

自動車や航空機、建設機械などの構造物には通常時々刻々変化するランダム荷重が作用する。その振動の大きさと構造によっては、材料にき裂をもたらす危険があることから、不規則に時間変化するランダム荷重に対して十分な耐久性をもつよう設計する必要がある。長年の使用により疲労損傷を受けた部品や構造物の寿命を予測する場合、応力シミュレーションと累積疲労則や統計解析を組み合わせた理論的アプローチが、非常に有効な方法の一つとなっている。実働荷重下の疲労寿命を予測する代表的な方法として、時間領域で考えるレインフロー法<sup>1)</sup>、および周波数領域で考えるランダム応答解析法<sup>2)</sup>が挙げられる。ここではそれぞれの手法の概要を紹介した上で、自動車の悪路走行を想定した耐久性能評価事例を紹介し、これらの特徴について考察する。また、自動車や鉄道車両のように部品点数が多岐にわたる場合、着目部位の耐久性能を向上するためには、何点もの部品の中から疲労寿命への寄与度の高い部品を選定し、部品設計をおこなう必要がある。そのような場合に機械学習をもちいた解析は有効な手法であり、当社においても電池分野を中心に多くの機械学習による取り組みが報告されている<sup>3-7)</sup>。そこで本稿では、機械学習を活用し短期間で疲労寿命への寄与度の高い部品を選定した解析事例を紹介する。



技術本部 計算科学センター モデルベース解析技術室  
 板谷 元宏 (いただに もとひろ)  
 技術本部 計算科学センター モデルベース解析技術室  
 山中 拓己 (やまなか たくみ)

受ける構造物は、疲労限以下となる応力範囲も少なくない場合があり、その応力範囲レベルも累積疲労損傷比Dに寄与する。疲労寿命を評価する手法として一般的にもちいられるマイナー則による方法では、疲労限以下の応力範囲における破断繰り返し数は $\infty$ として考えることから、変動荷重を受ける構造物の疲労寿命評価においては危険側な評価となる場合がある。疲労限以下の応力頻度を考慮する方法として修正マイナー則、ハイパツハの方法などさまざまな方法が提案されているが、本稿では修正マイナー則をもちいて検討する。なお、ここでは母材のS-N線図を活用して計算した事例を紹介したが、溶接部などの疲労評価においては、溶接継手の種類、仕上げの有無、想定破損箇所などによってS-N線図は異なるため疲労試験にてS-N線図の基礎データを取得する必要がある。<sup>8)9)</sup>

行った事例を紹介する。第3図に示すようにBEVボディを有限要素メッシュでモデル化し、悪路走行時の加振条件を入力とする時刻歴応答解析を行った。なお、解析モデルはBEVボディ(写真1参照)、バッテリーケース、モジュールをそれぞれ加振して得られた実験モーダル解析と一致するよう作成した。加振条件は第4図に示す実環境試験に基づいたパワースペクトル密度(PSD)<sup>10)</sup>を採用し、ランダムに仮定した位相を逆フーリエ変換して算出した。ここではバッテリーケースの取付ボルト(計10本)に着目した。ただし、応力の影響を明確にするため、ボルト径はM6を仮定した。

第5図にバッテリーケースのボルトの実環境試験に基づいた応力履歴を示す。第6図に示すボルト鋼材のS-N線図を使用し、レインフロー法で応力頻度をカウントし、修正マイナー則で疲労寿命を算出した(第7図参照)。10本のボルトの中で、⑤が最も疲労寿命が短く、わずか1.5 minでボルトが疲労破壊することが予想された。なお、今回はPSDから逆フーリエ変換する際、0から200 Hzの周波数範囲におけるデータ点数を256点とし1.28 sec間の時刻歴波形を作成したが、これが統計的に十分な時間領域であるか検証が必要である(後述)。

BEV(電気自動車)の悪路走行耐久性能評価として、バッテリーケースの締結ボルトについてレインフロー法で疲労寿命予測を

## 1.2 時刻歴応答解析による 悪路走行耐久性能評価

## E-1 レインフロー法による疲労寿命評価

### 1.1 レインフロー法をもちいた 応力範囲頻度分布解析法

レインフロー法は、不規則な繰り返し変動荷重を受ける部品や構造物などにおいて、疲労寿命を予測するための応力頻度あるいはひずみ頻度の計数法の一つである。この方法は、荷重変動による時間変化から疲労寿命に寄与する応力範囲(振幅)の大きさを基準に発生回数をカウントする手法である。このようにして求めた応力範囲頻度分布をもとに累積疲労損傷比Dを計算し、疲労寿命回数を予測する。累積疲労損傷比Dは、時間変化に対する不規則な応力範囲が*i*個存在した場合の*i*番目の応力範囲レベルを $\Delta\sigma_i$ 、その頻度を*m<sub>i</sub>*、 $\Delta\sigma_i$ のみが繰り返し作用したときの疲労寿命


