ノート

ディープラーニングを用いた不具合解析手法の検討
－電圧変動試験への時系列予測の適用－

石澤　賢太*　山川　泰弘*　木嶋　祐太*　牧野　斉*

Study of Failure Analysis Methodology using Deep Learning
– Application of Time Series Prediction to Voltage Fluctuation Test –

ISHIZAWA Kenta*, YAMAKAWA Yasuhiro*, KIJIMA Yuta* and MAKINO Hitoshi*

1. 緒　　言

電圧変動試験は，電圧ディップや短時間停電等の電圧変動に対して，電源に接続する電気電子機器が性能劣化せずに動作することができる能力を評価するものである。評価方法や電源電圧変動波形は，IEC 61000-4-11，IEC 61000-4-29 といった EMC 試験規格として規定されているが，規格で標準化された電圧変動試験波形は必ずしも性能劣化の実態に即していない場合がある。

本研究では，性能劣化の実態に合わせた電圧変動試験波形の生成方法の検討を目的として，ディープラーニングを用いて時系列データとして予測することを試みた。電圧の経時変動を表した一変量時系列のデータを用いて，その後に続く未来の電圧変動をディープラーニングで予測させ，予測結果を適用した電圧変動試験の実現可能性を検討した。試験対象物として LED 電球を用い，実際に点灯不具合の性能劣化が発生する電圧変動波形を使用して電圧変動の時系列データの予測を試みた。併せて，一連の検討に必要な測定器・電源装置の設定や，時系列データの予測手法の違いが電圧波形の生成にどのような影響を与えるかを調査した。

2. 試験システムの構成

2.1　ブロック図および検討方法

本研究で使用する試験機器および電圧出力も含め各種信号の流れを表したブロック図を図 1 に示す。

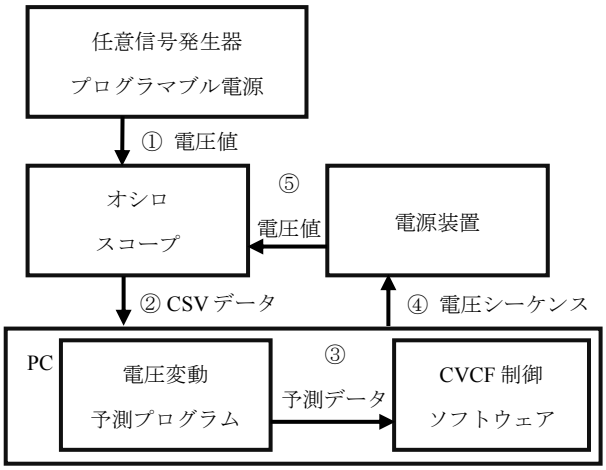

図 1　ブロック図

まず，任意信号発生器（Agilent Technologies 製，33220A）やプログラマブル電源（菊水電子工業(株)製，PBX40-10）により変動する電圧波形を作成し，これらの装置から電圧を出力する（図 1①）。出力した電圧を，オシロスコープ（Tektronix 製，MSO64）で観測し CSV データとして取り出す（同図②）。

この CSV データは，経過時間とその際の電圧値とが対応した 1,000 行 2 列の一変量時系列データである。次にこの CSV データの一部（1～n 行目まで）を，学習データとして電圧変動予測プログラムに読み込ませ，n+1 行以降の電圧値を予測データとして出力する（同図③）。

