

基于神经网络的雪崩光电二极管 SPICE 模型构建

谢海情^{1,2}, 宜新博¹, 曾健平^{3†}, 曹武¹, 谢进¹, 凌佳琪¹

- (1. 长沙理工大学 物理与电子科学学院, 湖南 长沙 410114;
2. 长沙理工大学 柔性电子材料基因工程湖南省重点实验室, 湖南 长沙 410114;
3. 湖南大学 物理与微电子科学学院, 湖南 长沙 410082)

摘要:针对雪崩光电二极管(Avalanche Photodiode, APD)雪崩前后电流数量级相差大、 $I-V$ 特性曲线变化剧烈的特点,在对 $I-V$ 特性数据进行对数化、归一化预处理的基础上,采用浅层神经网络完成 $I-V$ 函数拟合,并进一步优化神经网络结构以提升模型准确性.在此基础上,使用Verilog-A硬件描述语言实现APD的SPICE模型,并应用Cadence软件设计电路验证模型的有效性和准确性,引入相对误差评估模型的准确度.结果表明:优化后的神经网络学习的 $I-V$ 特性函数与TCAD仿真数据的均方误差损失为 2.544×10^{-7} ,SPICE模型验证电路采样数据与TCAD仿真数据的最大相对误差为3.448%,平均相对误差为0.630%,构建SPICE模型用时约50 h,实现了高精度、高效率的器件SPICE模型构建,对新型APD的设计与应用具有重要指导意义.

关键词:SPICE模型;雪崩光电二极管;神经网络;相对误差

中图分类号:TN364.2 **文献标志码:**A

SPICE Model Construction of Avalanche Photodiode Based on Neural Network

XIE Haiqing^{1,2}, YI Xinbo¹, ZENG Jianping^{3†}, CAO Wu¹, XIE Jin¹, LING Jiaqi¹

- (1. School of Physics & Electronics Science, Changsha University of Science & Technology, Changsha 410114, China;
2. Hunan Provincial Key Laboratory of Flexible Electronic Materials Genome Engineering, Changsha University of Science & Technology, Changsha 410114, China;
3. School of Physics & Electronics, Hunan University, Changsha 410082, China)

Abstract: To address the current of avalanche photodiodes (APD) with large differences in orders of magnitude before and after the avalanche and drastic changes in $I-V$ characteristic curves, a shallow neural network is used to complete the $I-V$ function fitting based on logarithmic and normalized pre-processing of $I-V$ characteristic data, and the neural network structure is further optimized to improve the model accuracy. On this basis, the SPICE model of APD is implemented in Verilog-A hardware description language, the validity and accuracy of the model are verified

* 收稿日期:2023-01-08

基金项目:湖南省自然科学基金项目(2021JJ30739), Natural Science Foundation of Hunan Province (2021JJ30739); 长沙市科技计划重点项目(kq1901102), The Key Projects of Changsha Science And Technology Plan(kq1901102); 湖南省教育厅科学研究项目(20K007), Scientific Research Fund of Hunan Provincial Education Department (20K007); 湖南省研究生科研创新项目(CX20210826), Postgraduate Scientific Research Innovation Project of Hunan Province(CX20210826)

作者简介:谢海情(1982—),男,湖南耒阳人,长沙理工大学副教授,博士

† 通信联系人, E-mail: 34907264@qq.com

by designing the circuit in Cadence, and the relative error is introduced to evaluate the model accuracy. The results show that the mean square error loss of the $I-V$ characteristic function learned by the optimized neural network and the TCAD simulation data is 2.544×10^{-7} , the maximum relative error of the SPICE model verification circuit and the TCAD simulation data is 3.448%, the average relative error is 0.630%, and the time spent to construct the SPICE model is about 50 hours. High-precision and high-efficiency device SPICE model construction are realized, which has important guiding significance for the design and application of new APDs.

