

DOI:10.19651/j.cnki.emt.2210082

Adam 优化的 BP 神经网络地铁空调环境模式检测 *

董正琪¹ 姜杰¹ 赵雪成^{1,2} 杨增汪^{1,2}

(1. 江苏师范大学物理与电子工程学院 徐州 221116; 2. 徐州市永康电子科技有限公司 徐州 221004)

摘要: 针对目前地铁空调系统环境模式的检测判定, 依旧存在效率低下智能化程度不高的问题, 设计了 Adam 优化的 BP 神经网络地铁空调环境模式检测模型。选取 3 个关键变量: 烟雾浓度、二氧化碳浓度、温度作为环境模式识别的特征条件, 采用 Adam 优化算法对传统 BP 神经网络模型的梯度下降进行优化, 采用一阶矩估计和二阶矩估计动态调整每个参数的学习率, 加快模型学习, 提高网络识别精度, 并在收敛时减小震荡。实验结果表明, 优化后的 BP 神经网络地铁环境模式检测模型收敛速度提高了 98.88%, 预测错误平均个数减少了 45.6%, 且收敛过程中震荡大大减小。同时相比于其他机器学习多分类模型, 优化后的 BP 神经网络模型准确率为 99.88%, 检测运行时间为 12 ms, 整体性能更优。

关键词: Adam; BP 神经网络; 优化算法; 地铁空调; 模式检测

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.4

Adam optimized BP neural network for subway air conditioning environment mode detection

Dong Zhengqi¹ Jiang Jie¹ Zhao Xuecheng^{1,2} Yang Zengwang^{1,2}

(1. School of Physics and Electronic Engineering, Jiangsu Normal University, Xuzhou 221116, China;

2. Xuzhou Yongkang Electronic Technology Co., Ltd., Xuzhou 221004, China)

Abstract: In view of the current detection and judgment of the environmental mode of subway air conditioning system, there is still the problem of low efficiency and low intelligence degree. BP neural network optimized by Adam is designed to detect the environmental mode of subway air conditioning system. Choose three key variables: smoke concentration, carbon dioxide concentration, temperature, as a condition of environment characteristics of pattern recognition, Adam algorithm are used to optimize the gradient descent of the traditional BP neural network model, first-order moment estimation and second-order moment estimation are used to dynamically adjust the learning rate of each parameter, to speed up the model learning, improve the identification accuracy of the network, and reduce the oscillation during convergence. The experimental results show that the convergence speed of the optimized BP neural network subway environmental mode detection model is improved by 98.88%, the average number of prediction errors is reduced by 45.6%, and the oscillation is greatly reduced in the convergence process. At the same time, compared with other machine learning multi-classification models, the accuracy of the optimized BP neural network model is 99.88%, the detection running time is 12 ms, and the overall performance is better.

Keywords: adam; BP neural network; optimization algorithm; subway air conditioning; pattern detection

0 引言

随着城市的经济及规模的发展, 地铁成为城市交通的重要组成部分之一。由于地铁建设在地下, 站内人流量密集等原因, 因此地铁站内公共区的空调系统在保障通风、制

冷、防火、排烟等方面起到十分重要的作用^[1-2]。目前地铁站内公共区空调系统中的风机、风阀、组合空调柜、冷水机组间的运行均采用环境模式下的组合联动控制, 空调系统工作在不同的环境模式(待机模式、制冷模式、通风模式、通风与制冷模式、排烟模式、火灾模式)下, 不同的环境模式对

收稿日期: 2022-05-23

*基金项目: 国家自然科学基金(61975070)、徐州市重点研发计划项目(KC21087)、江苏师范大学研究生科研与实践创新计划项目(2021XKT1247)资助

应空调系统不同的组合工况^[3-5]。但空调环境模式的检测切换需要车站根据运营环境做出判断参与环境模式的选择,然后进行就地或者远程控制,因此,存在地铁环境模式检测控制不智能、效率低、不及时、以及能源浪费等问题。如何根据车站现场采集的多种环境数据,自动进行环境模式识别,并提高准确度,是需要解决的问题。

神经网络以其强大的自学习和非线性拟合能力以及端到端无需多阶段流水线处理数据的特性被广泛应用环境参数预测研究中。申浩洋等^[6]研究了人工神经网络可用于预测环境空气二氧化硫浓度的变化;蒲国林等^[7]研究了将人工蜂群算法与 BP 神经网络结合对环境空气质量进行预测,提高了空气质量的预测精度;曲洪权等^[8]研究了自回归 LSTM 神经网络模型可以对地铁环境参数可进行有效预测;李景富等^[9]研究了相比较 RBF 神经网络和最小二乘支持向量机模型,BP 神经网络模型对空气质量检测的精度更高;刘一帆^[10]研究了应用 BP 神经网络模型对北京地铁站厅、站台 PM2.5 浓度进行预测,误差均低于 20%,验证 BP 神经网络模型的可行性。

