

文章编号: 2095-2163(2020)11-0101-05

中图分类号: TP18

文献标志码: A

基于 Adam 优化神经网络的电梯群控算法

雷 剑

(南华大学 电气工程学院, 湖南 衡阳 421000)

摘要: 针对传统 BP 神经网络搭建的电梯群控算法中出现的易于陷入局部极值、收敛速度慢、预测值与实际值偏差较大等问题, 本文通过分析研究, 在使用 BP 神经网络, 拟合某台电梯对某一楼层呼梯信号响应满意度函数的基础上, 应用 Adam 算法优化神经网络的权值和阈值, 使用 Dropout 缓解过拟合现象, 减小误差, 提高网络预测精度。仿真结果表明, 与传统的优化算法相比, 此算法收敛速度更快, 模型预测准确率更高, 减少了候梯时间, 提高了电梯运载效率。

关键词: Adam 算法; BP 神经网络; 电梯群控算法; 多目标优化

Elevator group control algorithm based on Adam optimized neural network

LEI Jian

(School of Electrical Engineering, University of South China, Huanan Hengyang 421000, China)

[Abstract] For the elevator group control algorithm built by the traditional BP neural network, it is easy to fall into the local minimum, the convergence speed is slow, and the deviation between the predicted value and the actual value is large. Through analysis and research, on the basis of using the BP neural network to fit the satisfaction function expression of a certain elevator's response to a certain floor call signal, the Adam algorithm is used to optimize the neural network weights and thresholds, and Dropout is used to alleviate The phenomenon of fitting reduces errors. The simulation results show that compared with the traditional optimization algorithm, the convergence speed is faster, the model prediction accuracy is higher, the waiting time and the long waiting time are reduced, and the elevator carrying efficiency is improved. The results show that the average relative error is less than 2% .

[Key words] Adam algorithm BP neural network elevator group control algorithm Multi-objective optimization

0 引言

电梯群控系统, 通常是指在高层建筑内集中收集呼梯信号并管理调度 3 台以上电梯的运行控制系统。目前电梯群控系统中, 大多采用并联或者全集选的调度方法。这些方法依托于候梯时间等单目标优化方法, 不能很好的同时解决候梯时间和运行效率的问题。20 世纪 90 年代, 基于 BP 神经网络的电梯群控技术已经成熟运用到实际应用中, 取得了很好的成绩^[1]。但传统 BP 神经网络还存在一些缺陷, 如收敛速度不理想^[2], 难以脱离局部极值。由于 BP 神经网络本身的结构和特性, 网络模型效果最优的隐含层神经元个数无法确定^[3], 学习率以及激活函数的选择都会对神经网络的学习精度产生较大的影响。

电梯群控系统是一个存在多目的性、不确定性、非线性以及扰动性的复杂系统, 同时包含着若干部电梯以及不同楼层之间的呼梯信号的庞大数据, 这些都是传统电梯群控算法难以高效率、低能耗解决的问题。Adam (adaptive moment estimation, 自适应

矩估计) 算法不仅适合解决含大规模数据和参数的优化问题, 而且收敛速度更快、效果更好, 能够更好的实现电梯调度分配, 提高系统的整体性能。

1 电梯群控系统模型

1.1 多目标优化评价函数表达式建立

函数表达式选用了一种综合评价函数, 作为某一楼层对某一台电梯呼梯的依据。通过满意度评价函数来弥补原本单目标优化电梯群控的不足。评价函数满意度的大小表示了电梯的呼梯次序。详细计算方法参看文献[4]。

公式(1)为第 i 部电梯与第 j 层呼梯信号之间的满意度评价函数^[5]。

$$F(i, j) = \omega_1 fw(i, j) + \omega_2 fr(i, j) + \omega_3 fe(i, j), \quad (1)$$

式中, ω_1 、 ω_2 、 ω_3 为评价函数中不同交通模式下的权重, 权重之和为 1。评价函数 $fw(i, j)$ 为乘客平均候梯时间表表达式; $fr(i, j)$ 为长时间候梯率表达式; $fe(i, j)$ 为能源消耗表达式。

