

HALT結果と機械学習モデルを用いた、製品の堅牢性と公表寿命の関係性に関する考察

A Study of the Relationship between Product Robustness and Publication Lifetime Using HALT Results and Machine Learning Models

福田 貴之* 藤本 恵一

Takayuki FUKUDA Keiichi FUJIMOTO

1. 概要

米国のメーカーに製品を納入する場合、航空機、半導体等のメーカーから HALT (Highly Accelerated Limit Tests) 結果を要求される場合があり、各メーカーは入手した HALT 結果より独自の判断基準を作成していると考えられる。HALT 結果の活用例としては McLean[1]らが報告した統計手法を用いて MTBF を予測する方法が示されている。これらより、各メーカーは集めた HALT 結果から、機械学習により採用の良否や寿命を判断するモデルを作成しているのはいかとう推定していた。

そこで本報では、寿命が公開されている製品として以前にも HALT に関する報告で使用した DC ファン[2]を対象として、HALT 結果(堅牢性)と公表寿命の相関性について機械学習モデルを作成し考察を行った。

2. HALT の条件と結果

2.1 供試品選定

寿命が製品仕様や試験データにより既知であり、比較的安価で入手可能な供試品を検討した結果、以前に HALT を実施した DC ファンを選択した。以下に供試品の選択条件を、表 1 に供試品の一覧を表示する。

- ・機械学習の目的変数として公表寿命(L10)を使うが、同一寿命の供試品を複数個使用する。
- ・同じメーカーの供試品で訓練データ (75%程度) が設定できる個数とし、残りを別メーカー品とする。

・温度と振動の動作限界値、ファン回転数、電流データ製品仕様を元データとして説明変数を作成する。そのため、回転数モニタ端子を持ち、モデル精度向上のために可能な限り広い公表寿命範囲から製品を選ぶ。

表 1 供試品一覧

供試品名	メーカー	使用温度範囲(°C)	40°C寿命(万時間)	個数
FAN1	A	-40~85	16	4
FAN2	A	-20~60	5	4
FAN3	A	-20~70	9	4
FAN4	A	-20~70	22	4
FAN5	A	-30~70	22	1
FAN6	B	-10~60	4	2
FAN7	C	-20~85	10	1
FAN サイズ80*80*25mm、定格電圧12V、軸受けはベアリング				

2.2 試験条件

共通試験条件を表 2 に示す。ステップストレス試験は供試品 4 個を HALT 装置に取付け、低温ステップ、高温ステップ、振動ステップを 1 セットとして 5 回実施した。各ステップストレス試験の供試品は表 3 の HALT 結果一覧に示す。供試品は図 1 に示すように振動テーブルに固定し、供試品取付位置での振動レベルの差は各固定治具上の振動レベル測定値から補正を行った。

表 2 共通試験条件

供試品	取付け治具	図 1 参照
	供給電圧	定格電圧
機能試験	項目	ファン回転パルス、電圧、電流
	稼働限界	回転数が70%以下、異常動作
温度範囲	-100~130°C	
振動範囲	5~75Grms/5Grms間隔	

* エスペック株式会社 テストコンサルティング本部 HALT 営業グループ
〒651-1514 神戸市北区鹿の子台南町 5-2-5 e-mail: halthass@espec.co.jp

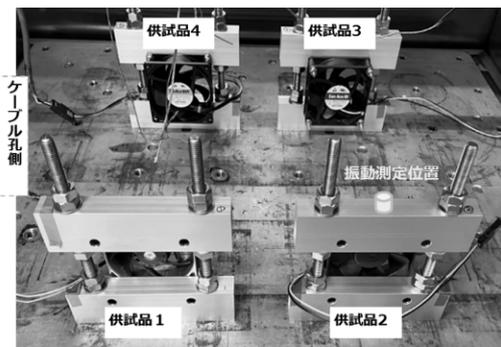


図1 供試品の振動テーブル取付け状態

2.3 HALT の結果

結果は、低温動作限界 (LOL), 高温動作限界 (UOL), 振動動作限界 (VOL) と機能試験結果として、電流変化, 回転数変化が得られた。表3には LOL, UOL, VOL のみを示し, その他のデータについては機械学習の説明変数の選択で説明する。40°C寿命(万時間)は以降, 寿命(万時間)又は寿命と省略する。

