

DOI:10.19651/j.cnki.emt.2519593

基于 LightGBM 的标准单元动态电流预测^{*}

徐一玮 周冉冉 王永

(山东大学集成电路学院 济南 250101)

摘要: 随着半导体技术的发展,晶体管数量持续增长,电压降违例已经成为超大规模集成电路电子设计和测试中的关键挑战。动态电压降高度依赖于标准单元开关瞬间产生的电流,因此,高效准确地预测标准单元的动态电流具有重要意义。本文提出一种基于 LightGBM 的标准单元瞬态电流预测模型,通过 SPICE 获取训练数据,提取特征,使用交叉验证和网格搜索方法搜索模型最佳参数。该模型能够在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下,对标准单元的动态电流进行建模与预测。使用该方法建模时,无需标准单元内部结构信息,建模过程高效、通用性强。实验结果表明,在模型精度方面,该模型在各类标准单元上进行动态电流预测时的决定系数均不小于 0.928,模型精度优于 XGBoost 和 RFR 方法;在泛化能力方面,其适应性优于 ANN 和 LSTM 模型;在运行时间方面,该模型的建模时间和预测时间均小于 ANN、LSTM 和 RFR 方法。该模型在模型精度和计算资源上取得良好的平衡,可用于标准单元开关行为引发的动态电流预测,为动态电压降分析和违例检测提供高效可靠的支持。

关键词: 动态电压降;LightGBM;标准单元

中图分类号: TN409 **文献标识码:** A **国家标准学科分类代码:** 510.3040

Dynamic current prediction of the standard cells based on LightGBM

Xu Yiwei Zhou Ranran Wang Yong

(School of Integrated Circuits, Shandong University, Jinan 250101, China)

Abstract: With the development of semiconductor technology, the number of transistors is growing exponentially, and voltage drop violations have become a key challenge in the electronic design and testing of very large scale integrated circuits. The dynamic voltage drop is highly dependent on the instantaneous current generated by the standard cell switching, therefore, it is of great significance to efficiently and accurately predict the dynamic currents of the standard cells. This article proposes a standard cell transient current prediction model based on LightGBM. Training data is obtained through SPICE, features are extracted, and cross validation and grid search methods are used to search for the optimal parameters of the model. The model can predict the dynamic current of a standard cell under different combinations of output toggle directions, power voltages, input transition times and output load capacitance. When using this method for modeling, there is no need for internal structural information of standard cells, and the modeling process is efficient and versatile. The experimental results show that in terms of model accuracy, the determination coefficients of the model for dynamic current prediction on various standard cells are all greater than 0.928. The model accuracy is superior to XGBoost and RFR methods; the generalization ability is superior to ANN and LSTM methods; in terms of running time, the modeling time and prediction time of this model are both shorter than those of ANN, LSTM and RFR methods. This model achieves a good balance in model accuracy and computing resources and can be used for dynamic current prediction caused by standard cell switching behavior, providing efficient and reliable support for dynamic voltage drop analysis and violation detection.

Keywords: dynamic IR drop;LightGBM;standard cell

0 引言

电压降(IR drop)是指电流通过电源分配网络(power

delivery network, PDN)时,由于金属连线的电阻而引起的电压损耗^[1]。过大的电压降会导致芯片内部供电电压低于标准单元的最低工作电压,从而严重降低芯片性能,甚至导

收稿日期:2025-08-13

* 基金项目:国家自然科学基金(U23A20348)项目资助

致功能故障^[2]。为确保芯片正常工作,须尽量减小电压降引发的偏差。随着集成电路设计和制造工艺的不断发展,芯片中的晶体管数量不断增长。晶体管数量的持续增加进一步加剧了电压分布不均问题和局部电压降超限风险,进而使电压降违例成为超大规模集成电路(very large scale integration, VLSI)电子设计和测试的重要挑战^[3]。

电压降主要分为静态电压降(static IR drop)和动态电压降(dynamic IR drop)两类。静态电压降是指在芯片稳态工作的条件下,由平均电流导致的平均电压下降;动态电压降则依赖于逻辑电路的开关活动,通常发生在信号触发沿,是由瞬间大电流需求产生的显著电压压降^[4]。动态电压降主要受到逻辑电路在信号触发沿的转换行为影响,对时钟周期依赖较小^[1]。因此,静态电压降分析通常基于平均电流的测量,其结果直接取决于时间周期;而动态电压降则依赖于对瞬态电流建模与计算,计算复杂度更高。

