

# 逾期风险预测的宽度和深度学习

宁 婷 苗德壮 董启文 陆雪松

华东师范大学数据科学与工程学院 上海 200062

(51185100026@stu.ecnu.edu.cn)



**摘 要** 逾期风险控制是信用贷款服务的关键业务环节,直接影响放贷企业的收益率和坏账率。随着移动互联网的发展,信贷类金融服务已经惠及普罗大众,逾期风控也从以往依赖规则的人工判断,转为利用大量客户数据构建的信贷模型,以预测客户的逾期概率。相关模型包括传统的机器学习模型和深度学习模型,前者可解释性强、预测能力较弱;后者预测能力强、可解释性较差,且容易发生拟合。因此,如何融合传统机器学习模型和深度学习模型,一直是信贷数据建模的研究热点。受到推荐系统中宽度和深度学习模型的启发,信贷模型首先可以使用传统机器学习来捕捉结构化数据的特征,同时使用深度学习来捕捉非结构化数据的特征,然后合并两部分学习得到的特征,将其经过线性变换后,最后得到预测的客户的逾期概率。所提模型中和了传统机器学习模型和深度学习模型的优点。实验结果表明,其具有更强的预测客户逾期概率的能力。

**关键词:** 逾期风险预测;机器学习;深度学习;宽度和深度模型

**中图法分类号** TP520

## Wide and Deep Learning for Default Risk Prediction

NING Ting, MIAO De-zhuang, DONG Qi-wen and LU Xue-song

School of Data Science and Engineering, East China Normal University, Shanghai 200062, China

**Abstract** Default risk control is a key business component of credit loan services, which directly affects the profitability and bad-debt rate of lenders. With the development of the mobile Internet, credit-based financial services have benefited the general public. Default risk control has changed from manual judgment based on rules to credit models built by using large amounts of customer data to predict the default rate of customers. Relevant models include traditional machine learning models and deep learning models. The former has a strong interpretability but a weak predictability; the latter has a strong predictability but a poor interpretability, which is prone to overfitting the training data. Therefore, the integration of traditional machine learning models and deep learning models has always been an active research area in credit modeling. Inspired by the wide & deep learning models in recommendation systems, a credit model first can utilize traditional machine learning to capture features of the structured data, while a deep learning can capture features of the unstructured data. Then, the model combines two parts of the learned features and uses an additional linear layer to transform the hidden features. Finally, the model outputs the predicted default rate. This model neutralizes the advantages of traditional machine learning models and deep learning models. Experimental results show that the proposed model has a stronger capability to predict the default probability of customers.

**Keywords** Default risk control, Machine learning, Deep learning, Wide & deep learning models

## 1 引言

随着移动互联网的发展,“互联网+”金融产品和服务逐渐成为日常生活中必不可少的一部分。利用大数据和信息技术,金融企业通过互联网提供支付、投资和贷款等业务,使得能够享受金融服务的人群达到了前所未有的规模。然而也正因为互联网金融服务覆盖了普罗大众,如何有效甄别客户质量成为了企业经营优化过程中至关重要的一环。其中,互联

网信贷的逾期风险控制(以下简称“风控”)是最具代表性的甄别好坏客户的任务之一。该任务通过分析客户在使用互联网服务时提供的各类数据,形成高维用户画像,并构建信贷模型来预测客户贷款后的逾期概率<sup>[1-2]</sup>。

现有的信贷模型主要分为传统的机器学习模型<sup>[3]</sup>和深度学习模型<sup>[1]</sup>。前者往往需要大量的特征工程来构建结构化的输入数据,如将客户性别、年龄、教育程度等数据进行分箱,并且需要将其转化为虚拟变量;后者将原始数据直接表示成向

收稿日期:2020-09-07 返修日期:2020-10-01 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(U1711262,61672234)

This work was supported by the National Natural Science Foundation of China(U1711262,61672234).

