

# パワー半導体テストのパラメータ自動調整における ベイズ最適化の適用

Automatic parameter adjustment for power semiconductor tester using bayesian optimization

山本 怜\* 滝浪 正義\* 瀧田 伸幸\*  
Rei Yamamoto Masayoshi Takinami Nobuyuki Takita

In order to realize our highly accurate power semiconductor tester, various parameters need to be optimized before shipment. In general, if the physical model of the target is known, parameter optimization can be performed using existing optimization methods. However, such model analysis methods often suffer from significant performance degradation due to modeling errors, and accurate model analysis is also difficult. In this paper, we outline a method for automatic parameter adjustment using bayesian optimization to obtain optimal parameters while performing model estimation.

KEY WORDS: Automation, Modeling, Search algorithm, Bayesian optimization

## 1. はじめに

現在、地球規模での気候変動への対応として、化石燃料使用量の削減が至上課題となっている。これに対する自動車業界の有効な対策として、ハイブリッド自動車（HEV）、電気自動車（EV）比率の引き上げが進んでいる。

HEV/EVはバッテリー、インバータ、モータを中心に構成されている。中でもインバータはエンジンと並ぶ重要なユニットとして位置づけられており、研究・開発・製造のそれぞれのフェーズで様々な測定や試験が行われている。

インバータの中核部品には、パワーデバイスという電流電圧のON/OFFを高速に切り替えることができる半導体があり、その中でも高耐圧と大電流の扱いに適しているIGBT（Insulated Gate Bipolar Transistor）が広く使われている。

検査技術開発グループが提供している新東パワーデバイステストシステム（SPTX）<sup>1)</sup>はIGBTを高速・高精度に検査する性能を実現している。しかし、さまざまな検査項目に対応するために出荷前に膨大な工数の校正作業が行われており、校正時の手動パラメータ調整の自動化が望まれている。

人間が手動で行っているパラメータ調整の自動化を実現するためには、パラメータ調整の過程における人間の知的行為が自動的に再現される必要がある。しかし、パラメータを入力するモデルを解析して最適パラメータを求めるモデル解析手法では、モデル化誤差による性能劣化が著しく、また正確なモデリングも困難なことが多い。一方で探索アルゴリズムを用いたパラメータ探索においては、パラメータ毎に探索アルゴリズムをチューニングしなければ効率的な探索ができない問題がある。

そこで本稿では、モデル推定を行いながら最適なパラメータを探索するベイズ最適化（Bayesian optimization）<sup>2),3)</sup>を用いてパラメータを自動調整する手法を概説する。

## 2. パラメータ調整

本稿ではパラメータ調整を、あるモデルの出力値が決められた目標値に近づくようにパラメータを増減させて、目標値との差が最小となるパラメータを探索する一連の行為と定義する。パラメータが1次元のモデルにおけるパラメータ調整をFig. 1に示す。

\*特機事業部 検査技術開発グループ 開発チーム

Fig. 1 に示すように、初期パラメータを任意に増減させながらモデル出力値と目標値との比較を繰り返すことで、モデルが限りなく目標値に近い値を出力するときのパラメータを探索する。この過程で得られるモデル出力値を探索サンプルとする。




Fig. 1 Model depended parameter adjustment.

### 3. 手動パラメータ調整

人間により手動で行われるパラメータ調整の概念図をFig. 2 に示す。Fig. 2 に示すように、人間はパラメータ調整の過程において、パラメータと入力によって得られた出力からそのモデルの概形を理解し、次に試行するパラメータを決定することで最適なパラメータを探索する。したがって、人間の知能により実現しているモデルの理解とパラメータ決定が自動的に再現されるものが理想的な自動パラメータ調整システムである。




Fig. 2 Block diagram of manual parameter adjustment.

