

DOI: 10.13382/j.jemi.B2104838

基于 QPSO-DBN 集成学习的城轨列车定位研究*

徐凯 杨锐

(重庆交通大学信息科学与工程学院 重庆 400074)

摘要:高精度的定位是实现列车自动驾驶的重要前提。针对现有机器学习用于列车定位时,存在特征选取理论依据不足、难以确定恰当的模型结构,从而导致列车定位数据不稳定、不精确等问题,提出了一种基于集成深度置信网络(deep belief network, DBN)的城轨列车定位新方法。该方法首先对原始数据集进行预处理,其次利用皮尔逊系数对特征进行筛选,然后基于 Stacking 集成模型,利用量子粒子群算法(quantum particle swarm optimization, QPSO)优化集成模型中 DBN 基学习器的结构。将所提出的 QPSO-DBN 集成模型与经典机器学习方法、传统算法优化的集成模型相比,进一步提高了列车的定位精度。最后,通过仿真实验验证了所提出模型的优越性。

关键词:深度置信网络;量子粒子群算法;集成学习;列车定位

中图分类号: TP301.6; TN966 **文献标识码:** A **国家标准学科分类代码:** 580.30

Research on the positioning of urban rail train based on QPSO-DBN ensemble learning

Xu Kai Yang Rui

(School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: Highly accurate positioning is an important prerequisite for automatic train driving. In terms of the problems that the existing machine learning is used for train positioning, such as the insufficient theoretical basis for feature selection and difficulty in determining the proper structure of model, which lead to the unstable and inaccurate data about train positioning. A new positioning method about urban rail train is proposed based on an ensemble deep belief network (DBN). This method firstly preprocesses the original dataset, then uses the Pearson coefficient to filter the features, finally utilizes the quantum particle swarm algorithm (QPSO) to optimize the structure of the DBN-based learner. Comparing the proposed QPSO-DBN model with the ensemble model about the classical machine learning methods and the traditional optimized algorithms, respectively, the positioning accuracy of the train is further improved. Finally, the superiority of the proposed model is verified by simulation experiments.

Keywords: deep belief network; quantum particle swarm optimization; ensemble learning; train positioning

0 引言

随着国内城轨交通里程和速度的不断提升,城轨列车运行的准确性、安全性面临着更大的挑战^[1],而列车定位的精度与其息息相关^[2]。因此,进一步提高列车定位精度,对列车安全保障及运营效率的改善都具有重要意义。

城轨列车通常依赖车载、轨旁装置组合实现定位^[3],此类方法存在建设成本、维护难度较大等问题。针对上述问题,学者们将机器学习技术引入到列车定位中。文献[4]采用传统机器学习算法,分别以支持向量机(support vector machine, SVM)、最小二乘支持向量机(least square SVM)作为列车位置计算模型。文献[5]采用浅层神经网络,分别建立了基于反向传播(back propagation, BP)神经网络的列车定位方法、基于径向基

收稿日期:2021-10-26 Received Date: 2021-10-26

* 基金项目:四川省科技厅川渝合作重点研发项目(20ZDYF3618)、重庆市自然科学基金项目(cstc2021jcyj-msxmX0017)、重庆市教委科学技术研究项目(KJQN202000703)资助

函数(radial basis function, RBF)的列车定位方法和基于自适应网络模糊推理系统(adaptive network-based fuzzy inference system, ANFIS)的列车定位方法。上述研究主要使用浅层机器学习算法,其数据挖掘能力有限,泛化能力不足,并且输入特征不够丰富,限制了模型的特征表达能力。

相对于浅层机器学习模型,深度学习模型具有更强的特征提取、数据挖掘能力^[6]。但目前将深度学习应用至列车定位领域的研究较少。文献[7]提出一种基于深度神经网络(deep neural networks, DNN)的列车定位方法。但该方法仅实现列车区间定位,定位精度提升有限。

在深度学习的实际应用中,模型结构、初始权值等参数往往难以靠人工经验确定^[8]。因此,模型参数的自动化设置逐渐成为研究热点。文献[9]采用粒子群优化(particle swarm optimization, PSO)算法优化 LSTM 的初始权值。文献[10]采用 GA 算法优化 LSTM 的隐层数、训练次数等超参数。文献[11]首先凭经验确定 DBN 模型的隐藏层数,接着使用 PSO 算法对隐藏层神经元数及学习率进行寻优。上述研究主要是使用一些经典的启发式算法,没有尝试进一步改进的算法,并且没有考虑将隐层数和隐层单元数两者同时优化。

相比单一深度模型,集成模型往往具有更优异的性能表现^[12],这是由于单一模型泛化能力有限,易于过拟合训练数据等问题,可通过集成算法对多个学习器进行集成得到一个强学习器,提升其泛化性能,降低过拟合的不良影响^[13]。Stacking 算法是一种集成算法,可通过集成多个深度模型提升其性能表现^[14]。大多数集成学习使用同一种基学习器算法产生同质的基学习器,即相同种类的学习器。

基于上述研究,提出了一种基于 Stacking 算法集成不同 DBN 的列车定位方法,并结合计算智能并行优化模型隐层数及隐层神经元数。仿真结果表明,所提方法满足列车定位的精度要求,精度能达到了厘米级。

