

技術紹介

3

ニューラルネットワークと多目的遺伝アルゴリズムを使った差動線路の設計最適化

Neural-Network-Assisted Multi-Objective Genetic Algorithm for Differential Transmission Line Design Optimization

池田 浩昭

Hiroaki Ikeda

コネクタ事業部 製品企画部 マネージャー

キーワード：ニューラルネットワーク、多目的遺伝アルゴリズム、クロストーク、反射損失、挿入損失**Keywords :** Neural-Network, Multi-Objective Generic Algorithm, Crosstalk, Reflection Loss, Insertion Loss

要 旨

多目的遺伝アルゴリズムとニューラルネットワークで構成された回帰モデルを使い、差動配線の設計最適化を行いました。挿入損失、反射損失、遠端クロストークの限度値を設定し、これらの値以下になる差動配線の物理寸法を出力するツールの開発に成功しました。

従来の遺伝的アルゴリズムを使った設計最適化では、設計パラメータの適合度を調べるために、物理シミュレーションが利用されていました。そのため、適合度の調査に数十万回の物理シミュレーションが必要になり、最適値の探索に多くの時間が必要でした。この物理シミュレーションをニューラルネットワークで構成された回帰モデルに置き換える事により、設計パラメータの探索を数日から 17 分程度まで短縮できました。本稿では、ニューラルネットワークを使った回帰モデルの作成方法、多目的変数に対応した遺伝的アルゴリズムを使った設計パラメータの探索方法について解説します。

SUMMARY

We performed design optimization of differential transmission lines using a regression model composed of a multi-objective genetic algorithm (GA) and a neural network (NN). By defining constraint thresholds for insertion loss, return loss, and far-end crosstalk, we successfully developed a tool that outputs the physical dimensions of differential transmission lines satisfying these requirements.

In conventional design optimization based on GA, physical simulations are used to evaluate the fitness of design parameters. As a result, several hundred thousand physical simulations are required, making the search for optimal solutions extremely time-consuming. By replacing these physical simulations with a NN-based regression model, the time required for exploring design parameters was reduced from several days to approximately 17 minutes.

This paper explains the methodology for constructing the NN-based regression model and the approach for searching design parameters using a multi-objective GA.

1. はじめに

電子機器に必須なプリント配線板 (PCB: Printed Circuit Board) の設計は、未だに手動で行われており、自動化が進んでいない分野です。その一つの原因として、設計ノウハウが属人化しており、文書化が難しい事が上げられます。最終目標を PCB の設計自動化とし、本稿ではその前段として、Non-dominated Sorting Genetic Algorithms II (NSGA-II)¹⁾を使って適切な配線構造を拘束条件のみ設定して求めました。

遺伝的アルゴリズム(GA)は、自然淘汰により環境に適応した遺伝子が生き残る原理を、最適パラメータ探索に応用したもので、古くから最適値探索手法として利用されてきました。GA はパラメータ探索範囲が広い場合や複数の解が存在するような場合でも、局所解に陥る可能性が低く、近似的な最適解を探せるのが利点です。欠点としては、適応度の評価に物理シミュレーションを使う事が多く、計算負荷が大きい事です。通常の GA では、パラメータの組み合わせを 100 組程度作り、そこから性能の良かったパラメータの組み合わせを交叉、変異させ、新しいパラメータの組み合わせ 100 組作ります。これを 1000 回行えば、10 万回の物理シミュレーションが必要になり、非常に多くの計算時間が必要になります。この計算時間を短縮するために、昨今、注目されるニューラルネットワーク(NN)を使った回帰モデルを物理シミュレーションの代替として、最適解を求めました。この代理モデルはサロゲートモデル(Surrogate Model)とも呼ばれます。

本稿では最初に NN を使った機械学習で回帰モデルを求め、その予測精度の検証を行います。次に、この回帰モデルを適応度関数として、差動配線の反射損失、挿入損失、遠端クロストークを設定した限度値以下になるように多目的変数に対応した NSGA-II で求めました。さらに、NSGA-II で求めた配線情報を用いて、電磁界シミュレータで再計算を行い、限度値を満たしている事を確認しました。

回帰モデルの作成には Graphic Processor Unit (GPU)を搭載したシングルボードコンピュータ (Jetson Orin Nano 8G バイトメモリ)を使った結果、1.5 時間程度で完了しました。NSGA-II による最適値探索は、GPU 非搭載シングルボードコンピュータ(Raspberry Pi5 8G バイトモデル)を使って 17 分程度の時間で最適解を探す事に成功しました。

