

基于改进 LS-SVM 算法的列车通信网络 时延预测方法

汪知宇¹ 张彤²

(大连交通大学电气信息工程学院, 116028, 大连; 2. 大连交通大学机车车辆工程学院, 116028, 大连 // 第一作者, 硕士研究生)

摘 要 由于通信网络诱导时延的存在会对列车牵引制动系统造成影响, 因此对时延精准预测并实现补偿十分重要。提出了一种基于改进粒子群(PSO)算法优化的最小二乘法支持向量机(LS-SVM)算法对列车通信网络时延进行预测, 搭建了列车网络控制系统半实物平台, 使数据通过多功能车辆总线(MVB)进行传输, 分别改变车辆控制单元(VCU)特征周期及负端口数量大小, 以获取大量不同特性的时延数据。将数据分组后利用改进的 PSO 算法优化 LS-SVM 算法进行预测仿真。仿真结果表明, 与传统的 LS-SVM 算法及 Elman 神经网络算法的预测方法相比, 所提出的方法在列车通信网络的时延预测方面具有更好的快速性和准确性。

关键词 列车通信网络; 时延预测; 改进粒子群算法; 最小二乘法支持向量机算法

中图分类号 U284; U231.7

DOI: 10.16037/j.1007-869x.2021.01.022

Time Delay Prediction Method for Train Communication Network Based on Improved LS-SVM Algorithm

WANG Zhiyu, ZHANG Tong

Abstract Communication network induced delay will affect the train traction braking system, therefore it is very important to accurately predict and compensate the delay. A least squares support vector machine (LS-SVM) algorithm optimized on the basis of improved particle swarm optimization (PSO) is proposed to predict the train communication network delay. A semi-physical platform of the train network control system is constructed for data to be transmitted through Multi-function Vehicle Bus (MVB), and the vehicle control unit (VCU) characteristic period and number of negative ports are respectively changed to obtain a large number of delay data of different characteristics. After the data is grouped, the improved PSO is used to optimize LS-SVM method and the prediction simulation is conducted. The simulation results show that compared with conventional LS-SVM algorithm and Elman neural network algorithm prediction methods, the proposed method has better prediction of the train communication

network time delay in terms of speed and accuracy.

Key words train communication network; time delay prediction; particle swarm optimization (PSO); least squares support vector machine (LS-SVM)

First-author's address School of Electrical and Information Engineering, Dalian Jiaotong University, 116028, Dalian, China

列车通信网络(TCN)是列车的关键系统之一, 被称为列车的“心脏”和“大脑”。由于 TCN 在运行过程中存在通信协议转换、运行环境多变等影响因素, 使信号在传输过程中不可避免的产生时延。网络诱导时延对 TCN 的控制作用产生较大影响, 使数据无法及时传输, 时延过大将会导致列车无法及时进行牵引、制动, 同时对旅客舒适度及旅客安全产生影响。因此, 分析和预测网络时延对 TCN 系统有着至关重要的作用^[2]。目前较为常用的随机时延预测方法有: 最小均方算法、经验模式分解算法、最小二乘法支持向量机(LS-SVM)算法、神经网络算法等^[3-5]。文献[6]采用了基于 Elman 神经网络算法对时延进行预测, 此方法适应时变能力的特性较好, 但精度不足以满足实际需要。文献[7]采用了基于 RBF 神经网络的预测算法, 虽然可以任意精度针对任意非线性函数进行逼近, 但神经网络具有有限的泛化能力, 容易得到局部极小值。文献[8]采用了未经改进的 LS-SVM 算法对时延进行预测, 由于参数无法确定, 预测精度不好掌控。基于以上分析, 本文提出了基于改进 PSO(改进粒子群)算法的 LS-SVM 算法对 TCN 时延数据进行预测^[9-10]。首先, 在所搭建的 TCN 半实物仿真平台上, 分别改变源端口特征周期及端口数量抓取了大量时延数据; 利用了 PSO 算法来优化 LS-SVM 算法的可调参数及平方带宽; 最后, 与传统的 LS-SVM 算法及 Elman 神经网络算法进行对比分析, 验证了该方法的有效性。