1 智能计算优化的集成 DBN 模型

1.1 DBN 模型

DBN 是一种概率生成模型,通过在输入数据与标签数据之间构建联合分布,实现对标签数据与输入数据之间的双向评估。其可见单元 v 与隐层单元 h 之间的联合概率分布密度函数为:

$$E(v, h | \theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (1)$$

式中: $\theta = \{w = (w_{ij})_{n \times m}, a = (a_i)_{1 \times n}, b = (b_j)_{1 \times m}\}$ 表示 RBM 的各类参数; v_i 和 a_i 分别为第 i 个可见单元的状态

及偏置; h_j 和 b_j 分别为第 j 个隐藏单元的状态和偏置; w_{ij} 为第 i 个可见层单元与第 j 个隐层单元间的连接权重; n 和 m 分别为可见层神经元及隐层神经元的数目。

DBN 的结构和训练过程如图 1 所示, DBN 由受限玻尔兹曼机(RBM)及 BP 神经网络堆叠而成,其训练过程^[15]可分为无监督预训练和有监督微调两阶段。预训练阶段使用无监督贪心算法对 RBM 进行逐层训练;微调阶段采用有监督学习方法调整 DBN 的相关参数。

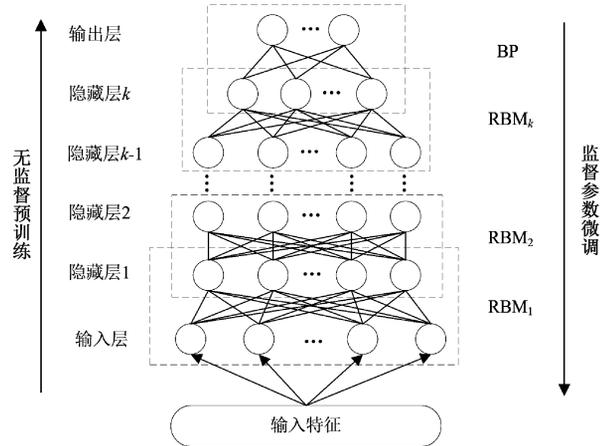


图 1 DBN 模型结构

Fig. 1 Structure of DBN model

RBM 是一种由一个可视层和一个隐藏层构成的能量模型,两层之间神经元以全连接的方式进行双向连接,但同层神经元间是相互独立的。在 RBM 中,隐藏层神经元 h_j 的激活概率为:

$$P(h_j = 1 | v, \theta) = \sigma(b_j + \sum_i w_{ij} v_i) \quad (2)$$

式中: σ 为激活函数,常用的激活函数有 sigmoid 函数、softmax 函数及 tanh 函数等。

由于 RBM 采用双向连接,因此可视层神经元也能被隐藏层神经元激活,其激活概率为:

$$P(v_i = 1 | h, \theta) = \sigma(a_i + \sum_j w_{ij} h_j) \quad (3)$$

1.2 Stacking 算法

Stacking 算法的思想^[16]是:首先将训练集等分为若干子训练集,分别训练第 1 层的基学习器,基学习器输出各自的预测结果。然后,将第 1 层的输出结果作为第 2 层元学习器的输入,对其进行训练。最后由第 2 层元学习器输出最终结果。Stacking 算法通过集成多个模型的长处,取长补短,提升模型的泛化能力,以获得整体精度的提升,如图 2 所示。

Stacking 算法的具体训练方式^[17]为:假定原始数据集为 $S = \{(y_n, x_n), n = 1, \dots, N\}$, 其中 x_n 为第 n 个样本的特征向量, y_n 为第 n 个样本对应的预测值。随机将数据集 S 划分为 K 个大小基本相等的子集,使 M 个基学习

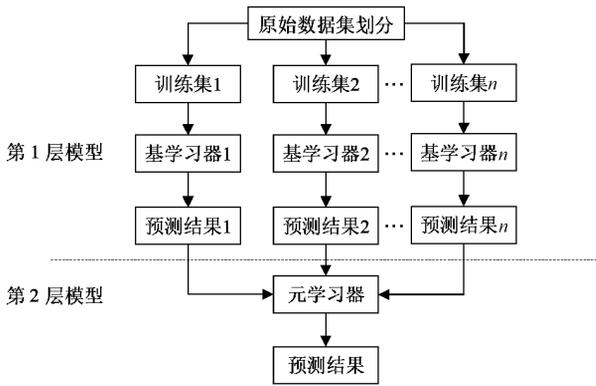


图 2 Stacking 集成方式

Fig. 2 Ensemble method of Stacking

器对数据集 S 进行 k 折交叉验证。对于测试集中的每个样本 x_i , 基学习器都有一个对应的预测结果 z_{Mi} , 将每个基学习器的 k 次预测结果进行合并, 即可得到新的数据集 $S_{new} = \{(y_i, z_{1i}, \dots, z_{Mi}), i = 1, \dots, N\}$, 元学习器以 S_{new} 作为训练集, 学习新构成的数据特征, 输出最终预测结果。