## 4. 自動パラメータ調整の問題点

### 4.1 モデル解析

パラメータ調整対象の現物モデルを求めることができれば、既存の最適化手法によるパラメータの最適化は可能である。しかし、個体の現物モデルは一般に、既知もしくは解析により決定可能な物理モデルとモデル化誤差の和で表されるが、モデル化誤差を正確に知ることは困難である。だ

が、パラメータ調整で最適パラメータの探索を行うことが前提ならば、モデル化誤差の解析は不要である。つまり、探索範囲の絞り込みにはモデル化誤差を含む推定モデルで良く、探索を効率的に行うための簡易的なモデル解析で十分である。

### 4.2 探索アルゴリズム

次に探索アルゴリズムの観点から最適パラメータの探索を考える。モデル $f(x)$ 、目標値 $T$ 、入力するパラメータ $x$ に対して評価関数 $f'(x)$ を以下のように定義する。

$$f'(x) = -|T - f(x)| \quad (1)$$

この評価関数 $f'(x)$ が最大値を取るときのパラメータ $x$ を探索アルゴリズムで導出できれば良い。

### 4.3 局所探索法

Fig. 3 (a) に単純な探索アルゴリズムである局所探索法（山登り法）によるパラメータ探索を示す。Fig. 3 (a) に示すように、山登り法ではあるパラメータの近傍で探索サンプルを取得（近傍探索）して、その探索サンプルの中の最大値を取るパラメータで更に近傍探索を繰り返すことで最適パラメータを探索できる。

ところが、この近傍探索の範囲・粒度を適切にチューニングしなければ、導出パラメータの精度低下や探索時間の増大などで、探索対象によっては実用に耐える性能が出せないことが知られている。

### 4.4 強化学習アプローチ

それに対して、Fig. 3 (b) に強化学習的なアプローチで探索するパラメータ探索を示す。

Fig. 3 (b) に示すパラメータ探索では、最初にモデルの概形を推定するためにランダムなパラメータで探索サンプルを取得し、その推定モデルから最適パラメータの存在が予測される局所を重点的に探索できている。このようにパラメータ探索の過程で得られる探索サンプルから探索範囲を

絞り込み、その絞り込んだ範囲を山登り法で探索する、というような機械学習の機構を盛り込んだ探索アルゴリズムが提案されている。

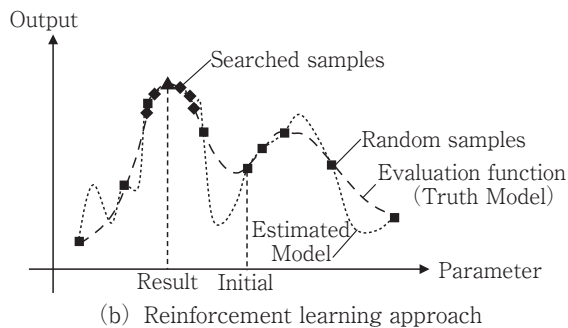
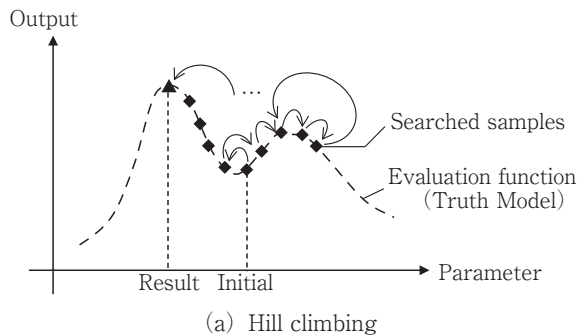


Fig. 3 Search algorithm for evaluation function.

### 5. ベイズ最適化

入力に対する出力だけがわかる未知のモデル  $g(x)$  を理想モデル  $f(x)$  に近づけるパラメータ調整を考える。理想的なパラメータ調整が完了すると、

$$g(x) \equiv f(x) \quad (2)$$

となり、未知のモデル  $g(x)$  は、恒等的に理想モデル  $f(x)$  と一致する。すなわち、パラメータ調整とは、未知のモデル  $g(x)$  を理想モデル  $f(x)$  に一致させることと同値となる。ベイズ最適化は、ガウス過程を用いて確率的に次の最適サンプル点を逐次推定しながら未知のモデル  $g(x)$  の最小値（最大値）を求める手法である。

