一种提升信用审批决策的模型融合方法

Yuanhong Wu*§、Jingyan Xu*§、Wei Ye†、Christina Schweikert‡ 和 D. Frank Hsu*，*IEEE*高级会员
*福特汉姆大学信息学与数据挖掘实验室、计算机与信息科学系，美国纽约州纽约市 10023

†福特汉姆大学经济学系，美国纽约州纽约市 10023
‡圣约翰大学 CSMS部门，美国纽约州皇后区 11439§这些作者贡献相同

arXiv:2601.12684v1 [cs.CE] 19 Jan 2026

摘要——**信贷违约给金融机构和消费者带来了重大挑战，造成巨额财务损失并削弱信任。因此，信贷违约风险管理一直是金融业的重要议题。本文提出组合融合分析（CFA），这是一种模型融合框架，通过结合多种机器学习算法，高准确率地检测和预测信用卡审批结果。我们介绍了采用五种预训练模型的设计方法论及其实现。CFA的结果显示，其准确率为89.13%，优于传统机器学习和集成方法。**

索引词—**银行风险管理、信用卡审批预测、模型融合、认知多样性、组合融合分析、排序组合、排序-评分函数**

一、引言

信用卡审批是零售银行业的一项重要任务，直接影响盈利能力和风险敞口。随着信贷市场不断发展、申请量持续增加，银行面临着更大的压力，需要更快速、更准确地做出决策。为此，机器学习算法已被用于评估申请人信用度。

逻辑回归、决策树和 k近邻（KNN）等传统模型已得到广泛应用，并在信用风险预测和欺诈检测方面展现出良好效果。近年来，人们采用集成方法，通过结合多个基模型的优势来提高准确率。

组合融合分析（CFA）是一种用于计算学习与建模、X信息学和模型融合的新范式 [10]。CFA提供了模型融合技术，既支持排序组合，也支持评分组合。它还定义了分类器之间认知多样性的定量衡量方法，并利用这种多样性进行模型融合。CFA已用于提升投资组合管理、信息检索、化学信息学、入侵检测等多个领域的决策任务表现[15]。本研究首次将CFA应用于信用审批预测任务，以提升其性能。本文表明，基于排序的模型融合可以优于传统机器学习和集成方法。

©2025年 IEEE。允许个人使用本材料。所有其他用途均需获得 IEEE 的许可。

本文其余部分安排如下：第一节介绍研究背景和动机；第二节回顾相关工作；第三节概述方法论，包括 CFA框架、基模型以及模型训练设置；第四节展示结果；第五节总结本研究并讨论未来工作。

II. 相关工作

自信用卡广泛普及以来，信用卡风险管理一直是重要的研究领域，其中信贷申请评估始终是核心关注点。自20世纪80年代以来，机器学习在这一领域发挥了重要作用 [3], , 随着计算能力和数据可用性的提升，其应用也日益广泛。

Hand 和 Henley [9] 回顾了消费者信用评分中使用的统计分类方法，重点介绍了这些方法的假设、优势和局限性。Roy 和 Vasa [20] 基于 PRISMA 对人工智能和机器学习在信用风险评估中的应用进行了系统性综述，涵盖了从传统统计方法到先进深度学习模型的各类方法。他们发现，集成模型——尤其是提升树和随机森林——在准确率方面始终优于其他方法，同时也指出了公平性、模型可解释性以及不平衡数据集处理等新兴挑战。Schmitt [21] 还比较了集成模型与深度学习方法的表现，并指出梯度提升机（GBM）和深度神经网络是信用风险管理领域的两种主流模型。他在三个结构化信用评分数据集上评估了这些模型的表现，发现 GBM 在曲线下面积和计算效率方面通常优于深度学习，尽管深度模型在某些情况下仍具竞争力。