现有研究多利用神经网络对环境参数进行预测,而根据

地铁环境数据对地铁环境模式进行预测判定的研究甚少,本文根据影响地铁公共区空调系统模式运行的主要环境参数,选取 3 个关键变量:烟雾浓度、二氧化碳浓度、温度作为环境模式识别的特征条件,采集站内环境以及实验室模拟环境数据并进行预处理,构建样本数据集,采用深度学习算法搭建 BP 神经网络模型并讨论神经元个数的影响以确立最佳模型,实验对比多种优化算法性能,最后采用带有指数加权平均数和偏差修正的 Adam 优化算法对传统 BP 神经网络模型的梯度下降进行优化,以提高地铁环境模式检测模型收敛速度、预测精度,并减小收敛过程中的模型震荡。

1 地铁公共区空调系统原理

地铁公共区空调系统由空调大系统和空调水系统组成,如图 1 所示,其中空调大系统主要包括风机、风阀及组合空调柜,为车站公共区实现送风、排风和制冷;空调水系统主要包括水泵、冷水机组、集分水器及冷却塔,为空调大系统提供冷源,与空调机组完成热交换过程,从而实现车站公共区温度的调节。空调大系统和空调水系统共同作用,实现地铁公共区环境的调节控制。

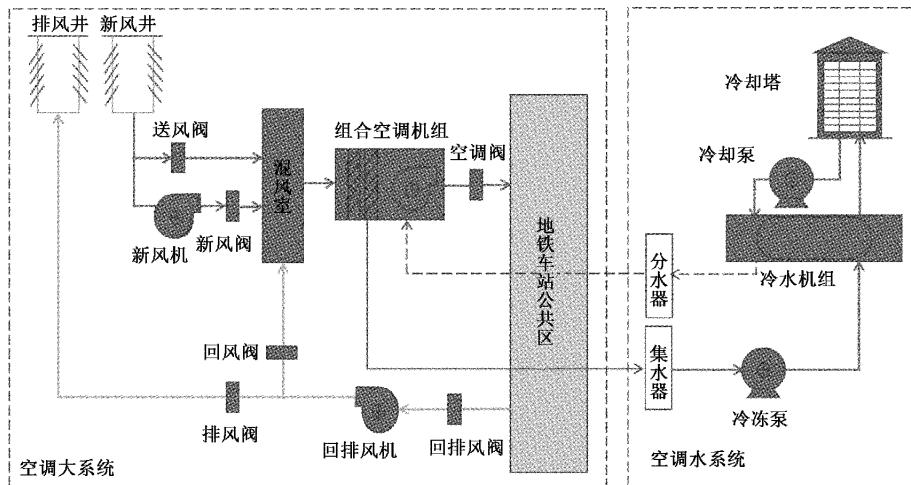


图 1 地铁空调系统原理图

地铁空调系统被设定为特定的运行模式,如表 1 所示,不同的运行模式对应着不同的风机风阀及各子系统间

的组合联动,以实现地铁公共区各环境模式下的特定控制。

表 1 地铁空调系统模式表

运行模式	新风机	组合空调	回排风机	空调阀	回排风机阀	送风阀	排风阀	回风阀	新风阀	空调水系统	消防系统
待机模式	关	关	关	关	关	关	关	关	关	关	关
制冷模式	关	开	开	开	开	关	开	关	开	开	关
通风模式	关	开	开	开	开	关	开	关	开	关	关
通风与制冷模式	开	开	开	开	开	开	关	开	开	开	关
排烟模式	关	关	开	关	开	关	关	关	关	关	关
火灾模式	关	关	开	关	开	关	关	关	关	关	开

2 环境模式检测模型构建

2.1 数据采集和预处理

为获取样本数据训练网络模型,选择徐州地铁人流量较大的彭城广场站作为实验点,根据影响地铁公共区空调系统模式运行的主要环境参数,选取 3 个关键变量:烟雾浓度、二氧化碳浓度、温度作为环境模式识别的特征条件,采用烟雾、二氧化碳、温度传感器分布式采集的站厅、站台环境数据,并添加在实验室模拟获得而在地铁现场无法取得的部分超高超低数据,设置环境模式识别条件并进行样本标签分类,本文分别选取 $0.05 \text{ obs}/\text{m}$ 、 800×10^{-6} 、 35°C 、 50°C 作为条件阈值,如表 2 所示,分别对不同模式下的样本类别进行 $C=6$ 类标记。

