

DOI: 10.13382/j.jemi.B2508553

# 抗过拟合的改进 GBDT 模型预测 IC 熔丝修调码\*

章礼华 张珺瑚 刘建 詹文法

(安庆师范大学电子工程与智能制造学院 安庆 246011)

**摘要:**针对芯片制造过程中熔丝修调依赖逐次搜索索引修调码、循环读写频繁、测试时间长以及硬件资源消耗大的问题,在梯度提升多分类框架基础上,设计了一种面向熔丝修调码的单次预测模型。模型从结构层面引入抗过拟合机制,在残差学习过程中通过随机丢弃部分残差样本,弱化模型对异常样本和噪声样本的过度记忆;同时在叶节点输出阶段引入高斯扰动,使模型对数据分布波动保持更好的鲁棒性与泛化能力,并结合模糊区域判别思想,构建修调码模糊区域的数学描述,对靠近相邻边界的样本进行再判别和校正,从而有效降低相邻类别间的误分类概率。实现对相邻修调码不确定样本的精细区分。实验结果表明,所提出模型在准确率和稳定性方面均具有显著优势,在熔丝修调索引任务中,对 32 bit 修调码的整体预测准确率超过 97.8%, $R^2$  指标达到 0.99 以上,显著缩短了测试时间并减少测试系统读写次数与硬件资源开销。

**关键词:** 熔丝修调;修调码;预测;抗过拟合;模糊区域

**中图分类号:** TN407;TP181

**文献标识码:** A

**国家标准学科分类代码:** 510.5040

## Over fitting-resistant improved GBDT model for predicting IC fuse trimming codes

Zhang Lihua Zhang Junhu Liu Jian Zhan Wenfa

(School of Electronic Engineering and Intelligent Manufacturing, Anqing Normal University, Anqing 246011, China)

**Abstract:** To address the problems that fuse trimming in chip manufacturing still relies on sequential search of trimming codes, leading to frequent read-write operations, long testing time, and high hardware resource consumption, this paper designs a single-shot trimming-code prediction model based on a GBDT multi-classification framework. Overfitting-resistant mechanisms are introduced at the structural level; during residual learning, part of the residual samples is randomly discarded to weaken excessive memorization of abnormal and noisy samples, while Gaussian perturbations are injected into the leaf-node outputs to enhance robustness and generalization under fluctuations in data distribution. In addition, a fuzzy-region discrimination strategy is incorporated to construct a mathematical description of trimming-code fuzzy regions, enabling secondary discrimination and correction of samples located near adjacent class boundaries, thereby effectively reducing misclassification between neighboring categories and achieving refined identification of uncertain trimming codes. Experimental results show that, in the fuse-trimming indexing task, the proposed model achieves an overall prediction accuracy above 97.8% and an  $R^2$  value greater than 0.99, while significantly shortening test time and reducing read-write operations and hardware resource overhead.

**Keywords:** fuse trimming; trimming code; prediction; overfitting resistance; fuzzy region

## 0 引言

随着芯片功能日益复杂、性能指标不断提升,工艺波

动和材料特性不确定性导致器件参数偏差,显著影响电路性能和产品一致性<sup>[1-2]</sup>,因此,为提升芯片性能、满足严格设计规格,通常在后工艺阶段应用修调技术,通过有选择地调整器件参数以补偿制造误差,进而提高产品良率

收稿日期:2025-07-11 Received Date: 2025-07-11

\* 基金项目:国家自然科学基金重大研究计划(92573109)、国家自然科学基金(62474002)、安徽省高校科研资助项目(2023AH050481)、安徽省高等学校质量工程项目(2023zygzs036,2024zybj022)资助

与精度<sup>[3]</sup>。

根据实现方式和应用需求的不同,目前修调技术主要包括齐纳修调、EPROM/EEPROM 修调、激光修调以及熔丝修调等多种形式。齐纳修调是一种通过击穿齐纳二极管来实现电路参数永久性调整的技术,支持电气编程,修调速度快,适用于需快速修正的场景<sup>[4]</sup>。EPROM/EEPROM 修调通过在非易失性存储器中编程控制数据位,间接调整电路性能,具备可重复编程和阶段性修正能力<sup>[5]</sup>。激光修调则通过高精度熔丝切割实现参数微调,在模拟与混合信号芯片中被广泛应用于后期修正<sup>[6]</sup>。