Quan 和 Sun [19] 提出了一种基于因子分解机（FM）模型的混合信用评分模型，该模型将线性建模与协同过滤相结合，以捕捉特征交互。该方法能够有效地对稀疏类别特征和连续特征建模，从而提高了在信贷申请数据集上的预测准确率。Dahiya 等人 [5]使用澳大利亚信用数据集，研究了装袋集成对用于信用评估的多层感知机（MLP）分类器的影响。作者得出结论：

装袋集成显著提高了 MLP 模型的分类准确率。E mmanuel 等人 [6] 开发了一种信用风险预测引擎，采用堆叠分类器，将随机森林、梯度提升和 XGBoost 作为基模型进行组合。其堆叠集成的表现优于人工神经网络、决策树和 KNN 等单个分类器。

一些论文探讨了如何提升信用风险模型的可解释性，将关注重点从单纯的预测性能转向模型透明度。例如，Misheva 等人 [18]同时采用 LIME 和 SHAP，解释基于 Lending Club 数据训练的机器学习模型所做出的预测。他们的研究表明，事后解释技术如何增强模型可解释性，并提升人们对自动化信用决策系统的信任。

在我们审阅的几乎所有信用风险管理论文中，采用基于排序的方法进行信用风险预测的模型寥寥无几。本文应用了 Hsu 等人 [10], 提出的组合融合分析（CFA）模型融合范式，该范式利用排序与分数信息整合模型。它借助排名-评分特征（RSC）函数和认知多样性度量 [11, 12] ，充分利用模型间多样性。CFA 已在多个不同领域展现出有效性 [1, 14, 16, 22]。本研究首次将其应用于信用风险管理，从模型融合的视角提出了一种新颖的方法。

III. 方法论

本节介绍五个基模型、组合融合分析方法，以及使用 UCI 机器学习资料库提供的数据集进行模型训练。

A. 基模型

1) KNN（模型*A*）： k近邻（KNN）算法是一种用于分类和回归的非参数方法 [4]。它会找出特征空间中距离最近的 k 个数据点，并分配多数类或平均值。KNN 依赖欧几里得距离等距离度量，并假设相似的实例彼此接近。它不需要对数据分布做先验假设。

2) LDA（模型*B*）：线性判别分析（LDA）是一种用于分类和降维的监督方法 [7]。它将数据投影到较低维空间，在最大化类间方差的同时最小化类内方差。

3) AdaBoost（模型*C*）：自适应提升（AdaBoost）是一种集成算法，它结合多个性能各异的学习器，构建一个强分类器 [8]。该算法依次在加权数据上训练学习器，并更加关注先前误分类的样本。最终预测通过加权多数投票得出。

4）随机森林（模型*D*）：随机森林通过自助采样数据和随机特征选择构建决策树集成 [2]。这种方法增强了树之间的多样性，从而提升泛化能力并减少过拟合。预测结果通过多数投票或取平均值进行汇总。

5）卷积神经网络（模型*E*）：卷积神经网络（CNN）是一种深度学习模型，专为处理图像和序列等网格结构数据而设计 [17]。卷积层通过共享权重来检测空间模式。利用池化层和全连接层降低维度，并执行分类或回归。

B. 组合融合分析

评分系统由以下三个组成部分表示：评分函数、排名函数和排名-评分特征（RSC）函数。在本文的研究背景下，所考虑的多重评分系统（MSS）包括：A（k近邻）、B（线性判别分析）、C（AdaBoost）、D（随机森林）和 E（卷积神经网络）。对于每一位向银行申请信贷的客户，模型都会提供一个评分值，用以表示该客户因信用风险而应获批准或被拒绝的概率。