を*N<sub>i</sub>*とすると、下記式で計算することができる。

$$D = \sum D_i = \sum \left( \frac{m_i}{N_i} \right)$$


ここに、D: 累積疲労損傷比  
 D<sub>i</sub>: 疲労損傷比

疲労寿命は次のように計算される。はじめに、第1図(ここでは鋼の例)に示すように時間と応力の関係から応力範囲の発生回数をカウントし、応力頻度を求める。次に第2図に示すS-N線図<sup>1)</sup>と第1図に示す応力頻度から疲労損傷比D<sub>i</sub>を算出し、その合計値から累積疲労損傷比Dを求め、疲労寿命を算出する。変動荷重を


第1図 発生応力の時間変化の例(左)、応力頻度の例(右)



第2図 S-N線図の例(左)、疲労損傷比の計算例(右)



第3図 BEVの悪路走行



第4図 悪路走行時の加振条件







写真1 BEVボディ加振試験




第5図 バッテリーケースのボルトの応力履歴





第6図 ボルト鋼材のS-N線図



第7図 レインフロー法で疲労寿命を算出した結果



第8図 バッテリーケースのボルトの応力RMS値




$n_{1\sigma}, n_{2\sigma}, n_{3\sigma}$ : 各発生確率における繰り返し回数  
 $N_{1\sigma}, N_{2\sigma}, N_{3\sigma}$ : 各発生確率における疲労寿命

各発生確率における繰り返し数は、加振時間とランダム応答解析から計算される等価周波数と各発生確率から算出する。

## 2.2 ランダム応答解析による悪路走行耐久性評価

1.2と同様のBEV、PSDを入力加振条件としてランダム応答解析を行った。なお、PSDの試験時間は実環境に基づいた試験<sup>10</sup>から21 hとした。第8図にバッテリーケースの各ボルトの応力RMS値を示す。ランダム応答解析の出力結果は、時刻歴応答解析が時刻歴で変化する応力に対し、応力RMS値のみである点が大なる特徴となる。したがって、ランダム応答解析は、レインフロー法のように時刻歴の応力から応力頻度をカウントし累積疲労損傷比を計算する必要が無く、応力RMS値からS-N線図をもちいて簡単に疲労寿命を算出することができる。応力RMS値から1.2と同様のS-N線図をもちいて修正マイナー則で発生確率99.7%の疲労寿命を算出した結果を第9図に示す。なお、1.2で示したレインフロー法の累積疲労損傷比は1.28 sec間の算出値であるため、21 h相当の累積疲労損傷比に換算した。ランダム応答解析で評価した疲労寿命とレインフロー法によるそれを比べると、ボルトごとの相対的な値はおおむね一致するものの、ランダム応答解析の方が約50%危険側に評価していることがわかる。このように、同じ材料や加振条件であっても、評価方法によって疲労寿命の予測値は大きく変わらえる。

第9図 ランダム応答解析による疲労寿命予測



## E-2 ランダム応答解析による疲労寿命評価

### 2.1 時刻歴応答解析における課題

時刻歴応答解析は直感的に理解しやすいが、考慮すべき時間領域の妥当性や時刻歴の応力データからレインフロー法で寿命予測する際の後処理の手間の多さに課題がある。一方、ランダム応答解析は入力波形のランダム性を考慮しながら周波数領域で計算するため、時間領域の影響を考慮する必要が無い。したがって、レインフロー法で疲労寿命を計算する必要が無く、後処理の手間を削減することができる。

地震や海洋波高、悪路走行などの不規則な振動(ランダム加振)は、その瞬間の大きさは未知であることから、統計的特性(平均値、標準偏差、特定の値を超過する確率など)をもちいて記述される。このようなランダム加振が作用する構造物の応力を予測する方法がランダム応答解析であり、入力加振に直接PSDを入力することで応力RMS値(実効値)が統計的な結果として出力される。ランダム応答解析の疲労寿命を推定する方法は、Steinbergの3バンド法、Dirlik法など多くの手法が提案されている<sup>11-13)</sup>。幅広く活