通信作者:陆雪松(xslu@dase.ecnu.edu.cn)

量输入模型,依靠模型的多层非线性结构自动学习原始特征和逾期表现之间的映射关系,尤其善于从非结构化数据中捕捉关键特征。传统的机器学习模型结构简单,可解释性强,深受金融行业的偏爱,但是其预测表现相对较差。深度学习模型预测能力强大,但是其结构复杂,缺乏可解释性,且容易造成过拟合。一个折中的办法是使用集成学习<sup>[4]</sup>,即使用相同的数据分别训练传统机器学习模型和深度学习模型,然后融合或者平均多个模型的预测结果。这种方法虽然简单易行,但是多个模型的预测结果仍然需要手动集成,且非常依赖专家经验。此外,训练多个模型也会增加风控的工作量和计算资源的消耗。

受到推荐系统中宽度和深度学习<sup>[5]</sup>的启发,本文提出将这一架构迁移到逾期风控任务中。其中,宽度模型为传统的浅层机器学习模型,如逻辑回归和随机森林等。其输入数据为经过特征工程加工后的结构化数据,以及部分结构化数据之间的交叉项。引入交叉项的目的是学习输入特征之间的依赖关系。传统机器学习模型的输入数据维度较高,因此在此架构中本文将这部分模型命名为宽度模型。深度模型可以采用各类神经网络,用于从难以结构化的原始数据中直接学习特征,如客户使用服务的行为序列、客户之间的关联关系、客户的支付流水等。最终,将深度模型的最后一个隐层和宽度模型输入层的特征进行合并,再经过线性层的转换,输出最终的预测结果。采用此架构,传统机器学习模型和深度学习模型可以被合并为一个模型,以进行端到端的训练。同时,两部分模型具有一定的互补性。深度模型部分从非结构化原始数据中捕捉关键特征,提升模型的预测能力;宽度模型部分学习结构化数据的特征,通过简单的线性变换来中和深度模型的复杂度,在一定程度上起到了正则的作用,降低了模型过拟合的风险,并且增强了模型的可解释性。本文构建了一个具体的宽度和深度模型(Wide & Deep Model),用于预测小微企业贷款后的逾期概率。之后详细阐述了模型的输入特征,以及选择它们的原因。此外,两部分模型的细节可以根据具体的任务采用不同的模型来实现,同时模型的整体架构很容易被泛化到其他逾期风控任务中,如预测个人商业贷款的逾期概率、构建信用评分卡等。

本文第2节简单回顾了信贷模型以及宽度和深度模型的相关工作;第3节详细说明了本文构建的模型;第4节通过实验验证了本文模型相比基准模型的预测性能优势;最后总结全文并展望未来。

## 2 相关工作

### 2.1 信贷贷款常用的模型

现有的信贷模型研究中,主要采用传统机器学习与深度学习算法。

常用的传统机器学习算法主要有 SVM(Support Vector Machine)、决策树、GBDT(Gradient Boosting Decision Tree)、XGBoost 等。Pu<sup>[3]</sup>使用了集成的 SVM 模型对上市公司进行风险评估。其采用 bagging,boosting 和 Stacking 这 3 种集成

策略对 SVM 进行集成,实验结果表明 Stacking 策略提高了高风险类别的召回率。其中,Stacking 是以多项式核函数和高斯核函数支持向量机作为第一层分类器,以线性核函数支持向量机作为第二层分类器。决策树模型<sup>[6]</sup>易于理解、实现和可视化,且其模型效果完全不受数据量纲缩放的影响。但是树模型容易过拟合,从而导致泛化性能不高,因此,在实际应用中,模型构建往往使用集成方法来替代单棵决策树。例如,Li 等<sup>[7]</sup>使用了异构的集成学习对 P2P 网络借贷平台的借贷数据进行建模。GBDT<sup>[8]</sup>和 XGBoost<sup>[9]</sup>都是以 boosting 思想为基础的集成学习,可以灵活处理各种类型的数据,包括连续值和离散值。这类模型使用了健壮性较强的损失函数,对异常值的鲁棒性非常强,能够得到更稳定的预测表现。然而 boosting 策略的思想是下一个学习器在上一个学习器训练效果的基础上,通过调整样本权重或者降低上一轮的残差来训练新的模型,因此学习器之间是相互依赖的,难以并行训练数据。