这些评分经过归一化，限定在 [0,1] 范围内，从而得到五个标记为A至E的评分系统。对于给定的一组 n 信用卡申请人 $D = \{d_1, ..., d_n\}$，每个评分系统都包含一个评分函数（s_A，s_B，s_C，s_D，s_E）以及由此导出的排名函数（r_A，r_B，r_C，r_D，r_E），后者按照可信度降序排列申请人。给定评分函数和排名函数后，评分系统的RSC函数 f_A A 定义如下：

$$f_A(i) = (s_A \circ r_A^{-1})(i) = s_A(r_A^{-1}(i)) \tag{1}$$

对于 $i = 1,...,n$ [10, 12, 13, 15]。

认知多样性（CD）量化了一对评分系统在对相同数据集项目（此处为信用卡申请人）进行评分时的差异 [11]。其定义为两个系统的 RSC 函数在所有申请人上的均方根差：

$$CD(A,B) = \sqrt{\frac{\sum_{i=1}^{n}((f_A(i) - f_B(i))^2)}{n-2}} \tag{2}$$

评分系统的多样性强度 $DS(A_j)$，对于评分系统 A_j，计算为所有包含 A_j [16] 的评分系统对之间 CD 的平均值，其定义为 $DS(A_i) = \sum_{j=1, j\neq i}^{t} CD_{(A_i,A_j)}{}_{t-1}$ [16]。

在 CFA框架 中，MSS 可通过评分组合或排序组合进行融合。融合可以采用非加权方式（所有系统权重相同）或加权方式，权重反映多样性 [13, 16]:

$$w_j = \begin{cases} 1 & \text{for average combination (AC)} \\ DS_j & \text{for weighted combination by diversity strength (WCDS)} \end{cases}$$

设 $A_1, ..., A_t$ 为评分系统，其对应的权重为 $w_1, ..., w_t$，评分组合的计算方式为 [13,16]:

$$s_{SC}(d_i) = \frac{\sum_{j=1}^{t} w_j * s_{A_j}(d_i)}{\sum_{j=1}^{t} w_j} \tag{3}$$

同样，排序组合的计算方式为 [13, 16]:

$$s_{RC}(d_i) = \frac{\sum_{j=1}^{t} (\frac{1}{w_j}) * r_{A_j}(d_i)}{\sum_{j=1}^{t} (\frac{1}{w_j})} \tag{4}$$

这种加权方法使融合过程能够同时优先考虑性能更高、且与其他评分系统差异更大的系统。

C. 模型训练

本研究使用来自 UCI机器学习资料库的澳大利亚信贷审批数据集，其中包含 690 个实例和 14 个不同类型的属性。每个实例都有一个标签，用于表示信用申请是否获批（1）或被拒（0）。数值特征、名义特征和二元特征的组合，使该数据集非常适合用于评估处理异构输入的模型。

数据集中的每个实例代表一个人的信用档案。每位申请人的属性包括：6 个数值属性（例如申请人的年龄、信贷金额）和 8 个类别属性，其中：3 个为二元属性，5 个为名义属性（多类别）。目标标签为二元标签（获批或未获批）。我们确认该数据集相对均衡，约 55% 的申请获批，45% 的申请被拒，从而降低了模型训练中出现偏见的风险。

为了分析不同类型的特征，我们采用以下编码策略。对于数值特征，使用 z 分数归一化（均值为零、方差为一）。标准化可确保各特征处于可比尺度，从而提升模型性能；这对于基于距离的模型（例如 KNN）以及神经网络中使用的基于梯度的优化器尤其有益。名义特征则使用独热编码进行转换，为该特征的每个类别创建一组二元变量。最后，我们保留二元特征的原始格式。所有转换均使用 scikit-learn 预处理工具实现，以确保结果可复现。

预处理完成后，采用分层抽样将数据集划分为训练集（80%）和测试集（20%），以保持标签比例。这样可以在不引入训练子集与测试子集之间分布偏移的情况下，稳健地评估模型。划分完成后，我们按照上一节所述训练五个基模型。每个模型都在训练集上通过随机超参数搜索和五折交叉验证进行优化。这些模型输出的是类别概率分数，而非二元预测。这些概率分数体现了各模型的置信度，比二元决策包含更多信息。我们将利用这些概率分数构建评分系统，再通过CFA融合技术将其组合起来。