1.3 量子粒子群算法

相对于经典粒子群算法 (PSO), 量子粒子群算法 (QPSO) 中粒子的状态仅需位置向量即可描述^[18]。其位置变化公式通过蒙特卡洛法随机模拟的方式^[19]得到:

$$p = (\varphi_1 p_i + \varphi_2 p_g) / (\varphi_1 + \varphi_2) \tag{4}$$

$$m_{best} = \frac{1}{N} \sum_{i=1}^N p_i =$$

$$\left(\frac{1}{N} \sum_{i=1}^N p_{i1}, \frac{1}{N} \sum_{i=1}^N p_{i2}, \dots, \frac{1}{N} \sum_{i=1}^N p_{id} \right) \tag{5}$$

$$x(t+1) = p \pm \beta | m_{best} - x(t) | \ln(1/u) \tag{6}$$

式中: φ_1, φ_2, u 为 $[0, 1]$ 之间的随机数, N 为整个粒子群的种群大小, t 为算法迭代次数, p_i 为个体最优位置, p_g 为全局最优位置, m_{best} 为所有粒子最优位置的均值, β 为收缩扩张系数。

1.4 计算智能优化集成 DBN 总体框架

计算智能优化集成 DBN 总体框架如图 3 所示。

该框架分为 4 个部分, 分别为数据的获取与处理, Stacking 集成 DBN 模型、模型结构与权值优化及列车定位。数据的获取与处理部分以离线的方式从列车监控、测速装置等设备获取列车的速度、位置及线路数据。其次对数据进行预处理, 即数据清洗及归一化并提取特征。接着使用皮尔逊系数对特征进行去冗余处理, 筛选出合适的输入特征。最后, 将数据划分为训练集和测试集, 分别用于模型的训练和测试。

其次, Stacking 集成 DBN 模型部分基于 Stacking 算法集成 2 个 DBN 网络。首先利用交叉验证法, 将原始训

练集划分为 2 个数据集, 对第 1 级的每个 DBN 模型, 用其中一个数据集作为训练集, 另一个数据集作为验证集。第 1 级中每个模型都能输出一个预测结果, 将这 2 个预测结果合并为一个新的数据集, 用来训练第 2 级的全连接层, 最终得到基于 Stacking 算法的集成 DBN 模型。

其次, 模型结构与权值优化部分基于 QPSO 算法并行地对 2 个 DBN 模型的隐层数与隐层神经元数进行寻优, 同时利用预训练优化模型初始权值, 实现结构与初始权值并行优化。结合图 3, 具体实现步骤如下:

步骤 1) 初始化粒子群位置, 每个粒子包含集成模型的隐层数及每一隐层神经元个数, 代表一种模型结构;

步骤 2) 计算粒子群平均最优位置;

步骤 3) 计算每个粒子的适应度。即通过粒子携带的信息得到模型的隐层数和隐层神经元数, 结合无监督预训练对模型进行训练, 最后根据设置的适应度函数输出对应的适应度值;

步骤 4) 计算粒子群当前全局最优位置;

步骤 5) 对目前保存的全局最优位置进行更新;

步骤 6) 更新粒子群中每个粒子的位置;

步骤 7) 判断是否满足终止条件, 即迭代次数达 100 次, 若是则输出最优粒子, 否则转步骤 2);

最后, 列车定位部分将上述测试集数据输入到优化的模型中实现预测。在实际应用中, 可通过相关设备在线获取数据, 从而实时生成列车的位置信息。

2 实验及分析

2.1 参数设置

1) 线路参数和列车参数

选取重庆轨道 3 号线郑家院子至唐家院子线路运营数据进行实验, 参数如表 1 所示。所用数据集含列车在站间运营 1 440 次共 647 590 个采样点数据, 其中训练集与测试集的比例为 7 : 3。

表 1 线路参数表

Table 1 Parameters of the line

参数名称	参数值
线路长度/m	1 056. 83
车站长度/m	120
车站限速/(km · h ⁻¹)	50
线路限速/(km · h ⁻¹)	75
0~400 m 坡度/%	-3
400~641 m 坡度/%	47. 83
641~971 m 坡度/%	-32. 439
971~1 056. 83 m 坡度/%	0
列车编组/节	6
列车重量/t	162
列车长度/m	120
区间运行时间/s	85~95

