

基于泛函网络的周期来压预测方法研究

崔铁军^{1,2} 马云东²

(辽宁工程技术大学安全科学与工程学院 阜新 123000)¹

(大连交通大学 辽宁省隧道与地下结构工程技术研究中心 大连 116028)²

摘要 为预测周期来压,构建了基于小波和混沌优化的泛函网络(FN)预测方法。该方法利用小波分解技术将所选的样本集数据分解成不同频率的分量。基于混沌理论对分量相空间进行重构。各重构分量分别使用 FN 模型进行训练。最后,将各个 FN 模型得到的预测分量进行小波重组,得到完整的周期来压荷载预测波形。通过在重构时的计算发现,荷载的时序序列有一定的混沌性。通过模拟并与 3 种其它模型进行比较发现,基于小波和混沌优化 FN 的预测模型得到的最终周期来压荷载波的精度更高,收敛性也较好,但是,时间成本较大。

关键词 周期来压预测,小波处理,混沌优化,泛函网络

中图分类号 TP18 **文献标识码** A

Prediction of Periodic Weighting Based on Optimized Functional Networks

CUI Tie-jun^{1,2} MA Yun-dong²

(College of Safety Science and Engineering, Liaoning Technical University, Fuxin 123000, China)¹

(Tunnel & Underground Structure Engineering Center of Liaoning, Dalian Jiaotong University, Dalian 116028, China)²

Abstract In order to improve the prediction the periodic weighting load, this paper proposed a new periodic weighting prediction method based on Functional networks(FN) optimized wavelet analysis and chaos. In the method, selected sample set data is decomposed using wavelet decomposition technique to obtain the different frequency components. The phase space of the components is reconstructed by chaos theory. The reconstructed components are respectively transmitted into FN model to carry on prediction. Finally, all the predicted components got by FN models are reconstructed by wavelet to get complete prediction waveform. The result of the calculation in the reconstruction shows that in a certain period, the load temporal sequence has some chaotic property. Through the comparison between the result of the method and three other models, the final load ware of the method is higher accuracy and convergence, but the cost of time is large.

Keywords Prediction of periodic weighting, Wavelet analysis, Chaos, Functional networks

1 引言

巷道内的液压支架是承受顶板压力的主要构件,在设置支架时要考虑很多因素,其中荷载的形式和变化规律是主要的考察因素。同时要实现工作面的安全高效生产,其周期来压步距及强度也必须掌握。因此必须以科学的方法来正确预测周期来压波形,传统的预测方法主要有:经验估算法、威尔逊估算法、老顶结构平衡关系估算法等^[1]。

目前,关于周期来压的预测研究并不充分。潘一山等对深部开采覆岩应力变化规律模拟进行了试验和研究^[2];刘正和等对大采高放顶煤工作面矿压显现规律进行了研究^[3];许家林等对特大采高综采面关键层结构形态及其对矿压显现规律进行了研究^[4];潘岳等研究了周期来压前受超前隆起分布荷载作用的坚硬顶板弯矩和挠度的解析解^[5];贺超峰等研究了基于 BP 神经网络的工作面周期来压的预测^[1];卢国志等对传递岩梁周期断裂步距与周期来压步距差异进行了分析^[6]。

针对周期来压预测研究较少且准确性差的现状,本文构造了基于泛函网络(Functional networks, FN)^[7]的预测方法,并对 FN 进行了优化。根据现有文献,使用 FN 对时序波的预测已取得良好效果^[8-10],现将这些研究成果应用到周期来压预测。模型的预测首先利用小波分解技术将所选的样本集数据根据不同频率分解成不同的分量。分解后的各分量运用混沌理论进行相空间重构。重构分量使用 FN 模型进行训练。最后,将各个 FN 模型得到的预测结果进行重组,得到完整的预测周期来压荷载波形。将结果与加权一阶局域法、BP 神经网络、混沌对角神经网络预测到的波形相比较,说明了该模型的正确性。

2 研究背景及周期来压的特性

某矿二采区 1212 回采工作面位于北二 12 煤集运巷以西,北邻北二采区 1210-1 采空区,南侧为未采区。工作面设计采高 4.0m,沿顶板推进。采用倾斜长壁后退式综合机械化