本研究采用准确率作为性能指标。之所以这样选择，是因为信用卡中心的运营重点主要在于对信用卡申请作出正确的批准或拒绝决定。准确率能够直接反映这一决策过程的质量。此外，准确率在相关研究中应用广泛，便于直接比较。

如前所述，组合融合分析（CFA）框架同时采用基于分数和基于排名的组合。分数指的是概率，通常会通过 0.5 的阈值转换为预测结果。相比之下，基于排名的融合会将概率转换为

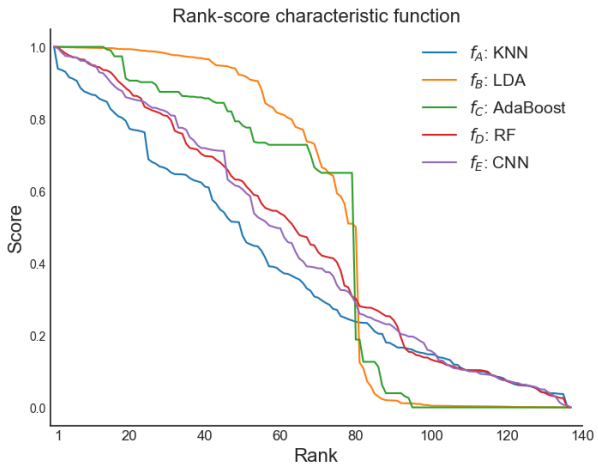

图 1：基模型 A、B、C、D 和 E 的排名-分数函数。

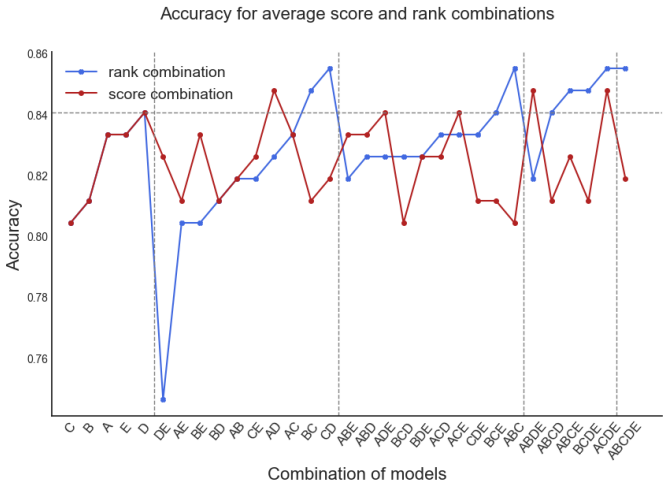

图 2：平均得分和排名组合的准确率。

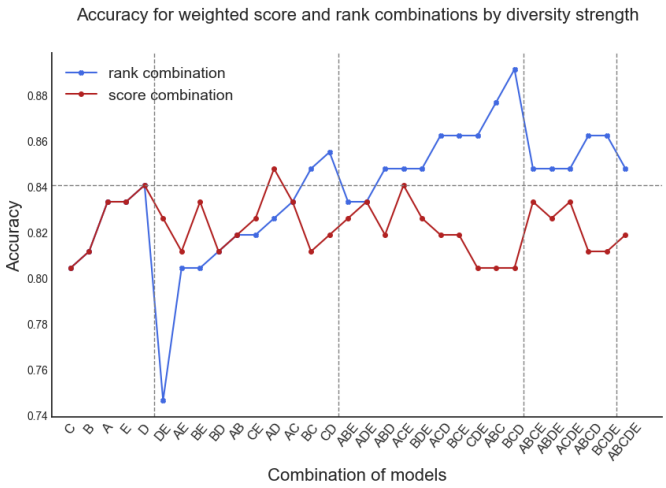

图 3：不同多样性强度下加权得分和排名组合的准确率。

	Best 单个模型	CFA k组合（k=2、3、4、5）			
		最佳双模型组合	最佳三模型组合	最佳四模型组合。	最佳五模型组合。
分数组合。	D（0.8406）	AD（AC，WCDS：**0.8478**）	ADE（AC：0.8406），ACE（AC，WCDS：0.8406）	ABDE（AC：**0.8478**），ACDE（AC：**0.8478**）	ABCDE（AC，WCDS：0.8188）
秩组合	D（0.8406）	CD（AC，WCDS：**0.8551**）	BCD（WCDS：**0.8913**）	ABCD（WCDS：**0.8623**），BCDE（WCDS：**0.8623**）	ABCDE（AC：**0.8551**）

表 I： k 组合（k=2、3、4、5）的性能。高于最佳单个模型性能的数值以粗体显示。

序数排名，其中排名较低的申请被视为更可靠。排名越低，信用风险越低，获批的可能性也越高。

为根据排名生成二元标签，我们以真实标注中的正例数量（即获批申请）作为阈值。例如，如果数据集中有 100 个获批案例，我们就将排名前 100 的申请标记为类别 1（获批），其余则标记为类别0（未获批）。这种方法直观且实用，因为它假设排名最低的申请人最有可能具备信用偿付能力，与现实中的风险评估实践十分契合。

IV. 结果