由于瞬态电流波形变化复杂,不同商业工具提出多种电流源模型来对逻辑电路开关行为进行建模。Cadence 提出有效电流源模型(effective current source model, ECSSM),可在任意电源网络下提供单个标准单元在特定时刻的瞬电流,并存储不同输入转换时间和输出负载电容组合下的电流波形信息。Synopsys 则提出复合电流源模型(composite current source model, CCSM),同样能够存储不同输入转换时间和输出负载电容组合下的电流波形。这两种模型均采用查找表(lookup tables, LUTs)的形式存储波形数据,存储的波形信息越多,对瞬态电流的预测越准确。然而,过多的波形信息会带来显著的时间和内存开销^[5]。在实际应用中,LUT 仅包含少数特定的输入转换时间和输出负载电容的组合。对于不在表中的组合情况,需通过插值或者外推获得,从而导致精确度降低^[6]。

近年来,学术界将机器学习、深度学习等方法引入电压降分析与预测任务中,用于替代大量查找表,提升计算速度并减少存储资源开销。在静态电压降的研究中,已有多种机器学习方法应用,包括梯度提升算法(extreme gradient boosting, XGBoost)^[7-8]、深度神经网络(deep neural network, DNN)^[9]和卷积神经网络(convolutional neural network, CNN)^[3,10]等。应用于动态电压降分析的机器学习方法,主要分为基于图像的方法和基于标准单元的方法。前者主要借助 CNN^[11]、U 型网络(U-Net)^[12]和 XGBoost^[13]等,从 PDN 提取模型特征,将电路特征转化为特征图用于模型训练;后者侧重于对标准单元建模开关行为建模。例如, Moradi 等^[14]使用长短时记忆网络(long short-term memory networks, LSTM)方法,通过波形的仿真数据拟合电压波形。Bai 等^[15]提出具有主动学习机制的高斯过程回归(Gaussian process regression, GPR)模型以捕捉标准单元的动态电流特性。Vibhu 等^[16]使用随机森林回归(random forest regression, RFR)模型来表征标准单元内部晶体管电流的特性。Huang 等^[17]提出人工神经网络

(artificial neural network, ANN)的方法,用于多种工艺-电压-温度(process-voltage-temperature, PVT)变化组合下的标准单元开关行为的建模。Sun 等^[18]则用多层感知机(multilayer perceptron, MLP)拟合高速信号中动态电压噪声。

上述方法为电压降分析和预测研究提供了重要支持,显著提升了准确性并减少了存储资源开销,但在计算效率方面仍存在不足。LSTM 的序列依赖特性阻碍了批量并行处理,导致训练效率较低;GPR 和 RFR 随着数据量的增加,计算复杂度显著增加,难以应对大规模数据情况;ANN 和 MLP 均采用反向传播算法训练,每轮迭代需逐元素更新神经元输入,迭代次数多,时间成本大。总体而言,现有方法难以兼顾高精度与低时间成本。相比之下,轻量梯度提升机(light gradient boosting machine, LightGBM)采用基于叶节点生长策略的梯度提升机制^[19],支持并行计算和大规模数据处理的能力,能够在保证精度的同时显著提升训练效率。

本文提出了一种基于 LightGBM 的标准单元瞬态电流预测模型。该方法对不同标准单元分别进行建模,以输出信号转换、电源电压、输入转换时间和输出负载电容作为输入特征,采用仿真得到的电流波形作为数据集,建立 LightGBM 模型。该模型能够预测在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下的瞬态电流变化。该方法在建模时,不需标准单元内部结构信息,输入特征较少,降低了前期数据特征提取和处理的难度。在预测精度方面,本文采用的 LightGBM 模型性能优于 XGBoost 和 RFR 模型;在泛化能力方面,其适应性优于 ANN 和 LSTM 模型;在模型效率方面,其建模时间和预测时间均小于 ANN、LSTM 和 RFR 模型。

1 方法介绍

1.1 方法概述

本文提出的基于 LightGBM 标准单元瞬态电流预测模型的工作流程如图 1 所示,该流程包括数据生成、数据处理、LightGBM 模型训练和模型应用 4 部分。首先,通过定义标准单元参数,基于 SPICE 仿真,获取不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下瞬态电流波形数据;其次,对仿真结果进行数据预处理与特征提取,构建模型训练所需要的样本集;随后,用样本集训练 LightGBM 模型,并依据预测精度需求判断是否需要调整参数重新训练,直至模型精度满足要求;最后,将训练好的模型应用于任意输入条件下的瞬态电流波形预测,以支持动态电压降的快速分析与违例预测。

