

技術論文

車載機器におけるEMC解析と
AI活用事例の紹介菅 翔平
Shohei Kan

概要

電動化・自動運転の進展に伴い、EMC設計の重要性が高まっている。本稿では、マルチフィジックス解析の重要性を示し、課題となる計算工数の高いEMC設計に対して、AIを用いた冗長設計技術の適用例を紹介する。さらに、AI学習において課題となる訓練データの取得に関して、効率的なサンプリング戦略を検討する。

1. はじめに

1.1 解析シミュレーションの戦略

近年、電動化や自動運転の実現に向けた技術革新が急速に進んでいる。図1に示すポートフォリオの成長領域では、特に統合化・高電圧化・知能化の分野における製品群の重要性が高まっている。これに伴い、EMC(Electromagnetic Compatibility:電磁両立性)設計の重要性がますます増している。また、OEMニーズの多様化や迅速な設計に対応するため、設計体制はさらなるスピードと柔軟性が求められる。これらの課題に対応するため、効率的かつ高品質な設計体制の構築が不可欠である。図2に示すように多くの企業ではこれら設計効率化に向け、解析シミュレーション・AI¹⁾・量子コンピュータ⁹⁾等を活用したフロントローディング設計による設計プロセスを実施している¹⁰⁾⁻¹²⁾。しかしながら、モデル作成・計算に工数を要し、理想のプロセスにまで工数を低減できていない場合もあるため注意が必要である。

これまで当社では、ECU単体のEMC対策は設計現場において簡易解析(2.5次元解析)で実施し、システム構成を考慮した高負荷な3次元電磁界解析は専任者が担当する体制を整備してきた。しかし、図1に示すように統合化ECUや高性能ECU、さらに複数性能を統合したPT(パワートレイン)系ECUの登場により、EMCによる問題は一層複雑化を増している。この結果、従来の簡易解析のみでは現象の全容把握ができず、高負荷な3次元電磁界解析が必要となる。また図3に示すように電子設計における課題はEMCだけでなく、熱やSI/PI(信号品質/

電源品質)などといった設計要件を満足する必要がある。しかし、これらのトレードオフを解消することは難しく、図4に示す解析フローAのように設計手戻りの発生により設計工数の増加が発生する。

このような背景から当社では一度の計算で複数の次元を同時に解析するマルチフィジックス解析(解析フローB)を推奨している。解析フローBを構築することで、異なる物理領域を同一の時間軸・空間軸で横並びに評価できる。これによる弱連成・強連成を通じた協調設計を通じて、設計者や専任者間の情報の非整合や手戻りを大幅に削減し、各性能を満足できる設計の効率化が可能となる¹⁰⁾⁻¹²⁾。