表 2 地铁环境模式标签分类

环境模式	烟雾/ (obs/m)	$\text{CO}_2/\times 10^{-6}$	温度/ °C	标签
待机	<0.05	<800	<35	0
制冷	<0.05	<800	≥ 35	1
通风	<0.05	≥ 800	<35	2
通风与制冷	<0.05	≥ 800	≥ 35	3
排烟	≥ 0.05	—	<50	4
火灾	≥ 0.05	—	≥ 50	5

筛选 10 500 组实验样本数据,节选部分数据如表 3 所示。

表 3 环境数据节选

序号	烟雾/(obs/m)	$\text{CO}_2/\times 10^{-6}$	温度/°C	标签
1	0.025	236.0	41.0	1
2	0.020	810.8	46.8	3
3	0.018	521.7	14.2	0
4	0.069	1 452.9	68.3	5
5	0.065	1 018.2	7.9	4
6	0.003	223.6	25.2	0
7	0.029	1 495.7	41.1	3
8	0.032	839.9	10.9	2
9	0.055	1 277.0	61.0	5
10	0.005	263.9	48.8	1
11	0.018	1 113.0	17.0	2
12	0.049	1 288.8	39.0	3
13	0.017	956.7	21.7	2
14	0.048	121.0	43.6	1
15	0.050	945.2	26.9	4
16	0.053	176.6	52.2	5
17	0.040	394.6	23.9	0
18	0.076	1 274.6	1.6	4
19	0.040	1 118.5	44.0	3
20	0.024	1 407.7	21.2	2

为了消除指标之间的量纲影响,需要进行数据标准化处理,以解决数据指标之间的可比性,可加快神经网络梯度下降的快速收敛和处理速度,提高模型的精准度。本文采用 min-max 标准化对原始数据线性变换,使各传感器检测结果值映射到 $[0, 1]$ 之间如式(1)所示。

$$x_{\text{normal}} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x_{\max} 表示样本数据最大值, x_{\min} 表示样本数据最小值, x_i 表示特征样本的第 i 个数据, x_{normal} 表示归一化后的数据。节选部分归一化后的数据如表 4 所示。

表 4 归一化后数据节选

序号	烟雾/(obs/m)	$\text{CO}_2/\times 10^{-6}$	温度/°C	标签
1	0.242 424 242	0.097 142 857	0.585 121 602	1
2	0.191 919 192	0.507 714 286	0.668 097 282	3
3	0.171 717 172	0.301 214 286	0.201 716 738	0
4	0.686 868 687	0.966 357 143	0.975 679 542	5
5	0.646 464 646	0.655 857 143	0.111 587 983	4
6	0.020 202 02	0.088 285 714	0.359 084 406	0
7	0.282 828 283	0.996 928 571	0.586 552 217	3
8	0.313 131 313	0.528 5	0.154 506 438	2
9	0.545 454 545	0.840 714 286	0.871 244 635	5
10	0.040 404 04	0.117 071 429	0.696 709 585	1
11	0.171 717 172	0.723 571 429	0.241 773 963	2
12	0.484 848 485	0.849 142 857	0.556 509 299	3
13	0.161 616 162	0.611 928 571	0.309 012 876	2
14	0.474 747 475	0.015	0.622 317 597	1
15	0.494 949 495	0.603 714 286	0.383 404 864	4
16	0.525 252 525	0.054 714 286	0.745 350 501	5
17	0.393 939 394	0.210 428 571	0.3404 864 09	0
18	0.757 575 758	0.839	0.021 459 227	4
19	0.393 939 394	0.727 5	0.628 040 057	3
20	0.232 323 232	0.934 071 429	0.301 859 8	2

2.2 BP 神经网络模型

BP 神经网络是一种基于误差反向传播训练的多层前馈神经网络,是一种当前被广泛应用的机器学习算法^[11]。如图 2 所示,BP 神经网络包含输入层、隐藏层、输出层 3 部分,层与层之间通过网络权重相互连接,利用梯度下降算法,通过减少网络实际输出与期望输出间的误差,不断更新网络权重,直到满足误差精度要求^[12]。

BP 神经网络是一个具有 3 层及 3 层以上的前向网络,层数的多少主要在于隐藏层层数的多少,任何闭区间内的连续非线性函数,采用单隐层 BP 神经网络就可完成逼近,一个 3 层的 BP 神经网络即可完成 n 维到 m 维的映射^[13]。因此本文选择 3 层 BP 神经网络进行建模。

$$\mathbf{a}^{[1(i)]} = g(\mathbf{W}^{[1]} \mathbf{X}^{(i)} + \mathbf{b}^{[1]}) \quad (2)$$