* 下越技術支援センター

表１　本研究で用いた電圧波形（学習データ・検証データ）の一覧

	直流電圧	交流電圧
周期的波形	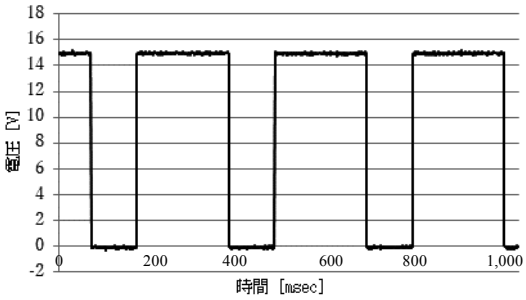	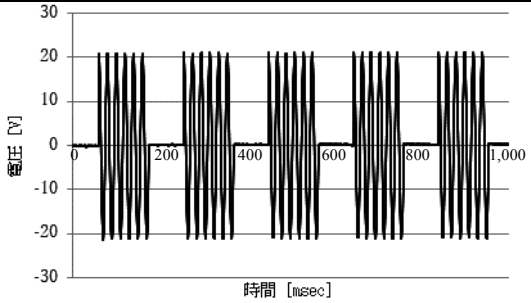
非周期的波形	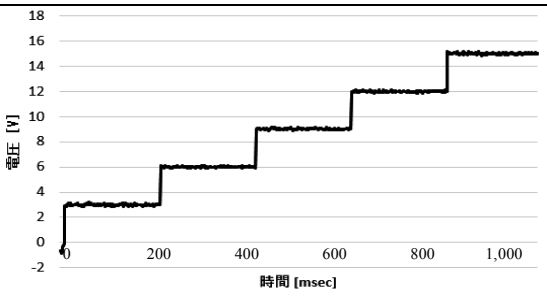	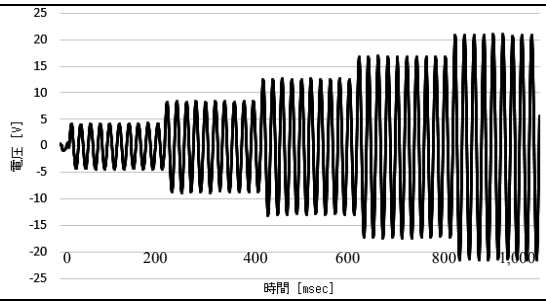

なお本研究では上記 CSV データの前半 70 %を学習用に，続く後半 30 %を検証用として用いることとする。

最後に，電圧値の予測データを電圧シーケンス（同図④）に変換して電源装置（菊水電子工業(株)製，PCR 9000LE2，以下 CVCF）に与え，電圧を出力する。この電圧値出力（同図⑤）を改めてオシロスコープで観測(実測データ)し，CSV データの後半 30 %に相当する検証データと比較することで予測データの妥当性を評価する。

なお，予測データを電圧シーケンスに変換するため，CVCF 制御ソフトウェア（菊水電子工業(株)製，Wavy for PCR-LE）を用いた。

2.2　試験対象物の検討・選定

本研究では，電圧変動波形を印加した際の不具合事象発生を確認するための試験対象物（Device Under Test，以下 DUT）として LED 電球（マルヤス電業(株)製，LE12-15Y-1，定格電圧：AC/DC 15 V）を選定した。この DUT を選定した理由は以下の 3 点である。

1) 視覚的・直感的に動作不具合事象（点灯・消灯・点滅）の発生を確認しやすいこと。
2) 電気的構造あるいは構成要素が簡素な DUT を用いることで，不具合事象発生の原因が DUT 側ではなく，給電電圧の変動によるものであることが判別しやすいこと。
3) この DUT は，直流・交流双方の給電で点灯可能であること。

2.3　電圧波形の検討・選定

本研究では直流，交流双方の電圧を用いて DUT に対して電圧変動試験を行うこととし，2 種類ずつ電圧波形を用意した。表 1 に本研究で用いた電圧波形の一覧を示す。

一般にデータの時系列予測を行う場合，その元となる学習データには「周期性（時系列が一定の間隔で同じような変動を繰り返す成分を持つ性質）」「季節性（時系列周期性の中で期間の決まっている性質）」「トレンド（時系列の長期的傾向）」のいずれかの特徴が含まれている必要があり，いずれの要素も含まない完全なランダムデータを予測することは難しい [1)]。そこで電圧波形として，周期性をもったもの（以

下周期的波形）と，周期性のないもの（以下非周期的波形）とを直流，交流それぞれで用意した。前者の周期的波形には，一定時間ごとの短時間停電を想定し電圧のオン／オフを繰り返すものを，後者の非周期的波形には，繰り返しの周期性はないものの一定時間ごとに電圧振幅が増大するものを用意した。

なお，あらかじめ周期的波形については直流および交流の電圧波形で DUT が実際に点滅することを，非周期的波形については両電圧波形で段階的に輝度が高くなることを，それぞれ目視確認した。

2.4 CVCF 制御ソフトウェアの制約条件

2.1 で述べた CVCF 制御ソフトウェアは，最大で 1,024 行の時系列データを読み込むことができる。もし 1,024 行を超える行数の時系列データを読み込んだ場合は，当ソフトウェアにおいて自動的にデータ数を間引く処理が行われる。ただしこの際，間引き処理の対象となるデータ行を操作者自身が選択できない。そのため，オシロスコープで CSV データを出力する段階から 1,024 行以内のデータとなるよう考慮した。ここでは，オシロスコープのサンプル・レートとレコード長をそれぞれ 1 kS/s，1 kpts とした。データ行数は 1,000 行，時間 1 秒のデータである。