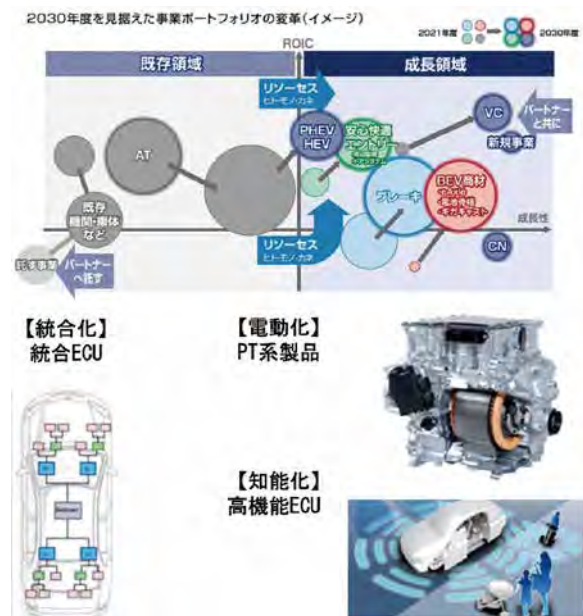


図1 事業ポートフォリオと成長領域の製品領域




図2 理想の設計プロセス

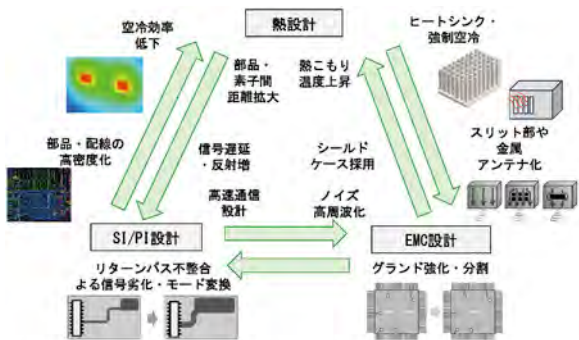


図3 電子設計における各解析のトレードオフ

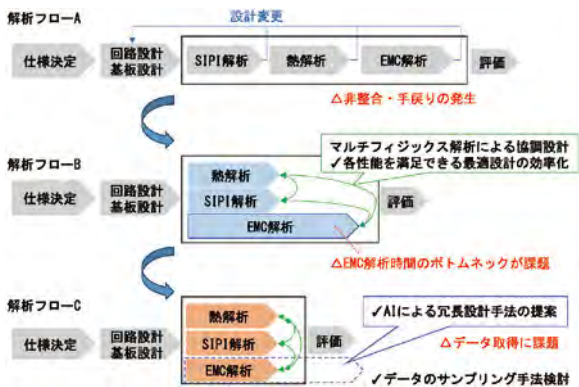


図4 現状の解析フローと理想の解析フロー

1.2 マルチフィジックス解析における課題

マルチフィジックス解析の課題の1つはEMC解析の計算工数が高いことである。EMC解析では、FEMやFDTDを用いた3次元電磁界解析や時間領域での過渡解析が必要となる。そのため、設計プロセスのボトルネックとなることも多く、マルチフィジックス解析における有効性が得られない場合がある。

この課題に対し、人工ニューラルネットワーク (Artificial Neural Network:ANN)を用いたサロゲートモデルによる設計効率化が注目されている。解析や実測による訓練データを用いて、ANNに学習させることで、短時間での予測が可能となり、EMC解析にかかる時間を大幅に短縮できることが報告されている^{1)-8),13)}。

そこで、我々はEMC設計効率化を目指した、ANNを活用した冗長設計手法を確立したので紹介する。これは

製品の横展開や急な仕様変更でも、目標を満足するように設計値を決定する手法であり、対策工数の削減が可能となる。それによりフローCのように他解析と同等、もしくはそれ以下の解析工数で設計できることが期待される。

2. ANNを用いた冗長設計手法とその課題

冗長設計手法の有効性を、車体系製品などのブラシモータを用いたシステムを例に説明する。車体系製品はブラシモータ内部に用いているブラシ接触によるノイズがEMI (Electromagnetic Interference) 問題を引き起こすため、EMIフィルタの設計 (例: C_x (Xコンデンサ), C_y (Yコンデンサ), L (コイル)) が重要である。この時、ノイズの目標値を達成する設計値の探索にはシミュレーションや実測を繰り返して一つの設計値を決める。この設計手法はポイントベース設計手法 (図5(a)) と呼ばれ、設計パラメータ X_n (例: X_1, X_2, \dots) の組み合わせを探索して要求を満たす一つの解を求める方法である。しかし、仕様変更やばらつきが発生する場合、この方法では目標を満たすことができない場合がある。例えば、図6に示すように、車両Aで合格とした設計値を車両Bなどに横展する場合、ケーブルの長さ L が変わるだけでノイズレベルが目標未達となり、設計の再検討が必要になる場合がある。

そこで、要求が満たされる範囲の中から設計値を選択できる手法 (冗長設計, 図5(b)) を提案する。これにより、仕様変更される場合や部品ばらつきなどが発生しても目標を満足できるため、対策工数の削減が可能となる。この設計思想は特に、今後増加の見込みがある統合化製品や高電圧、高機能製品などといった複雑なシステムではより効果が増してくると考えられる。