1.2 数据生成和数据处理

图 2 展示了建模前期数据收集的流程,涵盖数据生成和预处理两个阶段。对于每个标准单元,首先构建符合 SPICE 要求的对应仿真电路文件,接着修改仿真电路文件

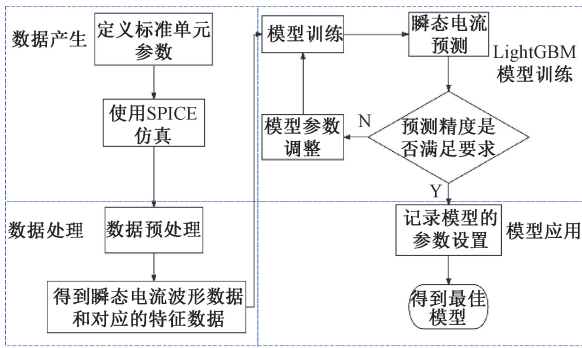


图1 瞬态电流预测模型的构建流程

Fig. 1 Flowchart of the construction process for the transient current prediction model

的参数设置,从而在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下对电路进行仿真。仿真后生成包含电流波形及相关特征参数的输出文件。最后,通过数据提取程序对文件进行处理,提取电流波形数据并将数据整理保存,供后续模型训练使用。




图2 电流波形数据集的产生流程图

Fig. 2 Flowchart for generating the current waveform dataset

一个标准单元的仿真电路如图3所示,图3中标注了需配置的参数,包括电源电压、输入转换时间以及输出负载电容。输出信号转换由标准单元的逻辑功能决定,通过设置输入信号高低电平组合来得到响应的输出信号的转换。在完成上述特征参数的配置后,即可得到对应的SPICE仿真电路文件。在仿真过程中采用逐一变量控制策略,依次以输出信号转换、电源电压、输入转换时间和输出负载电容为自变量进行仿真,每次仅调整其中一个参数,其余参数保持不变,以便准确分析各因素对标准单元动态电流的独立影响。

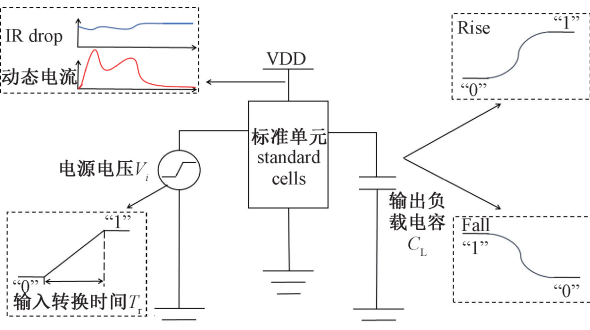


图3 标准单元的测试电路示意图

Fig. 3 Schematic diagram of the test circuit for standard cell

通过SPICE对仿真电路文件进行仿真,得到包含大量电路运行信息的输出文件。为提取有效数据,需对输出文件进行处理,仅保留与VDD端瞬态电流波形相关的电流数据及其对应特征参数。最终,将数据按{(标准单元名称、输出信号转换、电源电压、输入转换时间、输出负载电容)、(采样时间、电流值)}的格式存储,形成数据集。

批量生成仿真波形的具体过程如算法1所示。

算法1:批量生成仿真波形

Input: standard cell, output toggle direction (*Rise/Fall*), power voltage (*V*), input transition time (*T_r*), output load capacitance (*C_L*)

Output: Current waveform dataset

- 1: The process is TT, and the temperature is 25°C;
- 2: for *i* in standard cells
- 3: for *j* in (*Rise/Fall*)
- 4: for *v* in *V*
- 5: for *tr* in *T_r*
- 6: for *cl* in *C_L*
- 7: Modify the parameters *j*, *v*, *tr*, and *cl* in the simulation file;
- 8: Perform simulation using SPICE;
- 9: Extract waveform data from the output file;
- 10: end for
- 11: end for
- 12: end for
- 13: Sort out the waveform data;
- 14: return

在这一过程中,先设置工艺为TT、温度为25°C,再针对每个标准单元的不同输出信号转换类型,结合电源电压、输入转换时间以及输出负载电容的多种组合配置,依次调整仿真文件中的参数设置并进行SPICE仿真,生成多条瞬态电流波形,作为模型训练与测试的实验数据。

1.3 LightGBM 模型训练

本研究将标准单元在特定条件下的动态电流的预测问题转化为一个典型的回归建模任务,旨在刻画输出信号转换、电源电压、输入转换时间和输出负载电容等变量对电流变化影响。该问题具有电流波形变化复杂的特点,对模型在复杂情况的泛化能力、大规模数据的处理效率都提出了较高要求。综合评估多种回归模型后,本研究采用LightGBM算法构建标准单元电流预测模型。