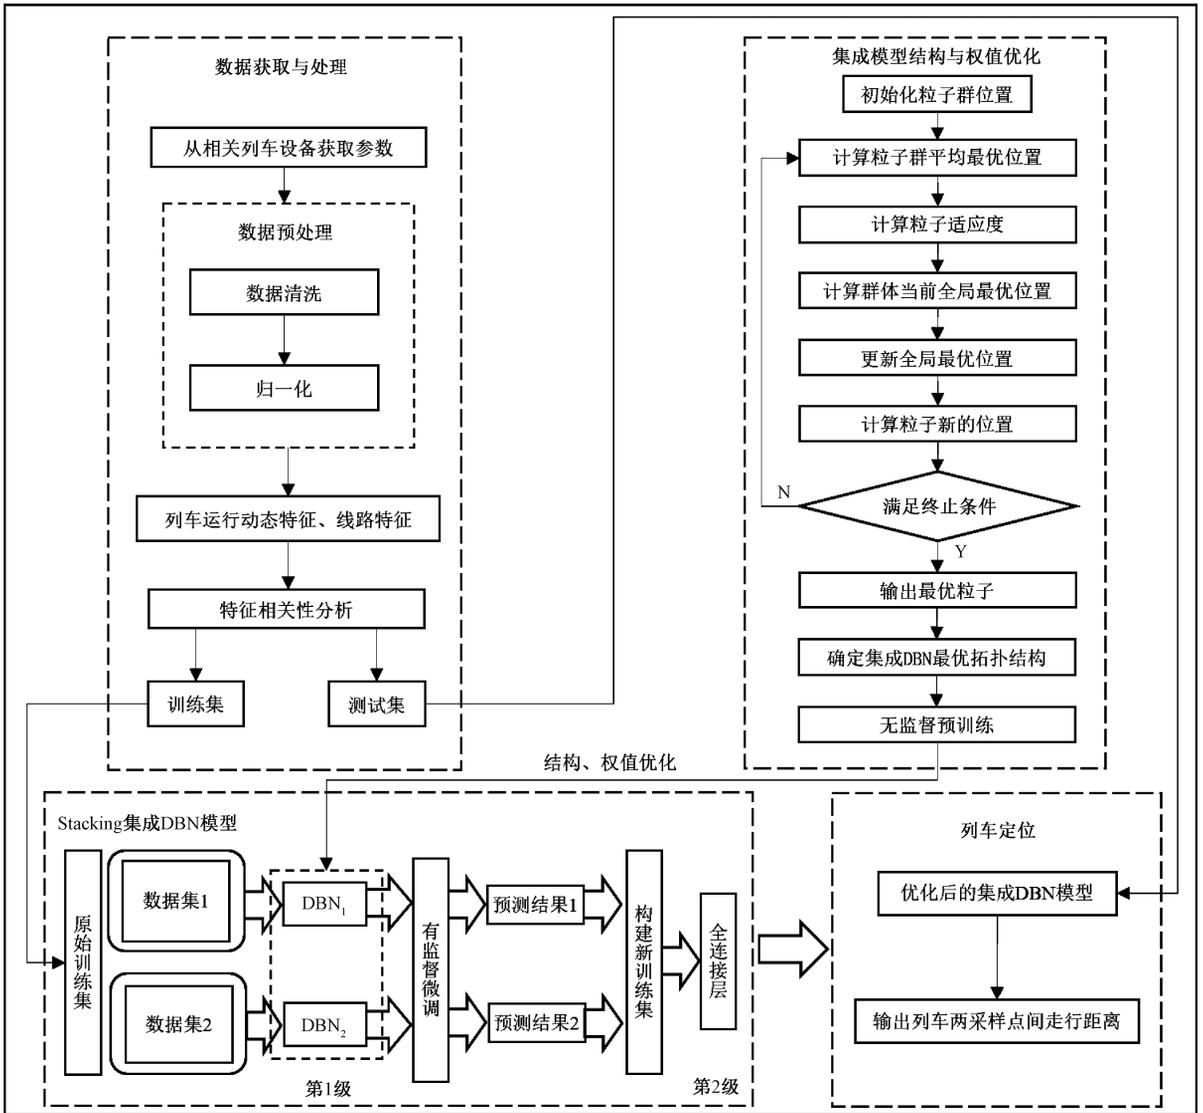


图 3 计算智能优化集成 DBN 总体框架

Fig. 3 Overall framework of ensemble DBN optimized by computational intelligence

2) 算法参数设置

参考文献[20]中的相关参数经验设置,在 QPSO 优化集成 DBN 结构算法中,集成 DBN 隐层数搜索范围设置为[1,4],隐层神经元数搜索范围设置为[8,128],迭代次数为 100。种群中设置 10 个粒子。收缩扩张系数 β 设置为 0.5。QPSO 算法的适应度函数为 MSE 指标,具体公式如式(10)所示。

3) 算法运行环境

以 Pytorch 作为运行环境,采用 Python3.6 编写。

2.2 模型评价指标

如下 4 个指标用于评价集成 DBN 模型的性能。

1) 站间平均累计误差 (mean accumulative error between adjacent states, MAE_{AS})

$$MAE_{AS} = \frac{1}{m} \sum_{i=1}^n y_i - y'_i \quad (7)$$

2) 平均误差 (mean error, ME)

$$ME = \frac{1}{n} \sum_{i=1}^n y_i - y'_i \quad (8)$$

3) 平均绝对误差 (mean absolute error, MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (9)$$

4) 均方误差 (mean square error, MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (10)$$

其中, y_i 与 y'_i 分别为真实值及模型预测值, n 为采样点个数, m 为测试集中列车在两站间的运营次数。上述指标均用于列车定位精准度的评价,其值越小,模型定位

越精准。

2.3 输入特征的选择

现有文献[2-3]输入特征仅涉及列车的速度信息,缺乏对列车动态特征及线路特征的综合考虑。因此,为丰富模型输入特征,提高定位精度,从原始数据集中提取多种特征。如表2所示。

