

# 基于小波降噪和神经网络的 GPS 高程时序预测模型

张仕森, 孙宪坤, 尹玲, 李世奎

(上海工程技术大学 电子电气工程学院, 上海 201620)

**摘要:** 全球定位系统(GPS)时序数据预测的工作中发现,通常时序数据中含有的噪声会干扰数据预测的结果.为了降低时序数据中噪声对预测结果的负面影响,将提升小波阈值降噪技术和长短期记忆(LSTM)神经网络相结合,实现一种 GPS 时序数据降噪预测模型.该模型在预测之前首先利用提升小波与平滑阈值函数对 GPS 时序数据中的噪声进行剥离,然后构建多层 LSTM 神经网络对时序数据进行单步预测.通过实验与多种时间序列预测模型进行对比,结果表明所提出的 LSTM 预测模型对 GPS 时间序列的预测具有较强的适用性和较高的准确性.

**关键词:** 提升小波变换;阈值;全球定位系统;时间序列;长短期记忆神经网络

**中图分类号:** TP391 **文献标志码:** A **文章编号:** 1008-9268(2019)03-0117-09

## 0 引言

全球定位系统(GPS)能够反映出时间与地理位置的变化信息.通过对 GPS 时序数据进行预测能为环境和灾害的监控等各方面工作带来极大方便.对得到的预测结果中的异常波动进行分析,可以尽可能在地质灾害尚未发生时发出预警,减少人员伤亡和经济损失.

传统的时间序列预测方法如带控项的自回归模型(CAR)、滑动平均模型(MA)以及自回归滑动平均模型(ARMA)<sup>[1]</sup>等都属于统计学范畴的线性模型,适用于季节性、周期性等特征平稳的线性时间序列预测.对于非线性、非平稳的 GPS 时间序列,由于线性模型不能全面反映时间序列的复杂变化特征,导致传统的线性模型难以适用于这一类问题的预测<sup>[2]</sup>.文献[3]将自回归求和滑动平均模型(ARIMA)用于对非线性的 GPS 时序进行建模预测,ARIMA 模型是将非线性序列转化为线性序列的一种预测方法.虽然 ARIMA 模型的预测效果相对于传统方法较好,但是它计算复杂、运算量大,并

且需要大量先验知识的储备.

人工神经网络(ANN)作为一种非线性的数据预测方法,具有良好的自适应能力,不需要先验知识的积累,因此更适用于实际工作中非线性时间序列的预测<sup>[4]</sup>.文献[5]运用反向(BP)神经网络,采用 Levenberg-Marquardt 算法进行训练,对电力负荷数据进行了预测研究.但是该预测方法受到 BP 神经网络结构简单和学习泛化能力较差的影响,难以达到很高的预测精度.文献[6]的研究表明循环神经网络(RNNs)作为一种包含循环结构的 ANN,能够结合时间序列过去时刻的信息,预测效果相对于结构简单的 BP 神经网络更好,但是在实际应用中存在着“梯度消亡问题”,导致训练速度慢、耗时长.文献[7]提出的长短期记忆(LSTM)神经网络则是一种特殊的 RNNs,能够学习时序数据之间的长期依赖关系,解决了 RNNs 中出现的梯度消亡问题<sup>[8]</sup>,对于处理时间序列相关的问题有很好的效果.

由于测量误差、人为操作等原因,实际获得的

收稿日期: 2019-01-21

资助项目: 国家自然科学基金青年基金项目(61802251);上海市科学技术委员会科研计划项目(16dz1206000);上海工程技术大学科研项目(E3-0501-18-01043).