然而,齐纳修调虽然支持电气编程且修调速度较快,但其对器件结构设计要求严格,击穿过程可能引入不可控的可靠性问题。EPROM/EEPROM 修调具备可重复编程能力,适合多阶段修正,但其芯片面积较大,编程时间长,且长期使用中易发生老化退化。激光修调在高精度参数微调方面效果显著,但所需设备昂贵,修调过程受限芯片物理布局,且难以实现大规模自动化应用。熔丝修调作为传统且广泛应用的方法,通过熔断多晶硅或金属熔丝改变电路连接状态实现参数调整,其工艺兼容性较好,制造成本低<sup>[7-8]</sup>。因此,在追求工艺成熟度、成本可控性和结构简洁性的实际应用中,熔丝修调技术依然是当前最为广泛采用的解决方案之一。

虽然熔丝修调作为一种成熟且广泛应用的技术被广泛采用,但其修调码的索引策略多依赖于传统的全局搜索或二分法,不仅导致修调过程耗时较长,而且对测试设备的性能和操作人员的经验提出了较高要求。由于熔丝修调具有不可逆性,任何修调失误均可能引发芯片功能或性能不达标,导致大量资源浪费<sup>[9]</sup>。此外,现有的搜索算法在最佳情况下仍需遍历约 1/2 的修调码空间,限制了修调效率的进一步提升<sup>[10]</sup>。因此,如何优化熔丝修调码的索引方法,减少修调时间,成为当前研究的关键问题。

芯片性能往往受到集成电路(integrated circuit, IC)制造工艺的影响而产生一定程度的性能偏差。这些偏差通常需要通过自动测试设备进行校准,从而增加了测试的成本和时间消耗。芯片修调技术能够在一定程度上弥补制造过程中的不确定性。然而,芯片修调的过程具有不可逆性,即一旦修调完成,修调结果无法恢复,可能对后续的测试与应用造成一定的局限。目前,二分法、校准算法和预修调技术虽然在理论上能够对修调过程进行模拟和优化,但其假设通常基于理想情况下的修调结果<sup>[11-13]</sup>。因此,在实际应用中,随着工艺偏差的增加,这些方法的准确性和适应性均会受到不同程度的影响,修调效果可能会出现明显的下降。现有修调技术在面对复杂的实际工艺环境时,仍存在一定的局限性,需要进一步改进和优化,以提高其在不同制造条件下的鲁棒性和可

靠性。

针对上述问题,面对芯片熔丝修调码,本文提出了一种融合抗过拟合机制与模糊区域判别策略的梯度提升决策树多分类模型(fuzzy integration, gradient boosting decision tree, FI-GBDT),用于预测熔丝修调码,以此实现单次准确搜索修调码。首先收集熔丝修调前后电压和修调码信息,将修调前后电压差值作为预测输入特征变量,利用传统 GBDT 框架基础,引入残差样本随机丢弃和叶节点输出高斯扰动机制,有效抑制过拟合,提升模型鲁棒性与泛化能力,同时,通过数学建模修调码模糊区域,增强对相邻修调码间不确定性样本的判别能力,显著降低误判率。模型在预测准确性、稳定性及模糊区域样本判别方面表现突出,仅需单次预测即可得到修调码,验证了其在复杂修调环境中实用价值与应用潜力。使用真实结果预修调码,解决了工艺带来的偏差。

## 1 FI-GBDT 模型结构

### 1.1 抗过拟合的梯度提升决策树多分类器模型

为有效抑制过拟合,增强模型泛化能力,本文在传统 GBDT 多分类模型<sup>[14]</sup>基础上进行了关键改进,提出一种抗过拟合的多分类器建模方法。该方法引入两项核心机制:1)叶节点残差样本的随机丢弃机制;2)叶节点输出的高斯噪声扰动机制。

残差样本的随机丢弃机制在每轮迭代过程中通过对样本子集进行随机抽样训练,有效减弱模型对训练数据的过度依赖,提升模型多样性;而在叶节点输出中引入高斯噪声,有助于平滑模型输出、增强对局部扰动的鲁棒性,并降低陷入局部最优解的风险。两者协同作用,使模型在处理复杂修调数据时具备更强的稳定性与泛化能力。

模型训练过程中采用交叉熵作为损失函数,以 softmax 层输出多类概率预测。每轮迭代中,针对各类别分别训练回归树以拟合残差值,并在叶节点输出引入高斯扰动后用于修正当前预测的 logits 值。最终通过 softmax 层计算预测概率,完成多类别的分类判决。