表2 特征定义

Table 2 Definition of features

特征类别	特征详解
列车运行动态特征	(F1) 前一采样点速度
	(F2) 当前采样点速度
	(F3) 前一采样点平均速度
	(F4) 当前档位信息
	(F5) 列车行驶时间
线路特征	(F6) 前一采样点位置平均坡度
	(F7) 前一采样点位置坡度平均速度
	(F8) 前一采样点位置坡度
	(F9) 前一采样点位置坡度剩余长度

为避免特征冗余,利用皮尔逊相关系数对所构建的9个特征进行相关性分析,以对特征进行去冗余处理。皮尔逊相关系数计算公式如下:

$$P_{ij} = \frac{\sum_{k=0}^w (f_i^{(k)} - \bar{f}_i) (f_j^{(k)} - \bar{f}_j)}{\sqrt{\sum_{k=0}^w (f_i^{(k)} - \bar{f}_i)^2} \sqrt{\sum_{k=0}^w (f_j^{(k)} - \bar{f}_j)^2}} \quad (11)$$

式中: f_i 和 f_j 分别表示第*i*个和第*j*个特征; \bar{f}_i 和 \bar{f}_j 分别表示第*i*个和第*j*个特征的平均值; k 表示第*k*个样本; P_{ij} 为特征*i*和特征*j*之间的皮尔逊相关系数。 P_{ij} 值范围为 $[-1, 1]$,一般 $|P_{ij}| > 0.5$ 认为两者线性相关, $P_{ij} = 0$ 则表示完全不相关, $P_{ij} > 0$ 表示正相关、 $P_{ij} < 0$ 负相关。

图4为9个输入特征之间的皮尔逊相关性热力图,Y表示输出特征,为列车在两采样点间的走行距离。图中颜色越深代表两个特征之间的相关性越强,强相关的特征属于冗余特征,会增加模型的训练和预测时间,且提高模型过拟合的概率。由图4可知, $|P_{ij}| > 0.95$ 的特征组为(F1,F2),属强相关特征,去除特征F1以降低特征之间相似性。更进一步地,所有特征中,F3、F9与输出特征Y的相关性过低,因此去掉选择特征F3、F9。最终保留的特征为(F2,F4,F5,F6,F7,F8)。

将输入特征分为两种情况,一是将9个特征作为输入特征,二是将去冗余后的6个特征作为输入特征。使用DBN模型对两种情况进行实验,将模型分别命名为DBN_a、DBN_b。各评价指标结果如表3所示。



图4 特征相关性热力图

Fig. 4 Correlation thermal maps between features

表3 DBN不同特征评价指标结果

Table 3 Result of DBN with different features

模型	MAE _{AS} /m	ME/m	MAE/m	MSE/m
DBN _a	0.717 82	0.004 06	0.113 96	0.076 51
DBN _b	-0.620 97	-0.003 45	0.097 39	0.066 29

由表3可看出,去冗余的DBN_b的各项指标优于未去冗余的DBN_a,其中DBN_b的MAE_{AS}、ME、MAE、MSE指标绝对值分别比DBN_a下降了0.096 85、0.000 61、0.016 57、0.010 22,表明DBN_b比DBN_a具有更小站间累计误差的同时,在每一采样点具有更高定位精度,并且稳定性更强。主要原因是经过去冗余处理后,模型的输入特征更合理,降低了模型在学习过程往某些冗余特征发生偏移的可能性,从而提高了模型的性能。且在实际训练中,DBN_b的训练时长较DBN_a短,训练效率得到提高。因此,在下文的算例分析中,均使用去冗余特征作为所有模型输入。

2.4 集成DBN模型结构的确定与性能分析

本节通过实验确定集成DBN模型结构及初始权值,在此基础上采用不同算法并行优化模型的隐层数与隐层神经元数,以验证所提模型的优越性。

1) 集成DBN模型结构优化

图5为QPSO优化时,集成DBN模型隐层变化图,由图5(a)与(b)可看出,DBN₁、DBN₂的隐藏层数在1~4层间波动,最终在23代趋于稳定,隐藏层数分别稳定在2和3层。其原因为,过多的隐层致使模型的学习能力过强,导致“过拟合”现象;而过少的隐藏层致使模型缺乏充分的信息处理能力。

最终得到的集成DBN结构如表4所示,其中DBN₁和DBN₂的输入层和输出层神经元数都为6、1,DBN₁的隐层神经元数分别为49、48,DBN₂的隐层神经元数分别为48、48、49。

