

信頼性に関する評価・解析の現状と 機械学習の活用について

エスペック株式会社
藤本 恵一

製品の設定寿命や安全性を確保することは必須であり、そのために製品開発プロセスの中で長期の信頼性評価を行い、問題が無いことを確認しているのが現状である。しかし、近年では製品開発サイクルの短期化や車載電子機器などに対する評価の長期化などが、製品開発期間に影響を及ぼしている。ここでは加速試験の現状とさらなる試験時間短縮の候補として、機械学習による試験結果の評価・予測などを紹介する。

1. はじめに

図1は製品開発プロセスの概念図で、その中に信頼性試験やそれに伴う故障解析及びフィードバック等が含まれており、製品品質を担保する仕組みになっている。

信頼性試験はおおまかに、信頼性適合試験、信頼性決定試験、信頼性比較試験の3つに分けられる。信頼性適合試験は公的な規格試験項目が多数含まれ、環境試験や機械的試験などが含まれる。信頼性決定試験は品目の信頼性を1つ以上の尺度を使って定量化する試験で加速・寿命試験が含まれる。信頼性比較試験は類似の機能をもつ2つの製品間の信頼性を比較する方法で、限界試験が含まれる。これらは図1の製品開発プロセスに示したようなタイミングで実施され、長い試験時間や量産前の適合性不良は、製品開発プロセスの進行に影響を与えるこ

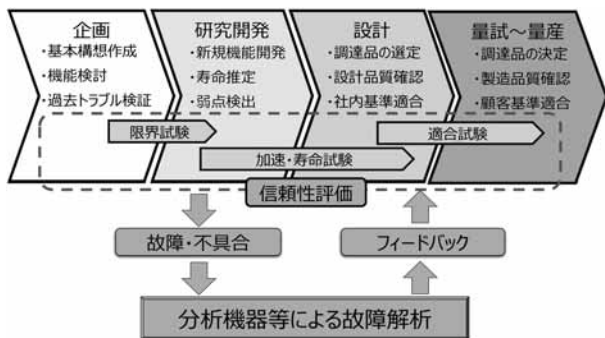


図1 製品開発プロセスと信頼性評価

とになる。そこで、開発初期の不具合検出や加速率の高い試験を行うことは、製品開発時間の短縮にも有効である。

2. 加速試験

加速試験は基準より高いストレスを加え、対象の故障発生までの時間を短縮する試験方法で、試験が成り立つには二つのストレス条件間で同じ故障モードを持ち、相関が規則化できることが必要となる。

2.1 加速試験の考え方

加速試験の考え方^{[1][2]}として、温度加速モデル、ストレス-ストレングスモデルを例示する。また、その他の加速試験は表1に示す。

(1) 温度加速モデル(アレニウスモデル)

電子部品の寿命予測などに使われており、アレニウスの式に基づき、以下の手順で試験を行う。

- ・常温以上の温度設定で寿命試験を数系列実施し、結果のワイブルプロット(図2)より、各温度での平均寿命などを求める。
- ・図3に示す様に、横軸 = $1 / \text{絶対温度}$ 、縦軸 = 寿命時間として、平均寿命をプロットし、常温時の寿命を外挿して求める。




図2 ワイブルプロット

$$L = A \exp\left(\frac{-Ea}{kT}\right) \quad : \text{アレニウスの式}$$

$$\ln L = \ln A - Ea / kT : \text{両辺対数化}$$




図3 温度加速試験からの常温寿命の予測

(2) ストレス-ストレングスモデル

図4に示すストレス-ストレングスモデルによる故障は、経年劣化による強度劣化から発生する。このモデルでは振動などにより大きなストレスを加え、負荷と強度の重なりをわざと作り出すことで、短時間で故障の有無を確認する。




図4 ストレス-ストレングスモデルによる故障

(3) その他の加速試験

表1 その他の加速試験

ストレス	故障モデル	加速試験例
温度、湿度 電圧等	アイリング型	・接着部の寿命推定 ・電解コンデンサの寿命推定
電圧 湿度等	n乗則	・樹脂封止部品の劣化試験 ・コンデンサの劣化試験
熱疲労	修正Coffin-Manson	・はんだ接続部の寿命評価
振動/疲労	マイナー則	・部品や材料の寿命評価 ・車載機器等の耐久評価
クリープ	Larson-Miller	・樹脂材料の耐久試験