本文受国家自然科学基金项目(51050003),辽宁省自然科学基金(201202022)资助。

崔铁军(1983—),男,博士生,工程师,主要研究方向为地下工程结构安全分析及区域安全分析, E-mail: ctj. 159@163. com; 马云东(1964—),男,教授,博士生导师,主要研究方向为安全科学与工程、环境科学与工程。

采煤方法。进刀方式为端部斜切进刀,返往一次割两刀煤,循环进尺为0.8m。

1212工作面开切规格为8.4m×3.5m,采用8m锚索、金属网、钢带联合支护。工作面开采初期采用单向割煤,从尾头推溜。一是为了调整运输机与转载机合理搭接长度;二是为了保证支架平行进入煤壁,支架顶梁进入煤壁后开始对支架大柱压力表进行读数记录。

在工作面建5条测线监测支架工作阻力变化情况,测线位置分别布置在10#、35#、60#、85#、107#左右支架,每个循环末对支架柱压力表读数一次,并将其作为记录结果。本文选取10#的观测数据进行分析,每班次交班时检查液压支架压力,即采样点时间间隔8小时,一共425组数据。10#支架来压荷载实际波形如图1(a)所示。




图1 支架10#小波分解图

根据作者及相关文献研究,在掘进速度保持稳定的情况下,周期来压与掘进距离(掘进时间)可以以某种正弦形式表示,如式(1)所示。

$$y = S \times \sin(2\pi x / T - \pi/2) + D \quad (1)$$

式中, S, T, D 是拟合求得的参数,分别表示周期(T)、缩放系数(S)和纵移系数(D)。 T 表示周期,对 y 表示的是正弦曲线的周期; S 表示缩放系数,对 y 表示的是正弦曲线的振幅程度; D 表示纵移系数,对 y 表示的是正弦曲线的纵向平移量; x 为掘进深度/m。

3 基于泛函网络的周期来压预测建模

3.1 预测机理

论文基于小波和混沌优化的FN方法进行预测。根据现有文献,使用FN对时序波进行预测已取得良好效果。将这些研究成果应用到周期来压预测。模型的预测首先利用小波分解技术将所选的样本集数据根据不同频率分解成不同的分量。分解后的各分量运用混沌理论进行相空间重构。重构分量使用FN模型进行训练,进而进行预测。最后,将各个FN模型得到的预测结果进行重组,得到完整的预测周期来压荷载波形。

3.2 泛函网络理论

FN是1998年由E-Castillo提出的,是人工神经网络的一般化推广。FN处理的是一般泛函模型,网络中各个神经元之间的连接不存在权重上的区别,并且神经元内的映射函数不是固定的,因此模型是一个给定的基函数族。人们可根据特定问题来选择不同的基函数族(如多项式、三角函数、Fourier展开级数等)以满足不同系统问题的建模和逼近。

FN对应的是泛函变换,它的拓扑结构描述的是一个函数变换系统。一般地,FN主要由5部分组成:输入单元层、一

层或多层泛函神经元(处理单元)、若干个中间存储层、输出层以及若干个直接连接。一般的FN模型如图2所示。




图2 泛函网络模型

(1)一个输入单元层。其功能是输入信息,在图2中输入单元包含 $\{x_1, x_2, x_3\}$ 。输入单元以带有相应名字的实心圆来表示。

(2)若干中间存储单元层。它存储由神经元产生的信息,在图2中只有一个中间存储单元层,包含 $\{x_4, x_5\}$ 。其也以带有相应名字的实心圆来表示。

(3)一层或多层泛函神经元(或称处理单元)。每个泛函神经元是一个计算单元,它计算的是一组来自前一层神经元或输入单元的输入值,并给下一层神经元或输出单元提供数据。计算单元相互连接,每一个神经元的输出可作为另一个神经元或者输出单元输出数据的一部分,一旦给定输入值,输出便由神经元的类型来确定,它由一函数定义。在图2中有两层泛函神经元,分别为 $\{f_1, f_2\}$ 和 $\{f_3\}$ 。

(4)一层输出层。这是最后一层单元,它输出网络的结果是数据,输出单元也以带有相应名字的实心圆来表示,图2中为 $\{x_6\}$ 。

(5)一些直接连接。它们连接输入层、中间层神经元和输出层,在图2中用箭头表示,箭头的方向表示信息流的方向。

FN有各式各样的结构,其中可分离泛函网络应用最为广泛,它的泛函表达式是各输入变量分离作用效果的组合,本文使用可分离FN进行预测。图3所示为一个简化的可分离泛函网络模型,这里用它来说明泛函网络的训练过程。