表3 HALT 結果一覧

試験	FAN	index	寿命(万時間)	LOL	UOL	VOL
1	1	0	16.2	-90	130	50
	2	1	5.3	-70	130	75
	3	2	9.0	-80	130	75
	4	3	21.5	-80	130	75
2	1	4	16.2	-80	130	50
	2	5	5.3	-80	130	65
	3	6	9.0	-80	130	75
	4	7	21.5	-90	130	70
3	5	8	21.5	-80	130	40
	6	9	4.1	-60	130	45
	6	10	4.1	-60	120	25
	7	11	10.0	-90	130	75
4	1	12	16.2	-80	130	55
	1	13	16.2	-80	130	45
	3	14	9.0	-80	130	75
	4	15	21.5	-80	130	75
5	2	16	5.3	-90	130	75
	2	-	5.3	-90	-	55
	3	17	9.0	-80	130	75
	4	18	21.5	-80	130	75

3. 機械学習用データ作成

3.1 特徴量の作成

表3に示したように実測データは20個で, 1個はデータの一部欠損のため19個のデータで機械学習を行うことになる。データ数が少ないためにモデルの精度が低下する可能性があるため, 説明変数を増やすことで機械学習の結果を安定させることにした。

6個程度の実測及び仕様値から39個の特徴量を作成したが, 多重共線性 (特徴量間の大きな相関性)

が生じる可能性が高く, 重回帰分析系モデル作成時の過学習により, 不必要に複雑なモデルが生成する可能性がある。

そのため作成した特徴量と寿命, 特徴量間の相関図より, 特徴量間の相関が大きい変数を取捨選択して説明変数を選び, 正則化の方法を用いてモデル作成時に過学習を防止することで, 説明変数がある程度多い場合でも, 良好なモデルの作成が行える。作成した特徴量について以下に説明を追加している。

- RF: Morris[3]が示した HALT 結果の評価指標で以下に説明を引用する。

「温度ロバストネスファクター (RF_T) は, 異常が発生した温度範囲 (A_{anomaly}) の設計温度範囲に対する比率である。RF_Tは, 以下の式に従って, 低温と高温の異常が発生した温度で計算することができる。ここで, T_{low}とT_{high}は製品設計の温度制限であり, T_{mid}は低温と高温の設計温度制限の平均を示す。」 (筆者訳)

- 回転パルス及び電流の分散
 - 分散のデータをそれぞれ3種類作成した。
 - 分散(1): 各ステップストレス試験の初期値~限界値までの全てのデータを用いて各供試品で計算。
 - 分散(2): 各限界値の範囲のみで各供試品で計算
 - 分散(3): 全供試品中で最小の限界値にあわせて各供試品で計算。
- 特徴量を正規化するために Zscore を使用した。

3.2 説明変数の選択

39個の特徴量から相互及び寿命との相関を考慮し表4に示す11個を説明変数として採用した。目的変数は表3の列名 '寿命' を 'life' に変え, 1列目として説明変数と結合して, 機械学習用データ (以降 data1) とした。紙面の都合で図2に説明変数2例のみを示す。

表4 説明変数一覧

変数名	内容説明
LOL	低温動作限界
RFTlow	低・高温ロバストネスファクター
RFThigh	
VOL	振動動作限界
L_f_vr_ln	低・高温ステップ時の回転パルスの分散(1)の対数
U_f_vr_ln	
L_i_vr_ln	低温ステップ時の電流の分散(1)の対数
VOL_f_vr_ln	振動ステップ時の回転パルスの分散(2)の対数
LVOL_f_vr_ln	振動ステップ時の全供試品中の最小VOLでの回転パルスの分散(3)の対数
LOL_i_av	低・高温ステップ時の電流の20°Cに対する変化
UOL_i_av	

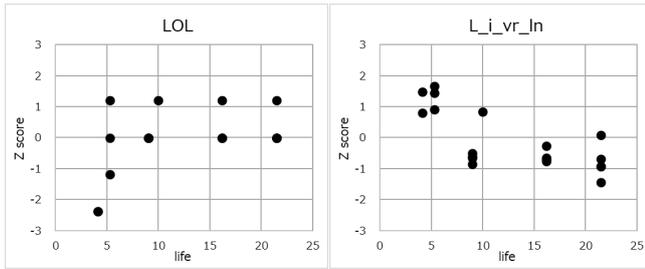


図2 説明変数例

4. リッジ回帰による寿命相関

4.1 寿命推定モデルの検討

寿命推定モデルについては正規分布を前提として通常の重回帰と、正則化による過学習を抑制できるリッジ回帰とラッソ回帰のモデルをPythonで作成した。またプログラムの作成については生成AIを活用した。テストデータを5個とした場合の各モデルの決定係数R²の結果を表5に示す。リッジ回帰が良い結果となったため、これをモデルとして採用した。