2.5 時系列データ予測プログラム

本研究では電圧変動予測プログラムの作成に Python を使用した。また，ディープラーニングを用いる手法 [2]の他に，周期的波形には統計的手法 [3] [4]によって波形の自己相関を用いるプログラムも作成し，両者での比較を試みた。周期的波形について統計的手法を試みた理由は，学習データが 700 行と少ないことと，波形に明確な周期性があるためである [5]。

前者のディープラーニングを用いる手法では，ライブラリとして TensorFlow/Keras を用いた。さらに電圧変動予測プログラムとして，単純再帰型ネットワーク（Simple Recurrent Neural Network：以下 Simple RNN），長・短期記憶（Long Short Term Memory：以下 LSTM），ゲート付きリカレントユニット（Gated Recurrent Unit：以下 GRU）の 3 つのネットワークを用いた。なお各ネットワークの説明詳細はここでは割愛する。エポック数はいずれの場合も 30 とした。

波形の自己相関を用いる統計的手法では自己回帰移動平均モデル（Autoregressive and Moving Average：以下 ARMA）を適用した。ARMA は自己回帰モデル（Auto Regressive：以下 AR モデル）と移動平均モデル（Moving Average：以下 MA モデル）を組み合わせたものであり，AR モデルに MA モデルを加えたことでモデルの柔軟性が高まり，定常過程の時系列データに対して強力な説明力・予測力を持つとされる。

また，いずれの手法を適用した場合に学習データと予測データとの相関係数（2 種類のデータ間の関連性の強さを示す指標。-1 から+1 までの値で表現する）が最も高くなるかを調査した。

3. 結　　果

3.1 予測電圧波形

表 1 で示した各試験波形について，時系列データ予測を行った結果のうち，特徴的なものの抜粋（時間軸：700～1,000 ms）を表 2 に示す。これは，2.1 で述べた検証データのほか予測データならびに実測データの 3 つが揃っている 700 行目以降のデータで比較したものである。なお，ここで実測データとは，図 1⑤に相当する電圧値である。また，予測データに対する実測データとの相関係数を表 3 に示す。なお表 2 ならびに表 3 には図示していないが，直流，交流ともに Simple RNN のネットワークを用いたディープラーニングでは，学習データと予測データとの相関係数が低く，上手く予測ができなかった。これは Simple RNN の場合，勾配消失や入出力重み衝突が起きやすいために，短期的な情報しか保持できないことが原因と考える。

表 2　電圧波形の予測結果抜粋（時間軸：700～1,000 ms）

	予測手法	直流電圧	交流電圧
周期的波形	ARMA	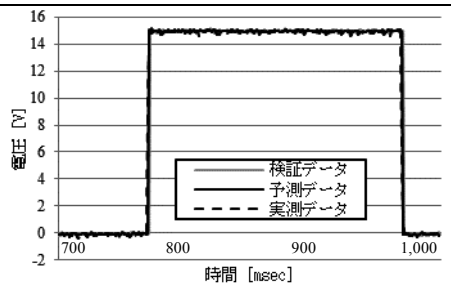	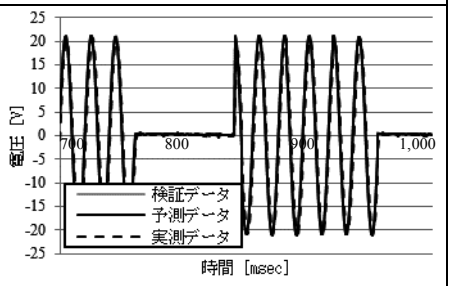
	LSTM	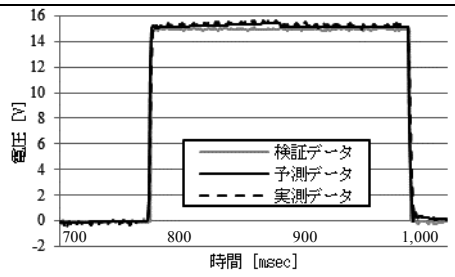	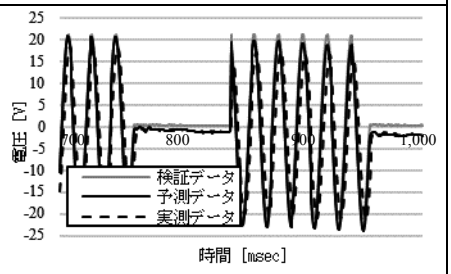
非周期的波形	LSTM	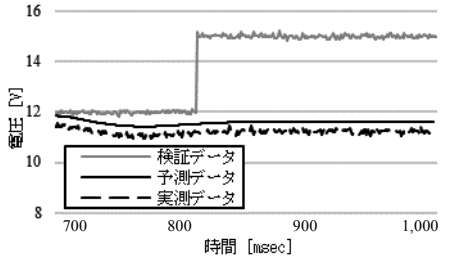	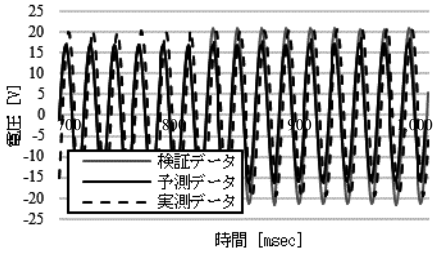
	GRU	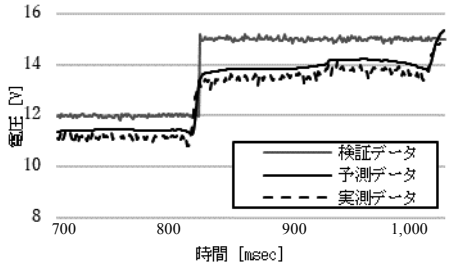	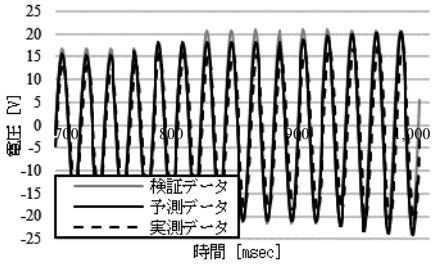