一方で、冗長設計の課題は、設計範囲内にある目標を満たす設計空間を広く探索するために、「時間のかかる計算or実測」を「設計空間を網羅できる分、サンプリング」する点である。




図5 ポイントベース設計と冗長設計手法




図6 仕様変更によるノイズレベルの変化

我々はこれらを解決するために、まず、計算時間を短縮する手法を検討する。これはシミュレーションをANNで代替させることで、短時間で結果を予測できるモデルを構築する。次に、実用性を鑑みて、設計変数が増加した場合を想定する。この時、膨大な設計空間を効率よく近似・網羅するために訓練データを効率的に準備可能なサンプリング戦略を検討する。

3. 車体系製品を対象としたAI活用

3.1 ANNを活用した冗長設計手法

ANNを用いた冗長設計手法を車体系製品のCISPR25¹⁴⁾準拠の伝導エミッション試験(図7)で適用した例を紹介する。本手法の手順は図8を用いて説明する。

- (i) 設計パラメータ X_n と目的関数 Y_m を決定。
- (ii) 部分組合せの解析結果 Y のデータを取得。
- (iii) (ii)の組合せと結果からANNに学習
- (iv) 学習済ANNで全組み合わせを予測。
- (v) 合格結果から設計パラメータの範囲解を抽出。
- (vi) 複数の範囲解から一番広い範囲解を決定

ANNモデルの構造とモデル学習に用いたハイパーパラメータは図9に示す。ミニバッチ確率的勾配降下法を使用して、エポックごとに真値と予測値の差分から重み w とバイアス b を更新することで作成する。設計パラメータとノイズ電圧スペクトルを訓練データとしてANNモデルに学習させる際、組み合わせは設計パラメータ3水準(=3⁴通り)とする。この入力変数と、これに対応する解析結果である出力変数を訓練データに用いた。よって、複数の要求性能を満たす、複数の設計パラメータを範囲解して得ること(冗長設計)が可能となる。

3.2 ANNを用いた設計手法の結果

まず、ANN予測結果と真値の比較を行う。図10にはノイズスペクトル V_H の比較を行っており、最大で3dBの誤差で予測可能であることを確認した。

次に、ANN予測計算を約150万通りの計算を行う

(iv). 図11にはANNによる約150万通りのノイズスペクトルと目標を満たしたノイズスペクトルのみを抽出した。

最後に、アルゴリズムにより逆解析をすることで(v)、複数の設計パラメータの範囲解を得た(例: $C_x = 500 \sim 1500\text{pF}$, $C_y = 2500 \sim 4000\text{pF}$, $L = 1500 \sim 1800\text{ nH}$, 配線長 $\Lambda = 1.7 \sim 2.3\text{m}$). これは部品バラツキや配線長が最大0.6m変化しても目標を満足できる範囲解を得たことを意味している。さらに従来計算工数が約150時間であったのに比べ、本手法は1時間21分で得られたため工数の短縮化が図れた。ANNにより従来の設計工数を低減できる有効な手法であることが示された。




図7 車体系製品の伝導エミッション試験解析モデル

- (i) 設計変数 X_n (例 C_x, C_y, L, Λ)と目的関数 Y_m (例 V_H, V_L)決定
- ※ n : 設計変数の数, m : 目的関数の数, s : 設計範囲の分割数