Key words: SPICE model; avalanche photodiode; neural network; relative error

随着半导体器件的飞速发展,摩尔定律已接近极限,研究人员积极寻求制造器件的新工艺、新材料、新结构^[1-3].构建高精度器件模型是实现器件设计、优化与应用的关键,以数学公式描述器件电气行为的 SPICE 模型因具有建模周期短、准确性高等特点而备受关注.根据器件某种特性的仿真、测量数据构建准确的特性函数对 SPICE 模型的有效性、准确性起决定性作用.梁家铨^[4]通过将 4H-SiC 材料参数及横向沟道结型场效应晶体管结构与 Shockley 模型结合,构建器件的 SPICE 模型,该模型仅能反映器件特性曲线的趋势,不能拟合特性细节,准确性差,对物理理论知识要求高,且建模时间长.Zhang 等^[5]首先构建了忽略沟道运输的理想漏电流模型,再分别采用 Drain-FET、Source-resistance 方法考虑沟道运输,构建了隧穿场效应晶体管的 SPICE 模型,此模型较好地模拟了器件的特性,但精度有限.邓雯娟^[6]将器件的特性曲线变换为多段近似线性曲线的组合,进而通过 Origin 工具对曲线进行拟合,基于此构建 SPICE 模型,该模型能较好地反映器件的特性趋势,但拟合曲线的精度有限,且建模时间较长.Zheng 等^[7]用分段非线性函数对器件的特性曲线进行拟合,并解决了函数的收敛问题,该方法在曲线非线性程度较低的部分拟合效果较好,但在非线性程度较高的部分拟合效果差.针对以上问题,近年来,神经网络作为一种新方法在器件建模领域被广泛使用.相较于传统方法,目前已有的基于神经网络构建的 SPICE 模型有效地提高了器件特性曲线的拟合精度,尤其是对复杂曲线的拟合能力大大增强,并且降低了建模的难度,缩短了建模时间,然而非线性程度较高的曲线中仍存在拟合准确度不高的缺点^[8-9],且往往缺少对拟合效果的评估^[10-11].此外,现有的基于神经网络的 SPICE 模型构建方法大多针对场效应晶体管,特性曲线变化程度相对平缓^[12-14].对雪崩光

电二极管而言,由于其存在雪崩过程,雪崩前后电流数量级相差大,曲线变化剧烈^[15],如不对数据进行预处理,神经网络模型不能很好拟合其特性曲线,导致 SPICE 模型准确性差.

针对上述问题,本文提出了一种从仿真或测量数据预处理,到神经网络搭建、优化,再到 SPICE 模型构建的方法.对数据进行预处理、优化神经网络结构以提升模型准确性.采用 Verilog-A 硬件描述语言实现 APD SPICE 模型构建,并在 Cadence 中验证模型的有效性和准确性,引入相对误差评估模型的准确度.

1 SPICE 模型构建与验证

神经网络算法能够从模型的输入中学习到数据特征与规律,并将其用于处理新的数据,因此数据决定了神经网络模型性能的上限.本文使用 Silvaco TCAD 工具对一种 SOI 基 LSAMB M APD (如图 1 所示^[16])的 $I-V$ 特性进行仿真计算,仿真数据作为神经网络的训练数据.




图 1 SOI 基 LSAMB M APD 结构

Fig.1 Structure of LSAMB M APD based on SOI film

为使数据更有利于神经网络模型的训练,本文采用对数化与归一化两种方法对数据进行预处理.对电流数据取对数[式(1)],放大了数据的变化,使神经网络能更好地学习数据中的细节特征.式(1)中, I 表示电流, I' 表示对数化后的电流.图2反映了

原始数据对数处理前后的变化,其中左轴为线性坐标轴,右轴为对数坐标轴.原始数据中电流的范围为 $8.5 \times 10^{-14} \sim 3.27 \times 10^{-6}$ A.数据量级过小,神经网络训练速度慢,且不利于损失函数评估训练结果;量级跨度过大,数值较大的特征可能会完全支配其他特征,不利于神经网络捕捉 I - V 特性中的细节信息.本文采用式(2)、式(3)分别对电压、电流数据进行归一化处理,式中, V 表示电压, V'' 表示归一化处理后的电压, I'' 表示归一化处理后的电流, V_{mean} 、 I'_{mean} 、 V_{std} 、 I'_{std} 分别表示 V 与 I' 的平均值、标准差.图3为数据经归一化处理后的曲线图.由图3可知,经过两种方法处理后,电压的分布范围为 $-1.73 \sim 1.67$ V,电流的分布范围为 $-0.70 \sim 2.30$ A,从而可提高神经网络对 I - V 特性细节的捕捉,缩短训练时间,提升模型的准确度.

$$I' = \lg I \quad (1)$$

$$V'' = (V - V_{\text{mean}}) / V_{\text{std}} \quad (2)$$

$$I'' = (I' - I'_{\text{mean}}) / I'_{\text{std}} \quad (3)$$

本文采用PyTorch机器学习库,搭建包含输入层、输出层与2个隐藏层的浅层神经网络模型,其中输入层、输出层各有1个神经元,每个隐藏层各包含10个神经元.为了避免梯度消失导致网络收敛慢、不收敛,在隐藏层的每个神经元上均使用ReLU函数[式(4)]作为激活函数.式中: x 表示神经元的输入值,在输出层神经元上使用线性激活函数.该神经网络的数学表达式见式(5).