LightGBM是一种基于梯度提升决策树(gradient boosting decision tree, GBDT)的高效框架,具备支持高效并行训练、训练速度快、内存开销小、预测精度高等显著优

势。LightGBM 在 GBDT 的基础上引入梯度单边采样技术 (gradient based one-side sampling, GOSS) 和独立特征合并技术 (exclusive feature bundling, EFB)^[19]。在标准单元瞬态电流波形的预测中, 原始波形信号存在波形突变段和平稳段。GOSS 会优先保留大梯度样本, 同时随机抽样保留小梯度样本, 从而将计算资源集中在电流快速变化区域, 提高模型对瞬态特征的捕捉能力。EFB 则通过合并互斥的稀疏特征, 减少特征矩阵的稀疏性与存储开销, 高效整合电源电压、输入转换时间和输出负载电容等模型特征, 从而提高模型的训练效率。

此外, LightGBM 使用直方图算法^[19]替代传统 GBDT 中预排序策略, 有效减少内存消耗并加快模型训练速度。该算法是将连续的浮点特征值离散成整数值, 统计每个区间累计信息并存储在直方图中。在标准单元瞬态电流预测中, 原始波形存在大量微小波动, 这些波动对整体趋势影响有限, 但会产生大量近似而非完全相同的浮点值。通过直方图算法离散化, 这些近似值被归入同一区间, 实现特征压缩与波形平滑。同时用整数代替浮点特征, 相当于对特征进行一定程度的正则化处理, 使模型更加关注波形的整体变化趋势而非局部噪声, 增强了模型鲁棒性。

LightGBM 的训练过程基于决策树模型, 把多棵决策树的输出加权求和作为最终的预测结果^[20]。首先, 使用 EFB 合并互斥的稀疏特征并初始化树模型; 随后, 计算负梯度拟合残差并将残差使用 GOSS 进行调整, 调整后的残差作为样本新标签导入到下一个树模型; 接着, 不断更新迭代树模型, 直至得到一个高精度的回归预测模型。在单棵决策树的构建中, 使用直方图算法加速最优分割点的搜索, 减少冗余计算带来的额外消耗。在整个训练过程中, 采用五折交叉验证和网格搜索穷举相结合的方式对超参数调优, 以获得最优的参数配置。五折交叉验证将数据集分成 5 个子集, 进行多次训练和验证, 确保每个样本都有机会作为训练和验证数据, 从而缓解因数据划分不均对模型性能的影响, 降低过拟合的风险并提高模型的泛化能力^[21]。

2 实验设置及结果分析

2.1 实验设置

本实验在统一的服务器环境中完成模型训练, 所采用的服务器配置为 Intel(R) Core(TM) i5-9500 CPU, 内存为 8 GB。训练与测试采用的软件环境为 Python 3.10.12。所有的实验均在该配置下进行, 所用标准单元均来自 UMC 55 nm 工艺标准库。为验证所提模型的有效性, 本文选取标准单元库中两个具有代表性的标准单元 INVM2T 和 DFCQM2T 进行实验。

其中, INVM2T 是一个反相器, 是一个典型的组合逻辑电路; DFCQM2T 是一个 D 触发器, 是一个常用的时序逻辑电路。模型的特征及其取值范围如表 1 所示, 所有瞬

态电流波形的特征参数都在该范围内选取。

表 1 模型特征的取值范围

Table 1 The range of values for model characteristics

特称名称	符号	选取范围
电源电压	V	1.08~1.32 V
输入转换时间	T_r	2~500 ps
输出负载电容	C_L	1~60 fF
输出信号转换	Rise/Fall	上升/下降

本研究使用的 LightGBM 模型采用负均方误差作为得分函数, 使用五折交叉验证和网格搜索对模型超参数进行调优, 选取的参数和搜索范围如表 2 所示。在模型训练过程中, learning_rate 控制模型学习速度, 避免参数更新步长过快或过慢; n_estimators 决定决策树的数量; feature_fraction 控制随机采样特征的比例, 提升泛化能力; num_leaves 和 max_depth 限制树的复杂度, 防止过拟合。

表 2 超参数的取值范围

Table 2 Range of values for hyperparameters

参数	名称	范围
learning_rate	学习率	[0.05, 0.06, 0.07, 0.08, 0.09, 0.1]
n_estimators	迭代次数	[100, 200, 300, 400]
feature_fraction	特征采样率	[0.7, 0.8, 0.9, 1]
num_leaves	叶子节点数	[15, 31, 63]
max_depth	树的最大深度	[6, 7, 8]

