

文章编号:1671-251X(2014)10-0036-05 DOI:10.13272/j.issn.1671-251x.2014.10.011
王安义,郭世坤.基于LS-SVM的矿井巷道场强预测[J].工矿自动化,2014,40(10):36-40.

基于LS-SVM的矿井巷道场强预测

王安义, 郭世坤

(西安科技大学 通信与信息工程学院, 陕西 西安 710054)

摘要:针对目前矿井巷道场强预测精度低的问题,提出采用最小二乘支持向量机方法建立预测模型,以某巷道实测数据作为训练样本,对矿井巷道场强进行预测;详细分析了训练集构造和参数选择对预测效果的影响。仿真结果表明,LS-SVM预测模型较双斜率模型和对数校正模型具有更高的预测精度。

关键词:矿井巷道;场强;预测模型;最小二乘支持向量机

中图分类号:TD601 文献标志码:A 网络出版时间:

网络出版地址:

Prediction of field intensity in mine tunnel based on LS-SVM

WANG Anyi, GUO Shikun

(College of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: For problem of low accuracy of current prediction of field intensity in mine tunnel, a prediction model based on the least squares support vector machine method was proposed to predict the field intensity in mine tunnel by taking measured data of a tunnel as training sample. Influence of training set construction and parameters selection on prediction effect were analyzed in details. The simulation results show that the LS-SVM prediction model has higher prediction accuracy than dual-slope model and logarithmic correction model.

Key words: mine tunnel; field intensity; prediction model; least squares support vector machine

0 引言

矿井无线通信系统在确保煤炭安全开采及最优化生产中起到关键作用,井下巷道场强覆盖的好坏直接影响系统的性能。在井下基站建成之前,了解其应用环境下的电磁传播路径损耗规律,提高场强预测准确度,可以避免基站覆盖范围过小造成网络覆盖弱区和盲区以及基站覆盖范围过大造成的资源浪费。

电磁波在矿井巷道中的传播包含了直射、反射、绕射、散射等各种传播机制,与在隧道中的传播方式相似。参考文献[1]提出了预测隧道中传播损耗的混合模型,并通过实验验证了其合理性,但该模型在远场区的计算较为复杂。参考文献[2]和参考文

献[3-4]分别提出了对数校正模型和双斜率模型,然而由于巷道传播环境复杂,上述模型均不能很好地体现信道场强的非线性特性,存在预测精度低的问题。参考文献[5-6]提出利用神经网络分别建立电磁传播预测模型和场强预测的方法,但神经网络易陷入局部最优,且存在过拟合现象。支持向量机能够很好地克服神经网络训练时间长、训练结果存在随机性和过拟合等不足^[7-8]。在此基础上,本文根据井下实际测量数据,建立了基于最小二乘支持向量机(Least Squares Support Vector Machine, LS-SVM)的场强预测模型。该模型以实际测量数据作为训练样本,通过设置合适的参数,可满足预测精度要求。

收稿日期:2014-04-29;修回日期:2014-08-14;责任编辑:盛男。

基金项目:陕西省教育厅科学研究计划资助项目(2013JK0864)。

作者简介:王安义(1968—),男,山东潍坊人,教授,博士,主要研究方向为无线传播与矿井通信技术,E-mail:wanganyi@xust.edu.cn。

1 LS-SVM 算法理论

LS-SVM 将二次规划问题转换成线性方程组的求解问题,具有快速求解的特点。设给定训练集为 $T = \{(x_i, y_i), i = 1, 2, \dots, N\}$, 其中 $x_i \in \mathbf{R}^n$ 为输入数据, $y_i \in \mathbf{R}$ 为输出数据, N 为训练集包含的样本数, n 为 x_i 的维数。首先利用非线性函数 $\phi(x)$ 将样本从输入空间 $\mathbf{R}^n$ 映射到高维特征空间。然后在高维特征空间构造最优决策函数 $y = \omega^T \phi(x) + b$, 其中 ω 为权系数, b 为偏置。利用结构风险最小化原则, 寻找最优的参数 ω, b 。LS-SVM 的优化问题可表示为^[9-10]

$$\begin{aligned} \min_{\omega, b, e_i} & \frac{1}{2} \|\omega\|^2 + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \\ \text{s. t. } & y_i = \omega^T \phi(x_i) + b + e_i \end{aligned} \quad (1)$$

式中: γ 为正则化参数; e_i 为误差。

定义拉格朗日函数为

$$\begin{aligned} L(\omega, b, e_i, \alpha_i) = & \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 - \\ & \sum_{i=1}^N \alpha_i (\omega^T \phi(x_i) + b + e_i - y_i) \end{aligned} \quad (2)$$

式中: α_i 为拉格朗日乘子。

根据 KKT(Karush-Kuhn-Tucker)条件对 ω, b, e_i, α_i 求偏导数, 并消除 ω, e_i , 得

$$\begin{bmatrix} 0 & \mathbf{v}^T \\ \mathbf{v} & \mathbf{K} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \quad (3)$$