在模型未经过训练时,尚不具备任何区分能力。此时可将每个类别的初始预测打分(logits)统一设定为 0,即:

$$F_k^{(0)}(x_i) = 0, \forall i, k \quad (1)$$

由于 logits 全 0,应用 softmax 后得到的初始预测概率为均匀分布:

$$\hat{p}_{ik}^{(0)} = \frac{1}{K}, \forall i, k \quad (2)$$

其中,样本  $i, i \in \{1, 2, \dots, n\}$ , 类别  $k, k \in \{1, 2, \dots, K\}$ ,  $x_i$  为第  $i$  个样本的特征。

为训练模型,使其逐步增强对正确类别的预测能力,需构建合适的损失函数。采用交叉熵损失函数(Cross-Entropy loss)如下:

$$\ell(m) = - \sum_{i=1}^n \sum_{k=1}^K y_{ik} \cdot \log \hat{p}_{ik}^{(m)} \quad (3)$$

其中,  $y_{ik} = 1 (y_i = k)$ , 定义只有真实类为 1, 其余为 0。

为了最小化损失函数,采用梯度提升方法。在第  $m$  轮中,定义残差作为每个样本对每个类别的当前误差目标,供回归树学习:

$$r_{ik}^{(m)} = \frac{\partial \ell}{\partial F_k^{(m)}(x_i)} = y_{ik} - \hat{p}_{ik}^{(m)} \quad (4)$$

在每一轮中,分别对每个类别训练一棵回归树,拟合该类别的残差值,以用于后续修正 logits。

$$f_k^{(m)}(x_i) = T_k^{(m)}(x_i) \approx r_{ik}^{(m)} \quad (5)$$

其中,  $T_k^{(m)}$  为第  $k$  类第  $m$  轮的分类与回归树(classification and regression tree, CART)。

为提升模型在噪声样本、边界样本及局部扰动下的鲁棒性,本文在回归树叶节点引入显式结构扰动机制: Dropout 与 Gaussian Noise。这两种机制并非简单加入随机性,而是在本模型的结构中承担不同但协同的功能:

1) 随机丢弃 Dropout 处理,对叶节点的残差样本按比例随机丢弃,可视对叶节点统计引入一种结构稀疏化约束:对每个叶节点中的残差样本集,按比例  $\rho \in [0, 1]$  随机丢弃一部分样本,这一策略不仅能够有效降低模型对个别样本的依赖性,还引入了结构上的多样性,从而减少过拟合的可能性。保留下来的样本集合为:

$$|\widetilde{\mathfrak{N}}_l^{(m,k)}| = (1 - \rho) |\mathfrak{N}_l^{(m,k)}|, \widetilde{\mathfrak{N}}_l^{(m,k)} \subset \mathfrak{N}_l^{(m,k)} \quad (6)$$

其中,叶子  $l, l \in \{1, 2, \dots, L\}$ ,  $\widetilde{\mathfrak{N}}_l^{(m,k)} = \{i | x_i \text{ 落入第 } l \text{ 个叶子节点}\}$ 。

其中,对于模型学习率  $v$ 、噪声标准差  $\sigma$ 、Dropout 比例均使用超参数搜索选择最优值<sup>[15]</sup>。

2) 对保留下来的样本,其残差值上加入高斯噪声扰动,其本质上是一种输出平滑机制:在保持残差信息有效性的基础上,提升了模型应对噪声样本的鲁棒性。其定义为:

$$r'_{ik} = r_{ik} + \varepsilon_{ij}, \varepsilon_{ij} \in N(0, \sigma_{noise}^2) \quad (7)$$

式中:  $\sigma_{noise}$  是用于控制扰动强度的噪声标准差;  $\varepsilon$  是从正态分布中采样的噪声。

3) 对每个叶节点,最终的输出值为保留样本加噪后的残差的均值,表示该叶对 logits 的修正值:

$$v_l^{(k,m)} = \frac{1}{|\widetilde{\mathfrak{N}}_l^{(m,k)}|} \sum_{i \in \widetilde{\mathfrak{N}}_l^{(m,k)}} r'_{ik}^{(m)} \quad (8)$$

回归树训练完成后,使用学习率  $v$  控制更新幅度,对

logits 进行更新:

$$F_k^{(m)}(x_i) = F_k^{(m-1)}(x_i) + v \times f_k^{(m)}(x_i) \quad (9)$$

其中,  $f_k^{(m)}(x_i) = v_l^{(k,m)}$ 。  $v$  是学习率,控制每轮更新幅度。

接着,再次通过 softmax 函数计算新的预测概率,用于下一轮残差计算:

$$\hat{p}_{ik}^{(m)} = \frac{e^{F_k^{(m)}(x_i)}}{\sum_{l=1}^K e^{F_l^{(m)}(x_i)}} \quad (10)$$