深度学习是机器学习的一个分支领域,其优势是可以将原始数据直接输入到网络中进行特征学习,无须人工提炼特征;此外其多层叠加的简单线性结构,也让深度模型易于处理大规模数据。信贷模型使用的网络结构主要有 BP(Back Propagation),CNN(Convolutional Neural Networks),LSTM(Long Short Term Memory),并结合 Attention 等辅助机制。Long<sup>[10]</sup>通过 3 层 BP 神经网络及输出层的转换,再利用 sigmoid 作为激活函数对上市公司的财务指标进行建模,为商业银行建立了上市公司信用风险评估模型。BP 网络是应用最为广泛的神经网络结构,通过信号的前馈计算和损失的反向传播,不断调整神经元的权重,并且能够自动关联输入的原始特征。Kvamme 等<sup>[11]</sup>基于 CNN 网络模型,使用银行账户的数据对抵押贷款违约率进行预测,其中,CNN 采用共享卷积核的形式,能够减少参数数量,同时还能处理经过重塑转换后的高维数据。Wang 等<sup>[12]</sup>使用了融入 Attention 机制的 LSTM 网络,对借款人的在线操作行为数据进行建模。其中,LSTM 是循环神经网络 RNN 的一种特殊结构,能够在一定程度上解决时序依赖模型的梯度消失问题,从而从时序数据中学习较为长期的依赖关系。Attention 机制可以自动学习各时刻隐层状态的重要性,并且根据各个隐层状态的权重进行聚合,从而提高各时刻隐层状态的表达能力,以最终提升输出预测的性能。

### 2.2 宽度和深度模型

Wide & Deep 网络框架最早于 2016 年由 Google 团队提出,主要用于 Google 应用市场的 APP 推荐功能<sup>[5]</sup>,其目的是提高 App 推荐的精准度,同时兼顾推荐系统的准确性和可扩展性。

近几年,随着此框架影响的加深,有学者逐渐将该框架应用在不同的领域场景中。Zheng 等<sup>[13]</sup>利用基于 Wide & Deep 的 CNN 模型对电力盗窃事件进行检测,Deep 模型首先采用 3 层卷积神经网络对输入进行进一步的特征提取,然后连接一层池化层和一层全连接层得到最后输出,帮助电网供应商

解决电力盗窃问题,降低经济损失。Niu 等<sup>[14]</sup>将此框架应用于专利和论文的分类任务中,Deep 部分首先采用 embedding 层对文本进行向量化,采用紧接着的一层卷积神经网络进行特征提取,然后使用最大池化降低数据维度,得到 Deep 模型输出,最后与 Wide 模型特征进行拼接,将其输入到 sigmoid 激活函数得到所属的类别,以便于专利审查员、律师和研究人员进行快速检索。Nguyen 等<sup>[15]</sup>在疾病检测上应用 Wide & Deep 框架,Deep 模型使用了两层全连接网络,通过 ReLU 激活函数得到输出的结果,将其与 Wide 模型特征进行拼接后,再将其输入到 ReLU 激活函数,以此获得了较高的准确率,进一步提升了模型对糖尿病发病率的预测性能。Bastani 等<sup>[16]</sup>将 Wide & Deep 应用于 P2P 借贷的个人逾期风险预测中,与 Cheng 等<sup>[5]</sup>的模型相似,该模型主要考虑贷款特征以及借款人的个人信息、信用评级、债务和信用记录这 5 个维度的特征。与 Bastani 等<sup>[16]</sup>的工作不同的是,本文将 Wide & Deep 框架应用于小微企业的贷后逾期风险中,将企业的交易流水这种非结构化特征加入到模型中进行训练,同时在两部分模型的特征输入上也做了具体区分。