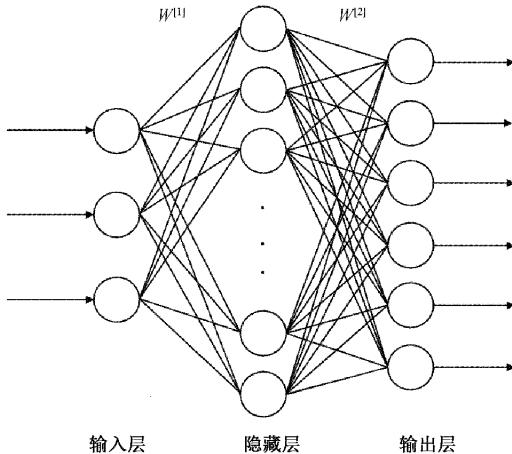


图 2 BP 神经网络结构示意图

$$\hat{y}(i) = \mathbf{a}^{[2](i)} = f(\mathbf{W}^{[2]}\mathbf{a}^{[1](i)} + \mathbf{b}^{[2]}) \quad (3)$$

式中: $\mathbf{X}^{(i)}$ 表示第 i 个输入样本, $\mathbf{W}^{[1]}$ 表示输入层和隐藏层间的网络权重, $\mathbf{b}^{[1]}$ 表示隐层神经元偏置, $\mathbf{a}^{[1](i)}$ 第 i 个样本在隐藏层的输出, $\mathbf{W}^{[2]}$ 表示隐藏层与输出层间的权重, $\mathbf{b}^{[2]}$ 表示输出层神经元偏置, $\hat{y}(i)$ 表示第 i 个样本输出, 以上参数均表示矩阵向量。 $g()$ 表示隐藏层激活函数, $f()$ 表示输出层激活函数, 为使 BP 神经网络逼近任意的非线性函数, 选取 ReLU 作为隐藏层激活函数, 为使神经网络进行多任务分类选取 Softmax 作为输出层激活函数, 公式分别为:

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

$$f(x) = \frac{e^x}{\sum_{c=1}^C e^x} \quad (5)$$

实际输出和期望输出之间的成本函数为:

$$J(\mathbf{W}, \mathbf{b}) = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^6 y_j^{(i)} \log \hat{y}_j^{(i)} \quad (6)$$

进行反向传播和梯度下降算法更新 BP 神经网络的权重 $\mathbf{W}^{[l]}$ 和偏置 $\mathbf{b}^{[l]}$:

$$\mathbf{W}^{[l]} := \mathbf{W}^{[l]} - \alpha \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{W}^{[l]}} \quad (7)$$

$$\mathbf{b}^{[l]} := \mathbf{b}^{[l]} - \alpha \frac{\partial J(\mathbf{W}, \mathbf{b})}{\partial \mathbf{b}^{[l]}} \quad (8)$$

式中: $l = 1, 2, \dots, \alpha$ 表示学习率, 学习率的大小可调。

2.3 模型结构确定

2.2 节已选取 3 层 BP 神经网络, 在此基础上对各层神经元数进一步确定。由于本文选取 3 个关键变量: 烟雾浓度、二氧化碳浓度、温度作为环境模式识别的特征条件, 因此输入层神经元数为 3; 输出层采用 Softmax 对 6 种地铁环境模式进行多任务输出分类, 因此输出层神经元个数为 6。隐藏层神经元节点个数的选取对神经网络的性能影响至关重要, 隐藏层神经元节点数过少, 网络不能建立复杂判断界, 数目过大, 网络复杂训练时间长且网络泛化能力

降低。可根据式(9)^[14]确定隐藏层神经元数目范围:

$$h = \sqrt{m+n} + a \quad (9)$$

式中: h 为隐藏层神经元数目, m 和 n 分别为输入层和输出层神经元数目, 分别取 3 和 6, a 为 1~10 之间的调节常数。由式(9)计算得到隐藏层神经元数目范围为 [4, 13], 采用预处理后的数据集对隐藏层神经元不同数目的 BP 神经网络进行训练, 设置循环次数 epoch=500 次, 观察训练集样本的成本误差变化。隐藏层神经元数与成本误差和测试集准确率关系曲线, 如图 3 所示, 曲线在隐藏层神经元数为 11 时训练集的成本误差最小。因此隐藏层神经元数为 11。