$$\sigma(x) = \max(0, x) \quad (4)$$

$$I'' = [w_{1,1}^3 \quad w_{1,2}^3 \quad \cdots \quad w_{1,10}^3] \sigma \left[\begin{bmatrix} w_{1,1}^2 & w_{1,2}^2 & \cdots & w_{1,10}^2 \\ w_{2,1}^2 & w_{2,2}^2 & \cdots & w_{2,10}^2 \\ \vdots & \vdots & & \vdots \\ w_{10,1}^2 & w_{10,2}^2 & \cdots & w_{10,10}^2 \end{bmatrix} \sigma \left[\begin{bmatrix} w_{1,1}^1 \\ w_{2,1}^1 \\ \vdots \\ w_{10,1}^1 \end{bmatrix} V'' + \begin{bmatrix} b_1^1 \\ b_2^1 \\ \vdots \\ b_{10}^1 \end{bmatrix} \right] + \begin{bmatrix} b_1^2 \\ b_2^2 \\ \vdots \\ b_{10}^2 \end{bmatrix} \right] + b_1^3 \quad (5)$$

式中: $w_{j,k}^i$ 表示第 i 层的第 j 个神经元与上一层第 k 个神经元之间的权重; b_j^i 表示第 i 层的第 j 个神经元上的偏置.

在训练时,初始学习率设置为0.1,并且每训练5000 Epoch便衰减为原来的99%.以随机梯度下降法作为网络优化器,以均方误差作为损失函数.使用预处理后的 I - V 特性数据训练该网络至500000 Epoch,此时损失值已收敛,训练用时约134 s,30次训练的最优损失值为 1.042×10^{-5} ,提取网络的权重矩阵与偏置矩阵,代入式(5),得到经过数据预处理的LSAMBM APD I - V 特性函数.

采用Verilog-A硬件描述语言,在Cadence软件中构建LSAMBM APD的SPICE模型.在Cadence




图2 原数据与电流取对数后的 I - V 特性曲线

Fig.2 I - V characteristic curve of the original data and the current after taking logarithm




图3 归一化后的 I - V 特性曲线

Fig.3 I - V characteristic curve after normalization

Verilog-A Editor中定义管脚、节点、支路、常量、变量,进而将经过数据预处理后的 I - V 特性函数作为器件的行为描述.并且,采用式(2)对SPICE模型的输入数据进行预处理使其符合 I - V 函数的数据特征.采用式(6)对输出数据做相应的反处理,使其符合APD SPICE模型的实际输出数据特征,式中: I'' 、 I''' 分别表示反处理前、后的电流.进一步建立LSAMBM APD的Symbol,完成基于神经网络的SPICE模型构建.

$$I''' = 10^{I'' \times I'_{\text{std}} + I'_{\text{mean}}} \quad (6)$$

在Cadence-Virtuoso Schematic Editing中分别为基于2层神经网络的SPICE模型、基于解析模型的SPICE模型^[7]搭建如图4所示的验证电路,获取 I - V 数据,与Silvaco TCAD工具的仿真数据对比,并计算

相对误差,以此评估 SPICE 模型的性能.




图 4 SPICE 模型验证电路

Fig.4 Verification circuit for SPICE models

图 5~图 8 为两种 SPICE 模型的验证结果与 TCAD 仿真结果的对比,图 5、图 7 左轴为线性轴,右轴为对数轴.由图 5、图 6 可以看出,基于解析模型的 SPICE 模型在雪崩电压附近与 TCAD 仿真数据的相对误差很大,最大相对误差为 82.553%,平均相对误差为 3.907%,不能精确地反映 APD 的 $I-V$ 特性.由图 7、图 8 可知,基于 2 层神经网络的 SPICE 模型最大相对误差为 6.673%,平均相对误差为 1.361%,误差相对较低,但在 7 V 以上的偏置电压范围内相对误差仍然不佳,产生这种现象的原因是数据预处理后, $I-V$ 特性曲线的非线性程度较高,仅有 2 个隐藏层的神经网络包含的参数少,对非线性程度较高曲线的学习能力弱.因此,本文进一步优化神经网络结构,以提升模型的精准度.