### 3 信贷风险的宽度和深度模型

我们在与一家支付服务公司的合作中获取了部分小微企业的经营数据,以及它们向第三方机构申请商业贷款的数据。我们构建了一个具体的宽度和深度模型,用于预测这些小微企业的贷款逾期概率,并以此数据中的一些特征来说明模型的输入和输出。尽管如此,模型的整体框架可以很方便地被泛化到其他信贷模型中。模型结构如图 1 所示。




图 1 信贷风险的宽度和深度模型

Fig. 1 Wide & deep model for credit risk

宽度模型指传统的机器学习模型,其因输入特征往往是高维数据而得名。输入特征可以是连续型特征、离散型特征编码后的向量或是离散型特征之间结合形成的交叉特征。交叉特征用于捕捉输入特征之间的交互,起到添加非线性结构的作用,同时能够增加输入特征的维度。针对宽度模型部分,我们采用金融行业常用的逻辑回归模型,输入特征包括小微企业的行业、所在的城市、法人的性别、实名状态等结构化数据,以及部分数据的交叉特征,如城市和行业、实名状态和性别等的交叉特征。这些特征都使用 one-hot 向量转换成虚拟变量输入到模型中。其结构如图 1 左半部分所示。

深度模型指深度神经网络,其因具有多层叠加的线性和非线性结构而得名。深度神经网络能够直接从原始数据中捕捉到关键特征,以用于各类机器学习任务,因此非常适合学习

蕴含在非结构化数据中的特征。互联网金融服务中,小微企业能够提供的结构化信息非常有限,但往往能提供大量非结构化的经营流水数据用于申请贷款。非结构化的数据不容易使用特征工程进行清洗,也难以依靠专家经验构建相关规则,因此长期以来,该类数据在信贷模型中没有很好地发挥鉴别作用。而深度神经网络可以从非结构化流水数据中自动学习关键特征,经过多层线性和非线性转换,发现在历史数据中很少或者没有出现的新特征组合,具有强大的泛化能力,从而能够快速学习以得到新的、有效的特征表示,提高逾期风险的预测表现。本文模型中,深度模型部分叠加了 3 个全连接层,其维度从前往后依次为 256,128 和 64,所有全连接层都使用 ReLU 函数进行激活。深度模型的输入为小微企业历史交易笔数、历史交易金额、交易流水方差等流水数据。其结构如图 1 右半部分所示。每层 ReLU 函数的计算公式如下:

$$\mathbf{X}_{t+1} = f(\mathbf{W}_t \mathbf{X}_t + b) \tag{1}$$

其中, $\mathbf{W}_t, \mathbf{X}_t$  分别表示深度网络第  $t$  层的参数和输入, $b$  为偏置项, $f(\cdot)$  使用 ReLU 作为激活函数。

在融合宽度和深度模型时,我们将深度模型最后一个隐层的特征和宽度模型的输入特征进行拼接,然后共同输入到一层全连接层网络,再通过 sigmoid 激活函数得到预测结果,即:

$$y = \sigma(\mathbf{W}_{\text{wide}} \mathbf{X}_{\text{wide}} + \mathbf{W}_{\text{deep}} \mathbf{X}_{\text{deep}} + b) \tag{2}$$

其中, $y$  表示模型的输出,即逾期概率; $\mathbf{X}_{\text{wide}}, \mathbf{X}_{\text{deep}}$  分别为输入到最后一层网络的宽度和深度部分的特征; $\mathbf{W}_{\text{wide}}$  和  $\mathbf{W}_{\text{deep}}$  分别为相应的参数; $\sigma(\cdot)$  为 sigmoid 激活函数。这样该模型可以使用端到端的方式,同时训练两个部分的参数,实现了宽度和深度模型的无缝融合。我们使用交叉熵来计算模型的损失函数,即:

$$L = - \sum_{i=1}^N y^i \log \hat{y}^i + (1 - y^i) \log (1 - \hat{y}^i) \tag{3}$$