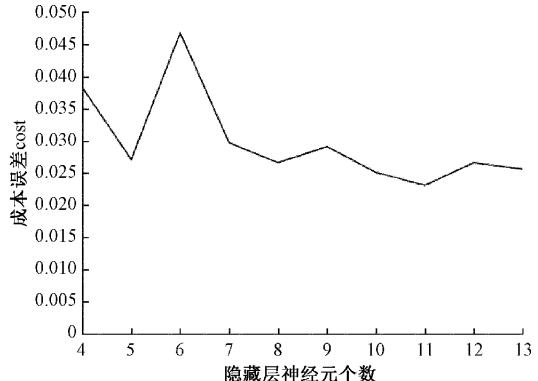


图 3 隐藏层神经元数与训练误差关系曲线

2.4 Adam 算法优化

传统的 BP 神经网络算法式(7)、(8)在进行梯度下降更新权重时, 容易在收敛的过程中出现震荡, 导致收敛速度下降, 且容易陷入局部最小值影响模型精度^[15]。因此对传统 BP 神经网络权重更新算法进行优化, 本文采用 Adam 优化算法^[16-17], 以梯度的一阶矩估计和二阶矩估计动态调整每个参数的学习率, 引入动量和自适应学习率使算法加快模型学习、提高网络识别精度并在收敛时减小震荡。以梯度下降第 t 次迭代为例, 网络权重更新过程为:

$$t = t + 1 \quad (10)$$

$$\mathbf{m}_t = \beta_1 \times \mathbf{m}_{t-1} + (1 - \beta_1) \times d\mathbf{W}_t^{[l]} \quad (11)$$

$$\mathbf{v}_t = \beta_2 \cdot \mathbf{v}_{t-1} + (1 - \beta_2) \cdot (d\mathbf{W}_t^{[l]})^2 \quad (12)$$

式中: \mathbf{m}_t 和 \mathbf{v}_t 分别为一阶动量项和二阶动量项, β_1 和 β_2 为超参数默认值为 0.9 和 0.999, \mathbf{m}_t 和 \mathbf{v}_t 的偏差修正值为 $\hat{\mathbf{m}}_t$ 和 $\hat{\mathbf{v}}_t$ 其计算公式为:

$$\hat{\mathbf{m}}_t = \mathbf{m}_t / (1 - \beta_1^t) \quad (13)$$

$$\hat{\mathbf{v}}_t = \mathbf{v}_t / (1 - \beta_2^t) \quad (14)$$

最后对权重和偏置进行更新, 第 t 次迭代的权重 $\mathbf{W}_t^{[l]}$ 和偏置 $\mathbf{b}_t^{[l]}$ 为:

$$\mathbf{W}_t^{[l]} = \mathbf{W}_{t-1}^{[l]} - \alpha \cdot \hat{\mathbf{m}}_t / (\sqrt{\hat{\mathbf{v}}_t} + \epsilon) \quad (15)$$

$$\mathbf{b}_t^{[l]} = \mathbf{b}_{t-1}^{[l]} - \alpha \cdot \hat{\mathbf{m}}_t / (\sqrt{\hat{\mathbf{v}}_t} + \epsilon) \quad (16)$$

式中: $\mathbf{W}_{t-1}^{[l]}$ 表示第 $t-1$ 次迭代时的模型权重, $\mathbf{b}_{t-1}^{[l]}$ 表示第 $t-1$ 次迭代时的模型偏置, α 为学习率默认为 0.001, ϵ 是一个很小的数, 其作用是避免分母为 0, 本实验取 ϵ 为 10^{-8} 。

3 实验与结果分析

3.1 实验环境

为了测试基于 BP 神经网络地铁环境模式检测模型的性能, 采用 Python3.8 在 PyCharm 集成编译环境中编写程序构建模型, 并采用 Tensorflow2.4.1 作为深度学习框架, 提高神经网络模型的开发和学习效率。

3.2 多种优化算法性能对比

为了选取最优优化算法, 将整个数据集作为训练集, 选取 RMSProp、AdaGrad、AdaDelta、Adam 4 种具有自适应学习功能的优化算法与传统算法 Gradient Descent 在地铁环境模式检测模型训练集上进行训练对比分析, 如图 4 所示, Adam 和 RMSProp 优化算法在地铁环境模式训练集上的成本代价和收敛速度均优于其他算法, 如图 5 所示, Adam 优化算法在成本代价、收敛速度上又稍稍优于 RMSProp 优化算法。