图 5 基于解析模型的 SPICE 模型与 TCAD 仿真结果对比
Fig.5 Comparison of simulation results of SPICE model based on analytical model and TCAD

2 SPICE 模型优化与验证

可学习参数更多的神经网络拥有更强的非线性函数拟合能力.由图 3 可知,经过预处理的 APD $I-V$




图 6 基于解析模型的 SPICE 模型与 TCAD 仿真结果相对误差
Fig.6 Relative error of simulation results of SPICE model based on analytical model and TCAD




图 7 基于 2 层神经网络的 SPICE 模型与 TCAD 仿真结果对比
Fig.7 Comparison of simulation results of SPICE model based on 2-layer neural network and TCAD




图 8 基于 2 层神经网络的 SPICE 模型与 TCAD 仿真结果相对误差
Fig.8 Relative error of simulation results of SPICE model based on 2-layer neural network and TCAD

特性数据仍然具有较高的非线性程度.因此,本文通过提升神经网络的深度以提升其可学习参数的数量,进而提高模型的精准度,寻求性能最佳的神经网络

络结构.图9反映了2~17层神经网络各训练30次损失值分布.




图9 2~17层神经网络各训练30次损失值分布

Fig.9 Distribution of loss values for each of the 2-17 layer neural networks trained 30 times

由图9可知,当隐藏层为2~13层时,各神经网络模型训练损失的最小值呈现下降趋势,这种现象契合了前面提到的更深的网络有更多可学习的参数,因此有更强的非线性函数拟合能力.但从14层开始,随着深度的增加,网络的最佳性能反而下降,并且在训练过程中,损失值过高,网络不更新的概率随着隐藏层数的上升而上升,17层以上的神经网络几乎不可训练.这是由于尽管在隐藏层神经元上使用ReLU作为激活函数,以降低梯度消失出现的概率,但过深的全连接神经网络在进行反向传播时,更多层的梯度累乘更容易导致网络陷入局部最优,同时训练更多的参数需要消耗更多的时间.从图9可以看出,当隐藏层数为13层时,神经网络的性能最好,此时最优的损失值为 2.544×10^{-7} ,比2层隐藏层神经网络模型的最优结果低2个数量级.

提取13层神经网络的权重和偏置参数,代入网络的函数表达式,得到 $I-V$ 特性函数.使用Verilog-A构建对应的SPICE模型,并搭建验证电路验证模型的有效性和准确性,结果如图10、图11所示,图10左轴为线性轴,右轴为对数轴.

由图11可知,基于13层神经网络的SPICE模型进一步改善了拟合精度,在线性坐标和对数坐标下都能精确地拟合 $I-V$ 特性数据,最大相对误差仅为3.448%,平均相对误差仅为0.630%,是基于2层神经网络的SPICE模型平均相对误差的46.3%,是基于解析模型的SPICE模型平均相对误差的16.1%.在建模用时上,由于训练参数更多的神经网络,构建系数更




图10 基于13层神经网络的SPICE模型与TCAD仿真结果对比

Fig.10 Comparison of simulation results of SPICE model based on 13-layer neural network and TCAD




图11 基于13层神经网络的SPICE模型与TCAD仿真结果相对误差

Fig.11 Relative error of simulation results of SPICE model based on 13-layer neural network and TCAD

多的数学表达式都需要更长时间,因此基于13层神经网络的SPICE模型的建模时间较其他两种模型更长,用时50 h.

3 结论

本文通过对一种SOI基横向吸收区-多缓冲区-倍增区分离雪崩光电二极管进行TCAD仿真获取 $I-V$ 特性数据,并对数据进行对数化和归一化预处理,构建、优化神经网络学习APD的 $I-V$ 特性函数,采用Verilog-A硬件描述语言构建其SPICE模型并进行了验证.结果表明,设计与优化的神经网络可以准确地拟合TCAD工具仿真得到的 $I-V$ 数据,最大相对误差仅为3.448%,平均相对误差仅为0.630%,进而使得SPICE模型能很好地反映APD的 $I-V$ 特性.相较于传

统的基于解析模型所构建的 SPICE 模型,基于优化后的神经网络所构建的 SPICE 模型准确性更高,且建模仅耗时 50 h,可以有效提高器件 SPICE 模型的构建效率,对新型光电器件的研发与应用具有重要推动作用.