组合融合分析是一种模型融合框架，能够高效且稳健地整合多个评分系统。它通过探索分数层面和排名层面的组合，以及加权组合，集成基模型的优势。借助评分和排名行为的多样性，CFA 显著提升了模型融合的潜力。理论研究发现，在某些条件下，基于排名的组合可以优于基于分数的组合，这进一步促使我们同时考虑这两种表示形式 [14]。

在本研究中，我们采用五个基础模型，并系统地考察它们的组合。对于每种组合规模$t \in \{2,3,4,5\}$，我们考虑所有 $\binom{5}{t}$ 种可能的组合。例如，共有10种不同的双模型组合（$\binom{5}{2} = 10$）。总计得到 $2^5 - 1 - 5 = 26$ 种独特的模型组合，不包括单个模型和空集。我们使用基于得分和基于排名的融合方法对每种组合进行评估，并进一步采用两种不同的加权方案进行组合：非加权平均和基于多样性的加权平均。这总共产生了$26 \times 2 \times 2 = 104$ 种模型融合案例。

为比较不同的组合策略，我们在两幅独立的图中展示模型组合的性能。图2和图3分别对应平均融合和多样性加权融合的结果。在分析这些评分系统组合的性能之前，我们首先考察图1所示的五个基础模型的排名-评分特征（RSC）函数。RSC函数清晰地展示了模型多样性，而模型多样性对于提升模型融合性能发挥着至关重要的作用。

在图1中，x轴表示测试数据集中的实例排名，而y轴显示归一化分数，即将原始预测概率缩放到范围$[0,1]$内的分数。这些归一化分数按降序排列，因此排名1对应最高分数。

从图1中可以看出，五个基础模型的排名-得分分布呈现出明显的多样性。大多数模型之间区分明显，只有模型D和模型E看起来较为接近。相比之下，排名行为差异更大的模型具有更高的多样性，这是提升模型融合效果的重要因素。

图2比较了所有模型组中平均得分组合与排名组合的分类准确率。横轴显示五个单独的基模型，以及由这些模型构成的所有26种可能组合。在单个模型中，模型D（随机森林）的准确率最高，达到0.84；图中以水平虚线标出该值，作为参考阈值。任何超过此线的模型组合都表明其性能优于表现最佳的单个模型。

在双模型组合中，基于排名的融合产生了两个优于最佳单个模型的组合（BC和CD），而基于得分的融合仅识别出一个这样的组合，即AD。值得注意的是，排名组合CD的性能提升大于得分组合AD。这可能是因为该组合包含模型D（准确率最高的模型），且与模型C相比具有较大的多样性，从而提升了集成效果。