用されているSteinbergの3バンド法は、不規則な応力応答値の発生確率が正規分布であることを仮定し、不規則な応力応答値を3つの発生確率(1σ、2σ、3σ)の帯域に分割して考える方法である。ここで、σは標準偏差を示す。したがって、各発生確率における応力は下記のように求めることができる。

- ・発生確率68.3%(1σ)における応力=応力RMS値
- ・発生確率95.5%(2σ)における応力=2×応力RMS値
- ・発生確率99.7%(3σ)における応力=3×応力RMS値

各発生確率における応力とS-N線図から各発生確率における疲労寿命求め、各発生確率における繰り返し回数を算出すると、累積疲労損傷比Dは下記式で計算することができる。


$$D = \frac{n_{1\sigma}}{N_{1\sigma}} + \frac{n_{2\sigma}}{N_{2\sigma}} + \frac{n_{3\sigma}}{N_{3\sigma}}$$

ここに、D: 累積疲労損傷比

### 2.3 ランダム応答解析とレインフロー法の疲労寿命予測の差異

前述の通り、ランダム応答解析とレインフロー法では、疲労寿命予測値が大きく異なる結果となった。この理由として、レインフロー法における時刻歴応答解析の時間領域(1.28 sec)が加振パターンの主要な周期に対して短すぎたことが考えられた。そこで、同じPSDで加振時間領域を変更した2水準(1.28, 20 sec)について位相のランダムパターンをAからDの4水準でボルト⑤の疲労寿命予測結果を比較した(第10図参照)。なお、20 secの時刻歴波形はPSDを逆フーリエ変換する際、周波数範囲を0から200 Hz、データ点数4096点として作成した。加振時間が1.28 secの

第10図 加振時間領域と疲労寿命の関係



場合、位相のランダムパターンを変更すると疲労寿命予測結果のばらつきが大きい。一方、加振時間が20 secの場合、位相のランダムパターンを変更しても疲労寿命予測結果はほぼ一定値を示す。したがって、レインフロー法では統計的に十分と判断できる時間領域を確保する必要があり、その条件下においてはレインフロー法とランダム応答解析の結果はおおむね一致する。また、ランダム応答解析のほうが安全側な疲労寿命予測結果になる。

以上、悪路走行などのランダム加振の疲労寿命評価において、

ランダム応答解析は比較的簡単な計算式から疲労寿命を算出することができ、短い解析時間で安全側な評価で疲労寿命を予測することができるため、設計に有効な手法であると言える。ただし、ラ

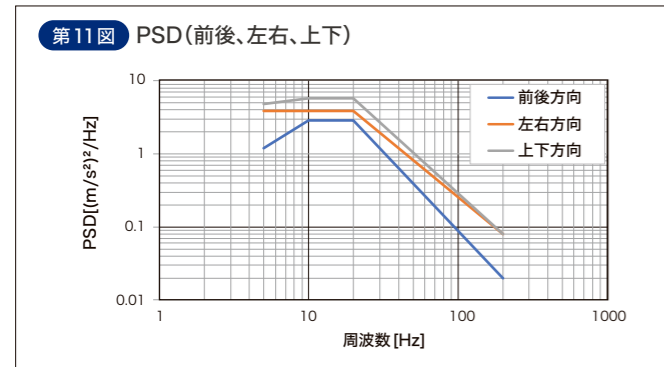
ンダム応答解析は線形領域の計算であるため、部材間の接触やゴム材料などの材料非線形の考慮が必要な非線形問題には活用できない点には注意が必要である。

### E-3 部材の厚みが疲労寿命に及ぼす影響の機械学習による定量的評価

自動車や鉄道車両のように部品点数が非常に多い場合、耐久性性能を向上するためには、何点もの部品の中から疲労寿命への寄与度の高い部品を選定し、部品設計をおこなう必要がある。従来では条件ごとにシミュレーションを行い、部品ごとの特性を評価することが多かった。一方、最近のデジタルツイン技術に代表されるように、シミュレーションと機械学習を組み合わせることで、比較的容易に寄与度の高い部品の選定ができるようになってきている<sup>3-7)</sup>。ここでは、BEVのバッテリーケースを対象とし、応力シミュレーションと線形および非線形の回帰モデルをもちいて、各部材の厚みの違いが疲労寿命へ及ぼす影響を分析する。

#### 3.1 疲労寿命予測手法

疲労寿命予測手法は、容易に計算できる2.2のランダム応答解析を活用する。第11図に示す実環境試験に基づいたPSD<sup>10)</sup>で前後、左右、上下の3軸を同時に加振し、バッテリーケースのボルトの疲労寿命を予測する。