作者简介: 雷 剑(1996-), 男, 硕士研究生, 主要研究方向: 智能控制算法的研究和应用。

收稿日期: 2020-09-07

1.2 电梯群控系统模型的搭建

1.2.1 BP神经网络的模型搭建

模型中神经网络分为3层结构,其中当前电梯内乘客数量、电梯到呼梯楼层的相对距离和电梯响应呼梯信号前需要停靠的楼层数,作为输入层的3个输入;隐含层是网络连接的核心,应根据具体情况建立相应模型;输出层只有一个神经元,作为某台电梯对当前呼梯信号满意度的输出。

网络训练中权值和阈值的修正过程如下:

- (1) 初始化网络的权值和阈值。
- (2) 向网络提供可学习的样本数据。

$$x_i^k = g[Z(f(\omega \cdot S + \theta_0)) + z_0]. \quad (2)$$

公式(2)表示,对于神经网络中第k层的第i个神经元的输出 x_i^k 。 S 为真实数据, $f(x)$ 、 $g(x)$ 分别为各个神经元以及输出层的激活函数。

(3) 计算上一层神经元的输出,作为下一层的输入:

$$u_i^k = \sum_{j=1}^n \omega_{ij} x_j^{k-1}, \quad (3)$$

$$x_i^k = f(u_i^k). \quad (4)$$

(4) 计算各层的学习误差 d_i^k ,对于输出层有 $k = m$:

$$d_i^k = (z_j^m - y) \cdot z_j^m \cdot (1 - z_j^m), \quad (5)$$

$$d_j^k = d_j^{k+1} \cdot \omega_{ij}^{k+1}. \quad (6)$$

得到误差后,在网络中进行反向传播。根据目标函数值的大小,以此对BP网络进行训练。

(5) 修正权值和阈值:

$$\omega_{ij}^k(t+1) = \omega_{ij}^k(t) - \eta \cdot d_{ij}^k \cdot z_{ij}^{k-1}. \quad (7)$$

为了使模型尽可能得到好的收敛效果,在网络训练修正参数的过程中,增加学习率 η ,从而调节网络模型训练速率:

$$\omega_{ij}^k(t+1) = \omega_{ij}^k(t) - \eta \cdot d_{ij}^k \cdot z_{ij}^{k-1}(t+1) + \alpha \Delta \omega_{ij}^k(t), \quad (8)$$

$$\Delta \omega_{ij}^k(t) = \omega_{ij}^k(t) - \omega_{ij}^k(t-1). \quad (9)$$

每组样本数据的学习得到最新修正的权系数后,判断预测值与实际值之间的相对误差是否满足预设目标。如满足则训练结束,否则返回步骤(3)。

1.2.2 Dropout

训练学习中,如果参数多,而训练样本少时,模型很容易发生过拟合的现象。Dropout^[6]可有效缓解过拟合的发生,在一定程度上达到正则化的效果。

Dropout是指在前向传播过程中,为了增强模型的泛化性,让某个神经元以特定的概率停止工作,进而缓解过拟合的发生。工作流程如图1所示。

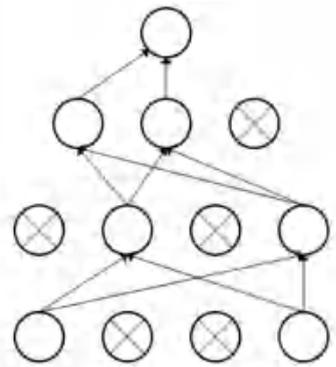


图1 引入Dropout的神经网络模型

Fig. 1 Introducing the neural network model of Dropout

具体学习过程如下:

(1) 训练前隐含层的所有神经元,以一定概率停止工作(暂时),不参与前向传播。输入输出神经元保持不变。

(2) 样本数据在改变后的网络中前向传播,得到的误差再通过修改的网络进行反向传播。每次迭代后,在原来的神经网络上按Adam算法更新权值和阈值。

(3) 重复执行以上两个步骤,直至完成迭代训练。

Dropout在随机选择神经元停止工作时,网络结构也会发生变化,而不同的神经网络模型也会产生不同的过拟合。其中互为“反向”拟合相互抵消,从而在整体上减少过拟合的现象,以此提升预测准确性。对三层BP神经网络模型来说,Dropout的超参数概率 p 设为0.2-0.4比较合适,不会因此让损失函数的值过大,可有效减少测试集的误差。