以 INVM2T 单元输出信号转换上升的情况为例, 根据电源电压、输入转换时间以及输出负载电容的多种组合配置, 生成超过 4 000 条瞬态电流波形, 作为模型训练的实验数据。对 INVM2T 开关活动发生后的电流波形进行采样, 每个电流波形包含 60 个采样点。其中训练集、验证集、测试集按照 7:2:1 的比例进行划分。该模型经过五折交叉验证和网格搜索后得到的最佳超参数配置为 {'learning_rate': 0.06, 'n_estimators': 300, 'feature_fraction': 0.9, 'num_leaves': 63, 'max_depth': 7}。

2.2 评价指标

本文采用了多种指标来评估预测波形的质量, 通过判断 SPICE 仿真结果与 LightGBM 模型预测结果的差距, 从而评价 LightGBM 模型的准确性。本文采用的评估指标有:

1) 均方根误差 (root mean squared error, RMSE), 用于衡量预测值与真实值之间差异的指标, 用于评估模型预测结果的偏离程度, 计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$


其中, n 为样本总数, y_i 为样本真实值, \hat{y}_i 为样本预测值。

2) 平均绝对误差(mean absolute error, MAE), 用于计算所有误差绝对值的平均值, 直观反映预测值与实际值的平均偏离程度, 计算公式如下:


$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

3) 决定系数(coefficient of determination, R^2), 用于衡量因变量与所有自变量的整体线性相关性, 表示模型预测值与实际值的拟合程度, 计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$



(a) INVM2T output signals rise




(c) DFCQM2T output signals rise

其中, \bar{y} 为实际值的平均值。


$RMSE$ 和 MAE 越小表示模型预测的误差越低, R^2 越接近 1 则表明模型拟合效果越好。

2.3 实验结果与分析

图 4(a) 和 (b) 展示了 INVM2T 单元的 LightGBM 模型在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下预测的瞬态电流波形与对应 SPICE 仿真的瞬态电流波形。图 4(c) 和 (d) 展示了 DFCQM2T 单元的 LightGBM 模型在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下预测的瞬态电流与对应 SPICE 仿真的瞬态电流波形。表 3 列出从训练集之外选取的不同单元类型及转换方向情况下所对应的特征参数组合, 图 4 中 INVM2T 和 DFCQM2T 的瞬态电流波形均采用该表中的特征参数设置。



(b) INVM2T output signals fall



(d) DFCQM2T output signals fall

图 4 LightGBM 模型的预测结果与 SPICE 的对比

Fig. 4 Comparison between the prediction results of LightGBM model and SPICE

图 4 显示了 SPICE 仿真和 LightGBM 模型预测的瞬态电流波形曲线。无论 INVM2T 还是 DFCQM2T 单元, 在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下的瞬态电流波形, 其实际值 (SPICE) 与预测值 (模型) 基本重合。经计算, 这 12 种情况的预测波形与实际波形的 R^2 均大于 0.95, 这表明预测波形与实际波形的拟合程度高。

为了进一步评价 LightGBM 模型的泛化能力, 在不同训练集中的输出信号转换、电源电压、输入转换时间和输出负载电容的组合, 为每个标准单元生成超过 630 个波形作为测试集数据。同时, 根据 2.2 节提出的指标对 INVM2T 和 DFCQM2T 单元的 LightGBM 模型在测试集

上的预测精度进行整体的评估, 结果如表 4 所示。

通过表 4 可知, INVM2T 和 DFCQM2T 两个单元所有测试集的 $RMSE$ 均小于 1.1×10^{-5} , MAE 均小于 7×10^{-6} 并且 R^2 均不小于 0.928。这表明 LightGBM 模型对不同标准单元在非训练集中输出信号转换、电源电压、输入转换时间和输出负载电容组合下的预测结果都具有较高的精度, 说明了 LightGBM 模型具有较强的泛化能力, 能够应对各种复杂情况。

2.4 其他回归模型对比

为了评估本文提出的 LightGBM 模型在模拟标准单元瞬态电流动态变化中性能的优劣, 本实验将 LightGBM 与 ANN、XGBoost、LSTM 和 RFR 方法进行比较。ANN