式中,  $\hat{p}_{ik}^{(m)}$  是第  $m$  轮中;样本  $x_i$  预测为第  $k$  类的概率。

如此迭代进行  $M$  轮后,最终模型输出为:

$$\hat{y}_i = \operatorname{argmax}_k \hat{p}_{ik}^{(M)} \quad (11)$$

即选取最终 softmax 概率最大的类别作为模型的分类结果。

在修调电路中,相邻修调码可能对应高度重叠的电压区间。落在此区间内的样本,在物理意义上同时允许相邻两种修调码。这意味着以单一精确标签训练会产生“错误惩罚过大”的问题,决策边界会在真实模糊区域处被迫过度锐化,降低模型稳定性。需在算法中引入模糊区域判别。

## 1.2 相邻修调码模糊判别机制

为提升模型在修调边界区域的判别能力,本文进一步提出了一种融合模糊区域识别机制与抗过拟合策略的多分类梯度提升决策树模型,简称 FI-GBDT。该方法在保留传统 GBDT 高效建模能力的基础上,通过引入修调电压模糊区域建模机制,提升了模型在边界样本上的容错能力,有效增强了修调码预测的准确性与工程实用性。

在熔丝修调过程中,部分相邻修调码所对应的平均修调电压区间存在一定程度的重叠。当芯片当前电压落在该重叠区间内时,采用其中任一相邻修调码均可能实现目标电压范围内的调节,从而满足修调精度要求。本文将此类由相邻修调码电压重叠形成的可共享调控区间定义为模糊区域。模糊区域的存在显著加大了修调码边界处的分类不确定性,易导致传统分类模型在该区域发生误判,进而影响整体预测性能。

以决策树(decision tree, DT)<sup>[16]</sup>、AdaBoost<sup>[17]</sup>、XGBoost<sup>[18]</sup>、随机森林(random forest, RF)<sup>[19]</sup>及 CatBoost<sup>[20]</sup>等典型机器学习模型均会将模糊区域内的样本被迫指定唯一标签,训练过程会试图把本不应强区分的点强行区分,导致模型代价函数偏移、预测非稳定。

在对称情况下,记第  $j$  个离散整数修调码对应的平均修调电压为  $\mu_j$ , 若存在某一区间使得对任意样本其实际修调电压  $V \in [\mu_j, \mu_{j+1}]$  均可由修调码  $j$  或  $j+1$  实现目标精度,则该区间被定义为模糊区域。设  $\mu_{j+1} > \mu_j$ , 其中心点为:

$$\bar{\mu}_{j,j+1} = \frac{\mu_j + \mu_{j+1}}{2} \quad (12)$$

若以中心点为基准,取其上下  $\eta\%$  的电压区间作为模糊区域,则该区域  $R_{j,j+1}^{FI}$  可表示为:

$$R_{j,j+1}^{FI} = \left[ \bar{\mu}_{j,j+1} - \frac{(\mu_{j+1} - \mu_j) \eta\%}{2}, \bar{\mu}_{j,j+1} + \frac{(\mu_{j+1} - \mu_j) \eta\%}{2} \right] \quad (13)$$

进一步可化简为:

$$R_{j,j+1}^{FI} = \left[ \frac{\mu_j}{2}(1 + \eta\%) + \frac{\mu_{j+1}}{2}(1 - \eta\%), \frac{\mu_j}{2}(1 - \eta\%) + \frac{\mu_{j+1}}{2}(1 + \eta\%) \right] \quad (14)$$

在非对称情况下,模糊区域两侧对应的可调电压范围不再等距分布,此时若仍以中心点作为判据,容易导致部分样本被错误纳入或排除。为此,引入可调距离阈值作为替代基准,并根据相邻修调码在历史样本中的电压分布差异自适应调整左右边界。该策略能够在存在孤立“断点”或异常偏移时,灵活修正模糊区域,从而进一步降低边界样本的误分类风险。

需要指出的是,根据文献[13]研究,修调码 0~15 与 16~31 分别位于两段不同的线性修调步长区间,15 与 16 之间存在步长突变点,因此该位置不构成连续模糊区,本文亦不将其纳入模糊区域建模范围。图 1 展示了实验数据中修调码与其对应修调电压均值之间的关系示意图,也进一步验证了以上观点。