1.2.3 电梯群控算法

Adam算法是一种基于低阶自适应的随机目标函数一阶梯度优化算法^[7]。由于该算法中包含了AdaGrad算法和动量法的优点,以此训练得到模型的实际应用效果,在大多数场景下都要更优。其迭代过程如下:

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

$$g_t = \tilde{\nabla}_{\theta} f_t(\theta_{t-1}), \quad (11)$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t, \quad (12)$$

$$v_t = \beta_2 m_{t-1} + (1 - \beta_2) g_t^2, \quad (13)$$

$$\theta_t = \theta_{t-1} - \alpha \frac{m_t}{(1 - \beta_1') \left(\sqrt{\frac{v_t}{1 - \beta_2'}} + \varepsilon \right)}. \quad (14)$$

上述推导公式中, t 为迭代数; α 为学习率;默认设定为0.001; g_t 为计算梯度;公式(11)、(12)中, m_t 、 v_t 分别为偏一阶矩向量和二阶矩向量。参数向

量初始化: $m_0 = 0, v_0 = 0; \beta_1, \beta_2$ 分别为对应矩估计的指数衰减率, 通常 $\beta_1 = 0.9, \beta_2 = 0.999; \epsilon$ 为一个非常小的正数, 通常取 $\epsilon = 10^{-8}$, 防止运算过程中出现分母为 0 的现象。公式 (14) 中, θ 即为待求的网络参数。

在确定了参数和目标函数之后, 网络训练中循环迭代地更新各个参数, 直到目标函数满足设定精度或达到预先设定次数为止。Adam 算法不仅易实现, 并具有很高的计算效率, 适合解决带有大规模数据和多个目标优化的问题。因此, 本文选用 Adam 算法, 作为基于神经网络的电梯群控系统的优化算法。

2 模型训练与测试

2.1 训练流程

BP 神经网络容易过早陷入局部极值且收敛速度较慢。因此本课题采用 Adam 替代传统优化算法, 并在网络的前向传播过程中加入 Dropout, 缓解过拟合的发生, 有效增强了神经网络的泛化能力和收敛性。训练流程如图 2 所示。流程步骤如下:

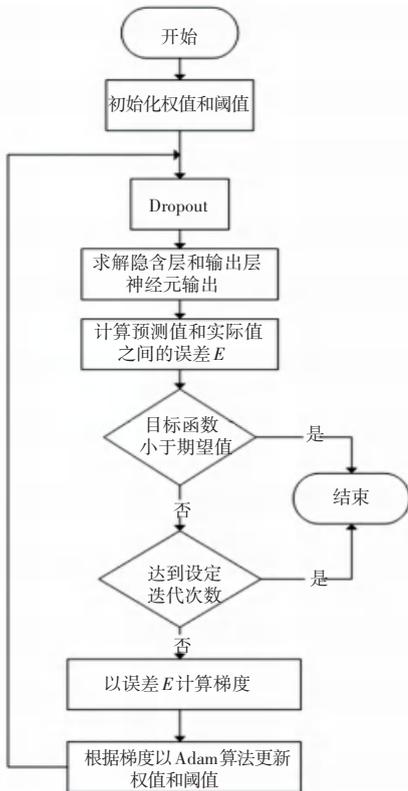


图 2 基于 Adam 算法优化 BP 神经网络训练流程

Fig. 2 Optimization of BP neural network training process based on Adam algorithm

(1) 根据样本数据计算多目标评价函数表达式, 得到满意度函数值, 再按照电梯群控系统要求建

立神经网络模型。

(2) 对网络的权值和阈值进行均匀分布初始化。

(3) 在数据开始训练前, Dropout 以概率 p 随机停止网络模型中神经元的工作。

(4) 以样本数据训练网络, 求解网络预测值和实际值的误差 E , 将误差在网络中反向传播。

(5) 根据误差求出目标函数的梯度, 用 Adam 算法修正网络的权值和阈值, 直到目标函数小于期望值或者达到设定迭代次数, 则退出训练; 否则返回步骤 (3) 继续执行。