未知のモデルに関して、

$$y_i = g(x_i) + \varepsilon_i \quad (i=1,2,\dots,n) \quad (3)$$

に従うデータ

$$D_{1:n} = \{(x_1, \dots, x_n), (y_1, \dots, y_n)\} \quad (4)$$

が与えられるとき、評価関数  $J(x)$  は理想モデル  $f(x)$ 、 $g(x)$  を用いて、

$$J(x) = \sum_{i=1}^n \{f(x_i) - g(x_i)\} \quad (5)$$

と置ける。つまり  $g(x)$  の推定とは、 $J(x)$  の最小化問題として定式化することができる。ここでは詳細は省くが、評価関数  $J(x)$  はガウス過程により、任意の入力  $x'$ 、平均  $\mu$ 、分散  $\sigma^2$  を用いて記述できる正規分布

$$J(x') \sim N\left(\mu(x'; D_{1:n}), \sigma^2(x'; D_{1:n})\right) \quad (6)$$

の集合として求めることができる。

ここで、パラメータ調整における次の最適なサンプル点は、1. 評価関数が小さくなる方が良く、2. 評価関数の信頼性が低くなる方が良く、と考えられる。そこで評価関数  $J$  の平均  $\mu$ 、分散  $\sigma^2$  から計算されるばらつきの指標  $d$ （次元は標準偏差）による獲得関数

$$a(x'; D_{1:n}) = \mu(x'; D_{1:n}) - d(x'; D_{1:n}) \quad (7)$$

を新たに導入する。獲得関数の定義については様々な議論があるが、工学的には他のサンプル点よりも最適らしい候補を探索すれば良いことから、本稿で獲得関数の評価については議論しない。

この獲得関数  $a$  が最小となる  $x'$  を次のサンプル点として、評価関数  $J$  があらかじめ設定した閾値よりも小さくなるまで試行を繰り返す。

ベイズ最適化の実行結果の例を Fig. 4 に、実行環境を Table 1 に示す。Fig. 4 に示すように、まず決められた範囲のランダムなパラメータを探索し（0 回目～15 回目）、次に未探索のパラメータとより最適らしいパラメータを織り交ぜて探索している（16 回目～31 回目）。結果として、ベイズ最適化は真のモデルとほぼ同等のモデルを推定

し、最適パラメータの近傍を重点的に探索できている。

Table 1 Execution Environment of bayesian optimization.

Description	Detail
python	version 3.9.0
bayesian-optimization	version 1.2.0
black-box function	$f(x) = e^{-(x-2)^2} + e^{-\frac{(x-6)^2}{10}} + \frac{1}{x^2+1}$ ( $-10 \leq x \leq 10$ )
acquisition function	expected improvement (ei)
initial points count	16
iteration points count	16

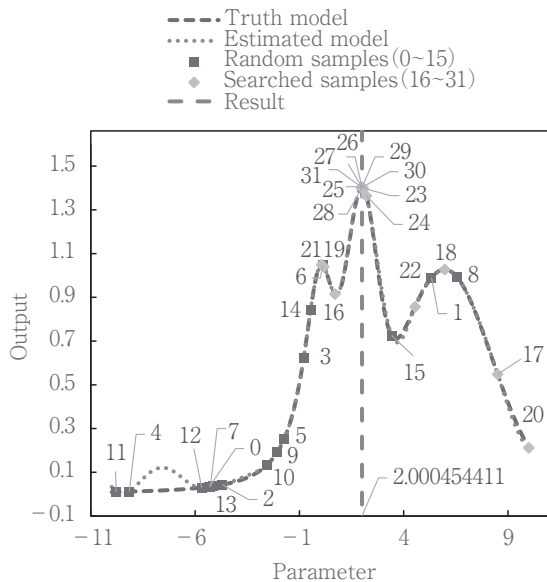


Fig. 4 Example of bayesian optimization.

## 6. おわりに

ベイズ最適化を用いて実際の設備やユニットといった現物モデルを推定しながら効率的にパラメータを探索して自動調整する手法を概説した。

今後、製品を対象にした自動パラメータ調整システムでの評価を進め、早い時期の実適用を目指す。

## 参考文献

- 1) 山田 務, 滝浪正義, 瀧田伸幸: パワーデバイス用静特性・動特性一体型テストの開発 新東技報No33 (2018) 57-63
- 2) Jasper Snoek, Hugo Larochelle, Ryan P. Adams: Practical Bayesian optimization of machine learning algorithms, NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems (2012), Volume 2, 2951-2959
- 3) 中野 雄一郎, 藤本 悠介, 杉江 俊治: ベイズ最適化を用いた制御器チューニング-提案と実験検証- 計測自動制御学会論文集 55巻 (2019) 4号 p.269-274