图 1 修调码对应修调范围

Fig. 1 Tuning code corresponding to tuning range

## 2 实验结果与分析

### 2.1 预测数据

本文所使用的实验数据均来源于真实的熔丝修调测试结果,由于工艺误差在一定范围,故仅涵盖修调码为 0~5 与 29~31 的相关修调数据,使用上述数据进行计算并不影响实验验证。基于上述数据,构建了 200 组用于模型预测的数据集,每组数据均包含修调前的测试电压、实际修调码以及对应的修调后测试电压,全面反映修调

前后特性变化情况。

为进一步验证模型在模糊区域的判别能力,除常规测试集数据外,本文还特别插入了处于模糊区间的数据样本,以评估模型在判别边界区域时的鲁棒性与准确性,特别是在混淆矩阵表现方面的变化。

结合实际数据分布情况及模型表现,本文采用 8:2 的训练集与测试集划分比例<sup>[21]</sup>,在确保样本代表性与分布一致性的基础上,兼顾模型训练效果与泛化能力。在训练时从数据集中随机选择进行预测,并使用余下数据进行验证,进行多轮实验求结果均值以验证结果稳定性。且训练集全部用于模型参数训练,测试集则用于模型性能评估与预测精度验证,确保实验结果的客观性与有效性。

### 2.2 基于评价指标的模型性能分析

为量化各模型的预测能力,本文选取决定系数 (coefficient of determination,  $R^2$ )、均方误差 (mean squared error, MSE)、均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE)、均方根误差与观测值标准差的比值 (ratio of the root mean squared error to the standard deviation of observations, RSR) 以及平均绝对相对误差 (mean absolute relative error, MARE) 6 类常用回归评价指标,以全面评估各模型在修调码预测任务中的拟合精度与泛化能力。具体计算公式如式 (15)~(19) 所示。

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (15)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (16)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$RSR = \frac{\sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2 / n}}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 / n}} \quad (19)$$

式中:  $n$  为样本个数;  $y$  是真实值;  $\hat{y}$  是预测值。上述指标中,  $R^2$  用于反映模型对样本方差解释能力,数值越接近 1 表示拟合越好<sup>[22]</sup>; MSE 与 RMSE 衡量预测误差的绝对水平, RMSE 在实际应用中具有更好的物理可解释性; MAE 衡量预测偏差的平均幅度,越小表明模型越精确; RSR 通过将 RMSE 标准化处理,便于不同模型间的比较,越接近 0 表示模型性能越优<sup>[23]</sup>。

表 1 为 DT、AdaBoost、XGBoost、RF、CatBoost 及所提出的 FI-GBDT 模型在各评价指标下的表现。通过图 2 对

比可以直观看出,由于在抽取训练集时分布不均匀,故未使用模糊区域的其他模型所有指标远差于 FI-GBDT 模型,说明 FI-GBDT 模型在修调码预测任务中具有更高的准确性与稳定性。

表 1 模型评价指标  
Table 1 Model evaluation metrics

|       | Xg<br>boost | DT       | RF       | Ada<br>boost | Cat<br>boost | FI-<br>GBDT |
|-------|-------------|----------|----------|--------------|--------------|-------------|
| $R^2$ | 0.148 5     | 0.481 5  | 0.574 4  | 0.843 7      | 0.847 9      | 0.996 8     |
| MSE   | 140.903 8   | 65.928 2 | 72.059 0 | 26.911 5     | 26.128 2     | 0.021 8     |
| RMSE  | 8.295 1     | 4.171 9  | 5.234 8  | 2.265 7      | 3.164 2      | 0.111 1     |
| MAE   | 5.826 9     | 3.659 0  | 3.659 0  | 1.816 7      | 1.741 0      | 0.021 8     |
| RSR   | 0.637 1     | 0.398 8  | 0.398 8  | 0.172 3      | 0.239 3      | 0.042 4     |




图 2 模型评价指标对比  
Fig. 2 Comparison of model evaluation metrics

2.3 基于泰勒图的模型性能对比

通过使用泰勒图<sup>[24]</sup>,在图 3 中直观地比较了各个模型在预测性能上的差异。图 3 中每个点越靠近观测点的位置,说明该模型的预测效果越好。整体来看,各模型均具备较好的拟合能力,其中 FI-GBDT 模型在相关系数与 RMSE 指标上优于其他对比模型,说明其具备更强的稳定性与泛化能力。