2.2 加速試験の課題と高加速試験

現状の加速試験に対して、市場から以下のような要望を受けることがある。

- (1) 「試験時間短縮の要望」として、製品開発サイクルの短期化や故障率・寿命への要求レベルが高いため、信頼性試験が長期化する。このため、さらに試験期間を短縮したい。
- (2) 「従来型試験の限界」として、従来型試験に適合しても市場で不具合が発生する。従来型試験では異常がないが、強制的に故障を発生させたい。

「試験時間短縮の要望」に対しては、HASTや高加速冷熱衝撃試験の適用、限界試験(HALTなど)による開発初期での不具合の顕在化、故障モードの同一性の制限から加速率が上がらない場合は、データ処理技術(例えば機械学習)などによる予測スクリーニングの活用が考えられる。「従来型試験の限界」については、使用範囲外のストレスを加える限界試験が有効な場合がある。

2.3 高加速試験による対応

既存の高加速試験としては、Air-HASTや高加速冷熱衝撃試験などが活用できる場合がある。

(1) Air-HASTの例^[3]

従来のHASTは槽内の加圧のために水蒸気を発生させ、その際槽内の空気を排気弁から排出していた。そのため槽内が酸化による故障が発生しない環境となり、高温

高温試験と故障モードが一致しない場合があった。Air-HASTは槽内に空気を残留させることで、酸化の影響が大きい故障に対して従来試験との相関性を維持し、加速試験が成立するようになる。試験例として、鉛フリーはんだによる半導体リードフレームから発生するウスカの評価結果を表2に示す。これにより、Air-HASTが高温高湿試験と同じ故障モードで、高い加速性を持つことが判る。

表2 鉛フリーはんだからのウスカ発生評価

試験方法	試験条件	試験時間(h)	ウスカの発生
高温高湿	85°C 85%	3000	有り
HAST	110°C /85%	200	なし
Air-HAST	110°C 85%	200	有り

(2) 高加速冷熱衝撃試験の例

従来の冷熱衝撃試験機に対して、槽容積縮小と温度制御の最適化を行った高加速冷熱衝撃試験機を使用し、温度変化時間(ΔT=165°C)を短縮することで、従来比で1サイクル当たり1/3の時間で試験可能とした。

供試品として鉛フリーはんだ(Sn3.0Ag0.5Cu)でチップ抵抗を実装したテスト基板を使い、冷熱衝撃試験を実施した。各経過サイクルでの断面観察結果(図5)より、高加速と従来型のクラックの進展はほぼ同等で、他の検証結果と併せて故障モードは従来型と同等で加速試験の要件を満たしていた。実際の寿命予測に際しては、供試品に応じて加速式のパラメータを確認することは必要である。




図5 はんだ部の断面観察(3216サイズ)

2.4 限界試験による対応

実施可能な限界試験の一つとして、HALT(Highly Accelerated Limit Test=高加速限界試験)がある。HALTは温度と振動を組み合わせた強いストレスを、ステップストレス試験を用いて供試品に加え、応答として得られたその稼働マージンと弱点に対して必要な改善を行うことで、製品信頼性を向上させることを目的としている。そのため、製品開発の比較的早い時期で実施される事が多い。

HALTを実施する装置(HALT装置)は、強いストレスを加えるために、高速温度変化(60°C/min以上)と6自由度振動を備えることが要件となっている。

図6にチップ型コンデンサ実装基板を供試品として、設定振動対コンデンサ脱落時間を求めた試験からのワイブルプロットを示す^[4]。試験はHALT装置及び単軸振動装置を用いて行った。各設定振動での傾き(形状パラメータ)より故障モードの変化点は設定振動50Grms付近と推定されたので、脱落したコンデンサリードの破面観察により、故障モードの変化を確定(疲労⇒脆性破壊)した。この結果より故障モードが疲労破壊の領域でHALT及び単軸振動を含めて加速試験が成立つように見える。但し、これは本試験条件に限定した結果であり、汎用的に成立つことはまだ確認されていない。