通信作者: 张仕森 E-mail: abcdefg890@vip.qq.com

GPS 时序数据含有一定噪声,噪声会弱化时间序列数据之间的相关性从而影响预测结果.单一的神经网络模型无法处理噪声问题,将神经网络与去噪算法结合变得越来越重要.平滑去噪处理法容易导致信号失真,傅里叶变换滤噪法计算量大并且在有用信号和噪声频谱重叠部分去噪效果不好,卡尔曼滤波法则需要准确的系统运动规律,维纳滤波法仅适用于处理平稳信号,而小波变换因其具有多分辨率、低熵性、去相关性等特点,在分析处理非线性信号方面具有明显优势<sup>[9-10]</sup>.在基于小波变换的去噪算法中,模极大值去噪法对小波分解尺度的选取要求很高,容易产生伪极值点或丢失某些局部奇异性;相关性去噪算法在信号边界去噪效果稳定,但其需要估计噪声的方差,计算量较大.文献[11]证明小波阈值去噪算法适用于信号中含有白噪声的情况,能够很好地保留原始信号的重要特征,并且计算速度较快.上述小波变换方法在信号去噪时通常采用 Mallat<sup>[12]</sup>算法,这种方法计算复杂、对内存占用高,在自身构造和对信号进行时频转换时需要耗费大量的系统资源.文献[13]用提升小波变换对多普勒雷达信号实现了去噪处理,取得了良好的效果.提升小波变换被称为第二代小波变换,相对于传统小波变换依赖于复杂卷积计算,提升小波变换的算法更加简洁、计算速度快、内存占用低、实现简单,并且继承了小波变换的多分辨率特性<sup>[14]</sup>.

参考上述文献,综合考虑到 GPS 时序数据的自身特性和各种小波变换方法的计算速度、资源占用等因素,本文将提升小波阈值降噪技术与 LSTM 神经网络相结合,以时序数据自身为训练数据和输出标签,充分利用降噪后数据之间的相关性,通过迭代训练的方式,建立 GPS 高程时序数据单步预测模型.实验结果表明该模型减少了原始数据中噪声对于预测结果的负面影响,提高了预测精度,并且该方法计算速度快、资源占用较少.

## 1 提升小波平滑阈值降噪算法

### 1.1 提升小波变换

为了增强时序数据之间的相关性,本文利用提升小波阈值降噪算法对原始数据中含有的噪声进行剥离.提升小波变换是由 Sweldens 提出的一种小波变换的简化计算方法,由于它的分解与重构部分结构相同,因此可以降低运算复杂度,减少系统

资源占用,快速实现小波变换<sup>[15]</sup>.

提升小波变换对信号的分解包括分裂(split)、预测(predict)、更新(update)三个过程.

提升小波首先将原始信号  $S_j$  按序号奇偶分为两部分:偶数序列  $e_{j-1}$  与奇数序列  $o_{j-1}$ .由于信号之间具有局部相关性,这样某一点的信号值可以通过与其相邻的信号值和适当的预测算子计算出来,同时计算出来的误差就是高频系数  $d_{j-1}$ ,这个计算过程称为预测环节.预测环节得到的高频系数再通过更新算子  $U$  来调节信号的下采样过程获得低频系数  $s_{j-1}$ ,这个过程则是更新环节.通过预测环节与更新环节可以得到信号的高频部分和低频部分.

提升小波变换的重构则是分解的一个逆过程,即根据得到的小波近似系数  $s_{j-1}$  以及  $P$  和  $U$  算子求出新的偶数序列  $e'_{j-1}$  和奇数序列  $o'_{j-1}$ ,最终将新得到的奇偶序列合并来获得重构信号  $S'_j$ .

### 1.2 阈值的选取规则

人们的研究发现,在小波域中,有效信号和噪声具有不同的特性,噪声的能量一般集中于高频部分<sup>[16]</sup>,因此小波降噪的核心内容是对信号的高频部分进行过滤,以达到信噪分离的目的.

提升小波阈值降噪的具体处理过程为对原始信号进行提升小波变换分解,得到信号高频部分和低频部分后,通过设定阈值的方式对高频部分进行非线性阈值处理.

本文采用的是 Donoho 提出的全局阈值法<sup>[17]</sup>,其定义为

$$\begin{cases} thr = \sigma \sqrt{2 \ln N}, \\ \sigma = median(|d_{j-1}|) / 0.6745. \end{cases} \quad (1)$$


式中:  $thr$  为阈值;  $N$  为每层小波高频系数序列的长度值;  $median(\cdot)$  为求中值函数;  $\sigma$  为噪声估计的标准差.