2.4 各模型预测结果对比

本文采用 DT、AdaBoost、XGBoost、RF、CatBoost 以及所提出的 FI-GBDT 模型对芯片熔丝修调码进行预测,预测结果如表 2 所示。通过各模型准确率的对比可知,融合模糊区域判别机制的改进 FI-GBDT 模型在预测准确率方面表现最为突出,显著超过其他对比模型。

表 2 各模型预测结果  
Table 2 Prediction results of different models

| 预测模型 | Xg<br>boost | Cat<br>boost | RF      | DT      | Ada<br>boost | FI<br>-GBDT |
|------|-------------|--------------|---------|---------|--------------|-------------|
| 准确率  | 0.243 6     | 0.279 5      | 0.248 6 | 0.300 0 | 0.307 7      | 0.978 2     |

需要说明的是,FI-GBDT 获得的较高准确率,并非单




图 3 泰勒图  
Fig. 3 Taylor diagram

纯源于模型学习能力增强,而主要由于其引入了区别于其他方法的模糊判决机制。修调档位由连续物理量离散化而来,相邻档位在电压等特征上往往存在重叠。FI-GBDT 基于训练数据的统计分布构建相邻档位的模糊区域,并在预测阶段允许区域内样本进行邻域一致性判决,从而避免将物理意义上等价或高度接近的结果视为完全误判。相比之下,其余模型在数据与流程相同条件下仍采用严格单一判决策略,未考虑档位的物理邻接关系,因此在该问题上表现出相对较低的分类准确率。

2.5 测试集混淆矩阵

为进一步分析各模型在分类任务中的具体表现,本文绘制了各模型在测试集上的混淆矩阵图。如图 4 所示,DT、AdaBoost、XGBoost、RF 和 CatBoost 模型均存在一定程度的模糊区域误判现象,即将原本可接受的预测结果判定为错误,导致分类精度下降。

相较之下,FI-GBDT 模型由于引入了模糊区域识别机制,能够有效识别处于相邻修调码共享区间内样本,从而显著降低了该类误判的发生频率,在混淆矩阵表现上更加贴近理想预测结果,验证了其对于模糊区域数据的高鲁棒性。

本研究针对修调码进行了多参数预测,所采用的数据集规模为 200 组。已有研究中,Amjad 等<sup>[25]</sup>使用 200 组数据,基于 XGBoost 模型对桩基承载力进行预测,所得模型评价指标  $R^2$  为 0.955;Zhu 等<sup>[26]</sup>使用 252 组数据,结合粒子群优化的支持向量回归(P SO-SVR)模型预测岩石剪切强度参数,得到模型评价指标  $R^2$  为 92.4%和 96.6%。相比之下,本研究所构建模型的  $R^2$  值达到 0.996 8,表明在一定程度上,此模型的预测性能高于其他模型,在预测准确率方面具有较强优势,具备较高的可




图 4 测试集混淆矩阵结果对比

Fig. 4 Comparison of confusion matrix results on the test set

靠性和适用性。

3 结 论

本文针对芯片熔丝修调过程中修调码预测精度受到模糊区域干扰的问题,提出了一种融合模糊区域判别机制的抗过拟合梯度提升决策树多分类模型(FI-GBDT)。

该模型在传统 GBDT 框架基础上引入残差样本随机丢弃和叶节点输出高斯扰动机制,有效抑制了过拟合现象,提升了模型的鲁棒性与泛化能力。同时,通过对修调码模糊区域的数学建模,增强了模型对相邻修调码间不确定性样本的判别能力,显著降低了误判率。基于真实熔丝修调数据集的对比实验结果表明,FI-GBDT 模型在  $R^2$ 、MSE、RMSE、MAE、RSR、MARE 等多项评价指标上均优

于传统机器学习模型,其中  $R^2$  高达 0.99 以上,显示出最佳的拟合效果。进一步通过泰勒图和混淆矩阵分析,FI-GBDT 模型在预测准确性和稳定性方面均表现突出,尤其在模糊区域样本的判别上优势明显,验证了其在复杂修调环境中的实用价值。