式中: $\mathbf{v} = [1 \ 1 \ \dots \ 1]^T$; $\mathbf{K}$ 为 N 阶方阵, 其第 i 行、第 j 列的元素为 $K_{ij} = \phi(x_i)^T \phi(x_j) = K(x_i, x_j)$, $K(\cdot, \cdot)$ 为核函数; $\mathbf{I}$ 为 N 阶单位矩阵; $\boldsymbol{\alpha} = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_N]^T$; $\mathbf{Y} = [y_1 \ y_2 \ \dots \ y_N]^T$ 。

常用的核函数有线性核函数、多项式核函数、径向基核函数等形式。本文选用径向基核函数:

$$K(x, x_i) = \exp\left(-\frac{|x - x_i|^2}{2\sigma^2}\right) \quad (4)$$

式中: x 为训练输入样本; σ 为核参数。

用最小二乘法求出 $\boldsymbol{\alpha}$ 和 b , 由此得到 LS-SVM 模型的预测输出为

$$\hat{y}(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (5)$$

2 数据测量和预处理

2.1 测量方案

以某煤矿直巷道作为测试环境, 巷道宽约 4.2 m, 高约 3.5 m。实验相关参数与测试方法如下:

(1) 选用单频点小区, 频点号为 9504(中心频率 1 900.8 MHz, 频率范围 1 900~1 901.6 MHz), 基站发射功率为 20 dB, 天线增益为 12 dBi。

(2) 从发射天线位置开始, 在矿井巷道中每隔 5 m 记录终端显示的接收电平值, 每个测量点记录 30 次, 直至巷道末。

2.2 数据预处理

由于矿井环境复杂, 为保证测量结果的有效性, 排除偶然因素的影响, 有必要对测量数据进行预处理, 滤除快衰落的影响。对每个测量点的数据进行算术平均, 得到 101 个实测点的平均接收电平值, 如图 1 所示。




图1 实测场强分布

3 基于LS-SVM的巷道场强预测

3.1 训练集构造对预测效果的影响

经过测试得到 101 个测量数据, 均匀分布在距离基站 0~500 m 范围内。利用测量数据分别构造训练集和测试集。为了评价训练集构成对 LS-SVM 预测效果的影响, 构造 4 个不同的训练集 A, B, C, D。训练集 A 共有 51 个训练数据, 均匀分布在 0~500 m 测试范围内; 训练集 B 共有 21 个训练数据, 均匀分布在 0~500 m 测试范围内; 训练集 C 共有 21 个训练数据, 均匀分布在 0~400 m 测试范围内; 训练集 D 共有 21 个训练数据, 非均匀分布在 0~500 m 测试范围内。分别利用训练集 A, B, C, D 对 LS-SVM 模型进行训练, 并用测试集进行检验, 得到不同训练集下 LS-SVM 预测结果如图 2—图 5 所示。

对比图 2 和图 3 可知, 在训练数据分布范围不变, 数量由 51 个减少到 21 个时, LS-SVM 预测误差增大, 在个别位置误差达到了 6 dB, 表明训练集的大小对于 LS-SVM 的预测效果有显著影响。训练数据越多, 训练集越大, 预测精度越好。但需要的测量数据越多, 时间成本越大。因此, 在满足一定精度要求下, 应尽可能减少测量数据。




图 2 LS-SVM 预测结果(训练集 A)




图 3 LS-SVM 预测结果(训练集 B)




图 4 LS-SVM 预测结果(训练集 C)




图 5 LS-SVM 预测结果(训练集 D)

从图 4 可看出,在 0~400 m 范围内预测误差为 -5~5 dB,而在 400~500 m 范围内误差最大可达 30 dB,表明预测精度和训练数据的选择范围密切相关。在测试集覆盖范围内,LS-SVM 能够更精确地

预测矿井场强覆盖情况。

对比图3和图5可知,训练数据非均匀分布时比均匀分布时的LS-SVM预测效果要好。

3.2 参数选择对预测效果的影响

LS-SVM预测需寻找最优的正则化参数 γ 和核参数 σ 。理论上 γ 用于控制模型的复杂度和逼近误差的折中, γ 越大则对数据的拟合程度越高,但同时模型的复杂度变大。 σ 用于控制支持向量的个数和泛化能力, σ 越大支持向量个数越少,泛化能力越强,但精度会降低。为了分析正则化参数 γ 和核参数 σ 对于LS-SVM模型预测精度的影响,采用固定变量法进行分析。

选用训练集A,保持固定 $\sigma=0.1$,分析 γ 对预测精度的影响。 γ 分别为1,10,100,1 000时,LS-SVM预测结果如图6所示。从图中可看出,对于不同的 γ ,模型预测结果区别并不明显,当 $\gamma>10$ 时预测结果几乎全部重合。

选用训练集A,保持固定 $\gamma=100$,分析 σ 对预测精度的影响。 σ 分别为0.1,0.5,1,2时,LS-SVM预测结果如图7所示。从图中可看出,在不考虑模型泛化能力的情况下, σ 越小,模型的预测结果更准确。