表 3 不同单元类型及转换方向下的参数组合选择

Table 3 Parameter selection under different cell types and transition directions

信号类型	瞬态	输出	电源	输出	输入
	电流 序号	信号 转换	电压/ V	负载 电容/fF	转换 时间/ps
INVM2T 输出上升	1	上升	1.08	10	50
	2	上升	1.20	30	250
	3	上升	1.32	50	450
INVM2T 输出下降	4	下降	1.08	10	50
	5	下降	1.20	30	250
	6	下降	1.32	50	450
DFCQM2T 输出上升	7	上升	1.08	10	50
	8	上升	1.20	30	250
	9	上升	1.32	50	450
DFCQM2T 输出下降	10	下降	1.08	10	50
	11	下降	1.20	30	250
	12	下降	1.32	50	450

模型是一种常用的机器学习算法,具有能够处理非线性关系及良好泛化性能的优点^[22]。XGBoost 是一种可拓展的提升树系统,具有高精度,高效运算和处理复杂数据的优点^[23]。LSTM 是一种能同时存储长期和短期信息的循环神经网络,能够捕捉序列数据中的趋势和周期性的特征,被广泛应用于处理时序数据的预测任务中^[24-25]。RFR 是一种基于多个决策树的集成学习方法,具有准确率高、抗

表 4 LightGBM 模型对 INVM2T 和 DFCQM2T 测试集的评估结果

Table 4 Evaluation results of the LightGBM model on the testing sets of INVM2T and DFCQM2T

单元名称	输出信号 转换	RMSE	MAE	R ²
INVM2T	上升	8.296×10^{-6}	6.762×10^{-6}	0.969
INVM2T	下降	1.097×10^{-6}	9.874×10^{-7}	0.928
DFCQM2T	上升	1.076×10^{-5}	5.466×10^{-6}	0.970
DFCQM2T	下降	7.498×10^{-6}	3.074×10^{-6}	0.939

拟合能力强的特点,广泛应用于回归任务中^[26]。

以标准单元 INVM2T 的某个训练集和测试集为例,该训练集包含 2 800 个不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下的电流波形。测试集包括了 630 个不同于训练集参数设置的电流波形。LightGBM 和 XGBoost 对特征尺度不敏感,输入特征无需标准化处理即可投入训练。ANN、LSTM 和 RFR 使用自适应矩估计算法(adaptive moment estimation, Adam)来优化网络权重,对输入特征进行标准化处理,有利于提升训练效率和模型性能。首先,LightGBM 和 XGBoost 使用原始特征数据进行训练,ANN、LSTM 和 RFR 使用经过标准化处理后的特征数据进行训练;然后,使用五折交叉验证和网格搜索来寻找最佳的模型参数;最后,得到每种模型的最优参数。5 种模型训练和测试的性能结果对比如表 5 所示。

表 5 不同算法模型在训练集和测试集效果的对比

Table 5 Comparison of the effects of different models on training sets and test sets

模型	训练集				测试集			
	RMSE	MAE	R ²	训练时间/s	RMSE	MAE	R ²	运行时间/s
ANN	2.501×10^{-6}	9.922×10^{-6}	0.995	1721.27	1.193×10^{-5}	5.288×10^{-6}	0.937	2.17
XGBoost	1.707×10^{-5}	1.421×10^{-5}	0.802	46.74	2.261×10^{-5}	1.498×10^{-5}	0.775	0.06
LSTM	4.799×10^{-6}	2.293×10^{-6}	0.988	3770.54	1.084×10^{-5}	2.292×10^{-6}	0.948	12.72
RFR	1.293×10^{-5}	6.775×10^{-6}	0.914	247.64	1.701×10^{-5}	8.638×10^{-6}	0.881	0.37
LightGBM	6.336×10^{-6}	3.742×10^{-6}	0.981	68.96	8.296×10^{-6}	6.762×10^{-6}	0.969	0.24

通过表 5 可知,ANN、XGBoost、LSTM、RFR 和 LightGBM 模型训练集的 R² 分别为 0.995、0.802、0.988、0.914 和 0.981;测试集的 R² 分别为 0.937、0.775、0.948、0.881 和 0.969。ANN、LSTM 和 LightGBM 模型在训练集的 R² 均在 0.98 以上,这 3 种模型能够很好地拟合训练集数据。在测试集上,LightGBM 拟合精度最高。这表明 LightGBM 不仅能准确捕捉标准单元瞬态电流复杂的非线性变化趋势,同时在不同数据条件下具有较强的预测能力。