2. NN を使った回帰モデルの作成

2.1 差動線路モデル

Fig.1 に NN の訓練及びテストデータの作成に使った 3 組の差動線路を持つ PCB を示します。Fig.1 の PCB は 12 ポートになりますので、シングルエンドの S パラメータは S_{11} から $S_{12,12}$ までの 144 個存在します。今回は、差動信号に対する応答のみを対象として、中央の差動線路の反射損失 (S_{dd33})、挿入損失 (S_{dd43})、中央の差動線路と左右の差動線路との遠端クロストーク (S_{dd42} 、 S_{dd46}) のみ扱います。したがって、NN で求めるパラメータは 4 個に削減されます。これを目的変数とします。差動線路の設計に必要なパラメータは配線幅(W)、差動配線を構成する配線の間隔(S_1)、差動線路同士の間隔(S_2)、絶縁層の厚み(T)、配線長(L)になります。絶縁層の比誘電率は 4.2 で固定としました。これらを説明変数とします。NN を一つの関数と考えれば、説明変数は独立変数、つまり入力、目的変数は従属変数になり出力となります。NN の訓練時は、説明変数と目的変数のセットを複数準備します。推論時は、説明変数のデータのみ準備すれば、目的変数の S パラメータが出力されます。




Fig.1 3 対の差動線路のポート番号と物理寸法

2.2 訓練、検証、テストデータの作成

差動線路の最適化配線幅(W)、配線長(L)、配線間隔(S1)、差動配線間距離(S2)、絶縁層厚(T)を説明変数、Sdd33、Sdd43、Sdd42、Sdd46 を目的変数として訓練及び、検証、テストデータを作成しました。Table 1 に訓練、検証、テストデータの作成に使った値を示します。周波数は 10MHz~10GHz、周波数間隔は 20MHz としました。T のみ 0.1~0.8mm の範囲で固定し、W、S1、S2 は以下に示す範囲でランダムに作成しました。差動の特性インピーダンスが 100Ω 付近になるように T に応じて、W、S1、S2 の範囲を決めています。

- $W=0.8T\sim2.5T$
- $S1=0.8T\sim2.5T$
- $S2=1.5S1\sim3S1$

W、S1、S2 のパラメータ間隔は 0.1T です。L の範囲は 10~160mm、間隔 1mm としてランダムに作成しました。訓練データは 2400 通り、検証、テストデータは、それぞれ 800 通りで重複がない事を確認しています。

目的変数の S パラメータは 2 段階で計算しました。第 1 段階では、2 次元電磁界シミュレータと Table 1 のパラメータを使い、配線の単位長さ当たりの抵抗値(R)、コンダクタンス値(G)、インダクタンス値(L)、キャパシタンス値(C)を求めました。第 2 段階では、この R、G、L、C の値を使って回路シミュレータ上で伝線路を定義し、差動モードの S パラメータを計算しました。訓練データは NN を訓練するために利用し、検証データは訓練中の予測精度の確認に使いました。テストデータは、訓練終了後の、最終的な精度確認に利用しました。

Table 1 差動線路のパラメータ

Parameter	Range	Step Size
freq [Hz]	10M~10G	20M
W, S_1 [mm]	0.082~1.998	Random
S_2 [mm]	0.16~5.677	
L [mm]	10~160	
T [mm]	0.1,0.12,0.15,0.18,0.2,0.3,0.5,0.8	Fixed

2.3 NN 構造

回帰モデルは Fig.2 に示す NN を定義し、各ノード間の重みとバイアスを機械学習で求めました。入出力層のノード数は、説明変数及び目的変数と同数になりますので、それぞれ、6 ノード、4 ノードです。中間層は 5 層あり、それぞれ 1000 ノードとしました。

NN 上の未知パラメータは、約 400 万個です。中間層の活性化関数は、Rectified Linear Unit (ReLU)²⁾ を使い出力層は線形結合としました。バッチサイズは 4096、最適化関数は Adaptive Moment Estimation (Adam) を使い 400 回の繰り返し計算を行いました。NN のプログラミングには、Tensorflow³⁾ を使いました。ハードウェアは Nvidia の Jetson Orin Nano 8G バイトメモリモデルを利用して 1.5 時間で完了しました。




Fig.2 NN 構造

2.4 回帰モデルの精度検証

予測精度の検証には、式(1)に示す決定係数 R^2 を利用しました。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - f(x_i))^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

ただし、 y_i は正解値、 $\bar{y}$ は正解データの平均値、 $f(x_i)$ は予測値です。決定係数が「1」であれば、予測値と正解値は完全に一致します。正解値の平均値で予測した場合は「0」となるので、一般的には、決定係数は0～1の値を持ちますが、大きく外れた場合は負になることもあります。