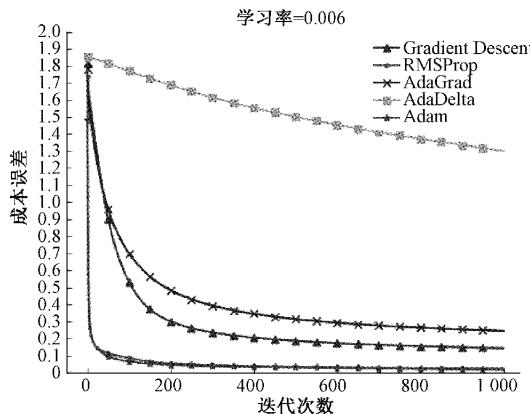


图 4 多种优化算法性能对比

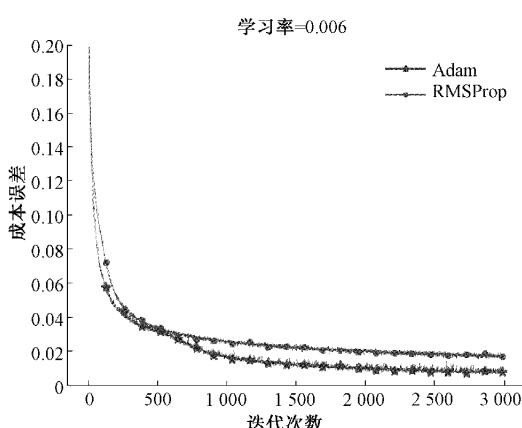


图 5 Adam、RMSProp 优化算法性能对比

3.3 优化前后模型性能对比

用训练集样本数据分别对传统 BP 神经网络模型和 Adam 算法优化后的模型进行训练, 对比达到误差要求所需循环次数。设置目标误差 cost = 0.02, 学习率 $\alpha = 0.006$, minibatch_size = 100, 观察两个模型分别到达误差要求时所需循环次数。

学习步长相同的情况下, 如图 6 所示, 未优化模型需要经过 45 000 次循环训练才能达到目标误差要求, 如图 7 所示, 经过 Adam 算法优化后模型只需要经过 500 次循环训练即可达到要求的目标误差, 收敛速度提高了 90 倍。经 Adam 算法优化后的模型大大提高了模型的收敛速度减少了训练次数。

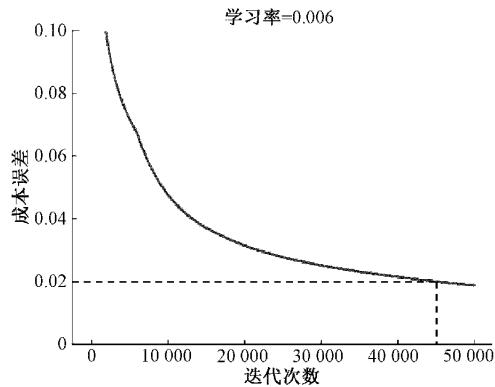


图 6 优化前 BP 神经网络训练结果

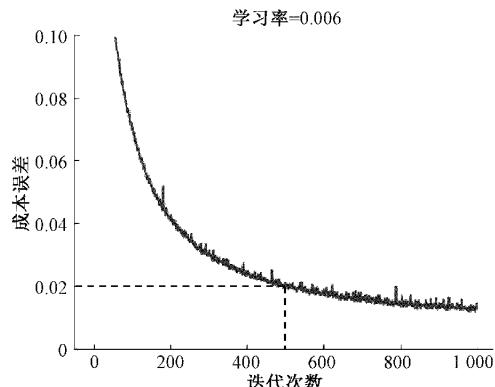


图 7 优化后 BP 神经网络训练结果

可通过增加传统 BP 神经网络学习率步长加快学习, 如图 8 所示, 可以看出增加传统 BP 神经网络的学习率可以加速模型收敛, 在 500 次循环以后两个模型的训练误差逐步减小到 0.02, 但传统模型在收敛的过程中震荡变大。对比分析经 Adam 算法优化后的 BP 神经网络模型不仅提高了地铁环境模式检测模型的收敛速度而且减小了模型震荡。

经过大量训练实验后传统 BP 神经网络模型在训练集的最小误差为 0.0091, 优化后的 BP 神经网络模型在训练集上的最小误差为 0.0028, 由于 Adam 优化算法学习率可自适应动态调节, 因此其收敛效果更好。

