

AlGaN/GaN HEMT のデバイスシミュレーションの機械学習

Machine learning for device simulation of AlGaN / GaN HEMT

名大院工¹, 名大未来研², 理研 AIP³, 産総研 GaN-OIL⁴

○蜂谷 涼太¹, 杓掛 健太郎^{2,3}, 原田 俊太^{1,2}, 田川 美穂^{1,2}, 宇治原 徹^{1,2,4}

Grad. School of Eng., Nagoya Univ.¹, IMASS Nagoya Univ.², AIP RIKEN³, GaN-OIL AIST⁴

○Ryota Hachiya¹, Kentaro Kutsukake^{2,3}, Shunta Harada^{1,2}, Miho Tagawa^{1,2}, Toru Ujihara^{1,2,4}

E-mail: hachiya@unno.material.nagoya-u.ac.jp

【緒言】 半導体デバイスの開発にはデバイスシミュレーションが必須であるが、物性値が正確に定まっていない材料系においては、実際のデバイス結果を良く再現するシミュレータを得ること自体が大きな課題である。現状では、膜厚、ゲート長などの構造パラメータ、移動度、誘電率などの物性パラメータの膨大な組合せから、実験結果に良く一致する組合せを経験的に得ているが、精度や根拠の点で課題がある。そこで我々は、調整パラメータを入力とした機械学習モデルを作成し、実験結果に一致するパラメータの組合せを統計的に求める方法を提案している。今回は、この方法の AlGaN/GaN High Electron Mobility Transistor (HEMT) (Fig. 1(a)) シミュレーションへの応用を検討した。HEMT の IV 特性の機械学習モデルを作成し、さらに、設定した IV 特性に一致するパラメータの組合せを求めた。

【計算方法】 機械学習に必要な教師データ作成のために、ゲート・ドレイン電極間距離(a)、ゲート・ソース電極間距離(b)、AlGaN 層膜厚(c)、AlGaN 層 Al 濃度(d)、ゲート電極幅(e)、ドレイン・ソース電極仕事関数(f)の 6 つのパラメータをランダムに振った 300 条件の IV 特性のデバイスシミュレーションを Atlas(Silvaco 社製)を用いて行った。記号は Fig.1(a)中の記号に対応する。計算結果からドレイン電圧とドレイン電流を抽出し、教師データとした。機械学習は、設定した 6 つのパラメータにドレイン電圧を加えた 7 つのインプットパラメータに対して、ドレイン電流をアウトプットパラメータとしてニューラルネットワークを用いた回帰を行った。その後テストデータを用いて精度の検証を行った。次に逆問題解析として、テストデータの一つを真値と定め、予測 IV カーブとの二乗和誤差が最小となるインプットパラメータ (AlGaN 膜厚、Al 濃度、仕事関数の三種) の値を求めた。計算手法は準ニュートン法の一つである L-BFGS 法を用い、初期値の組合せをランダムに 500 個設定し、収束値の分布を求めた。設定した真値と収束値を比較することで、逆問題解析の精度検証を行なった。

【結果と考察】 得られた機械学習モデルにおいて、テストデータの電流値とモデルの予測電流値の重相関係数は 0.9988 であった。最適化計算による AlGaN 膜厚と電極の仕事関数の 500 の収束値の分布を Fig. 1(b)と Fig. 1(c)に示す。図中に真値を矢印で示す。真値と収束値を比較すると、AlGaN 層の膜厚は概ね真値の付近に収束したが、仕事関数は真値とは外れた位置に収束した。最適化計算は、シミュレーションの IV カーブに対してフィットする解を、機械学習モデルを用いて探索した。そのため、仕事関数での真値と収束値の差は、機械学習モデルとシミュレーション結果との誤差によって生じていると考えられる。今後は本手法を用いて電子移動度などの予測を行なっていく。




Fig.1 (a) Structural example of AlGaN / GaN HEMT. (b) Distribution of solution of AlGaN layer thickness. (c) Distribution of solution of work function of electrode.