訓練、検証、テストデータに対する予測精度は、決定係数で、概ね0.99～1.00です。ただし、有効桁を少数点第2位としていますので、 $R^2 = 1.00$ でも完全に予測と正解データが完全に一致しません。Fig.3～Fig.6にSdd33、Sdd43、Sdd42、Sdd46のテストデータを使った正解値ー予測値の散布図を示します。横軸は、Sdd33～Sdd46の正解値を示し、縦軸はNNを使った予測値を示します。予測値と正解値が完全に一致していれば、45°の一直線となります。Fig.3、Fig.4は正解値と予測値が異なるものがいくつか存在しますが、小数点2桁の範囲では1.0になっています。




Fig.3 正解データと予測データの散布図 (Sdd33)




Fig.4 正解データと予測データの散布図 (Sdd43)




Fig.5 正解データと予測データの散布図 (Sdd42)




Fig.6 正解データと予測データの散布図 (Sdd46)

中央の差動線路と左側の差動線路の遠端クロストーク Sdd42 と右側の差動線路間の遠端クロストーク

Sdd46 は配線構造が完全に対称ですので、ほぼ同じ結果になります。(Fig.5 と Fig.6)




Fig.7 正解値と予測した S パラメータ

Fig.7 にテストデータを使い、予測した Sdd33、Sdd43、Sdd42 と正解のデータの一部を示します。Sdd46 は Sdd42 とほぼ同じ結果のため、省略しました。Sdd33、Sdd43、Sdd42 の正解データは、それぞれ、赤、マゼンタ、茶、予測データは緑、青、シアンで示します。各グラフの絶縁層厚は 0.1～0.8mm までの 8 種類、配線長は比較的長いケースを選びました。Fig.7 の結果からテストデータを使った予測値は、正解値に良く一致している事が分かります。つまり、未知データに対して十分な予測精度があり、配線の物理寸法から S パラメータを予測する回帰モデルとして、利用できる事が確認できました。

3. 差動線路の最適化

3.1 NSGA-II を使った配線パラメータの探索

差動線路の配線パラメータを最適化するために、多目的変数に対応した遺伝的アルゴリズム NSGA-II を使いました。周波数帯域を $10\text{MHz} \leq f < 5\text{GHz}$ と $5\text{GHz} \leq f \leq 10\text{GHz}$ の 2 つに分割し、Sdd33、Sdd42、Sdd46 は Table2 が示す閾値以下で、尚且つ閾値からの余裕度が最大になるような W、S1、S2、L を探索します。ただし、Sdd43 は閾値以上で、余裕度が最大になるように設定しました。

絶縁層厚は 0.1、0.2、0.3、0.5 の 4 通り、配線長は 50mm～160mm、周波数帯域は 10MHz～10GHz の範囲で配線パラメータを探索しました。初期パラメータはランダムに生成し、トーナメント選択方法を使い、パラメータの選定をしました。交叉は実数値を使い、2%の確率でパラメータの値をランダムに変更しました。パラメータの集団は 100 個、1000 世代としました。遺伝アルゴリズムに利用したハイパーパラメータは Table 3 の通りです。

Table 2 限度値

	$10\text{MHz} \leq f < 5\text{GHz}$	$5\text{GHz} \leq f \leq 10\text{GHz}$
Sdd33 [dB]	-30	-20
Sdd43 [dB]	-3	-6
Sdd42 [dB]	-40	-30
Sdd46 [dB]	-40	-30

Table 3 ハイパーパラメータ

パラメータ	役割	デフォルト値	備考
population_size	集団の個体数	100	世代ごとに進化する個体数
variator	交叉 + 突然変異オペレータ	GAOperator(SBX(), PM())	実数値GAでは SBX + PM が使われる
selector	親選択方法	TournamentSelector(2)	トーナメント選択 (サイズ2)
generator	初期集団生成	RandomGenerator()	ランダム初期化
archive	アーカイブ機構	None	一部アルゴリズムのみ使用
epsilons	多目的スケール係数	None	NSGAIでは不要 (ϵ -NSGA-II向け)

絶縁層毎のパレート最適解の数と、パレート最適解を使い、S パラメータを再シミュレーションし、Table 2 の限度値を満たしたパラメータ数を Table 4 に示します。絶縁層厚(T)が 0.1mm の場合は、パレ

3-8 技術紹介 ニューラルネットワークと多目的遺伝アルゴリズムを使った差動線路の設計最適化

ート最適解が 33 個、見つかり、Table 2 の限度値を満たすパラメータの組み合わせ数は、30 個であり 91%のパレート最適解が限度値を満たしました。T=0.2、0.3、0.5mm の場合のパレート解は、それぞれ 38、97、113 個であり、すべてのパレート最適解が限度値を満足していました。