RFR 和 LightGBM 模型的训练时间分别为 1 721.27、46.74、3 770.54、247.64 和 68.96 s,而运行时间分别为 2.17、0.06、12.72、0.37 和 0.24 s。ANN 和 LSTM 模型在训练集的拟合精度略高于 LightGBM 模型,泛化能力弱于 LightGBM 模型,但其训练时间和运行时间的消耗显著高于 LightGBM 模型,难以满足高效建模的实际需求。XGBoost 模型无论训练时间还是运行时间均最短,但其预测精度明显低于 LightGBM 模型。LightGBM 模型能够在较少的时间消耗下,有效捕捉动态电流变化中复杂的非线性关系。

在训练与运行效率方面上,ANN、XGBoost、LSTM、

综上,LightGBM模型在准确性、泛化能力、训练效率与运行速度之间取得了良好的平衡,尤其适用于标准单元动态电流建模与预测任务。该方法无需依赖复杂的电路结构信息,具备更强的通用性和扩展性,能够高效应对大规模采样点与多特征组合的建模挑战。

3 结 论

本文提出了一种基于LightGBM的标准单元动态电流的建模方法,用于预测不同标准单元在不同输出信号转换、电源电压、输入转换时间和输出负载电容组合下的瞬态电流波形。训练和测试过程中使用的数据通过SPICE仿真生成。针对每一个标准单元分别训练其对应的LightGBM模型,以适应复杂多变的电流特性。

本文通过对INVM2T和DFCQM2T两个标准单元建模并评估模型精度和泛化能力,验证了LightGBM模型在标准单元动态电流预测的有效性。以INVM2T单元为例,本文将LightGBM模型与ANN、XGBoost、LSTM和RFR模型进行了比较。实验结果表明,LightGBM的预测精度显著优于XGBoost和RFR模型,泛化能力优于ANN和LSTM模型,训练时间和运行时间均小于ANN、LSTM和RFR模型。因而本文提出的LightGBM建模方法可以在模型精度和计算资源上取得良好的平衡。该方法能够高效准确地模拟标准单元动态电流行为,为超大规模集成电路设计和测试中的动态电压降分析和违例检测提供高效可靠的支持。

参考文献

- [1] XIE ZH Y, LI H, XU X Q, et al. Fast IR drop estimation with machine learning: Invited paper[C]. IEEE/ACM International Conference on Computer Aided Design, 2020: 1-8.
- [2] FANG Y CH, LIN H Y, SU M Y, et al. Machine-learning-based dynamic IR drop prediction for ECO[C]. IEEE/ACM International Conference on Computer-Aided Design, Digest of Technical Papers, 2018: 1-7.
- [3] 李岳, 夏益民. 基于ResCSP-34的集成电路供电网络静态电压降预测研究[J]. 电子测量技术, 2024, 47(8): 148-156.
LI Y, XIA Y M. Research on static voltage drop prediction of IC power supply network based on ResCSP-34[J]. Electronic Measurement Technology, 2024, 47(8): 148-156.
- [4] CHEN Y F, DONG X, SHIH W K, et al. Invited paper: Unleashing the potential of machine learning: Harnessing the dynamics of supply noise for timing sign-off[C]. IEEE/ACM International Conference on Computer Aided Design, 2023: 1-6.
- [5] CHARAFEDDINE K, OUARDI F. Fast timing characterization of cells in standard cell library design based on curve fitting[C]. International Conference on Wireless Technologies, Embedded and Intelligent Systems, 2017: 1-6.
- [6] 胡伟, 安文婷, 袁甲. 一种近阈值电压标准单元特征化建库方法[J]. 湖南大学学报: 自然科学版, 2019, 46(4): 85-90.
HU W, AN W T, YUAN J. A characterization method for standard cell library at near threshold voltage[J]. Journal of Hunan University: Natural Sciences, 2019, 46(4): 85-90.
- [7] HO C T, KAHNG A B. IncPIRD: Fast learning based prediction of incremental IR drop[C]. IEEE/ACM International Conference on Computer Aided Design, 2019: 1-8.
- [8] PAO C H, SU A Y, LEE Y M. XGBIR: An xgboost based IR drop predictor for power delivery network[C]. Design, Automation & Test in Europe Conference & Exhibition, 2020: 1307-1310.
- [9] WEN J M, PAN S, CHANG N, et al. DNN based fast static on-chip thermal solver[C]. Semiconductor Thermal Measurement, Modeling & Management Symposium, 2020: 65-75.
- [10] YU J T, LIANG H, JIA S H, et al. UCMNet: Static IR drop estimation using attention convolutional network[C]. International Symposium of Electronics Design Automation, 2024: 439-443.
- [11] XIE ZH Y, REN H X, KHAILANY B, et al. PowerNet: Transferable dynamic IR drop estimation via maximum convolutional neural network[C]. Asia and South Pacific Design Automation Conference, 2020: 13-18.
- [12] CHEN Y H, CHENG Y CH, CHANG Y F, et al. Dynamic IR-drop prediction through a multi-task U-net with package effect consideration[C]. Design, Automation & Test in Europe Conference, 2025: 1-7.
- [13] CHEN J X, LIU SH T, WU Y T, et al. Vector-based dynamic IR-drop prediction using machine learning[C]. Asia and South Pacific Design Automation Conference, 2022: 202-207.
- [14] MORADI A M, SADROSSADAT S A, DERHAMI V. Long short-term memory neural networks for modeling nonlinear electronic components[J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2021, 11(5): 840-847.
- [15] BAI T, DENG Z Y, CAO P. Cell library characterization for composite current source models based on Gaussian process regression and active