## 参考文献

- [1] 朱刚俊, 张洪俞. 芯片 ATE 测试 CP 电修调的优化分析[J]. 集成电路应用, 2024, 41(3): 62-63.  
ZHU G J, ZHANG H Y. Optimization analysis of CP trimming in chip ATE testing [J]. Application of Integrated Circuits, 2024, 41(3): 62-63.
- [2] ISUKAPATI S B, ZHANG H, LIU T, et al. Monolithic integration of lateral HV power MOSFET with LV CMOS for SiC power IC technology [C]. IEEE International Symposium on Power Semiconductor Devices and ICs. 2021, 21(33): 267-270.
- [3] 朱刚俊, 董泽芳, 马培. ATE 芯片测试中的成测修调方法分析[J]. 集成电路应用, 2024, 41(6): 70-71.  
ZHU G J, DONG Z F, MA P. Analysis of final test trimming method in ATE chip testing[J]. Application of Integrated Circuits, 2024, 41(6): 70-71.
- [4] 朱刚俊, 马培. 齐纳修调优化在 ATE 测试中的应用[J]. 集成电路应用, 2023, 40(8): 46-47.  
ZHU G J, MA P. Application of zener trimming optimization in ATE testing[J]. Application of Integrated Circuits, 2023, 40(8): 46-47.
- [5] VASILE A M, NEGUT A, TACHE A, et al. A digital improvement—trimming a digital temperature sensor with EEPROM reprogrammable fuses [J]. Sensors, 2021, 21(5): 1700.
- [6] 贾晨强, 李文昌, 阮为, 等. 一种高精度快速激光修调方案设计 [J]. 半导体技术, 2024, 49(2): 171-177.  
JIA CH Q, LI W CH, RUAN W, et al. Design of a high-precision and fast laser trimming scheme [J]. Semiconductor Technology, 2024, 49(2): 171-177.
- [7] ZHANG H, WU C, ZHANG D W, et al. A new technology-adaptable design for high-endurance EEPROM [J]. Electronics, 2025, 14(4): 712.
- [8] DENG X, QIU Y, TOOPS D, et al. A trim bit one time programmable EPROM with aggressively reduced area, enhanced functionality, and extra features [C]. 2022 IEEE International Symposium on Circuits and Systems (ISCAS). IEEE, 2022: 1467-1471.
- [9] 张琳, 李静, 付东兵, 等. 一种易烧写高可靠的硅化物多晶熔丝修调电路[J]. 微电子学, 2021, 51(2): 221-224.  
ZHANG L, LI J, FU D B, et al. A programmable and highly reliable silicide poly-fuse trimming circuit [J]. Microelectronics, 2021, 51(2): 221-224.
- [10] 白世发. 基于 ATE 的 BMIC 芯片测试系统开发及其修调测试方法研究[D]. 成都: 电子科技大学, 2023.  
BAI SH F. Development of BMIC chip test system based on ATE and research on its trimming test method [D]. Chengdu: University of Electronic Science and Technology of China, 2023.
- [11] WAN G, ZHANG H, XIE Y. A novel adaptive fitting and trimming algorithm of chip power module based on wafer level packaging [J]. IEEE Transactions on Instrumentation and Measurement, 2025. DOI: 10.1109/TIM.2025.3573375.
- [12] WANG J, WANG X, QIN P. A digital trimming circuit with pre-trimming function [C]. 2024 IEEE 4th International Conference on Power, Electronics and Computer Applications (ICPECA). IEEE, 2024: 693-697.
- [13] 曾圣懿. 基于 STS8200 的车载控制芯片测试软件开发及其修调算法研究[D]. 成都: 电子科技大学, 2025.  
ZENG SH Y. Development of test software for in-vehicle control chips based on STS8200 and research on its trimming algorithm [D]. Chengdu: University of Electronic Science and Technology of China, 2025.
- [14] FRIEDMAN J H. Greedy function approximation: A gradient boosting machine [J]. Annals of Statistics, 2001: 1189-1232.
- [15] BISCHL B, BINDER M, LANG M, et al. Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges [J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2023, 13(2): 1484.
- [16] MIENYE I D, JERE N. A survey of decision trees: Concepts, algorithms, and applications [J]. IEEE Access, 2024, 12: 86716-86727.
- [17] DING Y, ZHU H, CHEN R, et al. An efficient AdaBoost algorithm with the multiple thresholds classification [J]. Applied Sciences, 2022, 12(12): 5872.
- [18] 肖寅东, 曾宇通, 刘科, 等. 基于 XGBoost 的模拟集成电路测试参数优化方法 [J]. 电子测量与仪器学报, 2023, 37(4): 61-68.  
XIAO Y D, ZENG Y T, LIU K, et al. Optimization method of analog IC test parameters based on XGBoost [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 61-68.
- [19] 易茂祥, 宋晨钰, 于金星, 等. 基于随机森林的集成电路适应性测试方法研究 [J]. 郑州大学学报(工学版), 2021, 42(4): 13-18.