对于三模型组合，只有一个基于排名的融合结果超过了阈值，而表现最佳的基于得分的组合仅与最佳单个模型的性能持平。在四模型组合组中，基于排名的融合产生了三个准确率有所提升的组合，而基于得分的方法产生了两个。最后，在组合全部五个基础模型时，基于排名的融合再次优于单模型基准，而基于得分的融合则未能做到这一点。

总体而言，基于排名的融合表现优于基于分数的融合，这表明在此场景下，排名平均是模型组合的更优策略。

图3展示了基于模型多样性得出的权重所对应的加权得分和排名组合的分类准确率。对于双模型组合，其结果与图2中的基于平均值的方法相同：基于排名的融合识别出两个超过最佳单个模型的组合（BC

类别	方法	准确率
混合或集成方法	基于多层感知机的装袋集成 [5]	0.8875
	因子分解机 [19]	0.8844
	堆叠随机森林、梯度提升和 XGBoost [6]	0.8623
CFA	平均分数组合（AD、ABDE、ACDE）	0.8478
	平均排名组合（ABC）	0.8551
	基于 DS 的加权分数组合（AD）	0.8478
	基于 DS 的加权排名组合（BCD）	**0.8913**

表 II：将 CFA 与其他单个模型和集成模型进行比较。

和CD），而基于得分的融合仅得到一个（AD）。然而，随着组合模型数量增加到3个、4个和5个，排名融合的优势变得更加明显。在这些组别中，基于排名的组合的准确率曲线始终高于基于得分的组合。值得注意的是，得分融合未能产生任何超过最佳单个模型的组合，而大多数排名组合都表现出明显提升。若干基于排名的组合，如ABC和BCD，甚至超过了0.86的准确率。

表 I 比较了使用 CFA 方法得到的最佳单个模型与不同融合规模下最佳模型组合的性能。CFA 结果对应的每个单元格均包含以下信息：(a) 括号外标明参与组合的模型；(b) 括号内的第一项表示组合类型，例如，“AC”表示平均组合，“WCDS”表示多样性强度加权组合；(c) 括号内的第二项表示该组合的准确率。加粗的准确率表示性能优于最佳单个模型。总体而言，我们观察到，基于 CFA 的模型组合在基于分数和基于排名的融合方法中，以及在不同组合规模下，均优于单个模型。此外，排名融合在四种组合规模下都提高了准确率，而分数融合仅在其中两种规模下表现更佳。

在所有组合中，准确率最高的模型集合是多样性强度加权排名组合中的 BCD，由线性判别分析、AdaBoost 和随机森林组成。该组合的准确率达到**0.8913**，显著高于最佳单个模型（准确率为 0.84 的随机森林）。鉴于基线准确率已经很高，这一近 5% 的提升尤为显著，因为在这种情况下，即使提高 1% 通常也很难实现。如图1所示，模型 B、C 和 D 的 DS（多样性强度）加权组合取得了最高性能，部分原因在于它们具有多样性。

此前，我们比较了基于 CFA 的模型组合与各个基模型的表现。现在，我们进一步将 CFA 的结果与几种成熟的混合方法和集成方法进行比较。比较结果汇总于表 II。

我们所有基模型的准确率都低于表 II 中列出的混合集成方法。表中，Dahiya 等人 [5] 采用了多层感知机（MLP）的装袋集成，准确率达到 0.8875。Quan 等人 [19] 提出了一种混合因子分解机模型，将线性建模与协同过滤相结合，以捕捉特征交互。该模型在同一数据集上的准确率达到 0.8844。此外，Emmanuel 等人[6] 提出了一种由随机森林（RF）、梯度提升和 XGBoost（XGB）组成的堆叠集成，准确率为 0.8623。