- learning [C]. ACM/IEEE Symposium on Machine Learning for CAD, 2024: 1-7.
- [16] VIBHU V, MITTAL S, KUMAR V. Machine learning-based model for single event upset current prediction in 14 nm FinFETs [C]. The IEEE International Conference on VLSI Design, 2023: 187-129.
- [17] HUANG H Y, GUAN ZH. ANN-based standard cell switching waveforms characterization model for pvt variations [C]. International Conference on Neural Networks, Information and Communication Engineering, 2024: 478-484.
- [18] SUN S Y, DONG X, SUN Q, et al. Fast machine learning driven supply noise aware macro-modeling for high-speed nonlinear drivers[J]. IEEE Transactions on Computer Aided Design of Integrated Circuits and Systems, 2025, 44(3): 1204-1208.
- [19] KE G L, MENG Q, FINLEY T, et al. Lightgbm: A highly efficient gradient boosting decision tree [C]. International Conference on Neural Information Processing Systems, 2017: 3149-3157.
- [20] 韩杰, 王然风, 付翔, 等. 基于遗传算法优化的 LightGBM 浮选尾煤灰分预测模型研究[J]. 矿业研究与开发, 2025, 45(1): 269-276.
- HAN J, WANG R F, FU X, et al. Research on a prediction model of ash in flotation tailings based on LightGBM optimized by genetic algorithm[J]. Mining Research and Development, 2025, 45(1): 269-276.
- [21] 胡山, 朱向华. 基于 ResNet18 与 K 折交叉验证的电机轴承故障诊断[J]. 自动化与仪表, 2025, 40(4): 40-45.
- HU SH, ZHU X H. Motor bearing fault diagnosis based on ResNet18 and K-fold cross validation[J]. Automation & Instrumentation, 2025, 40(4): 40-45.
- [22] 刘航宇, 顾晓强, 胡靖. 基于 ANN 的上海土体 HSS 模型模量参数研究[J]. 地下空间与工程学报, 2025, 21(3): 800-804.
- LIU H Y, GU X Q, HU J. Study on modulus parameters of HSS model for shanghai soils using ANN[J]. Chinese Journal of Underground Space and Engineering, 2025, 21(3): 800-804.
- [23] CHEN T Q, GUESTRIN C. XGBoost: A scalable tree boosting system[C]. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016: 785-794.
- [24] 郑文培, 周少杰, 王颖君, 等. 电潜泵剩余使用寿命预测集成学习算法研究[J]. 电子测量与仪器学报, 2025, 39(3): 13-23.
- ZHENG W P, ZHOU SH J, WANG Y J, et al. Prediction of remaining service life of electric submersible pump based on ensemble learning model[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 13-23.
- [25] ZHAO L P, WU K Y. Mach number prediction for a wind tunnel based on the CNN-LSTM-attention method[J]. Instrumentation, 2023, 10(4): 64-82.
- [26] 汪宇航, 黄海宏, 王海欣, 等. 基于荷电状态差异的退役电池健康状态快速估计研究[J]. 仪器仪表学报, 2023, 44(12): 55-68.
- WANG Y H, HUANG H H, WANG H X, et al. Research on fast estimation of the state of health of retired batteries based on the state of charge differences [J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 55-68.

作者简介

徐一玮, 硕士研究生, 主要研究方向为集成电路设计与自动化。

E-mail: xu.yi.wei@mail.sdu.edu.cn

周冉冉(通信作者), 博士, 高级实验师, 硕士研究生导师, 主要研究方向为集成电路设计与自动化。

E-mail: rzhou@sdu.edu.cn

王永, 博士, 教授, 博士研究生导师, 主要研究方向为集成电路设计与自动化。

E-mail: yongw@sdu.edu.cn