列学習による学習時間削減の効果が大きいためである。これらの実験結果より、提案手法を用いることで高精度かつ高速な摩耗予測が実現可能であることが示された。

6 む す び

エンジン主軸受の摩耗予測は、機器の適切なメンテナンスを実施するためにも必要な重要な課題であり、本研究では車両の時系列センサデータからエンジン主軸受の摩耗度を将来予測する手法を提案した。提案手法ではセンサデータから推定摩耗量を算出し、またそれを Gompertz 関数を用いて摩耗度へと変換することで現在時刻の摩耗予測を行う。センサデータを用いることで、メンテナンス時にしか得られないイベントデータとしての摩耗度を時系列領域に拡張している。さらに提案手法は将来時点の摩耗度も予測する。時系列パターンごとに時系列予測モデルを用意することで、高速な学習と高精度な将来予測を実現した。また、大型マイニングショベルを対象にした実データでの実験では、提案手法が高精度に摩耗度の将来予測を実現





図 8: 時系列将来予測の実行例




図 9: 時系列将来予測の性能評価




図 10: モデル学習時間の評価

できることを確認した。

謝辞 本研究の一部は JSPS 科研費 JP20H00585, JP21H03446, JP22K17896, 国立研究開発法人情報通信研究機構委託研究 NICT 03501, 総務省 SCOPE JP192107004, JS-TAIP 加速課題 JPMJCR21U4, ERCA 環境研究総合推進費 JPMEERF20201R02 の助成を受けたものです。

文献

- [1] 植木洋輔, 雨川洋章, 沼田逸平, 山東篤生, 中島誠, “時系列計測データを活用したダメージ基準生存時間解析に基づく機器の寿命モデル化 (化学プラント機器への適用の試み)”, 日本機械学会論文集, vol. 86, no. 886, pp. 20-00042, 2020.
- [2] X. Zhang, R. Xu, C. Kwan, S. Y. Liang, Q. Xie, and L. Haynes, “An integrated approach to bearing fault diagnostics and prognostics,” in *Proceedings of the 2005, American Control Conference, 2005*. IEEE, 2005, pp. 2750–2755.
- [3] Q. Zhai, and Z.-S. Ye, “Rul prediction of deteriorating products using an adaptive wiener process model,” *IEEE Transactions on Industrial Informatics*, vol. 13, no. 6, pp. 2911–2921, 2017.
- [4] A. Rai, and S. H. Upadhyay, “An integrated approach to bearing prognostics based on eemd-multi feature extraction, gaussian mixture models and jensen-rényi divergence,” *Applied Soft Computing*, vol. 71, pp. 36–50, 2018.
- [5] Q. Ni, J. Ji, and K. Feng, “Data-driven prognostic scheme for bearings based on a novel health indicator and gated recurrent unit network,” *IEEE Transactions on Industrial Informatics*, vol. 19, no. 2, pp. 1301–1311, 2022.
- [6] D. Wang, K.-L. Tsui, and Q. Miao, “Prognostics and health management: A review of vibration based bearing and gear health indicators,” *Ieee Access*, vol. 6, pp. 665–676, 2017.
- [7] F. Camci, K. Medjaher, N. Zerhouni, and P. Nectoux, “Feature evaluation for effective bearing prognostics,” *Quality and reliability engineering international*, vol. 29, no. 4, pp. 477–486, 2013.
- [8] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *nature*, vol. 323, no. 6088, pp. 533–536, 1986.
- [9] S. Hochreiter, and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [10] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, “Learning phrase representations using rnn encoder-decoder for statistical machine translation,” *arXiv preprint arXiv:1406.1078*, 2014.
- [11] 本田崇人, 松原靖子, 川畑光希, 櫻井保志・他, “大規模時系列テンソルによる多角的イベント予測”, 情報処理学会論文誌データベース (TOD), vol. 13, no. 1, pp. 8–19, 2020.
- [12] J. Archard, “Contact and rubbing of flat surfaces,” *Journal of applied physics*, vol. 24, no. 8, pp. 981–988, 1953.
- [13] B. Gompertz, “Xxiv. on the nature of the function expressive of the law of human mortality, and on a new mode of determining the value of life contingencies. in a letter to francis baily, esq. frs &c,” *Philosophical transactions of the Royal Society of London*, no. 115, pp. 513–583, 1825.
- [14] A. Sottoriva, J. J. Verhoeff, T. Borovski, S. K. McWeeney, L. Naumov, J. P. Medema, P. M. Sloot, and L. Vermeulen, “Cancer stem cell tumor model reveals invasive morphology and increased phenotypical heterogeneity,” *Cancer research*, vol. 70, no. 1, pp. 46–56, 2010.
- [15] M. H. Zwietering, I. Jongenburger, F. M. Rombouts, and K. Van’t Riet, “Modeling of the bacterial growth curve,” *Applied and environmental microbiology*, vol. 56, no. 6, pp. 1875–1881, 1990.
- [16] T. Honda, Y. Matsubara, R. Neyama, M. Abe, and Y. Sakurai, “Multi-aspect mining of complex sensor sequences,” in *2019 IEEE International Conference on Data Mining (ICDM)*. IEEE, 2019, pp. 299–308.
- [17] D. Palaz, M. Magimai-Doss, and R. Collobert, “End-to-end acoustic modeling using convolutional neural networks for hmm-based automatic speech recognition,” *Speech Commu-*

nication, vol. 108, pp. 15–32, 2019.

- [18] T. Almutiri, and F. Nadeem, “Markov models applications in natural language processing: A survey,” *Int. J. Inf. Technol. Comput. Sci*, vol. 2, pp. 1–16, 2022.
- [19] A. Viterbi, “Error bounds for convolutional codes and an asymptotically optimum decoding algorithm,” *IEEE transactions on Information Theory*, vol. 13, no. 2, pp. 260–269, 1967.
- [20] L. E. Baum, T. Petrie, G. Soules, and N. Weiss, “A maximization technique occurring in the statistical analysis of probabilistic functions of markov chains,” *The annals of mathematical statistics*, vol. 41, no. 1, pp. 164–171, 1970.