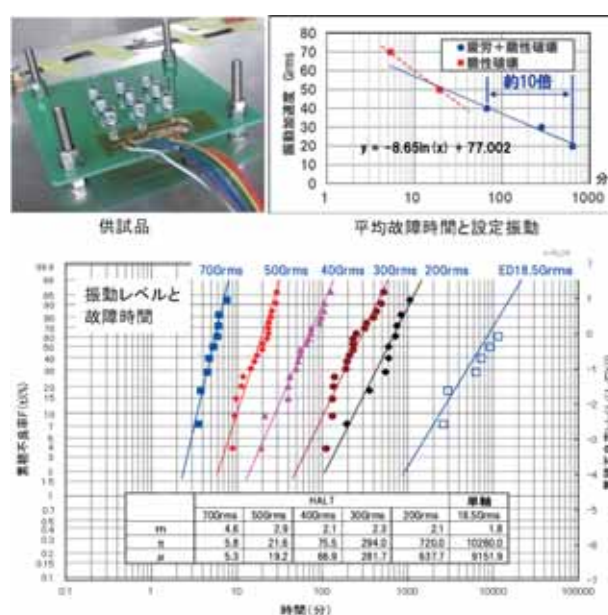


図6 振動レベルによる故障時間と故障モードの関係

2.5 機械学習(データ処理技術)による対応

先に述べたように、加速試験の加速率はストレスを大きくしても、故障モードの同一性の制限があるため、比例して加速率が上がる訳ではなく、試験方法で試験時間を短縮するのは容易ではない。そこで深層学習の発展と共に、データ処理技術の大きな流れとなっている機械学習に着目し、下記のような目的設定でソフト的な時間短縮の可能性を検討することにした。


- ・時系列データの異常検知:故障発生検知など
- ・結果予測:2次電池の寿命、冷熱衝撃試験の結果など
- ・画像解析:温度分布予測、破面解析など

機械学習とその事例については、次の3.に記載する。

3. 信頼性評価への機械学習の活用

機械学習はAIに内包されるデータ処理技術の一つで、コンピュータに与えたデータに基づき、特徴の抽出とそれに基づくモデル化を行い、作成したモデルに基づく予測や分類を自動的に行う手法である。そのため、理論的な裏付けや過程があやふやでも、予測が当たる(誤差が小さい)ことが重要と考えられる側面がある。時系列的には、図7に示すようにAIが最初に提唱され、これに含まれる機械学習から深層学習に進むにつれ、自動的に高精度なデータ分析が可能な方向に進化している。

機械学習には、説明変数に対する目的変数の正解値(実測値)に相当する「教師データ」の与え方により、「教師あり学習」と「教師なし学習」に大別され、それぞれ回帰・分類とグループ分けなどに使用される。



(総務省ICTスキル総合習得プログラムより)

図7 AI、機械学習、深層学習の包含関係と隆盛

機械学習の一般的な流れは、使用ソフトの準備、データ入手、データの可視化と前処理、特徴量の抽出、モデル作成と調整、複数モデルの融合、予測、結果の評価、の順序となる。ここで、特徴量の抽出～複数モデルの融合まで

の過程を自動化により補助するのが、AutoML(自動機械学習)に当たり、同じ部分に多層ニューラルネットワークを使用したのが、深層学習と理解するのが判り易い。

3.1 機械学習のためのツール

信頼性評価のように、現象のモデル式を考慮して予測を行う機械学習に使用するツールは、科学計算用のライブラリ群をプログラム中から呼び出して使うPython言語又はR言語が適当であり、後ほど紹介する事例でもどちらかの言語を使って機械学習プログラムを作成している。また、プログラム作成が難しい場合には、市販又はオープンソースでユーザーによるプログラムが簡便又は不要な、GUIタイプの機械学習ツールの使用も目的により可能である。ここでは各ツールの説明は省略する。