对于 CFA框架的结果，我们评估了四种不同的融合策略，并报告了每种组合技术所达到的最高准确率，以及相应的融合模型集合。许多 CFA 组合的准确率约为 0.85。观测到的最高准确率为 0.8913，由基于多样性强度、采用模型 B、C 和 D 的加权排名组合取得。这一表现优于表 II 中列出的混合模型和集成模型。

这些结果凸显了 CFA框架的有效性和灵活性。通过系统地探索并利用不同模型的互补优势，CFA 不仅能够媲美传统的集成方法和混合方法，而且往往表现更优。其模型融合策略支持定制组合，可根据基础分类器特定的多样性或性能模式进行调整，因此，CFA 是一种强大的工具，能够提升复杂决策任务（如信用卡审批预测）中的预测准确率。

鉴于信贷审批所涉及的监管要求和社会影响，此类任务若采用单个模型，可能会引发严重的偏见、透明度和公平性问题。采用排名有助于向潜在申请人解释其申请获批或被拒的原因。认知多样性和聚合技术也能发现并有效减轻偏见。这些因素有助于将 CFA 纳入金融领域日益壮大的负责任人工智能运动。

V. 结论与未来工作

在本研究中，我们应用组合融合分析（CFA）框架来提升信用卡审批预测的效果。我们选取了五种多样化的基模型作为 CFA 框架的输入：KNN、线性判别分析、AdaBoost、随机森林和卷积神经网络。这些模型通过两种加权方案进行融合：平均组合和基于多样性的加权组合。

实验结果表明，基于 CFA 的模型融合显著优于单个基模型。CFA 配置的准确率高于最先进水平

的混合方法和集成方法。值得注意的是，使用模型 BCD（线性判别分析、AdaBoost、RF）的多样性强度加权排名组合达到了 0.8913 的准确率，超过了现有基准。

CFA 的一项关键优势在于，它不仅利用分数，也利用排名。我们的结果表明，正如 CFA框架所采用的那样，基于排名的组合能够显著提升预测性能，效果之强甚至出乎意料，尤其是在模型/算法多样的情况下。这种面向秩的方法和模型多样性的定量度量能够捕捉互补信息，而这些信息在基于分数的融合中可能无法得到充分体现。因此，我们倡导更广泛地采用基于秩的融合策略，并强调 CFA 是实现这一目标的实用且灵活的框架，尤其适用于信贷风险预测等决策质量至关重要的场景。

展望未来，我们确定了两个研究方向。首先，我们计划探索多层CFA架构，即将一层模型融合的输出作为第二层融合的输入。这样一来，最初的 104 种组合可以根据准确率和多样性标准筛选为五个表现更优的集成，再将它们重新组合，以取得可能更好的结果。初步实验表明，这种多层设计能够进一步提升准确率 [15]。

其次，我们旨在将在线学习能力整合到CFA框架中。这样一来，银行便可随着新的申请数据到来而动态更新模型，无需从头开始重新训练模型。

另一方面，准确率本身无法反映非对称错误成本或类别不平衡。因此，未来的工作必须扩展至能够捕捉这些特征的指标。为验证鲁棒性和泛化能力，我们还应纳入其他数据集，这些数据集应在不平衡分布、结构方面与当前数据集有所不同，并且最好来自信用卡审批以外但与信用风险相关的其他领域。

参考文献

[1] A. Alfatemi等，“通过多模型深度学习融合和组合分析识别分布式拒绝服务攻击”，《网络与系统管理杂志》，33，（1），第8页，2025年。[2] L. Breiman，“随机森林”，机器学习，45，（1），第5–32页，2001年。[3] C. Carter和J. Catlett，“使用机器学习评估信用卡申请”，《*IEEE*智能系统》，2，（03），第71–79页，1987年。[4] T. Cover和P. Hart，“最近邻模式分类”，《*IEEE*信息论汇刊》，13，（1），第21–27页，1967年。[5] S. Dahiya、S. Handa和N. Singh，“装袋法对信用评估多层感知机分类器的影响”，载于*2016*年第*3*届可持续全球发展计算国际会议（*INDIACom*），IEEE，2016年，第3794–3800页。