#### 3.2 データセットの構築

第1表に示す部材の厚み(CASE INR、CASE OTR、CASE BRKT、FRAME)を説明変数(入力データ)とし、バッテリーケースのボルトの疲労寿命を目的変数(出力データ)とし重回帰分析をおこなう。CASE BRKTは2種類、FRAMEは5種類の板厚が使用されているが、今回は対象エリアの中から寄与度の高いエリアを抽出することを目的としているため、一つの説明変数内の板厚の組み合わせの違いは考慮しない。説明変数の水準は基準板厚に対する変化率とし、4変数4水準の全ての組み合わせを考慮し256通りのデータセットを作成する。なお、データセット数は設計に活用できることを想定し、数値解析時間(FEMモデル作成除く)と分析が完了までの時間が48時間になるように決定した。

#### 3.3 線形重回帰による検討

重回帰分析は第1表に示すような説明変数xの変動(今回の場合、板厚)によって目的変数yの変動(疲労寿命)の関係を方程式で表現する方法である。線形重回帰モデルでもちいる計算式を下記に示す。

$$y = a_1X_1 + a_2X_2 + \dots + a_nX_n + b$$

ここに、y: 目的変数  
 $a_1, a_2, \dots, a_n$ : 回帰係数(偏回帰係数)  
 $X_1, X_2, \dots, X_n$ : 説明変数  
 b: 定数項

256通りの板厚パターンと疲労寿命の関係データの内、ランダムに選んだ192通りの訓練データと残りの64通りの検証データをもちいて線形重回帰分析を行った(第12図参照)。目的変数は対数を取った場合とそうでない場合の2パターン検討した。元値(数値解析)と予測値(線形重回帰)との関係を回帰分析モデルによって予測した値が真値とどの程度一致しているかを決定係数R<sup>2</sup>値により評価した。決定係数R<sup>2</sup>値は、目的変数を疲労寿命の対数を取ることで20%以上改善した。これは、板厚に対して応力は線形挙動を示すが、疲労寿命は対数に対して線形挙動を示すため目的変数を対数とすることで目的変数が線形近似され予測精度が改善した。

#### 3.4 回帰モデルの検討

3.2の線形重回帰分析の決定係数R<sup>2</sup>値は0.7であったが、さらなる回帰精度向上のため、回帰モデルをランダムフォレストに変更し、学習を行う。


ランダムフォレストは、複数の決定木を組み合わせる予測や分類を行う機械学習の手法である(第13図参照)。決定木はデータを分割するためのYes or Noで回答できるルールをツリー状に表したものである。ランダムフォレストでは、元値から一部をランダムに選んで決定木を作り、その過程で使う特徴量もランダムに選ぶことで、多様な決定木を生成する。そして、予測したいデータの入力条件をすべての決定木に入力し、その結果を多数決や平均値などで集約することで「偏り」や「ばらつき」を小さくして予測精度を高めていく。このように、ランダムフォレストは単一の決定木よりも高い精度や安定性を実現することができる。

第13図に示すように回帰モデルをランダムフォレストに変更することで検証データの決定係数R<sup>2</sup>値が大幅に改善されており、十

第1表 説明変数(入力データ)

No.	説明変数	対象エリア		基準板厚 t(mm)	基準板厚からの変化率			
		全体図	詳細図		-50%	0%	50%	100%
1	CASE INR			1.40	0.70	1.40	2.10	2.80
2	CASE ONR			1.00	0.50	1.00	1.50	2.00
3	CASE BRLT			1.80	0.90	1.80	2.70	3.60
				1.10	0.55	1.10	1.65	2.20
4	FRAME			1.40	0.70	1.40	2.10	2.80
				1.50	0.75	1.50	2.25	3.00
				1.00	0.50	1.00	1.50	2.00
				0.90	0.45	0.90	1.35	1.80
				1.20	0.60	1.20	1.80	2.40

第12図 目的変数の検討結果



分な予測精度を確保できると考えられた。

#### 3.5 寄与度分析結果



部材の厚みがバッテリーケースのボルトの疲労寿命にどのような影響を与えたかを分析するためにSHAP(SHapley Additive exPlanation)<sup>14)</sup>をもちいて分析を行った(第14図参照)。SHAP値は、機械学習モデルの予測結果に対する各特徴量(説明変数)の寄与度を数値化する。第14図(a)から疲労寿命に対してCASE INRの寄与度がもっとも高く、FRAMEがもっとも寄与度が低いと解釈される。また、第14図(b)に部材の厚みと疲労寿命の相関性を示す。第14図(b)はSHAP値(疲労寿命)に対して、説明変数が正の相関(板厚増と疲労寿命長)があるのか負の相関(板厚減と