表5 決定係数R²比較表

alpha	線形回帰		リッジ回帰		ラッソ回帰	
	train data	test data	train data	test data	train data	test data
0.01	-	-	0.812	0.936	0.834	0.914
0.1	-	-	0.763	0.742	0.712	0.713
1	0.965	-3E+15	0.718	0.613	0.542	-0.074
10	-	-	0.587	0.086	0.187	-0.233

4.2 リッジ回帰による寿命推定モデル作成結果

リッジ回帰により欠損データを削除した19個のデータで、テストデータ数の違いによるモデルの変化を確認した。R²とMSEを評価値とした。実施結果の条件、評価値を表6に示す。

表6 リッジ回帰のデータ検討結果

データ名	data1			
	testdata数	5	7	9
λ	0.614	0.509	1.707	
R2_traindata	0.893	0.892	0.857	
R2_testdata	0.917	0.924	0.871	
MSE_traindata	4.368	4.872	6.698	
MSE_testdata	3.889	2.686	4.891	

テストデータ数による影響は僅かであった。クロスバリデーション(以降CV)の分割数を4にするためテストデータを5個とし、モデルの検証を行った結果を表7に示す。

その結果、テストデータがindex10~18の間で訓練&テスト評価値が良好であった。index0~9をテストデータにした場合のテスト評価値が少し低いのは、データのばらつきなどにより過学習気味になってい

ることが原因と考えられる。回帰モデルを他に変更することも考えられるが、データが少ないためのばらつきの影響が推定されるので、データを増やしての検証が優先と考えている。

表7 リッジ回帰CV結果

データ名	data1				平均	
	testdata index	0~4	5~9	10~14		14~18
λ		2.057	0.614	1.177	0.614	
R2_traindata		0.915	0.992	0.906	0.893	0.927
R2_testdata		0.702	0.662	0.833	0.917	0.779
MSE_traindata		3.886	0.274	4.590	4.368	3.279
MSE_testdata		9.898	19.836	3.559	3.889	9.295