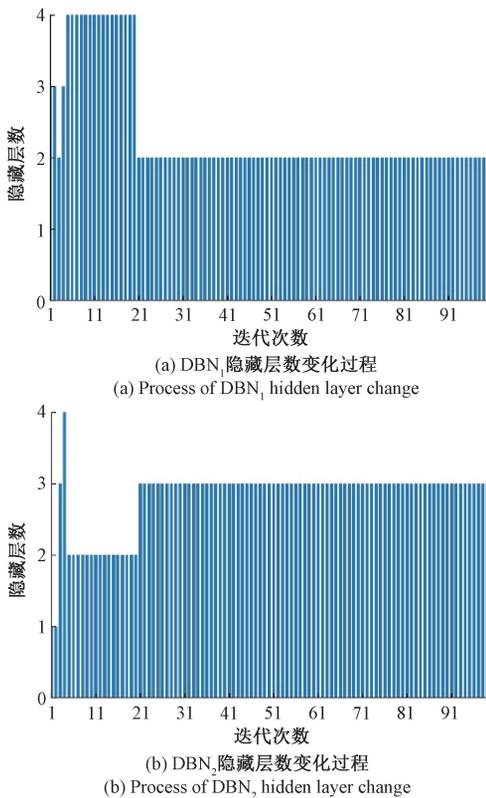


图 5 集成 DBN 模型隐层变化

Fig. 5 Hidden layer change of ensemble DBN

表 4 DBN 基学习器模型结构

Table 4 Structure of DBN-based learners

基学习器	DBN 结构
DBN ₁	[6, 49, 48, 1]
DBN ₂	[6, 48, 48, 49, 1]

2) QPSO-DBN 集成模型优越性验证

针对前言所述问题,在前述集成 DBN 模型的基础上,使用 QPSO 算法优化其结构,同时利用预训练并行优化初始权值。在 QPSO 算法中,粒子变化的随机性强,具有良好的全局搜索能力,不易陷入局部最优,且粒子更新公式简单,收敛速度较快。

图 6 为 QPSO、PSO、GA 算法优化集成 DBN 模型过程中适应度函数的变化情况。适应度函数为评价指标 MSE。由图 6 可见,GA 与 PSO 算法相比,GA 算法达到最优解所需迭代次数要大于 PSO,但搜索到的最优解要比 PSO 更优,其原因为 GA 由于基因变异等操作,使每一个基因具有更强的随机性,相比 PSO 算法具有更好的全局搜索能力,但由于其遗传操作较为复杂,而 PSO 算法原理更加简单,参数少,执行的操作简单,因而 GA 的收敛时间要长于 PSO,但 PSO 容易早熟,陷入局部最优,不适用高维复杂问题。而 QPSO 算法不仅继承了 PSO 算法操作简单,收敛时间短的优点,更进一步提升了算法的全

局寻优能力,具有更强跳出局部最优的能力。由图 6 可见,QPSO 找到的最优解要优于 GA。

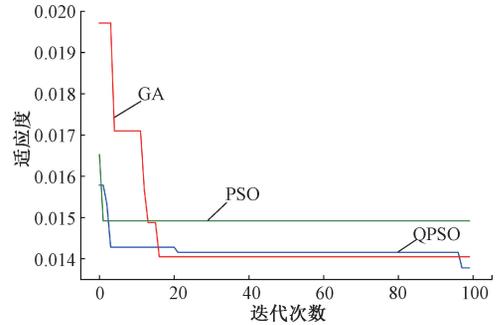


图 6 模型适应度变化曲线

Fig. 6 Change curve of model fitness

为更好验证所提算法在时间复杂度和空间复杂度方面的优越性,现将 QPSO 算法与 PSO、GA 算法优化集成 DBN 模型的时间复杂度和空间复杂度进行对比分析,结果如图 7 所示。由图 7 可知,随着种群规模的增大,3 种算法的时间复杂度和空间复杂度都逐渐增长。其中 QPSO 算法的时间复杂度要明显优于其他两种算法,最优处(种群规模 = 10)QPSO 算法的时间复杂度比 PSO 算法和 GA 算法分别缩减了 14.60% 和 38.50%。但 QPSO 算法的空间复杂度要比 PSO 算法差,比 PSO 算法增加 3.08%,优于 GA 算法,缩减了 13.11%。可能的原因是 QPSO 算法的状态更新步骤更少,但状态更新公式比 PSO 算法更复杂。虽然 QPSO 算法与 PSO 算法在时间复杂度和空间复杂度方面各有优劣,但从图 7 可看出,使用 QPSO 优化集成 DBN 能寻到更优的结果。

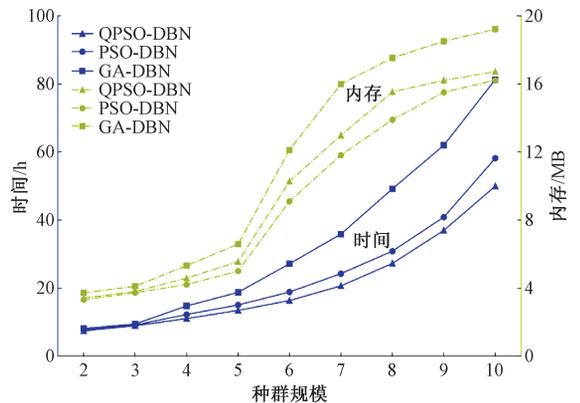


图 7 优化时间和内存占用对比分析

Fig. 7 Optimization time and memory usage comparison analysis

基于上述分析可得到用于列车定位的 QPSO-DBN 集成模型。为验证该模型优越性,分别与浅层神经网络、传统机器学习算法以及 PSO、GA 优化的集成 DBN 模型进行对比分析,其结果如表 5 所示。