2.2 模型参数

模型中, 需对以下 4 个参数进行调优。其主要目的是让目标函数在满足设定精度的基础上, 不断提高预测准确率。

(1) 目标函数。目标函数是网络预测值与实际值的平均相对误差率, 设定精度 $e < 5\%$ 。

$$e = \sum_{i=1}^n \frac{|y_i - y'_i|}{ny'_i}$$

(2) 学习率。网络中用 SGD 以及 Adam 两种算法进行比较。SGD 算法学习率设为 0.01, Adam 算法学习率设为 0.001。

(3) 神经元个数与激活函数的选择。隐含层神经元个数一般采用实验法确定, 为了神经网络能够得到最好的输入输出的映射关系, 同时损失函数和输出误差满足期望要求, 需要通过实验测定一个最佳的隐含层节点数。依据文献 [8] 的经验公式, 可估算神经元个数的范围在 3-12 之间。先设置数量较少的神经元个数进行训练, 然后逐渐增加, 使用同一数据集训练, 最终选取网络误差最小时对应的隐含层节点数 [9], 见表 1。

表 1 神经元个数与激活函数的选择对误差的影响

Tab. 1 The Influence of the Number of Neurons and the Selection %

激活函数 神经元个数	Tanh	Sigmoid	ReLU
3	6.94	5.6	11.08
4	6.23	5.11	12.52
5	6.06	5.53	11.87
6	5.7	4.03	8.25
7	6.19	3.66	8.98
8	6.93	2.42	7.62
9	5.61	2.91	10.34
10	6.33	3.62	10.56
11	7.39	4.01	11.35
12	6.5	5.28	9.58

从表 1 中可以看出,当隐含层神经元个数为 8、激活函数为 Sigmoid 时,平均相对误差最小。

(4)网络初始化。网络中的参数初值采用均匀分布初始化的方法。使用 TensorFlow 提供的 tf.random_uniform 函数,默认取值范围为[0, 1],可以有效减少梯度弥散问题,使得输入信号在网络中传递的更深。

2.3 模型的仿真与测试

在 TensorFlow 框架中用 Spyder 对神经网络进行搭建、训练与仿真。网络模型结构为三输入一个输出,隐含层层数为 1,神经元个数为 8。把经过统计的 300 组电梯样本数据和对应的满意度评价函数随机分成训练集和测试集并进行归一化处理,训练集包括 290 组样本数据,其余 10 组作为网络模型的验证的测试集。

图 3 为基于 BP 神经网络评价函数测试集平均相对误差结果对比。在条件相同的情况下训练 1 000 次,每 25 次取一次结果。结果表明,基于 Adam 算法优化的网络平均相对误差 $e < 2\%$,传统 SGD 方法训练耗时 10.716 S,而 Adam 算法仅耗时 8.634 S,收敛更加迅速。误差结果:随机梯度下降法平均相对误差为 11.96%;Adam 算法平均相对误差为 1.60%。

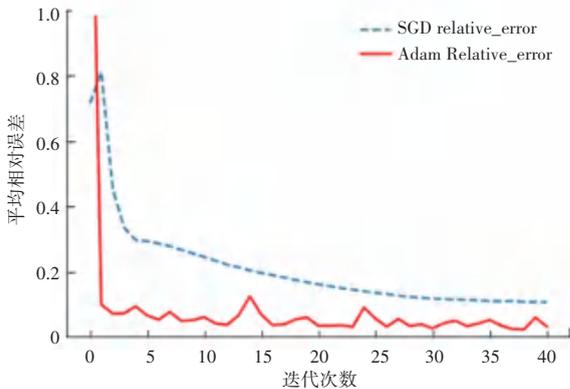


图 3 神经网络拟合评价函数对比两种算法平均相对误差示意图
Fig. 3 Schematic diagram of comparing the average relative error of the two algorithms on the neural network fitting evaluation function

由图 4、图 5 可见,在测试集上预测结果表明:基于 Adam 优化神经网络的算法误差更小,相比较传统 BP 神经网络,真实值和预测值的相对误差减小一个数量级,网络预测精度有明显的提高。