表 3　電圧波形の相関係数

	予測手法	直流電圧		交流電圧	
		検証データ - 予測データ	予測データ - 実測データ	検証データ - 予測データ	予測データ - 実測データ
周期的波形	ARMA	0.985	0.994	0.999	0.971
	LSTM	0.992	0.997	0.998	0.852
非周期的波形	LSTM	0.268	0.761	0.985	0.717
	GRU	0.976	0.990	0.995	0.941

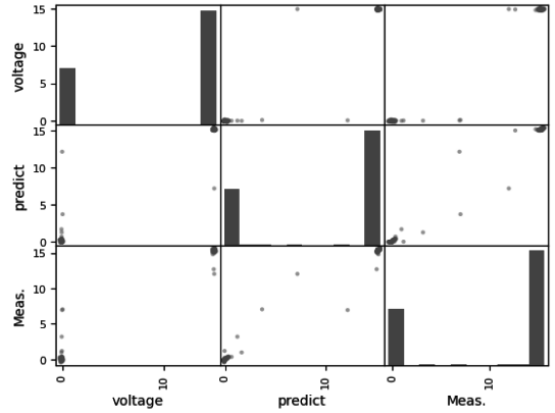

(a)　直流電圧

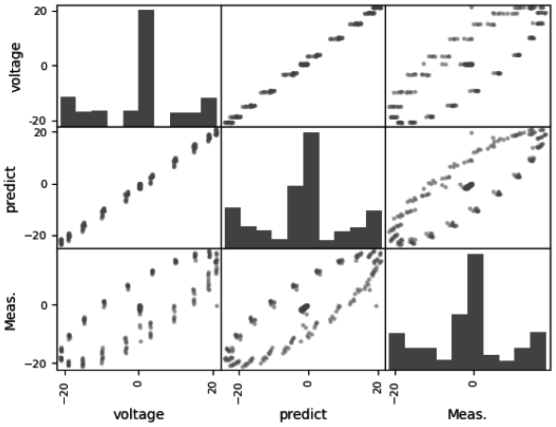

(b)　交流電圧

図 2　散布図行列（周期的波形の LSTM の場合）

3.1.1　周期的波形

直流電圧波形の場合，検証データと予測データとの相関係数は LSTM を適用した際に 0.992，ARMA を適用したときに 0.985 といずれも高い値になった。また交流電圧波形においては，ARMA と LSTM の双方の手法において，検証データと予測データとの相関係数が 0.998 以上と高い相関を示した。