表5 不同模型评价指标结果

Table 5 Results of different model evaluation indicators

模型	MAE _{AS} /m	ME/m	MAE/m	MSE/m
SVR	5.149 92	0.028 76	0.151 13	0.095 65
BP	-5.739 02	-0.031 75	0.162 64	0.104 88
MLP	5.634 13	0.031 14	0.177 33	0.101 09
DBN	0.209 11	0.001 21	0.105 48	0.069 55
集成 DBN	-0.849 45	-0.004 73	0.022 81	0.016 87
PSO-DBN	-0.166 25	-0.000 93	0.022 27	0.010 27
GA-DBN	-0.026 62	-0.000 06	0.025 55	0.010 49
QPSO-DBN	-0.339 24	-0.001 82	0.019 39	0.009 88

由表5可看出, BP与MLP的各项指标都较差, 其因为浅层神经网络缺乏足够的数据挖掘及计算能力, 导致定位精度不佳; 而传统机器学习算法SVR由于指向性更强, 其各项指标要优于BP与MLP。且DBN各项指标优于SVR、BP、MLP, 这是因为深度学习模型相对于浅层机器学习算法而言, 具有更强的特征提取、信息处理能力。

其次, 集成DBN、PSO-DBN、GA-DBN模型各项指标值明显优于DBN。这是因为单DBN模型具有偶然性、随机性, 容易发生过拟合现象, 导致泛化性能不强。而集成DBN模型可将不同结构的子模型集成, 取长补短, 获得更强的泛化性能。

特别地, 表5所有模型中, QPSO-DBN模型MSE、MAE指标最优, 而MAE_{AS}、ME指标却较GA-DBN、PSO-DBN模型差, 其因为QPSO-DBN采样点误差正负波动更小, 计算MAE_{AS}时抵消量较少, 致使MAE_{AS}、ME指标较差, 而MSE、MAE指标较优。列车控制系统要求稳定可靠的定位信息, 因此体现数据稳定性的MSE指标, 和体现每一采样点误差大小的MAE指标更为关键。就MSE、MAE指标而言, QPSO-DBN比DBN分别降低了0.059 67、0.086 09, 相比性能优良的PSO-DBN、GA-DBN, MSE指标分别降低了0.000 39、0.000 61, MAE指标分别降低了0.002 88、0.006 16。并且所提模型的MAE_{AS}指标降至33.9 cm, 达到了厘米级定位。上述实验充分验证了所提模型的优越性, 进一步提高了列车的定位精度及稳定性。

3 结论

本文有机融合了计算智能和集成深度学习, 实现了精准、可靠的列车定位。经仿真实验分析与验证得到如下结论:

1) 通过皮尔逊相关性热力图分析, 筛选出集成DBN模型的输入特征, 去除冗余特征, 提高了模型训练效率, 为实现高精度的列车定位奠定良好基础。

2) 基于Stacking算法集成两种不同结构的DBN模型, 降低了仅使用单一DBN模型所存在的偶然性、随机性, 进一步提高了列车的定位精度。集成DBN模型与单DBN模型相比, 具有明显的优越性。

3) 采用计算智能与集成深度学习结合方式, 优化集成DBN模型结构。所提出的QPSO-DBN模型与经典机器学习方法、传统算法优化的集成模型相比, 具有更高的定位精度和稳定性。

参考文献

- [1] 胡和平. 中国南车城轨基地发展策略研究[D]. 长沙: 中南大学, 2014.
HU H P. The research on the development strategy of urban rail vehicle base in CSR[D]. Changsha: Central South University, 2014.
- [2] 李静. 信号系统故障环境下的城市轨道交通列车辅助定位研究[D]. 南京: 东南大学, 2019.
LI J. Research on auxiliary positioning of urban rail transit trains in signal system fault environment[D]. Nanjing: Southeast University, 2019.
- [3] 林俊亭. 轨道交通列车碰撞防护技术研究[D]. 兰州: 兰州交通大学, 2018.
LIN J T. Research on technologies of train collision avoidance for rail transit[D]. Lanzhou: Lanzhou Jiaotong University, 2018.
- [4] CHEN D, WANG L, LI L. Position computation models for high-speed train based on support vector machine approach[J]. Applied Soft Computing, 2015, 30: 758-766.
- [5] CHEN D, HAN X, CHENG R, et al. Position calculation models by neural computing and online learning methods for high-speed train[J]. Neural Computing and Applications, 2016, 27(6): 1617-1628.
- [6] 邵美阳. 基于深度置信网络的电力系统暂态稳定评估[D]. 北京: 北京交通大学, 2020.
SHAO M Y. Transient stability assessment of power system based on deep belief network[D]. Beijing: Beijing Jiaotong University, 2020.
- [7] 王任文. 基于无线信号强度的城轨列车组合定位方法研究[D]. 北京: 北京交通大学, 2018.
WANG R W. A train integrated positioning method based on received signal strength for urban rail transit[D]. Beijing: Beijing Jiaotong University, 2018.
- [8] 付华, 赵俊程, 付昱, 等. 基于量子粒子群与深度学习的煤矿瓦斯涌出量软测量[J]. 仪器仪表学报, 2021, 42(4): 160-168.
FU H, ZHAO J CH, FU Y, et al. Soft measurement of coal mine gas emission based on quantum-behaved particle swarm optimization and deep learning[J].