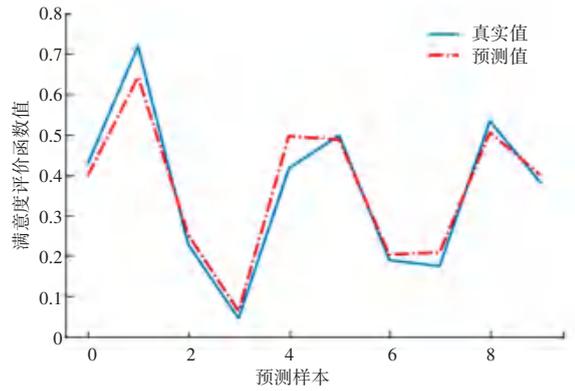


图 4 基于传统 BP 神经网络测试集满意度评价函数结果
Fig. 4 The result of satisfaction evaluation function based on traditional BP neural network test set

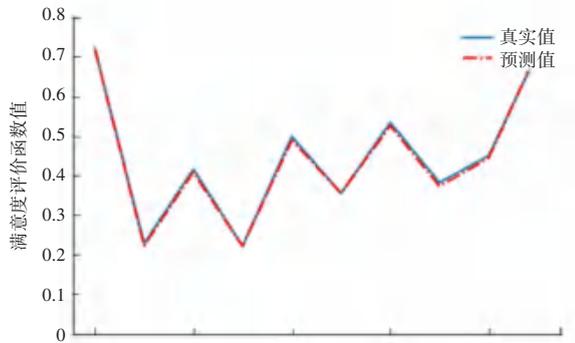


图 5 基于 Adam 优化神经网络测试集满意度评价函数结果
Fig. 5 The result of satisfaction evaluation function based on Adam optimized neural network test set

表 2 中数据为基于 Adam 优化神经网络测试集样本真实值和预测值的详细结果。从表中可见,最大相对误差为 2.50%,最小相对误差为 0.08%。整体测试集平均相对误差为 1.26%,远小于传统 SGD 算法训练后的误差结果。

表 2 测试集在 Adam 优化神经网络模型的测试结果

Tab. 2 Test set results based on Adam optimized neural network model

	真实值	预测值	相对误差 %
1	0.719 8	0.719 257 772	0.08
2	0.227	0.221 934 885	2.23
3	0.416 1	0.407 805 711	1.99
4	0.221 1	0.220 288 694	0.37
5	0.498 6	0.489 072 382	1.91
6	0.354 3	0.355 131 239	0.23
7	0.533 8	0.525 601 983	1.54
8	0.381 8	0.372 261 733	2.50
9	0.45	0.443 854 541	1.37
10	0.713 5	0.716 515 064	0.42

3 结束语

针对 BP 神经网络的电梯群控传统算法的收敛速度慢,且易于陷入局部最小值,导致出现聚集效应、群控系统效率不高等问题的课题研究。首先在前人的基础上介绍了一种基于神经网络的多目标优化模型,在网络模型中将样本数据分别在基于传统随机梯度下降法的 BP 神经网络与基于 Adam 算法的 BP 神经网络下各自学习,通过仿真测试验证效果。从表 1 中的神经元和激活函数的组合搭配中可以看出,神经元个数和激活函数的选择会对网络的预测结果造成一定的影响,根据误差最小值选择为神经元个数为 8,激活函数为 Sigmoid,以此进行网络的学习训练和预测。但训练过程中出现了训练集效果很好,而测试集误差偏大的现象,因此在网络前向传播过程中加入了 Dropout,一定程度上缓解了过拟合现象的发生,提高了预测的准确率。基于表 2 的测试结果可以得出,Adam 算法优化后神经网络模型不仅收敛性更强,训练速度更快,同时更易于挣脱局部极值的束缚,提高了网络输出的准确率。在以多目标优化的基于神经网络的电梯群控系统的基础

(上接第 100 页)

3 结束语

本文提出了一种基于系统聚类的特征选择与支持向量机的组合模型(H-SVM)分类方法,并将实验结果与 SVM 算法进行了比较。在特征选择阶段,使用系统聚类来识别乳腺癌的隐藏模式,将数据集与隐藏模式之间的相似性作为新肿瘤特征数据集,以此判断待测肿瘤数据是否为恶性肿瘤。该算法通过特征提取和选择对原始肿瘤数据集进行降维,在不减少样本数量的前提下,将其重建为更加紧凑的新数据集。实验结果表明,本文提出的算法与仅使用 SVM 算法比较,不仅在精确率上由原来的 95.3% 提高到 97.5%,而且也明显降低了模型的训练时间,由 15.891 3 s 减少到 0.208 8 s。