3.1.2　非周期的波形

非周期的波形の場合は，波形に自己相関性を含まないことからディープラーニングによる予測のみを試みた。直流電圧波形では GRU を適用した際に，検証データと予測データとの相関係数が 0.976 と最も高くなった。同様に交流電圧波形においても，GRU を用いたディープラーニングによる予測手法において 0.995 の高い相関を示した。LSTM については，本研究で用いた電圧波形をネットワークに学習させる場合，セルやゲートを最適化するのに十分な学習データ量ではなかったと考える。

3.2　予測データを用いた，CVCF からの電圧出力

表 2 で示した予測データに基づいて CVCF からの電圧出力を試みた。表 3 より周期的波形，非周期的波形ともに，直流の場合は予測データに対して再現性良く電圧値を出力できることが実測データとの相関係数から分かる。一方で交流の場合は，予測データに対して実測データの相関が低い傾向がある。特に，電圧オン時における振幅のピークが予測データよりも低いことから，経時電圧変化のデータを最初に作成した任意信号発生器やプログラマブル電源に対して，CVCF のスルーレートが大きいことが原因と考える。

3.2.1　周期的波形

予測データと実測データとの相関係数は，交流電圧よりも直流電圧を出力した場合に高くなる。これは直流電圧の場合，オン／オフ双方の状態において電圧値が一定値に留まる時間が長いことから予測しやすいためと考える。

図 2 は，周期的波形を LSTM で予測した結果を散布図行列で表したものである。ここで散布図行列とは，複数のデータがある場合に 2 変数同士の組み合わせで散布図を作成して行列にまとめたグラフである。これにより，どのデータ間に相関があるかを視覚的に確認しやすくなる。(a) 直流電圧の場合は，プロットされた点の位置が 2 点に集中しているものの，2 点を結ぶと正の相関が見られる。また (b) 交流電圧の場合，検証データ (voltage) と予測データ (predict) とに強い正の相関が見られ，精度高く予測できていることが分かる。また，予測データ (predict) と実測データ (Meas.) との間にも正の相関が見て

取れることから，予測結果に対して概ね忠実に電圧出力ができているといえる。

また学習データおよび検証データと同様に，予測データに基づく出力電圧でも DUT に点滅が発生することを目視で確認した。

3.2.2 非周期的波形

直流・交流のいずれの電圧波形においても，GRU を用いた電圧予測結果を用いた場合に予測データと実測データとの相関係数が高くなる傾向が見られた。これは LSTM を用いた場合に，3.1.2 と同様の理由により予測精度が低いうえ，電圧値の変動が複雑であるために CVCF で忠実に出力をすることが困難であったものと考える。

また周期的波形と同様に，予測データに基づく出力電圧で DUT の輝度が段階的に高くなることの目視確認を試みたが，上述の理由から LSTM を用いた直流電圧のみ目視確認はできなかった。

4. 結　　言

(1) LED 電球を DUT に見立て，実際に点灯不具合の性能劣化が発生する電圧波形を用いて電圧値変動の時系列予測を試みることができた。

(2) 予測した電圧波形を適用した電圧変動試験でも，LED 電球に同様の点滅が発生し，実用に耐えうることを確認した。

(3) 一連の検討に必要な測定器・電源装置の設定や，時系列予測手法の違いにより，電圧波形の生成に影響があることを確認した。

(4) 電圧波形の挙動に対して学習データが十分でなく，かつ波形に明確な周期性が見られる場合には，波形の自己相関を用いる統計的手法が有効なケースがある。

(5) 直流・交流電圧ともに，周期的波形では予測データに対して CVCF からの出力電圧が概ね忠実に出力でき，DUT の動作確認も可能であった。しかし，非周期的波形では DUT による目視確認をできない場合があった。

参考文献

1) Laurence Moroney 著, 菊池彰 訳, “動かして学ぶ AI・機械学習の基礎－TensorFlow によるコンピュータビジョン, 自然言語処理, 時系列データの予測とデプロイ”, オーム社，2022.

2) 初心者の RNN（LSTM）| Keras で試してみる https://qiita.com/sasayabaku/items/b7872a3b8acc7d6261bf, 2023 年 11 月 16 日.

3) 自己相関に基づく時系列分析の手法（A-R・MA・ARMA・ARIMA・SARIMA），https://gri.jp/media/entry/7602#:~:text=ARMA, 2023 年 11 月 20 日.

4) 時系列解析（分析）とは　概要やメリット, モデル, 進め方, 事例を紹介, https://www.skillupai.com/blog/time-series/, 2023 年 11 月 20 日.

5) Interface 2023 年 10 月号, “Python でデータサイエンス”, pp.103-114, CQ 出版社, 2023.