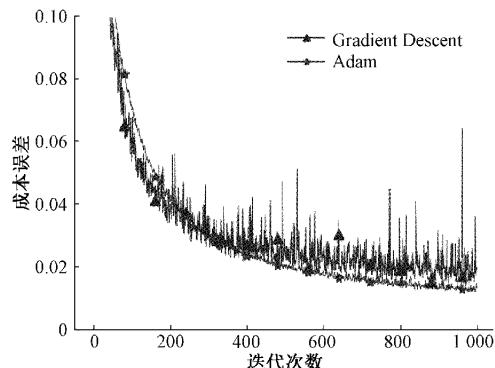


图 8 两种模型震荡对比

3.4 环境模式检测实验结果对比

将采集的数据集划分为 4 组,采用优化前后的两种 BP 神经网络模型分别进行 4 组仿真实验,并设置模型参数 num_epochs = 500、minibatch_size = 100, 进行小批为 100 循环次数 500 轮迭代,每组仿真实验的训练数据和测试数据的数量如表 5 所示。

表 5 设计实验

实验编号	训练数据/个	测试数据/个
1	300	150
2	1 000	500
3	3 000	1 500
4	7 000	3 500

选取预测错误数(M)、准确率(ACC)、MacroF1 宏平

表 6 优化前后模型实验结果对比

实验编号	优化前 BP 神经网络			优化后 BP 神经网络		
	M/个	ACC/%	MacroF1/%	M/个	ACC/%	MacroF1/%
1	11	92.67	92.13	8	94.67	93.93
2	19	96.20	95.12	10	98.00	97.45
3	14	99.06	98.82	9	99.40	99.33
4	13	99.63	99.60	4	99.88	99.83

3.5 多分类模型性能对比

选取实验编号 4 的数据集作为实验数据,通过实验对传统的机器学习多分类模型与优化前(BP)和优化后的(AD-BP)BP 神经网络模型进行多方面对比分析。如表 7 所示,为实验结果数据,其中朴素贝叶斯(naive Bayes)模型和逻辑回归(logistic regression)模型的运行检测时间较小分别为 1.2 和 4.9 ms,但其准确率较低分别为 96.91% 和 94.57%;随机森林(random forest)模型的准确率最高为 99.94%,稳定性最好,但运行检测时间较长 35.9 ms。而优化后的 AD-BP 神经网络模型准确率较高为 99.88% 仅次于随机森林模型的 99.94%,且运行测试时间较小为 12 ms,综合了精度高、运行时间短的优点,总体上性能更优,而随着训练集数据的增加 AD-BP 神经网络模型的精

度会进一步提高,且模型的运行时间不变,对处理大数据集效果更佳。

$$ACC = (1 - \frac{M_{test}}{X_{test}}) \times 100\% \quad (17)$$

其中, M_{test} 为预测错误数, X_{test} 为测试样本总数。

MacroF1 宏平均是用于衡量多分类模型精度、稳定性的一种指标,同时兼顾了分类模型的精确率和召回率,取值范围在(0,1)之间^[18]。将 n 多分类评价拆成 n 个二分类评价,分别计算每个二分类的 F1 值, n 个 F1 的平均值即为 MacroF1 宏平均,其公式表示为:

$$F1^{(i)} = 2 \times \frac{P^{(i)} \times R^{(i)}}{P^{(i)} + R^{(i)}} \quad (18)$$

$$MacroF1 = \frac{1}{n} \sum_{i=1}^n 2 \times \frac{P^{(i)} \times R^{(i)}}{P^{(i)} + R^{(i)}} \quad (19)$$

式中: $P^{(i)}$ 、 $R^{(i)}$ 分别为第 i 类的精确率和召回率。

实验计算优化前后的两种模型的预测错误数(M)、准确率(ACC)、MacroF1 宏平均值并进行对比。如表 6 所示,随着训练集和测试集数量的增加,两种模型的准确率均在提高,传统 BP 神经网络的平均测试准确率为 96.89%,优化后的 BP 神经网络模型的平均准确率为 97.99%,模型准确率提高了 1.1%;优化后 BP 神经网络的 MacroF1 平均值从 96.42% 增加至 97.63%,模型精度和稳定性有所改善;优化后模型预测平均错误个数较优化前减少了 45.61%。同一实验编号优化后的 BP 神经网络模型在预测错误个数、准确率和稳定性都优于传统 BP 神经网络模型。

表 7 多分类模型实验性能对比

模型	M/个	ACC/%	MacroF1/%	T/ms
Logistic Regression	190	94.57	94.57	4.9
Naive Bayes	108	96.91	96.89	1.2
KNN	104	97.02	96.77	72.6
SVM	64	98.17	98.01	65
BP	13	99.63	99.6	12
AD-BP	4	99.88	99.83	12
Random Forest	2	99.94	99.87	35.9