本文使用 H-SVM 对 WDBC 数据集进行诊断的精确率为 97.5%,说明分类算法还存在优化空间。探索在不增加模型训练时间的前提下,进一步提高分类精确率将作为下一步的研究方向。

参考文献

- [1] BALZER M, BIRK M, DAPP R, et al. 3D ultrasound computer tomography for breast cancer diagnosis [C]//2012 18th IEEE - NPSS Real Time Conference, June 9-15, 2012;1-4.
- [2] 樊重俊, 金阳, 杨云鹏. 基于节点活跃度与疾病交互多重影响因素的传染病模型[J]. 系统管理学报, 2017, 26(5):941-946.

上改善了电梯运载效率,达到了优化目的,提升了整体电梯群控系统的性能。

参考文献

- [1] 郎曼, 李国勇, 徐晨晨. 电梯群控系统的节能调度优化仿真[J]. 计算机仿真, 2017, 34(2):375-379.
- [2] Sirui Zhang, Botao Wang, Xueen Li, et al. Research and Application of Improved Gas Concentration Prediction Model Based on Grey Theory and BP Neural Network in Digital Mine[J]. Procedia CIRP, 2016, 56.:399-408.
- [3] ZHANG Minli, QIAO Shanshan. Research on the Application of Artificial Neural Networks in Tender Offer for Construction Projects[J]. Physics Procedia, 2012, 24:1781-1788.
- [4] 郭方欣. 神经网络在电梯群控技术中的应用[D]. 哈尔滨:哈尔滨工程大学, 2017.
- [5] 罗飞, 赵小翠. 新型电梯群控系统多目标优化调度策略[J]. 自动化与仪表, 2010, 25(9):28-31.
- [6] 程俊华, 曾国辉, 鲁敦科, 等. 基于 Dropout 的改进卷积神经网络模型平均方法[J]. 计算机应用, 2019, 39(6):1601-1606.
- [7] 高玉明, 张仁津. 基于遗传算法和 BP 神经网络的房价预测分析[J]. 计算机工程, 2014, 40(4):187-191.
- [8] 郑绪枝, 雷靖, 夏薇. 基于快速确定隐层神经元数的 BP 神经网络算法[J]. 计算机科学, 2012, 39(S1):432-436.
- [9] WANG Y, ZHOU P, ZHONG W. An optimization strategy based on hybrid algorithm of adam and sgd [C]//MATEC Web of Conferences. EDP Sciences, 2018, 232: 03007.

- [3] PENA-REYES C A, SIPPER M. A fuzzy-genetic approach to breast cancer diagnosis [J]. Artificial Intelligence in Medicine, 1999, 17(2):131-155.
- [4] AKAY M F. Support vector machines combined with feature selection for breast cancer diagnosis [J]. Expert Systems with Applications, 2009, 36(2):3240-3247.
- [5] CHEN Y W, LIN C J. Combining SVMs with various feature selection strategies[R]. Berlin Heidelberg:Springer, 2008.
- [6] PRASAD Y, BISWAS K K, JAIN C K. SVM classifier based feature selection using GA, ACO and PSO for siRNA design [C]//The First International Conference in Swarm Intelligence (ICSI), June 12-15, 2010;307-314.
- [7] 樊重俊等. 大数据分析与应用[M]. 上海:立信会计出版社, 2016.
- [8] JAIN A, ZONGKER D. Feature selection: Evaluation, application, and small sample performance[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(2):153-158.
- [9] ZHENG B, YOON S W, LAM S S. Breast cancer diagnosis based on feature extraction using a hybrid of K-means and support vector machine algorithms[J]. Expert Systems with Applications, 2014, 41(4):1476-1482.
- [10] 郑雅文. 基于特征选择和支持向量机的乳腺癌诊断研究[D]. 太原:太原理工大学, 2019.
- [11] IDICULA-THOMAS S, KULKARNI A J, Kulkarni B D, et al. A support vector machine - based method for predicting the propensity of a protein to be soluble or to form inclusion body on overexpression in Escherichia coli [J]. Bioinformatics, 2006, 22(3):278-284.