3.2 時系列データからの異常検知例

さまざま現場や試験の計測データは、電圧や電流などを一定時間間隔で記録する時系列データに相当し、過去からも異常な電圧など閾値を超えた場合に警告を出す用途に用いられてきた。信頼性試験に機械学習の適用を考えたのは、HALT試験時の供試品モニタデータ(電圧)から異常を判り易く判別するためで、そのために参考としたのが井出の著書^{[5][6]}に記載された機械学習による心電図データの異常検知方法である。この方法は回帰・分類手法であるk近傍法と部分時系列法を用い、R言語で作成されていたので、それを参考にHALTの時系列データの取扱いに合わせてプログラムを作成した。プログラムでは、図8に示す全データ中の3000番までを教師データ(正常値)とし、残りを検証データとして異常度を計算(図9)し異常を検出できることを確認した。なお、心電図データはWEBで公開されている。




図8 心電図データ




図9 検証データの異常を検出

以上の検証で、異常を検出できることを確認したので、DCDCコンバータ^[7]に対して、HALT振動を5G間隔で上昇させたステップストレス試験の出力電圧モニタデータに対して、同様に機械学習プログラムで処理すると、図10に示す僅かな出力電圧低下が、異常の始まりと区別することができた。

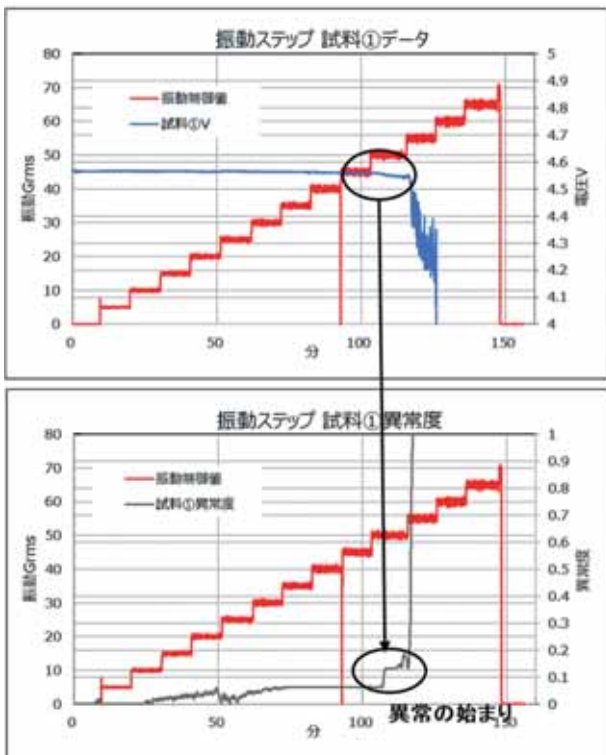


図10 検証データの異常を検出

3.3 時系列データからの予測例

信頼性試験において、試験途中までの時系列データから、閾値に達する時間を予測することで、スクリーニング手法として試験時間短縮が行える可能性がある。

この事例では、熱衝撃試験の進行に伴い、供試品に実装されたチップ抵抗はんだ部の抵抗変化データ^[8]から、

R言語と時系列データ予測ライブラリ「Prophet」の非線形モデルを使用して、1200サイクル迄の抵抗値を教師データとして閾値に達する時間を予測した例で、実測及び予測結果を図11に示す。結果より、2000サイクル付近までは、実測と予測がほぼ一致しており、それ以降はクラックの進展によりモデルからの乖離が進んだと推定される。「Prophet」による予測は簡単な設定でほぼ自動で行えるので、有効な予測手段と考えている。




図11 熱衝撃試験中のはんだ抵抗値よりの予測結果

3.4 リチウムイオン電池の寿命推定例

充放電回数に対するリチウムイオン電池の寿命は非線形挙動を示すため、初期の充放電試験の結果から寿命時間(充放電回数)を予測することは困難である。この課題に対して機械学習を使用して、初期データからの寿命予測を行ったのが、「Data-driven prediction of battery cycle life before capacity degradation」^[9]に掲載された方法である。この論文では機械学習のための充放電試験データとPythonのデータベースへの読み込みプログラムが公開されていたので、論文の記載に基づいて、Pythonによる予測プログラムを独自に作成した。充放電試験データはEV用としても使用され始めているリン酸鉄リチウムイオン電池に対し、EVの急速充電の対応したさまざまな充放電速度で行った試験結果が含まれており、教師データ、テストデータ1、テストデータ2の3つに分割して、教師データの100サイクルまでから抽出した特徴量をモデル作成に使用している。実測寿命と作成したプログラムによる予測寿命の比較グラフを図12に、計算結果の評価値と論文の評価値を併記したものを表3に示す。