图3 可分离泛函网络模型

泛函神经元 $f_1, f_2, \dots, f_d$ 由基函数族 Φ_k 线性组合而成,基函数族可依据实际情况进行选取。结合图3可得该FN的输入输出关系,如式(2)所示。

$$y = \sum_{k=1}^d \bigwedge_{j=1}^{m_k} a_{kj} \phi_{kj}(x_k) \quad (2)$$

式中, a_{kj} 为FN参数。

设训练数据集为 $\{(x_{i,1}, x_{i,2}, \dots, x_{i,d}; y_i) | i=1, 2, \dots, N; N > d\}$, N 为训练数据个数。FN训练误差如式(3)所示,网络的初始条件如式(4)所示。

$$e_i = y_i - \sum_{k=1}^d \sum_{j=1}^{m_k} a_{kj} \phi_{kj}(x_k) \quad (3)$$

$$f_k(x_0) = \sum_{j=1}^{m_k} a_{kj} \phi_{kj}(x_{k0}) = v_{k0}, k=1, 2, \dots, d \quad (4)$$

使用拉格朗日乘数法可得到目标函数,如式(5)所示。

$$Q_d = \sum_{i=1}^N (y_i - \sum_{k=1}^d \sum_{j=1}^{m_k} a_{kj} \phi_{kj}(x_{i,k}))^2 + \sum_{k=1}^d \lambda_k (\sum_{j=1}^{m_k} a_{kj} \phi_{kj}(x_{k0}) - v_{k0}) \quad (5)$$

FN 最优参数,可解线性方程组,如式(6)所示。

$$\begin{cases} \frac{\partial Q_p}{\partial a_{pr}} = -2 \sum_{i=1}^N (x_{i,d} - \sum_{k=1}^d \sum_{j=1}^{m_k} a_{kj} \phi_{kj}(x_{i,k})) \phi_{pr}(x_{i,p}) + \\ \lambda_p \phi_{pr}(x_{p0}) = 0 \\ \frac{\partial Q_p}{\partial \lambda_p} = \sum_{j=1}^{m_k} a_{pj} \phi_{pj}(x_{p0}) - v_{p0}, p=1,2,\dots,d, r=1,2,\dots,m_p \end{cases} \quad (6)$$

3.3 泛函网络的构建

3.3.1 数据的小波分解

预测数据样本集繁多且存在一定的非平稳性、非线性,使得 FN 的预测精度会受到影响。为了解决这一问题,利用小波分析方法的多分辨率分析对数据进行分层次处理^[11]。支架荷载的采样点是对于时间而言的,在时间上是离散的。对于这种情况,可以使用 Mallat 快速算法实现离散小波变换。Mallat 算法是运用小波滤波器对离散信号进行低通和高通的滤波过程。

设第 i 尺度上的低频分量是 a_i , 高频分量是 d_i , 正交小波滤波器分别为 h (低通)和 g (高通),则某尺度上的小波分解和合成的 Mallat 算法表示如式(7)和式(8)。分解和合成过程如图 4 和图 5 所示。

$$\begin{cases} a_i(k) = \sum h(n-2k) a_{i-1}(n) \\ d_i(k) = \sum g(n-2k) a_{i-1}(n) \end{cases} \quad (7)$$

$$a_{i-1}(n) = \sum_k h(n-2k) a_i(k) + \sum_k g(n-2k) d_i(k) \quad (8)$$




图 4 Mallat 算法的分解过程




图 5 Mallat 算法的合成过程

用 Mallat 小波分析方法对该 10# 支架来压荷载进行分解,使用 matlab 中 dwt 的正交小波基(db4)进行 3 级分解,共分解出 4 个分量,其中, a_1 为低频分量(趋势项), d_1, d_2, d_3 为各等级高频分量。分解的分量图分别见图 1(b)~(e)。

3.3.2 混沌性辨识与相空间重构

预测模型的训练样本是通过时间序列进行相空间重构^[12]产生的。对该空间的重组首先要证明其混沌性。通过计算混沌吸引子的维数和 Lyapunov 特征指数来识别其混沌性。液压支架周期来压荷载在不同周期下循环形成的时序图如图 6 所示。