其中, $y^i, \hat{y}^i$  分别为第  $i$  个样本的真实逾期表现和预测逾期概率。

## 4 实验评估

### 4.1 数据描述

我们获得了部分小微企业的经营数据,以及它们通过该平台向第三方金融机构申请贷款的数据。首先筛选出贷款表现完全的小微企业样本,即已结清和确认逾期(超过理论结清日)的贷款记录。然后,选取曾逾期超过 30 天的小微企业,并将其定义为逾期样本,标记为 1。某些金融服务公司也会关注逾期超过 5 天和 90 天的逾期率预测,但这些预测率往往用于警示或者预测坏账率,并不是主要关注的客户信用和逾期风险。此外,该数据中贷款审批未通过的企业,往往是因为金融机构掌握了其法人的不良征信记录而拒绝放贷,这些企业被认为有极大概率会发生逾期,所以我们将这些样本也标记为 1。其余的样本均为表现完全的非逾期样本,标记为 0。这样我们获得的正负样本比例大约为 6:4,是一个比较适合用于预测模型的分布。筛选出这些样本后,我们提取对应小微

企业的基本信息和经营流水信息。清洗之后获得的数据集样本本总共有 129880 条。我们将数据集按照 60%, 20% 和 20% 的比例划分为训练集、验证集和测试集。通过训练集训练模型, 再利用验证集不断优化参数, 最后在测试集上验证模型的最终预测效果。

模型中输入的特征主要包括小微企业的基本信息、历史借贷表现、交易流水和交叉特征这 4 大部分。

(1) 基本信息: 企业法人性别、所属一级行业、二级行业、城市、实名验证状态和银行卡验证状态等。

(2) 交叉特征: 根据基本信息进行组合形成交叉特征, 例如城市和行业组合、法人性别和实名状态的组合等。

(3) 历史借贷表现: 企业历史借款次数、历史平均逾期天数和历史逾期次数等。历史借贷表现反映了企业过去的信用, 对预测当前贷款的逾期可能性有一定的影响。

(4) 交易流水: 企业的日常交易流水明细, 按照金额和笔数分别聚合过去一段时间内交易总金额、交易总笔数、笔均/日均交易金额、笔均/日均交易金额方差和交易笔数方差等。交易流水体现了企业经营效益的好坏, 是财务状况的“晴雨表”, 可以折射出企业未来一段时间内对风险的抵御能力。

我们将基本信息、交叉特征和历史借贷表现输入到宽度模型中, 将交易流水输入到深度模型中进行深度的特征提取。

## 4.2 实验设置

我们在宽度模型和深度模型部分分别使用了引入交叉特征的逻辑回归和三层全连接网络(Wide & Deep+ cross\_feature)。作为实验对比, 我们还实现了另外 5 个基准模型, 包括逻辑回归(LogisticRegression)、三层全连接网络(DNN)、不含交叉特征的宽度和深度模型、逻辑回归+交叉特征(LogisticRegression+cross\_feature), 以及三层全连接网络+交叉特征(DNN+cross\_feature)。

### 4.2.1 超参数设置

我们在验证集上选取了取得最优表现的超参数设置, 用于报告在测试集上的实验结果。具体设置如表 1 所列。

表 1 超参数设置

Table 1 Hyper parameter settings

参数	说明	最优值
batch_size	批样本大小	256
learning_rate	学习率	0.0001
loss	损失函数	binary_crossentropy
optimizer	优化器	Adam
activation	激活函数	ReLU

### 4.2.2 评价指标

逾期率预测为典型的分类任务, 即区分好客户和坏客户, 因此模型的评价采用精确率(Precision)、召回率(Recall)、F1-score 和 AUC(Area Under the Curve)这 4 个指标。其中, F1-score 是精确率与召回率的调和平均值, 起到兼顾两者的作用; AUC 是曲线与 TPR(True Positive Rate)和 FPR(False Positive Rate)坐标轴围成的面积。所有指标均为越大越好。