1 TCN 平台搭建与时延测试

TCN 时延测试平台采用 TCN 技术搭建符合 IEC-61375 协议标准,通过 MVB(多功能车辆总线)对各子系统进行连接,完成了设备之间的数据通信。网络控制系统设备包括:VCU(车辆控制单元)、REP(中继器)和 HMI(人机接口界面)。使用 TCN 分析仪抓取时延数据,通过 PC 机对时延数据进行监测。为了实现通过 TCN 平台的时延进行测试,采用 Unicap 组态软件对各控制单元软件进行开发,对输入模块及输出模块进行程序编写。

TCN 时延实质上是整个 TCN 的信息交互时间,其中包括了发送时延、传输时延、接收时延,而发送时延又包括处理时延、等待时延、应答时延。同时通信设备、通信距离等因素都会对时延数据产生影响,TCN 的总体时延等于各部分时延数据之和。时延的产生主要包括以下部分^[6]:

- 1) 源端口进行数据发送所消耗时间(与数据包长度有关)。
- 2) 数据在传输过程中所消耗的时间(与 MVB 长度有关)。
- 3) 通信寄存器进行数据收发及处理的排队等待时间。

为了避免其他设备属性对数据产生影响,保持其他属性不变,只使用 VCU、HMI 等网络设备。现设计如下时延测试基本步骤:

步骤 1: 通过 UNICAP 软件编写 HMI 及 VCU 组态程序,分别取多组不同特征周期及不同端口数量的时延数据进行分析及预测,将组态软件程序通过 MVB 下载到 VCU 及 HMI 中。时延传输过程如图 1 所示。




图 1 时延数据传输过程

系统总时延即各设备时延数据之和:

$$T_d = T_{V-H} + T_{H-V} + T_V + T_{V-R} + T_R + T_{R-H} + T_H + T_{H-R} + T_R + T_{V-R} \quad (1)$$

式中:

T_d ——系统总时延;

T_{V-H} ——VCU 到 HMI 之间的时延;

T_{H-V} ——HMI 到 VCU 之间的时延;

T_{V-R} ——VCU 到 REP 之间的时延;

T_{R-H} ——REP 到 HMI 之间的时延;

T_H ——数据通过 HMI 产生的时延;

T_V ——数据通过 VCU 产生的时延;

T_R ——数据通过 REP 产生时延。

试验平台通过 TCN 进行搭建,使过程数据在设备之间进行通信。

步骤 2: 通过 IPTDM2 软件与 PTS402 配置软件一起使用,采用 IPTLMlog 工具来对 TCN 采集数据,收集通过 MVB 得到的数据帧并形成数据文件。图 2 为通过抓包软件得到的数据解析图,是利用 TCN 分析仪抓取的时延数据包。通过 IpTLMview 工具对所收集到的图形数据进行读取及解析,从中可以看到各端口过程数据发送时间及接收时间。通过查找发送及接收端口号对应的时间数据,对数据包进行统计及计算。传输过程中数据通过 VCU、REP 和 HMI 模拟形成一个 VCU 到 HMI 之间的网络控制系统。其中,一台 PC 机控制 VCU 数据发送,使用网络分析仪接入模拟系统中对时延数据进行抓取;另一台 PC 机对网络分析仪抓取到的数据量进行控制。