[6] I. Emmanuel、Y. Sun 和 Z. Wang，《一种基于机器学习的信用风险预测引擎系统：采用堆叠分类器和基于过滤器的特征选择方法》，《大数据杂志》，11，（1），第 23 页，2024年。[7] R. A. Fisher，《多重测量在分类学问题中的应用》，《优生学年鉴》，7，（2），第 179–188 页，1936年。[8] Y. Freund 和 R. E. Schapire，《在线学习的决策理论泛化及其在提升中的应用》，《计算机与系统科学杂志》，55，（1），第 119–139 页，1997年。[9] D. J. Hand 和 W. E. Henley，《消费者信用评分中的统计分类方法：综述》，《英国皇家统计学会杂志：*A*辑（社会统计学）》，160，（3），第 523–541 页，1997年。[10] D. F. Hsu、Y.-S. Chung 和 B. S. Kristal，《组合融合分析：组合多个评分系统的方法与实践》，载于《生物信息学高级数据挖掘技术》，IGI Global Scientific Publishing，2006年，第 32–62 页。[11] D. F. Hsu、B. S. Kristal、Y. Hao 和 C. Schweikert，《认知多样性：衡量多个评分系统之间差异度的方法》，《互联网络杂志》，19，（01），第 1 940001 页，2019年。[12] D. F. Hsu、B. S. Kristal 和 C. Schweikert，《秩分数特征（RSC）函数与认知多样性》，载于《脑信息学：*BI 2010*国际会议》，Springer，2010年，第 42–54 页。[13] D. F. Hsu、B. S. Kristal 和 C. Schweikert，《组合融合分析》，《*IEEE*计算机》，第 96–100 页，2024年。[14] D. F. Hsu 和 I. Taksa，《比较信息检索中数据融合的秩与分数组合方法》，《信息检索》，8，（3），第 449–480 页，2005年。[15] L. Hurley、B. S. Kristal、S. Sirimulla、C. Schweikert 和 D. F. Hsu，《利用认知多样性进行多层组合融合》，《*IEEE*开放获取》，9，第 3919–3935 页，[16] N. Jiang、M. Quazi、C. Schweikert、D. F. Hsu、T. I. Oprea 和 S. Sirimulla，《通过组合融合分析提升ADMET性质模型的性能》，*ChemRxiv*，2023年。[17] Y. Lecun、L. Bottou、Y. Bengio 和 P. Haffner，《将基于梯度的学习应用于文档识别》，*IEEE*会议录，86，（11），第 2278–2324 页，1998年。[18] B. H. Misheva、J. Osterrieder、A. Hirsa、O. Kulkarni 和 S. F. Lin，《信用风险管理中的可解释人工智能》，*arXiv*预印本 *arXiv:2103.00949*，2021年。[19] J. Quan 和 X. Sun，《利用带有特征交互的因子分解机模型进行信用风险评估》，《人文与社会科学通讯》，11，（1），第 1–10 页，2024年。[20] J. Roy 和 L. Vasa，《信用风险评估转型：人工智能与机器学习应用的系统综述》，《基础设施、政策与发展杂志，9，（1），第 9652 页，2025年。[21] M. Schmitt，《深度学习与梯度提升：针对信用评分领域最先进机器学习算法的基准测试——

算法》，*arXiv*预印本 *arXiv:2205.10535*，2022年。

[22] Y. Wu、W. Ye、J. Xu 和 D. F. Hsu，《利用机器学习和组合融合分析预测比特币价格》，载于*2025*年*IEEE*人工智能会议（*CAI*），IEEE，2025年，第 61–68 页。