## 4.3 实验主要结果

表 2 列出了本文的宽度和深度模型与基准模型对比的主

要实验结果。所有深度模型的超参数都基于使得该模型在验证集上取得最优表现来选择。由实验结果可知, 不包含交叉特征的 DNN 模型的预测能力强于逻辑回归模型, 两者结合后的宽度和深度模型能够进一步提高预测效果。当加入交叉特征后, 逻辑回归模型的预测表现有所下降, 这可能与过拟合有关; DNN 的预测表现有所上升; 本文模型, 即加入了交叉特征的宽度和深度模型, 在所有 4 个指标上都取得了比基准模型更好的预测效果。

表 2 实验结果

Table 2 Results of experiments

Model	AUC	Precision	Recall	F1-score
LogisticRegression	0.6509	0.6526	0.6849	0.6203
DNN	0.6529	0.6561	0.6871	0.6337
Wide & Deep	0.6616	0.6679	0.6933	0.6377
LogisticRegression+ cross_feature	0.6508	0.6507	0.6841	0.6196
DNN+cross_feature	0.6607	0.6638	0.6911	0.6495
Wide & Deep+cross_feature	0.6690	0.6690	0.6950	0.6530

## 4.4 敏感度分析

本节调整部分超参数设置来评估不同参数值对模型的影响。我们选取 epoch、batch\_size 和学习率(learning rate, lr)这 3 个模型中最重要的超参数, 逐渐改变它们的取值, 并给出 AUC 和 F1-score 指标的变化情况, 结果如图 2 所示。

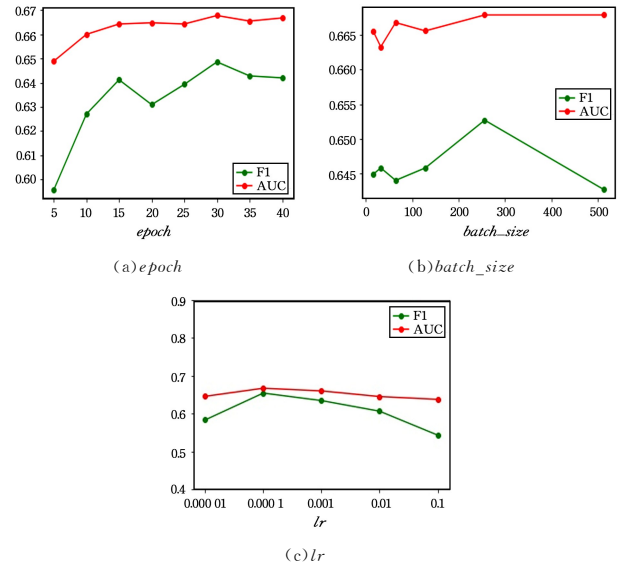


图 2 AUC 和 F1 随超参数的变化曲线

Fig. 2 Curve of AUC and F1 with changing of hyper parameters

如图 2(a) 所示, 随着 epoch 数量的增加, AUC 和 F1-score 在 epoch 达到 30~35 时收敛并逐渐趋于平稳, 随后两个指标略有下降, 这可能预示有过拟合的发生。该结果表明本文模型可以快速收敛并达到最佳效果。如图 2(b) 所示, batch\_size 取值为 16, 32, 64, 128, 256 和 512。当 batch\_size 取值较小时, 两个指标有所波动, 但随后模型效果趋于稳定, 这表明本文模型并不需要设置太大的 batch\_size, 这可以降低训练时对硬件的需求。最后, 如图 2(c) 所示, 学习率 lr 的取值为 0.00001, 0.0001, 0.001, 0.01 和 0.1。当 lr 为 0.0001 时, AUC 和 F1-score 值达到最大, 之后随着 lr 的逐渐增大, 模型效果逐渐下降, 这表明本文模型能够接受一个相对较小