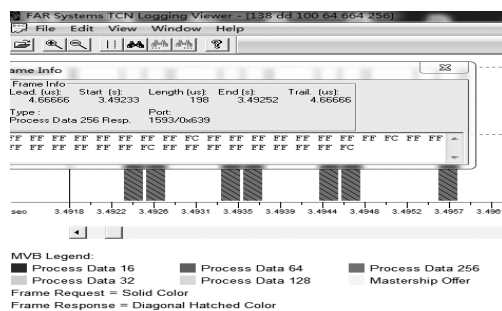


图 2 数据解析实景图

2 基于 PSO 算法的参数优化

2.1 LS-SVM 算法分析

LS-SVM 算法是一种新型的支持向量机算法,该方法用等式约束替代 SVM 算法中的不等式约束,将求解过程转变为对等式方程的求解问题,使算法的运算速度加快;通过结构风险最小化原则增加了算法的泛化能力,解决了局部最小值等问题。因此,使用 LS-SVM 算法对非线性函数进行预测,可以得到较好的预测效果。其回归函数为

$$y = u\varphi(x) + b \quad (2)$$

式中:

u ——惯性权重系数;

b ——偏置。

对于给定的训练集 $(x_i, y_i), i = 1, 2, \dots, n$, 其中 $x_i \in R, y_i \in R$ (R 为实数)。LS-SVM 定义如下:

$$\min J(w, e) = \frac{1}{2} uw + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \quad (3)$$

式中:

w ——惯性权重;

γ ——正则化参数;

e_i ——LS-SVM 中的损失函数, 需要满足以下条件:

$$y_i = u\varphi(x_i) + b + e_i \quad (4)$$

将式(2)、(3)、(4)进行优化后得到拉格朗日方程

$$L = J(w, e) - \sum_{i=1}^n a_i [u\varphi(x_i) + b + e_i + y_i] \quad (5)$$

式中, a_i 为系数。

由 Karush-Kuhn-Tucker 优化法可知, 通过对 w, b, e, a 求偏微分, 可以得到最优值。求解偏微分步

骤如下: $\frac{\partial L}{\partial w} = 0$, 得 $w = \sum_{i=1}^l a_i$; $\frac{\partial L}{\partial b} = 0$, 得 $w =$

$\sum_{i=1}^l a_i = 0$; $\frac{\partial L}{\partial e} = 0$, 得 $a_i = ce_i$ (c 为系数); $\frac{\partial L}{\partial a} = 0$,

得 $u\varphi(x_i) + b + e_i + y_i = 0$ 。

消除 w 和 e , 得到回归函数方程为

$$\begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 & \mathbf{A}^T \\ \mathbf{A} & \Omega + r^{-1} \mathbf{A} \end{bmatrix}^{-1} \cdot \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中:

Ω ——核函数;

\mathbf{A} ——相应维数的单位矩阵。

则 LS-SVM 预测模型为

$$y(x) = \sum_{i=1}^l a_i K(x, x_j) + b \quad (7)$$

式中:

$K(x, x_j)$ ——把样本映射到特征空间的核函数;

x_j ——第 j 个支持向量的位置输入。

2.2 基于 PSO 算法迭代优化 LS-SVM

LS-SVM 算法模型需要对 γ 及平方带宽 σ 进行调节。这 2 个参数在很大程度上决定了 LS-SVM 算法的学习及泛化能力。假设 γ 与 σ 的取值范围均为 0 到 500, 则计算时间将达到数十 h。如果将 PSO 算法引入, 将会在参数选取、收敛速度方面具有一定

的优势^[11]。通过对 PSO 算法研究, 结果发现存在误差的粒子群将会降低收敛时间, 加快运行速度, 但有可能错过了最优解。因此, 本文提出了一种改进的粒子群优化模型, 粒子群比较了状态最优解与全局最优解, 根据方程(8)、(9)、(10)来调节迭代状态, 更新位置及速度。权重调整公式如(8)、(9)、(10)所示:

$$v_{i+1} = \delta [wv_i + c_1\gamma_1(p - x_i) + c_2\gamma_2(g - x_i)] \quad (8)$$

$$x_{i+1} = x_i + \alpha v_{i+1} + \beta \quad (9)$$

$$w = w_{\max} - (w_{\max} - w_{\min})t/T_{\max} \quad (10)$$

式中:

v_{i+1}, v_i ——分别为第 $i+1, i$ 个粒子的速度;

x_{i+1} ——第 $i+1$ 个粒子的位置;

t ——当前迭代次数;