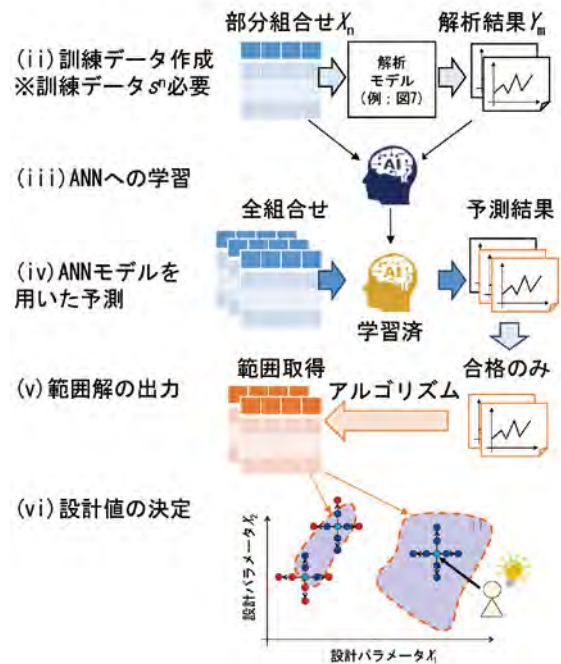


図8 ANNを用いた冗長設計手法の手順




図9 ANNモデルとハイパーパラメータ

ハイパーパラメータ	
条件	手法
最適化	Adam
損失関数	MSE
学習率	0.0001
バッチサイズ	5
エポック数	1000




図10 ANN予測結果と真値の比較




図11 予測結果150万通りから目標値を満足した結果のみを抽出したスペクトル

4. PT系製品を対象としたAI活用

4.1 PT系製品におけるAI活用の課題

本節ではPT系製品への適用における課題を考える。PT系製品ではIGBTやMOSFETなどのスイッチング素子を含む非線形回路が含まれており、数100Vの変動でかつ100MHzを超えるノイズ波形を正確に予測する必要がある。そのため、計算工数の高い過渡解析が不可欠である。また回路規模やノイズ源の増加に伴い、設計変数は4変数から7変数に増加する。その結果、表1に示す通り車体系製品と同様の訓練データの取得には9ヶ月以上を要する見込みで非現実であり、訓練データに用いるサンプリング数の戦略を考える必要がある。

そこで少数の学習データでもANNの効率的な学習を実現することを目的に、既存のサンプリング法の評価を行う。この時、直交配列(Orthogonal Arrays: OAs)^{15),17)}とラテン超方格サンプリング(Latin Hypercube Sampling: LHS)^{16),18)}によって取得したデータを用いてANNモデルを学習し、ノイズ電圧スペクトルの予測精度を検討する。OAsは実験計画法に基づく手法であり、OAsは規則性を持つ均等なサンプリングを行う手法である。一方でLHSはランダム性を加えつつ設計空間全体にばらけた分布を持たせる手法である。また比較の基準として一般的なランダムサンプリングも含めた。

4.2 シミュレーションモデルとANNモデルの学習方法

図12に対象とするPT系製品の回路ブロック図を示す。この回路モデルは高電圧バッテリーを電源とし、三相交流、交流100V、直流12Vを生成する車両用電源システムである。この時、設計パラメータX(この場合 $C_x, C_{y1}, C_{y2}, L_{c1}, L_{c2}, L_{c3}, L_{c4}$)と目的関数Y(100

VAC(V_{ac}), DC12 V(V_{lv}), 高電圧バッテリー(V_{hv}))を決定した。ANNモデルにおけるハイパーパラメータは3.2節と同様のモデルを用いる。

4.3 各サンプリング手法と予測精度評価法と結果

サンプリング手法比較のための訓練データセットを表2に示す。予測精度の評価指標には平均二乗誤差(Mean Squared Error: MSE)を採用した。表2に示す3種類のノイズ電圧スペクトル(V_{ac}, V_{lv}, V_{hv})の3種類の計算で予測精度の評価を行う。テストデータ $M=21$ 組を用い、ANNモデルによる予測値とシミュレーションによる真値を比較する。MSEは図13に示すように各周波数における予測値と真値(シミュレーション結果)のスペクトル間におけるMSEを平均化することで計算した(式(1)(2))。