YI M X, SONG CH Y, YU J X, et al. Research on adaptive testing method for integrated circuits based on random forest [ J ]. Journal of Zhengzhou University ( Engineering Science ), 2021, 42(4): 13-18.

[ 20 ] IBRAHIM A A, RIDWAN R L, MUHAMMED M M, et al. Comparison of the CatBoost classifier with other machine learning methods [ J ]. International Journal of Advanced Computer Science and Applications, 2020, 11(11): 738-748.

[ 21 ] AHMAD M, HU J L, AHMAD F, et al. Supervised learning methods for modeling concrete compressive strength prediction at high temperature [ J ]. Materials, 2021, 14(8): 1983.

[ 22 ] AHMAD M, AHMAD F, WRÓBLEWSKI P, et al. Prediction of ultimate bearing capacity of shallow foundations on cohesionless soils: A gaussian process regression approach [ J ]. Applied Sciences, 2021, 11(21): 10317.

[ 23 ] STAJKOWSKI S. Machine learning modelling of the thermal impacts of urban stormwater ponds on receiving streams[ D ]. Guelph: University of Guelph, 2023.

[ 24 ] DESPOTOVIC M, NEDIC V, DESPOTOVIC D, et al. Evaluation of empirical models for predicting monthly mean horizontal diffuse solar radiation [ J ]. Renewable and Sustainable Energy Reviews, 2016, 56: 246-260.

[ 25 ] AMJAD M, AHMAD I, AHMAD M, et al. Prediction of pile bearing capacity using XGBoost algorithm: modeling and performance evaluation [ J ]. Applied Sciences, 2022, 12(4): 2126.

[ 26 ] ZHU D, YU B, WANG D, et al. Fusion of finite element and machine learning methods to predict rock shear strength parameters[ J ]. Journal of Geophysics and Engineering, 2024, 21(4): 1183-1193.

作者简介



章礼华,2000 年于安庆师范大学获得学士学位,2007 年于安徽大学获得硕士学位,2014 年于安徽大学获得博士学位。现为安庆师范大学电子工程与智能制造学院教授,主要研究方向为集成电路测试与修调、测试数据压缩和量子信息处理等。

E-mail: zhanglh@aqnu.edu.cn

Zhang Lihua received his B. Sc. degree from Anqing

Normal University in 2000, the M. Sc. degree from Anhui University in 2007, and the Ph. D. degree from Anhui University in 2014, respectively. Now he is a professor at the School of Electronic Engineering and Intelligent Manufacturing at Anqing Normal University. His main research interests include integrated circuit testing and trimming, test data compression, and quantum information processing.



张珺瑚,2022 年于吉林工程技术师范学院获得学士学位,现为安庆师范大学硕士研究生,主要研究方向为集成电路测试、集成电路修调。

E-mail: 1332365434@qq.com

Zhang Junhu received his B. Sc. degree from Jilin Engineering and Technical Teachers College in 2022. Now he is a M. Sc. candidate at Anqing Normal University. His main research interests include integrated circuit testing and trimming.



刘建,2023 年于武汉工程大学获得学士学位,现为安庆师范大学研究生,主要研究方向为光谱测量与集成电路修调。

E-mail: ythaliu@163.com

Liu Jian received his B. Sc. degree from Wuhan Institute of Technology in 2023. Now he is a M. Sc. candidate at Anqing Normal University. His main research interest includes spectral measurement and integrated circuit trimming.



詹文法(通信作者),2000 年于安庆师范大学获得学士学位,2004 年于合肥工业大学获得硕士学位,2009 年于合肥工业大学获得博士学位。现为安庆师范大学电子工程与智能制造学院教授,主要研究方向包括集成电路测试与修调、测试数据压缩以及自动测试向量生成(ATPG)算法等。

E-mail: zhanwf@aqnu.edu.cn

Zhan Wenfa (Corresponding author) received his B. Sc. degree from Anqing Normal University in 2000, the M. Sc. degree from Hefei University of Technology in 2004, and the Ph. D. degree from Hefei University of Technology in 2009, respectively. Now he is a professor at the School of Electronic Engineering and Intelligent Manufacturing at Anqing Normal University. His main research interests include integrated circuit testing and trimming, test data compression, and automatic test pattern generation (ATPG) algorithms.