4 结 论

为解决地铁空调系统环境模式检测效率低智能化程度不高的问题,本文设计了基于 BP 神经网络的空调环境模式检测模型。由于传统 BP 神经网络算法在进行地铁环境模式识别时存在收敛速度慢,精度不高,收敛过程震荡等缺点,进而在实验对比分析了多种具有自适应学习率调节算法后,提出基于 Adam 算法进行优化改进,将优化前后的两种模型的性能从多个方面进行实验对比分析。实验结果表明,Adam 优化后的 BP 神经网络模型的训练速度提高了 98.88%,准确率提高了 1.1%,预测错误平均个数减少了 45.6%,且收敛过程中的震荡较优化前也大大减小。与多个传统机器学习多分类模型对比分析,经实验测试本模型的准确率可达 99.88%,检测运行时间为 12 ms,综合比较优化后的地铁环境模式检测模型的整体性能更好。

本文仍存在一定不足,需进一步增加训练集数量,随着训练集数据的增加,在模型检测运行时间不变情况下,优化后的地铁环境检测模型的精度会进一步增加。本研究对地铁空调环境模式智能检测系统的开发有着重要意义和参考价值。

参考文献

- [1] 张涛,刘晓华,关博文. 地铁车站通风空调系统设计、运行现状及研究展望[J]. 暖通空调,2018,48(3):8-14.
- [2] KIM M J, BRAATZ R D, KIM J T, et al. Indoor air quality control for improving passenger health in subway platforms using an outdoor air quality dependent ventilation system [J]. Building and Environment, 2015,92(10):407-417.
- [3] 张金花,檀婧静,李亮,等. 地铁通风空调系统设计优化方法研究[J]. 施工技术,2020,49(S1):676-679.
- [4] 杨昭,余龙清,马锋,等. 地铁通风空调系统的逐时优化节能控制策略[J]. 天津大学学报,2012,45(7):599-603.
- [5] 李峰,郑林涛. 地铁车站空调系统模式及能耗分析[J]. 城市轨道交通研究,2017,20(1):40-43.
- [6] 申浩洋,韦安磊,王小文,等. BP 人工神经网络在环境空气 SO_2 质量浓度预测中的应用[J]. 环境工程,2014,32(6):117-121.
- [7] 蒲国林,刘笃晋. 基于改进神经网络的环境空气质量预测[J]. 计算机技术与发展,2018,28(9):181-184.
- [8] 曲洪权,李博,庞丽萍,等. 基于自回归 LSTM 神经网络的地铁车站环境参数概率预测[J]. 制冷与空调,2020,34(6):676-681.
- [9] 李景富,崔英杰. 基于多传感器融合的空气质量检测[J]. 现代电子技术,2020,43(19):171-174.
- [10] 刘一帆. 基于 BP 神经网络的北京地铁 PM2.5 预测研究[D]. 廊坊:华北科技学院,2020.
- [11] 马健,滕召胜,邱伟,等. 基于 IGA-BP 神经网络的智能电能计量设备退化趋势研究[J]. 仪器仪表学报,2021,42(11):123-131.
- [12] 余安安,吴雪菲,李栋,等. 基于神经网络的毫米波测云雷达云状识别研究[J]. 国外电子测量技术,2021,40(4):82-86.
- [13] JIA W, ZHAO D, SHEN T, et al. An optimized classification algorithm by BP neural network based on PLS and HCA[J]. Applied Intelligence, 2015, 43(1): 1-16.
- [14] 崔少华,李素文,汪徐德. BP 神经网络和 SVD 算法联合的地震数据去噪方法[J]. 电子测量与仪器学报,2020,34(2):12-19.
- [15] LI J, SHENG V S, SHU Z, et al. Learning from the crowd with neural network[C]. IEEE, International Conference on Machine Learning and Applications, IEEE, 2015.
- [16] KINGMA DIEDERIK P, ADAM J B. A method for stochastic optimization [J]. ArXiv Preprint, 2014, ArXiv:1412.6980.
- [17] 张怡文,袁宏武,孙鑫,等. 基于 Adam 注意力机制的 $\text{PM}_{2.5}$ 浓度预测方法[J]. 大气与环境光学学报,2021,16(2):117-126.
- [18] WU X Z, ZHOU Z H. A unified view of multi-label performance measures[C]. Proceedings of the 2017 34th International Conference on Machine Learning, Cambridge: PMLR, 2017: 3780-3788.

作者简介

董正琪,硕士研究生,主要研究方向为人工智能、计算机视觉技术。
E-mail:1635275902@qq.com

杨增汪(通信作者),副教授,硕士研究生导师,主要研究方向为嵌入式系统、人工智能。
E-mail:yangzw72@126.com