$$MSE_j = \frac{1}{N} \sum_{i=1}^N (y_{ij} - \hat{y}_{ij})^2 \quad (1)$$

$$Mean\ MSE = \frac{1}{M} \sum_{j=1}^M MSE_j \quad (2)$$

※ $N=300$ はスペクトル点数、 y_{ij} はテストデータ j の真値スペクトルの第 i 成分、 \hat{y}_{ij} はANN予測値である。

表1 車体系と車両電源システムの比較

	車体系製品	PT系製品
設計変数	4変数	7変数
解析手法	周波数解析 (1分/1回)	過渡解析 (3時間/1回)
サンプル数	3 ⁴ (81)通り	3 ⁷ (2187)通り
解析時間	1時間21分	6561時間 (約9ヶ月)

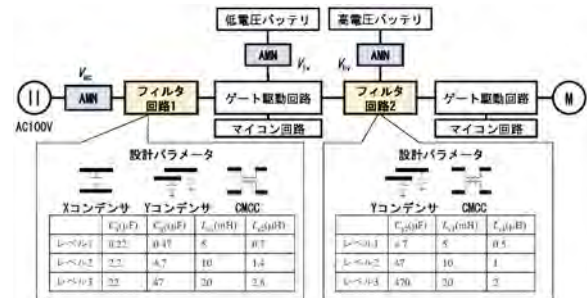


図12 PT系製品のブロック図と設計パラメータ

表2 訓練データに用いるサンプリング手法

サンプリング手法	サンプル数 (呼称)	MSE結果		
		V_{ac}	V_{lv}	V_{hv}
OAs	18(OA18)	10.2	2.7	2.3
	27(OA27)	11.5	2.8	2.0
LHS	18(LHS18)	15	3.4	2.9
	27(LHS27)	13.2	3.1	2.7
ランダム	18(RND18)	11.8~15.8	2.6~3.9	2.0~3.4
	27(RND27)	11.2~15.3	2.6~3.4	1.8~2.6




図13 シミュレーション結果とANN予測結果の比較

表2に、各サンプリング手法における予測精度MSEの比較結果を示す。評価対象は3種類のノイズ電圧スペクトル(V_{ac} , V_{lv} , V_{hv})である。またランダムサンプリング(RND18, RND27)の10セットの分布を表している。

全てのノイズ予測スペクトルにおいて、OAsはLHSやランダムサンプリングよりも低いMSEが得られた。これは、OAsがパラメータ空間に対して因子の水準を均等かつ系統的に配置できる特性を持ち、限られたサンプル数でも情報を効果的に抽出できるためと考えられる。ランダムサンプリング(10セット)は予想通り、ばらつきが大きく、最大で約5dBの差が確認された。以上より、少数の学習データであっても、OAsのような系統的なサンプリング手法は、ランダムサンプリングやLHSに比べて高い予測精度と安定性を実現できることが確認できた。

5. 今後の展望とまとめ

本稿では統合化・高電圧化・知能化の分野における製品群におけるマルチフィジックス解析の重要性に着目した。特にEMC解析では計算工数が高くなる傾向がある課題を示し、車体系製品を例にANNを用いた冗長設計手法を説明した。またPT系製品を対象とした場合での訓練データ取得の効率化を検討した。今後は、3次元電磁界解析におけるAIを用いた短縮化、マルチフィジックス自動解析と最適設計プラットフォームの作成を目指す。