参考文献

- [1] 顾晓峰,彭宏伟,梁海莲,等. 高速小回滞双向 SCR 的 ESD 防护器件设计[J]. 湖南大学学报(自然科学版),2019,46(8): 105-109.
GU X F, PENG H W, LIANG H L, et al. Design of ESD protection device for high speed and very small snapback DDSCR [J]. Journal of Hunan University (Natural Sciences), 2019, 46(8):105-109.(in Chinese)
- [2] LIU C, LU Y, YU X, et al. Hot carriers assisted mixed-dimensional graphene/MoS₂/p-GaN light emitting diode [J]. Carbon,2022,197:192-199.
- [3] ZENG M L, WANG Y, JIN X L, et al. Design, fabrication, and verification of blue-extended single-photon avalanche diode with low dark count rate and high photon detection efficiency [J]. Journal of Nanoelectronics and Optoelectronics, 2021, 16 (4) : 546-551.
- [4] 梁家铖. 4H-SiC LJFET 的 SPICE 模型研究与宽温反相器设计 [D]. 西安:西安电子科技大学,2021: 23-38.
LIANG J C. SPICE model research and wide temperature inverter design of 4H-SiC LJFET [D]. Xi'an: Xidian University, 2021: 23-38.(in Chinese)
- [5] ZHANG L N, CHAN M S. SPICE modeling of double-gate tunnel-FETs including channel transports [J]. IEEE Transactions on Electron Devices, 2014, 61(2):300-307.
- [6] 邓雯娟. SiC 横向 BJT SPICE 建模及在功率集成电路中的应用 [D]. 长沙:湖南大学,2021: 25-44.
DENG W J. Modeling of SiC transverse BJT SPICE and its application in power integrated circuits [D]. Changsha: Hunan University, 2021: 25-44. (in Chinese)
- [7] ZHENG L X, TIAN J J, WENG Z Q, et al. An improved convergent model for single-photon avalanche diodes [J]. IEEE Photonics Technology Letters, 2017, 29(10): 798-801.
- [8] LIU Y, ZHANG W Q, ZHU Z Q, et al. DC model for SiC MOSFETs using artificial neural network optimized by artificial bee colony algorithm [J]. AIP Advances, 2021, 11(11): 115219.
- [9] LEI Y, HUO X, YAN B P. Deep neural network for device modeling [C]//2018 IEEE 2nd Electron Devices Technology and Manufacturing Conference (EDTM). Kobe: IEEE, 2018: 154-156.
- [10] WANG J, KIM Y H, RYU J, et al. Artificial neural network-based compact modeling methodology for advanced transistors [J]. IEEE Transactions on Electron Devices, 2021, 68 (3) : 1318-1325.
- [11] ZARATE-DE LANDA A, ROBLIN P, REYNOSO-HERNANDEZ J A, et al. Modeling the I-V curves and its derivatives of microwave transistors using neural networks [J]. IEEE Microwave and Wireless Components Letters, 2012, 22 (9) : 468-470.
- [12] WEI J, MAO W, FANG H, et al. Advanced MOSFET model based on artificial neural network [C]//2020 China Semiconductor Technology International Conference (CSTIC). Shanghai:IEEE, 2020:1-3.
- [13] ABO-ELHADEED A F. Modeling carbon nanotube transistors using neural networks approach [C]//2012 International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD). Seville: IEEE, 2012:125-128.
- [14] MEHTA K, WONG H Y. Prediction of FinFET current-voltage and capacitance-voltage curves using machine learning with autoencoder [J]. IEEE Electron Device Letters, 2020, 42 (2) : 136-139.
- [15] 鲍诗仪,母浩龙,周锦荣,等.不同晶态 Ge 薄膜键合层对 InGaAs/Si 雪崩光电二极管性能的影响研究[J/OL].中国激光: 1-21. (2022-10-29) [2023-01-07]. <http://kns.cnki.net/kcms/detail/31.1339.TN.20221028.1035.058.html>.
BAO S Y, MU H L, ZHOU J R, et al. Effect of different crystalline Ge film bonding layers on the properties of InGaAs/Si avalanche photodiodes [J/OL]. Chinese Journal of Lasers: 1-21. (2022-10-29)[2023-01-07]. <http://kns.cnki.net/kcms/detail/31.1339.TN.20221028.1035.058.html>.(in Chinese)
- [16] XIE H Q, PENG Y D, LI J Y, et al. Lateral separate absorption multibuffer multiplication avalanche photodiode based on SOI film [J]. IEEE Transactions on Electron Devices, 2019, 66(7):3003-3006.