testdata index=14~18の場合の、正則化項の損失係数λの検討グラフ図3に、λ=0.614のときの公表寿命と予測寿命の相関グラフを図4に示す。

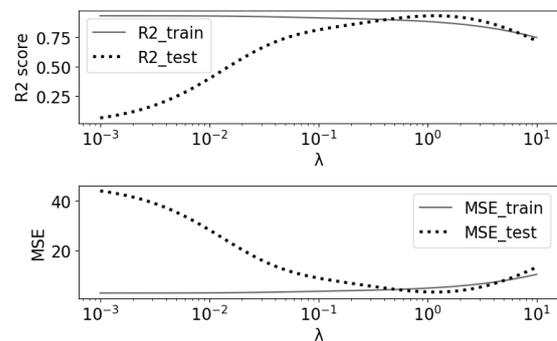


図3 損失係数λの検討グラフ

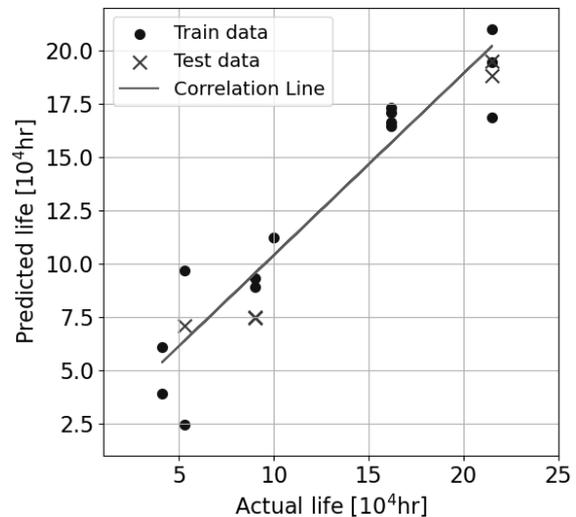


図4 公表寿命と予測寿命の相関グラフ

4.3 リッジ回帰による寿命相関のまとめ

表7と図4に示した通り、data1を用いた範囲では、異なった会社の製品も含めて最も良い結果で90%程度のR²スコアで寿命推定可能なことが判った。

但し、データが少ない部分を説明変数の数で補っているため、モデルが複雑な方向に振れている可能性があると考えられる。

5. ロジスティック回帰による寿命分類

5.1 寿命分類モデルの検討

寿命分類については正則化ロジスティック回帰分類を用い、表 8 に示すように、テストデータ数と寿命閾値を変更して確認したところ、テストデータが 5 個では寿命閾値に係らず訓練・テストの全データの正解率が 1 になる C の値が存在した。この場合 C が小さくなるとモデルが複雑化することを考慮し、寿命閾値 10 (万時間)、C=0.5 を採用した。図 5 に示すように分類は正確であり、正解率、適合率、再現率は全て 1 であった。

表 8 テストデータ数及び寿命閾値と正解率

testdata index	10~18	14~18		
寿命閾値 万時間	10	6	15	
全データの正解率が 1 になる C 値	なし	0.5	0.1	0.25

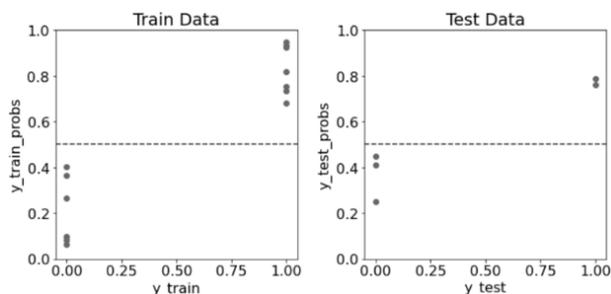


図 5 目的変数とその予測確率

5.2 CV で寿命分類モデルを検証

評価スコアが良すぎるため、CV による検証を行った。テストデータ数は 5 個とし、全 19 個のデータからは 1 個を重複使用することで、データの先頭から順に 4 回のテストデータの取り出しを行い、各残りのデータで C=0.5 として訓練したモデルで予測を行った。表 9 に示す CV 結果より、テストデータの正解率平均=0.95 となり、モデルの精度は良好であると判断した。

表 9 CV 結果

C	0.5			
testdata index	0~4	5~9	10~14	14~18
traindata 正解率	1	1	1	1
testdata 正解率	1	1	0.8	1
traindata 正解率平均	1			
testdata 正解率平均	0.95			

5.3 寿命分類結果まとめ

結果に示した通り、得られたデータを活用した範

围では、異なった会社の製品も含めて非常に良好な分類が可能であった。サイズ違いも含めて複数社のファンのデータを追加することで、堅牢性データからファン選択時の汎用スクリーニングツールとして使用できる可能性も考えられる。

6. おわりに

今回使用したデータの範囲内では、回帰ではリッジ回帰、分類ではロジスティック回帰を使用することで、DC ファンの公表寿命について HALT 結果と良好な相関関係を数値化することができたと考えている。

また、モデル作成において、実測データ数が少ないため説明変数を増やして評価値を向上する方法を用いたが、過学習気味のモデルになっていることも懸念している。供試品として DC ファンを用いることを継続するのであれば、様々なメーカーの製品データを追加して汎用的な分類の可否を確認することも必要である。

機械学習の手法については、データ分布に応じた適正なモデルの選択などは検討が十分に行えていないので、今後も改善に取り組んでいきたい。

参考文献

- [1] Harry McLean, Mike Silverman, 「From HALT Results to an Accurate Field MTBF Estimate」, 2010 Annual Reliability and Maintainability Symposium (RAMS), 25-28 Jan. 2010
- [2] 藤本恵一, 前川 裕行, 「HALT によるDC ブラシレスファンの比較評価と機能試験での機械学習活用」, 日本信頼性学会第29回春季信頼性シンポジウム, 2021.
- [3] Garron. K. Morris, Rockwell Automation, 「Taking the (Emotional) Stress Out of HALT」, 2017 Annual Reliability and Maintainability Symposium (RAMS), 23-26 Jan. 2017.

(ふくだ たかゆき/エスペック株式会社)