作成したプログラムによる予測精度は論文と類似して

おり、100サイクルまでの短期データから2000サイクルまでの寿命予測を再現できた。

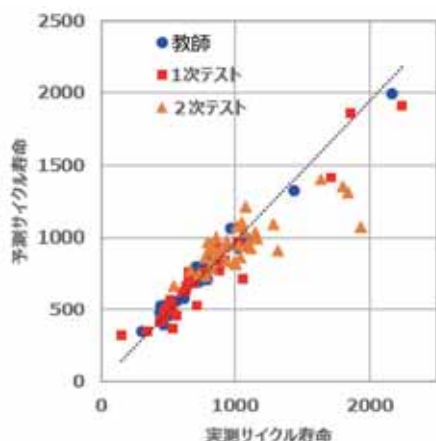


図12 実測寿命と作成プログラムによる予測寿命の比較

表3 計算結果の評価値と論文の評価値

	二乗平均平方根誤差 (RMSE)			平均%誤差 (MAPE)		
	訓練	1次テスト	2次テスト	訓練	1次テスト	2次テスト
論文	51	91	214	5.6	14.1	10.7
プログラム	59	105	219	7.4	9.6	12.4

4. まとめ

本報告では、まず製品開発プロセスにおける加速試験方法と課題点を説明し、試験方法での課題解決として、高加速試験又は限界試験による方法を事例にて説明した。しかし、加速率を簡単に大きくするのは難しいので、機械学習によるソフト的な時間短縮を考えた。機械学習の実施事例に示したように、試験データを機械学習で処理することで、試験の初期データのみを使用して、はんだ接続部の寿命やリチウムイオン電池のサイクル寿命が予測できることが確認できた。この考え方は他の試験にも適用可能と考えており、機械学習で最も時間を必要とする特徴量抽出とモデル作成の半自動化も含めて、検討を続ける予定です。

参考文献

- [1] 山本 敏男「加速試験と信頼性へのガイダンス 電気・電子機器および部品の場合」、ESPEC技術情報 No.4.
 [2] 田中 浩和、「加速試験の現状と課題」、エレクトロ

ニクス実装学会誌 Vol.13, No.7, 2010.

- [3] 青木 雄一、「Air-HASTによる表面腐食の加速試験」、表面技術、Vol.70, No.6, pp.297-300, 2019.
 [4] 藤本 恵一、河合 秀己、前川 裕行、「HALT(6自由度振動)と電動加振(単軸振動)が供試品に与えるストレスの相関性についての一考察 第2報」、日本信頼性学会第32回秋季信頼性シンポジウム, 2019.
 [5] 井出 剛、「入門機械学習による異常検知-Rによる実践ガイド」、コロナ社, 2015.
 [6] 井出 剛、「部分時系列クラスタリングの理論的基礎」、The 20th Annual Conference of the Japanese Society for Artificial Intelligence 2A1-2, 人工知能学会, 2006.
 [7] 藤本 恵一、河合 秀己、前川 裕行、「小型DC-DCコンバータを対象としたHALT評価及びHASS条件の設定」、日本信頼性学会第33回秋季信頼性シンポジウム, 2020.
 [8] 青木 雄一、辻江 一作、永井 孝幸、「はんだ接合部の熱疲労試験に及ぼす温度変化率の影響」、エスベック技術情報No.50, 2007.
 [9] Kristen A. Severson etc 「Data-driven prediction of battery cycle life before capacity degradation」 Nature Energy volume 4, pp.383-391, 2019.



藤本 恵一(ふじもと けいいち)

- 1985年 三洋電機株式会社 製品開発、品質評価などに従事
 2012年 パナソニック株式会社 信頼性及び安全性評価などに従事
 2018年 エスベック株式会社 信頼性試験技術の開発に従事