图 6 不同周期下系统的混沌情况

图 6 中 $(D, C)_{T=20} = (1.484, 0.9749)$, $(D, C)_{T=18} = (1.481, 0.9826)$, $(D, C)_{T=16} = (1.464, 0.9876)$, $(D, C)_{T=14} = (1.485, 0.9782)$, 其中 D 为关联维, C 为相关系数。

从图 6 可以看出,系统在 $T=16$ 时更接近混沌。根据 G-P 算法计算出时间序列的关联维 d , 嵌入维数 $m=2d+1$ 。根据本例数据可求得 $m=3$ 。利用互信息法求得相空间重构的时间延迟 $\tau=2$ 。利用小数据量法求得平均周期为 $T=15.44$, Lyapunov 指数为 $\lambda>0$ 。由此可知,周期来压时间序列具有混沌特性^[12]。

相空间重构认为系统的每个分量的演化均受到相关联的其他分量的影响。因此在重构时,考察一个分量,并将它在某个固定的时间延迟上的测量作为增维处理,以确定某多维状态空间的一点。不断重复上述过程并对于不同时间测量各延迟量,可以产生大量这样的点,这样吸引子的许多性质便保留下来,就可以通过采用系统的一个分量重构原动力系统模型,初步确定系统的真实相空间的维数^[13,14]。

设 10# 支架的周期来压荷载数据为 $\{x(t)\}$, $t=1,2,\dots,n$, 其中 n 为样本个数。根据 Takens 定理,延迟时间(τ)和嵌入维(m)就可以将混沌时间序列进行重构,如式(9)所示。

$$X_n = (x_n, x_{n+\tau}, \dots, x_{n+(m-1)\tau}) \quad (9)$$

同样也可采用 C-C 法进行相空间重构,具体计算过程见文献^[15]。

3.4 周期来压预测建模建立步骤

通过上述论述,论文提出的基于 FN 的周期来压预测流程如图 7 所示。




图 7 基于 FN 的周期来压预测流程

这里使用小波分解后的 4 个时序序列波形进行预测,使用时序序列的前 350 个点作为训练集合,后 75 个点作为模拟对比集合。针对本例,与混沌相关的参数在第 3 节已计算列出。预测形成的各个频率的 4 条时序序列波进行小波重组后形成最终的周期来压荷载预测波。

为对比该模型的性能,这里构建了 3 个模型,分别为:加权一阶局域法预测、BP 神经网络预测、混沌对角神经网络预测^[16],在数据和相关条件相同且各个模型达到最优时进行模拟。为了评价模型性能,采用均方误差(mean squared error, MSE)和平均相对百分比误差(mean absolute percent error, MPAE)作为模型性能的评价指标,它们的定义分别如式(10)和式(11)。

$$MSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (x_t - \hat{x}_t)^2} \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{x_t - \hat{x}_t}{x_t} \right| \times 100 \quad (11)$$

式中, x_t 表示支架周期来压荷载的实际观测值, $\hat{x}_t$ 表示荷载的预测值, n 表示样本数。

4 实例及分析

几个模型的预测曲线如图 8 所示。几个模型构建和评价结果如表 1 所列。




图 8 4 个模型的预测曲线与实际曲线的对比图

表 1 4 个模型构造和评价指标结果

模型	参数	构造	MSE	MAPE
模型 1		采用混沌理论(样本重构)与加权一阶局域法预测	7.7122	23.1545%
模型 2		采用混沌理论(样本重构)与 BP 神经网络相结合的预测方法	5.7106	17.2672%
模型 3		混沌对角神经网络预测[16]	3.1958	8.9872%
本模型		见图 7	1.2085	2.4731%

模型 1 为加权一阶局域法,其预测是通过线性拟合时序序列实现的。其优点是计算结构复杂度低,计算方便,速度在这 4 个模型中。但是,支架所受的周期来压荷载在很大程度上是混沌的,是非线性的,所以该方法的精度是最低的。

模型 2 使用 BP 神经网络。神经网络的自适应非线性构造适合于对非线性系统进行预测,其精度高于模型 1。但是 BP 神经网络学习方法是经验风险最小化原则,容易出现过拟合,使其精度严重降低。同时,使用神经网络的时间成本要比模型 1 大。