参考文献

- 1) V.Devabhaktuni, C.F.Bunting, D.Green, D.Kvale, L.Mareddy, and V.Rajamani, "A New ANN-Based Modeling Approach for Rapid EMI/EMC Analysis of PCB and Shielding Enclosures," IEEE Trans.on Electromagn.Compat., vol.55, no.2, pp.385-394, 2013.
- 2) A.Veluswami, M.S.Nakhla, and Q.-J.Zhang, "The Application of Neural Networks to EM-Based Simulation and Optimization of Interconnects in High-Speed VLSI Circuits," IEEE Trans.Microw.Theory Tech., vol.45, no.5, pp.712-723, 1997.
- 3) J.Xu., M.C.E.Yagoub, R.Ding, and Q.-J.Zhang, "Neural-Based Dynamic Modeling of Nonlinear Microwave Circuits," Proc.IEEE Trans.Microw.Theory Tech., vol.50, no.12, pp.2769-2780, 2002.
- 4) H. Chen and S.Ye, "Modeling and Optimization of EMI Filter by Using Artificial Neural Network," Proc.IEEE Trans. Electromagn.Compat., vol.61, no.6, pp.1979-1987, 2019.
- 5) J.Gao, D.Lu, S.Ye, and H. Chen, "Modeling of EMI Filter by Means of Recurrent Neural Network with Encoding

Layer," Proc.2022 APEMC, pp.285-288, Sept.2022.

- 6) H.Suenaga, M.Nagata, "Prediction of Automotive Radiated Emission Using Machine Learning", EMC Europe 2023, pp.1-5, Kraków Poland, Sep.2023.
- 7) H.Ikeda and A.Sakurai, "EMC design with machine learning," Annual Meeting Record, I.E.E.Japan, S5-4, Mar.2022.
- 8) S.Kan, N.Takahashi, M.Himuro, A.Mashino, K.Iokibe, and Y.Toyota, "Multi-Objective Design of Filter Installed in Brush Motor by Artificial Neural Network Accounting for Cable Length," Proc.2023 IEEE EMC+SI/PI, p.591, Grand Rapids, USA, July 2023.
- 9) J.M.Marinis et al., "Quantum Supremacy using A Programmable Superconducting Processor," Nature, vol.574, pp.505-510, 2019.
- 10) P.Wu et al., "Co Design Optimization For PI/SI When Considering Thermal Performance," Semiconductor Engineering Manufacturing, Packaging & Materials, Apr.21, 2025.
- 11) T.-Y.Wang and J.-L.Tsai, "Thermal and Power Integrity based Power/Ground Networks Optimization," in Proc. Design, Automation and Test in Europe Conference and Exhibition (DATE'04), Munich, Germany, Mar. 2004, pp.830-835.
- 12) R.Ciprian and B.Lehman, "Steady State Electro Thermal Modeling," in Proc.IEEE COMPEL Workshop, Rensselaer Polytechnic Institute, Troy, NY, USA, July 16-19, 2006, pp.289-294.
- 13) S.Maeta, R.Maekawa, S.Kan, T.Mikura, K.Iokibe, and Y. Toyota, "ANN-based EMI Filter Optimization with Limited Data in Vehicle Power Systems," Proc. 2025 IEEE EMC+SI/PI, pp.164, Raleigh, USA, Aug.2025.
- 14) International Electrotechnical Commission, CISPR 25: Vehicles, boats and internal combustion engines - Radio disturbance characteristics - Limits and methods of measurement for the protection of on-board receivers, IEC Standard 25, 2021.
- 15) G.Taguchi, Introduction to Quality Engineering, Asian Productivity Organization, 1986.
- 16) M.McKay, R.Beckman, and W.Conover, "A comparison of three methods for selecting values of input variables in the analysis of output from a computer code," Technometrics, vol.21, no.2, pp.239-245, 1979.
- 17) D.A.Abdaljabar and A.A.A.Al Khafaji, "Reducing cost and time by proposing methodology to fill Taguchi orthogonal array using prediction and neural network," Procedia of Engineering and Medical Sciences, vol.10, no.1, pp.1-8, 2025.
- 18) P.Borisut and A.Nuchitprasittichai, "Adaptive Latin Hypercube Sampling for a Surrogate Based Optimization with Artificial Neural Network," Processes, vol.11, no. 11, pp.3232-3248, Nov.2023.

筆者



菅 翔平

解析技術部 部付
電子系解析技術に従事