- Chinese Journal of Scientific Instrument, 2021, 42(4): 160-168.
- [9] 姬少培. 基于深度 LSTM 神经网络的软件可靠性预测[D]. 哈尔滨:哈尔滨工程大学, 2018.
- JI SH P. Software reliability prediction based on depth LSTM network [D]. Harbin : Harbin Engineering University, 2018.
- [10] 温惠英, 张东冉, 陆思园. GA-LSTM 模型在高速公路交通流预测中的应用[J]. 哈尔滨工业大学学报, 2019, 51(9): 81-87,95.
- WEN H Y, ZHANG D R, LU S Y. Application of GA-LSTM model in highway traffic flow prediction [J]. Journal of Harbin Institute of Technology, 2019, 51(9): 81-87,95.
- [11] 杨松柳. 基于多尺度小波分解融合深度学习的短时交通流预测研究[D]. 北京:北京交通大学, 2019.
- YANG S L. Research on short term traffic flow prediction based on multi-scale wavelet decomposition and deep learning [D]. Beijing: Beijing Jiaotong University, 2019.
- [12] 王双玲. 基于集成学习和深度学习的应用研究[D]. 济南:山东大学, 2014.
- WANG SH L. Research of applications based on ensemble learning and deep learning [D]. Jinan: Shandong University, 2014.
- [13] 沈冬冬, 周凤余, 栗梦媛, 等. 基于集成深度神经网络的室内无线定位[J]. 山东大学学报(工学版), 2018, 48(5): 95-102.
- SHEN D D, ZHOU F Y, LI M Y, et al. Indoor wireless positioning based on ensemble deep neural network[J]. Journal of Shandong University (Engineering Science), 2018, 48(5): 95-102.
- [14] 史佳琪, 张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报, 2019, 39(14): 4032-4042.
- SHI J Q, ZHANG J H. Load forecasting based on multi-model by stacking ensemble learning[J]. Proceedings of the CSEE, 2019, 39(14): 4032-4042.
- [15] 冯兆熙, 邱度金, 孔令驹, 等. 基于深度置信网络的轴承剩余使用寿命预测[J]. 电子测量与仪器学报, 2021, 35(10): 124-129.
- FENG ZH X, QIU D J, KONG L J, et al. Remaining useful life prediction of bearing based on deep belief network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 124-129.
- [16] KARDANI N, ZHOU A N, NAZEM M, et al. Improved prediction of slope stability using a hybrid stacking ensemble method based on finite element analysis and field data [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2021,13(1): 188-201.
- [17] 宛艳萍, 谷佳真, 张芳. 融合改进 Stacking 与规则的文本情感分析[J]. 小型微型计算机系统, 2021, 42(7): 1389-1395.
- WAN Y P, GU J ZH, ZHANG F. Text emotion analysis based on the integration of improved stacking and rules[J]. Journal of Chinese Computer Systems, 2021, 42(7): 1389-1395.
- [18] 张同心. 基于量子粒子群的支持向量机算法的研究与应用[D]. 杭州:浙江大学, 2013.
- ZHANG T X. Research on support vector machine based on quantum particle swarms optimization and its application [D]. Hangzhou: Zhejiang University, 2013.
- [19] 蒋奇峰, 杜景林, 周芸. 一种基于 QPSO-RBF 模型预测 PM_{2.5} 浓度值的方法研究及应用[J]. 计算机应用与软件, 2020, 37(9): 202-208.
- JIANG Q F, DU J L, ZHOU Y. A method for predicting PM_{2.5} concentration based on QPSO-RBF model and its application [J]. Computer Applications and Software, 2020, 37(9): 202-208.
- [20] 蒋龙陈, 王红军, 张顺利. 燃气轮机气流激振深度置信网络故障诊断模型[J]. 电子测量与仪器学报, 2021, 35(2): 115-121.
- JIANG L CH, WANG H J, ZHANG SH L. Flow excitation fault diagnosis model of gas turbine based on deep belief network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (2): 115-121.

作者简介



徐凯, 2002 年于重庆大学获得硕士学位, 现为重庆交通大学教授, 主要研究方向为机器学习、计算智能、轨道交通自动化与控制。

E-mail: xkxjwx@hotmail.com

Xu Kai received his M. Sc. degree from Chongqing University in 2002. Now he is a professor at Chongqing Jiaotong University. His main research interests include machine learning, computational intelligence, automation and control of urban rail train.



杨锐(通信作者), 2018 年于太原理工大学获得学士学位, 现为重庆交通大学硕士研究生, 主要研究方向为深度学习与计算智能。

E-mail: 15735185742@163.com

Yang Rui (Corresponding author) received his B. Sc. degree from Taiyuan University of Technology in 2018. Now he is a M. Sc candidate at Chongqing Jiaotong University. His main research interests include deep learning and computational intelligence.