与神经网络 BP 预测相比,模型 3 具有很好的预测效果,且收敛速度加快,并提高了预测精度。基于文献[12]对混沌对角神经网络预测模型的论述,说明模型 3 是目前比较优秀的预测方案。

本模型的性能如表 1 所列,就 MSE 和 MAPE 而言,其比传统的模型 1 和模型 2 有很大提高;与不久前提出的混沌对角神经网络预测模型相比,其预测性能也有所进步。但是,性能提高的代价就是时间成本略微偏高。对于液压支架周期来压荷载这种数据形成的非线性且具有一定混沌性的相空间,使用基于 FN 进行预测的结果更为精确。但是为了能将其用于实际矿区液压支架周期来压荷载的实时监测预测,进而进行预警,就要降低其计算的时间成本,这也是下一步研究的内容。

结束语 论文针对液压支架周期来压荷载的预测问题,提出了基于 FN 模型的预测方法。主要结论如下:

1. 通过混沌理论的相空间重构过程分析,并结合液压支架周期来压荷载的实际数据,发现就这组时序序列而言, $T=16$ 时的系统空间的相是混沌的,并通过计算说明了这点。即周期来压在某周期下显现出混沌的特性。

2. 基于该时序序列的混沌性,构造了基于 FN 模型的预测方法。小波用于对原波形进行分解。对分解后的波进行相空间重构。用 FN 结合重构波进行训练,使用训练后的 FN 来进行预测。最后将各个预测波进行小波重构,形成最终周期来压荷载的时序序列预测波。

3. 为说明该模型性能的优越性,构建了 3 个相关模型并进行了性能预测比较。表 1 的对比结果显示,论文提出的方法在收敛性和精度方面都优于其它 3 种方法。但是,其时间成本较大。

参考文献

[1] 贺超峰,华心祝,杨科,等. 基于 BP 神经网络的工作面周期来压预测[J]. 安徽理工大学学报:自然科学版,2012,32(1):59-63

[2] 潘一山等. 深部开采覆岩应力变化规律模拟试验研究[J]. 中国地质灾害与防治学报,2011,22(3):61-66

[3] 刘正和,赵阳升,弓培林,等. 大采高放顶煤工作面矿压显现规律的研究[J]. 太原理工大学学报,2011,42(5):524-527

[4] 许家林,鞠金峰. 特大采高综采面关键层结构形态及其对矿压显现规律的研究[J]. 岩石力学与工程学报,2011,30(8):1547-1556

[5] 潘岳,顾士坦,戚云松. 周期来压前受超前隆起分布荷载作用的坚硬顶板弯矩和挠度的解析解[J]. 岩石力学与工程学报,2012,31(10):2053-2063

[6] 卢国志,汤建泉,宋振骐. 传递岩梁周期断裂步距与周期来压步距差异分析[J]. 岩土工程学报,2010,32(4):538-541

[7] Castello E. Functional networks[J]. Neural Proc Lett,1998,7:151-159

[8] Castello E, Gutierrez J M. Nonlinear time series modeling and prediction using functional networks, extracting information masked by chaos[J]. Phys, Lett A,1998,244:71-84

[9] Castello E, Cobo A, Gutierrez J M. Working with differential functional and difference equations using functional networks[J]. Apply Math Model,1999,23:89-107

[10] Castillo E, Cobo A, Gutierrez J M. Functional networks with applications[M]. [S. l.]:Kluwer Academic Publishers,1999

[11] 陈民铀,杨艳利,何为. 等基于粒子群优化算法的电阻抗图像重建[J]. 重庆大学学报,2011,34(1):82-87

[12] 席剑辉. 混沌时间序列的长期预测方法研究[D]. 大连:大连理工大学,2005

[13] 孙韩林,金跃辉,崔毅东,等. 粗粒度网络流量的灰色模型预测[J]. 北京邮电大学学报,2010,33(1):7-11

[14] 谢高岗,闵应骅,张大方,等. 一个基于实际测试的网络流量模型[J]. 计算机工程与科学,2001,23(5):51-54

[15] Kim H S, Eykholt R, Salas J D. Nonlinear dynamics, delay times, and embedding windows[J]. Physica D,1999,127:48-60

[16] 李占英,王科俊,徐亮,等. 混沌对角递归神经网络的船舶横摇预报方法[J]. 控制与决策,2012,27(11):1681-1693