图6 γ 对LS-SVM预测结果的影响




图7 σ 对LS-SVM预测结果的影响

由支持向量机理论可知,模型精度和复杂度对参数的要求是相互矛盾的^[11-12],实际运用时应根据选择最佳的模型参数。本文采用多层动态自适

应优化算法^[13]对参数进行选择,当 $\gamma=100, \sigma=0.1$ 时,模型的预测误差平均值可控制在0.5 dB左右,同时最大预测误差可控制在3 dB以内,预测精度能够满足实际要求。

4 模型预测性能分析

4.1 模型预测性能指标

预测值和实测值的统计平均差为

$$\mu = \frac{1}{N} \sum_{i=1}^N |P_i - P_{pi}| \quad (6)$$

式中: P_i 为实测值; P_{pi} 为预测值。

预测值和实测值的标准差为

$$e_s = \sqrt{\frac{1}{N-1} \left(\sum_{i=1}^N |P_i - P_{pi}|^2 - N\mu^2 \right)} \quad (7)$$

预测值和实测值之间的相关系数为

$$r = \frac{\sum_{i=1}^N (P_i - \bar{P})(P_{pi} - \bar{P}_p)}{\sqrt{\sum_{i=1}^N (P_i - \bar{P})^2} \sqrt{\sum_{i=1}^N (P_{pi} - \bar{P}_p)^2}} \quad (8)$$

式中: $\bar{P}$ 为实测值的平均值; $\bar{P}_p$ 为预测值的平均值。

其中 μ 和 e_s 越小表明预测效果越好, r 越大表明预测值与实测值越接近。

4.2 预测结果与性能分析

利用实测数据分别对对数校正模型、双斜率模型和LS-SVM模型进行回归分析,结果如图8所示。其中LS-SVM模型的训练集为A, $\gamma=100, \sigma=0.1$ 。从图中可看出,LS-SVM模型的预测结果和实测数据更接近。




图8 3种模型回归结果

对数校正模型、双斜率模型和LS-SVM模型预测性能指标见表1。可看出利用LS-SVM模型预测的性能指标 μ 和 e_s 比对数校正模型和双斜率模型小得多,而 r 达到了0.998 2,证明了LS-SVM模型的优越性。

表 1 3 种模型预测性能指标

预测模型	μ	e_s	r
对数校正模型	3.499 3	2.877 9	0.944 6
双斜率模型	2.219 2	1.873 0	0.972 6
LS-SVM 模型(训练集 A)	0.532 8	0.531 0	0.998 2

5 结语

采用 LS-SVM 算法建立了矿井巷道场强预测模型,分析了训练集构造和参数选择对模型预测精度的影响。实验结果表明,该模型有效提高了场强预测精度。但本文是在特定频率、巷道环境下的场强预测,模型相对简单,预测范围受到限制。将影响矿井巷道电磁传播的因素,如频率、巷道截面(包括形状和大小)以及天线的位置参数等作为输入,将信道的场强变化作为输出,以此来训练支持向量机模型,从而获得更普遍适用的场强预测模型,将是进一步的研究方向。

参考文献:

[1] 张跃平,张文梅,郑国莘,等. 预测隧道中传播损耗的混合模型[J]. 电子学报,2001,29(9):1283-1286.

[2] 余晨辉. 高速铁路隧道无线传播损耗模型校正[J]. 移动通信,2007,31(12):73-76.

[3] 张跃平,张文梅,盛剑桓,等. 900 MHz 无线电波在地下长壁煤矿的传播[J]. 煤炭学报,2002,27(1):83-87.

[4] FOROOSHANI A E, BASHIR S, MICHELSON D

G, *et al.* A survey of wireless communications and propagation modeling in underground mines[J]. IEEE Communications Surveys and Tutorials,2013,15(4):1524-1545.

[5] 唐秋菊,徐松毅. 基于神经网络的传播预测模型浅析[J]. 无线电工程,2010,40(3):21-23.

[6] 关捷,李国宁,温宇钧. 基于 GRNN 的 GSM-R 场强覆盖预测算法[J]. 铁道标准设计,2014,58(2):106-111.

[7] 顾燕萍,赵文杰,吴占松. 最小二乘支持向量机的算法研究[J]. 清华大学学报:自然科学版,2010,50(7):1063-1066.

[8] 王宇红,黄德先,高东杰,等. 基于支持向量机的非线性预测控制技术[J]. 信息与控制[J]. 2004,33(2):133-136.

[9] 刘瑞芳,梅孝安. 基于最小二乘支持向量机的瓦斯传感器非线性校正[J]. 工矿自动化,2009,35(3):8-12.

[10] 潘磊,李丽娟,丁婷婷,等. 基于改进 PSO 算法和 LS-SVM 的短期电力负荷预测[J]. 工矿自动化,2012,38(9):55-59.

[11] 张全明,刘会金. 最小二乘支持向量机在电能质量扰动分类中的应用[J]. 中国电机工程学报,2008,28(1):106-110.

[12] 吴青,刘三阳,杜喆. 回归型模糊最小二乘支持向量机. 西安电子科技大学学报[J]. 2007,34(5):773-778.

[13] 朱家元,杨云,张恒喜,等. 基于优化最小二乘支持向量机的小样本预测研究[J]. 航空学报,2004,25(6):565-568.