γ_1, γ_2 ——范围在 $[0, 1]$ 之间的随机数;

c_1, c_2 ——范围在 $[0, 2]$ 之间的随机数;

g ——全局最优位置解;

T_{\max} ——最大迭代次数;

p ——状态最优解;

α ——局部搜索因子;

β ——微调因子;

δ ——速度调节因子。

在第 t 次迭代中, 对 w 进行调整。当迭代次数增加时, w 将减少, 使优化过程更加准确。同时本文加入 α 及 β 对模型进行改进, 实质上在每次位置更新后, δ 将本次的搜索速度当成新的搜索范围。如果更新后的搜索位置优于当前搜索位置, 则将更新后的位置作为开始点; 否则, 继续使用原位置。

本文采用高斯函数作为仿真试验的核函数。由于核函数的参数 σ 和 LS-SVM 算法的可调参数会影响算法的性能, 因此采用 PSO 迭代算法对参数进行寻优, 可在很大程度上提高模型的精度。将时延数据分为测试样本和训练样本, 具体步骤如下:

1) 对粒子群参数包括迭代次数 T 、粒子位置属性 δ 及速度属性 σ^2 进行初始化;

2) 当粒子的当前速度比前面最好位置出现的适应度小时, 就作为最好的位置 p ;

3) 当粒子经过的位置比最优位置对应的位置 g 的小时, 则作为最优位置 g ;

4) 根据粒子的变化速度 v_{i+1} , 得到新的种群, 输入测试样本进行预测。

3 仿真试验方案

根据搭建好的半实物平台, 分组对不同情况下

的时延数据进行测试,并对得到的时延数据进行分析,针对不同特性的数据进行预测仿真,以此来验证本文所采用算法的有效性。

3.1 时延数据特性分析

对 TCN 时延数据进行抓取。为了避免其他设备属性对特征周期产生影响,保持其他属性不变,只增加源端口发送周期。统一设置抓取时间为 60 s,进行分组测试,试验数据见表 1。表 1 中分别分 3 组对源端口不同特征周期下的最大时延、最小时延及平均时延进行整理及计算,并统计出不同情况下的过程数据包请求个数、过程数据包响应个数及负载率大小。时延趋势变化对比如图 3 所示。经过分析得出,当保持其他参数不变时,只增加源端口特征周期,使数据解码及数据访问时间发生变化,从而导致系统

时延增加。同时特征周期的增加导致端口被轮循的次数减少,因此负载率降低。




图3 不同特征周期对时延数据影响(端口数为138个)

表1 不同源端口特征周期时延数据对比

HMI 端口数/个	VCU 特征周期/ms	系统最大时延/ms	系统最小时延/ms	系统平均时延/ms	过程数据包请求数/个	过程数据包响应数/个	负载率/%
第一组 138	发送 64	313.25	164.22	236.83	377 536	358 662	56.154
	发送 128	321.70	194.63	254.25	247 172	239 612	35.044
	发送 256	382.69	196.24	263.69	134 325	127 899	19.077
	发送 512	453.25	201.15	326.23	81 276	77 288	9.925
第二组 64	发送 64	250.74	156.76	208.34	278 808	265 009	37.676
	发送 128	278.24	156.12	224.62	177 303	168 772	19.476
	发送 256	298.84	164.85	257.45	76 663	72 988	10.122
	发送 512	364.59	172.15	272.46	35 039	33 445	5.407
第三组 28	发送 64	224.25	128.18	196.31	8 160	7 789	0.589
	发送 128	256.05	128.15	212.64	5 160	4 974	0.346
	发送 256	264.12	128.32	228.35	3 054	2 944	0.285
	发送 512	312.64	128.08	256.75	2 320	2 245	0.194