T=0.1mm の場合、パレート最適解の探索にかかった時間は、シングルボードコンピュータである Raspberry pi5 (メモリ 8G バイト)を利用して 16.8 分でした。GPU を搭載した PC を利用すれば、探索時間は 1/10 程度に短縮可能です。

Table 4 絶縁層毎のパレート解と限度値以下となった解の数

T	No. of Pareto Solution	No. of Accesptable Case	Accuracy [%]
0.1	33	30	91
0.2	38	38	100
0.3	97	97	100
0.5	113	113	100

3.2 パレート最適解の検証

絶縁層厚が 0.1mm のケースで、再シミュレーションで確認後、Table 2 の限度値を満たさなかったパラメータの組み合わせを Table 5 に示します。

Table 5 限度値を超えた差動線路パラメータ

W	S1	S2	T	L
0.117	0.224	0.507	0.1	50.7
0.119	0.224	0.485	0.1	50.7
0.123	0.249	0.715	0.1	66.4

Fig.8～Fig.10 に限度値を超えた S パラメータを示します。破線はパレート最適解を使って再計算した S パラメータ、実線は、NN の回帰モデルで予測した S パラメータです。階段状の一点鎖線は、同色の S パラメータの限度値を示します。赤線は Sdd33、緑線は Sdd43、青線は Sdd42 を示します。Sdd46 は対称構造のため Sdd42 と同等になるので省略しました。Fig.8～Fig.10 を観察すると、Sdd33 の予測値は、正解値と比較して若干小さく予測されているため、正解の S パラメータでは、限度値を超えている事が分かります。限度値を超えなかった S パラメータの一例を Fig.11 に示します。Fig.11 の S パラメータは、限度値に対して十分な余裕度がありますので、予測値と正解値に差があっても、限度値を超えません。したがって、予測値と正解値に誤差が生じることを想定して、NSGA-II 実行時は、限度値を低め設定すれば、限度値を超える可能性が少なくなります。ただし、Sdd43 の場合は高めに設定します。




Fig.8 限度値を超えた S パラメータ
($W=0.117$, $S1=0.224$, $S2=0.507$, $T=0.1$, $L=50.7$)




Fig.9 限度値を超えた S パラメータ
($W=0.119$, $S1=0.224$, $S2=0.485$, $T=0.1$, $L=50.7$)




Fig.10 限度値を超えた S パラメータ
($W=0.123$, $S1=0.249$, $S2=0.715$, $T=0.1$, $L=66.4$)




Fig.11 限度値を満足した S パラメータ
($W=0.11$, $S1=0.238$, $S2=0.464$, $T=0.1$, $L=97.6$)

4. まとめ

限度値以下の S パラメータを目標に差動線路の配線パラメータを NN と NSGA-II を使い探索しました。その結果、 $T=0.1\text{mm}$ では 91%の精度で最適解が求まりました。また、 $T=0.2$ 、 0.3 、 0.5mm では 100%の精度で最適解を探索できました。これは、パレート最適解を使って再シミュレーションし、実際に限度値以下になった比率になります。つまり、 $T=0.1\text{mm}$ の場合は、9%のパラメータ組み合わせは、実際には、限度値を僅かに超えますが、 $T=0.2$ 、 0.3 、 0.5mm では、すべてのパレート最適解が限度値に入ると言う意味です。

本稿では、適応度関数に NN を使った回帰モデルで代替することにより、ワンボードマイコン利用時でも 16.8 分で配線パラメータを求める事ができました。また、限度値は、周波数軸に対して任意に設定できますので、実際の設計現場で使われる USB^{4,5)}や PCI-Express⁶⁾規格を満たす配線構造を短時間で求められる事が可能になります。さらに、NN を使った回帰モデルは、配線長に起因する反射を S パラメータに正確に反映していますので、訓練データがあれば、コネクタのような 3 次元構造物でも、設計パラメータの自動探索が短時間で可能になります。

【参考文献】

- 1) K. Deb, S. Agrawal, A. Pratab, and T. Meyarivan.” A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II.” ,In KanGAL report 200001, Indian Institute of Technology, Kanpur, India, 2000
- 2) 我妻幸長, “はじめてのディープラーニング”, SB クリエイティブ, 2018.
- 3) 中井悦司, “TensorFlow と Keras で学ぶディープラーニングの仕組み”, マイナビ, 2019.
- 4) 畑山仁、野崎原生、池田浩昭、志田晟, “USB 3.2 のすべて”, CQ 出版, 2020
- 5) 野崎原生、畑山仁、池田浩昭、永尾祐樹、長野英生、宮崎仁, “USB Type-C のすべて”, CQ 出版, 2020
- 6) 畑山仁, “PCI Express 設計の基礎と応用”, CQ 出版, 2015