的学习率,以此逐步逼近模型的最优点。

**结束语** 本文提出了基于宽度和深度模型架构的金融信贷风险模型,用于预测小微企业的贷款逾期概率。模型的宽度部分采用了逻辑回归,深度部分采用了三层全连接网络,两个部分首先分别学习结构化和非结构化的特征,然后由宽度部分的逻辑回归层融合两部分特征,最后输出预测结果。两部分模型的参数可以统一训练,这提升了模型的训练效率。实验结果表明,本文提出的宽度和深度模型的逾期预测表现优于其他 5 个基准模型。

未来我们将进一步优化模型的细节,比如在宽度部分使用基于树状结构的模型,在深度部分使用循环神经网络结构直接从原始流水数据中学习特征,并结合 Attention 等机制提升预测效果。在融合两部分模型时,我们也将寻找其他方式,如门结构等,来优化融合的效果。

### 参 考 文 献

- [1] FU K, CHENG D W, TU Y, et al. Credit Card Fraud Detection Using Convolutional Neural Networks[C] // International Conference on Neural Information Processing. Springer, Cham, 2016:483-490.
- [2] CHEN Z Y. Zhulianbihe: Towards Network Credit Score Card Model based on Machine Learning [J]. Wuhan Finance, 2020 (3):42-50.
- [3] PU Z. Towards Green Credit Risk Assessment Model of Listed Companies based on RF and Ensembling SVM [D]. Shanghai: Shanghai Normal University, 2019.
- [4] REN S P, PENG Y N. Default Risk Assessment of Consumer Credit Based on Soft Voting Fusion Model [J]. Financial Theory and Practice, 2020(4):77-83.
- [5] CHENG H T, KOC L, HARMSSEN J, et al. Wide & Deep learning for recommender systems[C] // Deep Learning for Recommender Systems. 2016:7-10.
- [6] YAO Z. Score Functions for Decision Tree Models [J]. Journal of Management, 2005(S2):166-168.
- [7] WEI L, SHUAI D, HAO W, et al. Heterogeneous ensemble learning with feature engineering for default prediction in peer-to-peer lending in China [J]. World Wide Web, 2020, 23(1): 23-45.
- [8] JEROME H, FRIEDMAN N. Greedy Function Approximation: A Gradient Boosting Machine[J]. The Annals of Statistics, 2001, 29(5):1189-1232.
- [9] CHEN T, GUESTRIN C. XGBoost: A Scalable Tree Boosting System[C] // Proceedings of the 22nd Sigkdd International Conference on Knowledge Discovery and Data Mining. 2016:785-794.
- [10] LONG Z D. Towards Credit Risk Assessment of Commercial Banks based on BP Neural Network [D]. Hubei: Hubei University of Technology, 2018.
- [11] KVAMME H, SELLEREITE N, AAS K, et al. Predicting Mortgage Default using Convolutional Neural Networks[J]. Expert Systems with Applications, 2018, 102:207-217.
- [12] WANG C, HAN D, LIU Q, et al. A Deep Learning Approach for Credit Scoring of Peer-to-peer Lending using Attention Mechanism LSTM[J]. IEEE Access, 2018(99):1-1.
- [13] ZHENG Z, YANG Y, NIU X, et al. Wide and Deep Convolutional Neural Networks for Electricity-theft Detection to Secure Smart Grids[J]. IEEE Transactions on Industrial Informatics, 2017, 14(4):1606-1615.
- [14] NIU M, CAI J. A Label Informative Wide & Deep Classifier for Patents and Papers[C] // In Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). 2019:3429-3434.
- [15] NGUYEN B P, PHAM H N, TRAN H, et al. Predicting the Onset of Type 2 Diabetes using Wide and Deep Learning with Electronic Health Records[J]. Computer Methods and Programs in Biomedicine, 2019, 182:9.
- [16] BASTANI K, ASGARI E, NAMAVARI H. Wide and deep learning for peer-to-peer lending[J]. Expert Systems With Applications, 2019, 134:209-224.



**NING Ting**, born in 1996, postgraduate. Her main research interests include machine learning and so on.



**LU Xue-song**, born in 1985, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include FinTech, computational pedagogy and natural language processing.