注:HMI端口的任务周期为100 ms,特征周期为64 ms;VCU的任务周期为64 ms。

当保持其他属性不变,只改变端口数量,进行分组测试,试验数据见表2,时延趋势变化对见图4。从图4中可以看出,当保持其他参数不变时,只增加端

口数量,导致时延数据变大,同时负载率增加。这样就增大了控制信号反应时间,降低了数据传输的实时性,最终影响了TCN数据的及时传输。

表2 不同端口数的时延数据对比

端口数量/个	时延数据					
	系统最大时延/ms	系统最小时延/ms	平均时延/ms	过程数据包请求数/个	过程数据包响应数/个	负载率/%
28	312.64	128.08	256.75	2 320	2 245	0.194
64	364.589	172.15	272.46	35 039	33 445	5.407
138	453.25	201.15	326.23	81 276	77 288	9.925

注:HMI的任务周期为100 ms,特征周期为64 ms;VCU的任务周期为64 ms,特征周期为512 ms。

3.2 时延预测仿真

针对不同情况下时延变化情况,进行时延预测仿真。利用试验平台测试得到550组前向时延数据,前500组作为训练样本,后50组作为测试样本。使用Matlab软件进行仿真试验,训练得到对应的参数。设置粒子位置属性 γ 范围为[0.01,300]、速度属

性 σ 范围为[0.1,1 000],仿真得到LS-SVM中 γ 为0.931 4, σ 为8.159。为了进行预测结果精度对比,本文将预测结果与Elman神经网络算法及未经优化的LS-SVM算法预测结果进行比较,结果如图5、图6、图7、图8所示。

生成训练样本和测试样本后,通过改进PSO算




图4 不同端口数对时延数据的影响(特征周期为 512 ms)




图7 端口数为 28 个、VCU 特征周期为 64 ms 时的时延预测仿真图




图5 端口数为 138 个、VCU 特征周期为 64 ms 时的时延预测仿真图




图8 端口数为28 个、VCU 特征周期为 128 ms 时的时延预测仿真图




图6 端口数为 138 个、VCU 特征周期为 128 ms 时的时延预测仿真图

法迭代寻优,搜索参数初始值如表3所示。

通过比较得出本文所采用的基于 PSO 迭代优化 LS-SVM 算法适用于不同特性的时延数据的预测,而 Elman 神经网络算法及 LS-SVM 算法均无法达到理想的预测效果。为了对三种方法进行定量

评定,从运算时间、均方误差和绝对误差率 3 个方面进行对比,如表4所示。

从表4中可以看出,本文采取基于 PSO 迭代优化的 LS-SVM 算法节约了运算时间,同时预测精度也有大幅度提高。使用 LS-SVM 算法预测时,由于 γ 及 σ 直接对预测效果产生影响,而本文算法不但

表3 PSO 算法参数初始值

粒子群参数	初始值
种群规模参数	50
局部搜索能力参数	1.8
全局搜索能力参数	1.5
弹性系数	0.8
T/次	100

表4 3种预测方法的相关参数平均值对比

预测方法	各对比参数平均值		
	均方误差	运算时间/s	绝对误差率/%
LS-SVM	0.008 5	2.68	4.49
Elman	0.006 8	12.00	3.20
本文方法	0.004 2	1.20	1.48

避免了局部极小值问题,同时解决了计算复杂度高、运算速度慢等问题。因此,可得出本文预测方法适用于 TCN 控制系统的时延数据及高实时性、高精度数据的预测。

4 结语

在对试验平台进行搭建后,进行时延测试,通过 MVB 对时延数据进行抓取,得到大量有效的时延数据,并对时延数据进行统计,分析其时延变化特点。本文提出基于改进的 PSO 算法迭代来优化 LS-SVM 算法对 TCN 时延进行预测,试验结果表明本文方法在预测精度及预测速度上较其他方法有大幅度提升,对于 TCN 时延的预测具有良好的效果,为 TCN 时延补偿得到了大量有效数据。

参考文献

- [1] 张彤. 基于 T-S 模糊模型的高速动车组通信网络实时控制方法[J]. 中国铁道科学, 2018(3): 95.
- [2] 李常贤, 赵焱, 张彤. 列车网络控制系统时延特性研究[J]. 中国

铁路, 2018(1): 49.