疲労寿命長)があるのかを示したものである。CASE INR、CASE BRKT、CASE OTRは板厚と疲労寿命が負の相関関係にありFRAMEは正の相関関係を示す。すなわち、CASE INR、CASE BRKT、CASE OTRは板厚を下げるほど疲労寿命は増加し、FRAMEは板厚を上げるほど疲労寿命は増加する傾向であることが分かる。これはバッテリーケースを構成する部品(CASE INR、CASE BRKT、CASE OTR)の剛性を低下させることで、バッテリーケース側が変形しボルト部へ作用荷重を低減したと考えられる。また、FRAMEの板厚を上げることでバッテリーケース全体の振動が減少し、ボルト部に作用する荷重を低減したと考えられる。ただし、バッテリーケース側の板厚を下げると、バッテリーケースの疲労寿命は減少すると予想されるため、バッテリーケースの疲労寿命も含めて評価する必要がある。

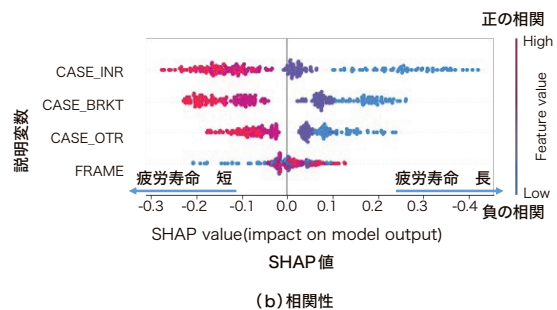

以上のように機械学習を活用した寄与度分析により複数の部材の中からボルトの疲労寿命への寄与度の高い部材を特定し、効率的に耐久性能の向上を検討することができる。また、疲労寿命

を評価する適用範囲をバッテリーケースなどに拡大することで効率的な設計に貢献できると考えている。さらに、機械学習と最適化手法を組み合わせることでさらなる効率化が期待される。

第13図 回帰モデル(ランダムフォレスト)



第14図 寄与度分析結果(SHAP値)



シミュレーションで実働荷重下の疲労寿命を予測した事例について紹介した。線形問題としての取り扱いが可能な場合、ランダム応答解析は設計に活用する上で有効な手法であり、レインフロー法とほぼ同等の精度で疲労寿命を予測できる。また、今回紹介した事例のように実験モーダル解析と検証された解析モデルをもちいることでより高精度な疲労寿命予測が可能となり、耐久性能の実機検証段階で発生する想定外のき裂発生トラブルを削減し、設計開発における手戻り削減に寄与するものと考えられる。さらに、機械学習とランダム応答解析を組み合わせることで、従来と比べて複数の部材の中から疲労寿命への寄与度の高い部材を短期間で特定することができ、設計開発の期間短縮へ貢献できることが期待される。

今後は機械学習を活用し、耐久性能の他、剛性、音に対する寄与度分析をおこなうことでさまざまな設計開発に貢献していきたいと考えている。

参考文献 \*1) 社団法人日本鋼構造協会, 鋼構造物の疲労設計指針・同解説-付・設計例-[2012年改定版](2014)  
 \*2) 伊藤章人ほか: 材料, Vol.57(2008)No.12  
 \*3) 山中拓己ほか: R&D神戸製鋼技報, Vol.71(2021)No.1  
 \*4) 山中拓己ほか: こべるにくす, NOV.2019, No.49  
 \*5) 野口暁ほか: こべるにくす, NOV.2022, No.55  
 \*6) 高岸洋一ほか: こべるにくす, APR.2022, No.54  
 \*7) Y.Takagishi et al.: Batteries, Vol.54(2019)No.5  
 \*8) 種子島亮太ほか: 日本機械学会論文集A編, Vol.76(2010)No.770  
 \*9) 種子島亮太ほか: 日本機械学会論文集A編, Vol.78(2012)No.787  
 \*10) 前田清隆ほか: 自動車技術会予稿集, Vol.46(2015)No.1  
 \*11) F.Sherrat, pp.93-1113(2000), NAFEMS Ltd..  
 \*12) D.Benasciuttiet al., Department of Engineering, University of Ferrara, Italy(2005)  
 \*13) S.Okajima et al., ASME, PVP2005-71682(2005)  
 \*14) S.Lundberg et al., A Unified Approach to Interpreting Model Predictions, arXiv:1705.07874.