- [3] 王宏伟, 杨先一, 金文标. 基于 Elman 网络的时延预测及其改进[J]. 计算机工程与应用, 2008(6): 136.
- [4] TIAN Z D, GAO X W, LI K. Time-delay prediction based on LS-SVM optimized by PSO for GPRS industry control network[J]. Journal of Northeastern University, 2012, 33(10): 1377.
- [5] 王宏伟, 宋芄. 基于神经网络的网络时延预测[J]. 微计算机信息, 2008(4): 271.
- [6] GAO X W, TIAN Z D. Time-delay prediction method based on maximum Lyapunov exponent and Elman neural network[J]. Entia Simica, 2013, 43(8): 1042.
- [7] 刘婷, 姜顺, 潘丰. 网络控制系统前向通道随机时延的在线多步预测[J]. 信息与控制, 2017(5): 114.
- [8] 田中大, 高宪文, 李琨. 基于 EMD 与 LS-SVM 的网络控制系统时延预测方法[J]. 电子学报, 2014(5): 868.
- [9] 陈维鹏, 敖志刚, 屠义强, 等. 基于 PSO 优化 LS-SVM 算法的网络空间态势预测研究[J]. 通信技术, 2018(5): 164.
- [10] 杨刚, 王乐, 戴丽珍, 等. 自适应权重粒子群优化 LS-SVM 的交通流预测[J]. 控制工程, 2017(9): 1838.
- [11] 曹净, 丁文云, 赵党. 基于 PSO-LS-SVM 模型的基坑变形时间序列预测[J]. 控制工程, 2015(3): 475.

(收稿日期: 2019-04-08)

(上接第 96 页)

Java 与 Matlab 语言交互与调用程序, 实现了全自动全站仪、倾角传感器的远端三维可视化自动监测, 以及三维激光扫描监测断面数据的解析、计算、拟合、分析功能, 从监测功能模块获取监测数据显示。

3) 使用 MVC 以及 Struts 框架等相关 Web 框架搭建技术, 完成了软件平台的框架搭建, 将监测模块、评估模块、管养决策模块集成至软件平台的框架中, 建立了数据传输模块、监测中心应用管理模块、人工监测数据录入模块、预警管理模块等。

参考文献

- [1] 刘胜春, 张顶立, 黄俊, 等. 大型盾构隧道结构健康监测系统设计研究[J]. 地下空间与工程学报, 2011(4): 742.
- [2] 黎晨, 赵小军, 范中林. 盾构隧道结构健康监测系统设计[J]. 武汉理工大学学报, 2014(2): 346.
- [3] 邱冬伟, 梁青槐, 杨松林. 北京地铁隧道结构整体变形监测的研究[J]. 测绘科学, 2008(1): 16.

- [4] BHALLS S, YANG Y W, ZHAO J. Structural health monitoring of underground facilities Technological issues and challenges [J]. Tunneling and Underground Space Technology, 2005, 20(5): 487.
- [5] LEE J S, CHOI I Y, LEE H U. Damage identification of a tunnel liner based on deformation data[J]. Tunneling and Underground Space Technology, 2005, 20(1): 73.
- [6] 候海民. 三维激光扫描仪在青岛胶州湾海底隧道的应用[J]. 隧道建设, 2010(6): 693.
- [7] 邱冬伟. 穿越工程影响下既有地铁隧道变形监测与分析[D]. 北京: 北京交通大学, 2012.
- [8] 简骁, 童鹏. 基于地面激光雷达技术的隧道变形监测方法研究[J]. 铁道勘察, 2011(6): 19.
- [9] 康志忠, 托雷, 王保前, 等. 基于三维激光扫描的地铁隧道连续形变监测数据处理软件系统[J]. 测绘工程, 2013(5): 82.
- [10] ZHOU W, SUN Z, TANG S. Research on liquid level on-line monitoring system of deep tunnel drainage basin [J]. China Water & Wastewater, 2018, 34(1): 1.

(收稿日期: 2019-01-10)