常用的阈值函数分为硬阈值函数和软阈值函数<sup>[18]</sup>.硬、软阈值函数的表达式为式(2)、(3),函数曲线如图 1(a)、(b) 所示.


$$d'_{j-1} = \begin{cases} d_{j-1}, & |d_{j-1}| \geq thr, \\ 0, & |d_{j-1}| < thr, \end{cases} \quad (2)$$

$$d'_{j-1} = \begin{cases} \text{sgn}(d_{j-1})(|d_{j-1}| - thr), & |d_{j-1}| \geq thr, \\ 0, & |d_{j-1}| < thr. \end{cases} \quad (3)$$

式中:  $d'_{j-1}$  为经过阈值处理后的高频部分.



(a) 硬阈值函数特性图 (b) 软阈值函数特性图



(c) 平滑型阈值函数特性图

图 1 不同阈值函数的特性图

### 1.3 平滑形阈值函数

由于硬阈值函数在小波域内不连续,会在 $(\pm thr)$ 阈值处产生间断,从而会导致重构后的信号出现伪吉布斯现象.软阈值函数则在小波域的连续性较好,但在阈值处理过的系数与原系数之间总是存在一个偏差值,造成部分高频系数损失,从而导致重构后的信号存在一定误差.

平滑型阈值函数是针对软阈值函数的一种改进,在软阈值函数的基础上对阈值点处建立一个平滑过渡区,减少了高频系数的损失,使得阈值处理后的信号更加符合信号的自然连续性.平滑型阈值函数的表达式为式(4),函数曲线如图 1(c)所示.

$$d'_{j-1} = \begin{cases} d_{j-1} + thr - \frac{thr}{2k+1}, & d_{j-1} < -thr, \\ d_{j-1} - thr + \frac{thr}{2k+1}, & d_{j-1} > thr, \\ \frac{d_{j-1}^{2k+1}}{(2k+1)thr^{2k}}, & |d_{j-1}| \leq thr. \end{cases} \quad (4)$$

式中: $thr$ 为阈值; $k$ 为提升小波对信号的分解层数.

最后将经过阈值处理的高频部分和保留的低频部分进行重构,得到降噪后的信号 $S'_j$ .

提升小波阈值降噪的过程如图 2 所示.




图 2 提升小波阈值降噪的过程

## 2 GPS 高程时序预测模型建立

### 2.1 GPS 坐标时间序列分析

高精度 GPS 坐标时间序列是将台站的连续观测数据经过解算后得到的位置信息序列.近几十年来,国际上已建立了很多 GPS 台站和网络.我国的国家大型科学工程重大项目“中国地壳运动观测网络”包括多个分布在中国大陆上的 GPS 连续观测基准台站,如图 3 所示,具有很好的稳定性,成为中国形变监测的基准框架.

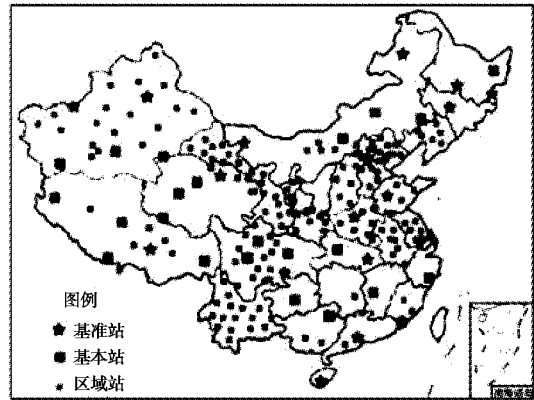


图 3 中国地壳运动观测网络台站分布

国内 GPS 坐标时间序列运动主要表现为板块水平方向运动和板块高程方向运动.符养<sup>[19]</sup>通过对 GPS 时间序列进行计算分析,获得了全球高程时间序列的振荡特性;张鹏研究了我国地壳运动观测网络基准站的坐标位置变化规律,发现位于中国境内的 GPS 时间序列在高程方向分量的周期性最为明显<sup>[20]</sup>.因此,研究 GPS 高程方向时间序列更加有利于分析大陆板块运动规律,以及对地质灾害

的预测。

GPS 时间序列中若包含了非长期趋势项、阶跃项、噪声项以及季节项,那么 GPS 时间序列就会表现出显著的非线性变化,传统的线性模型则难以适用于这一类问题的预测。

本文使用 LSTM 对时间序列具有强辨别力和学习能力,通过学习相关数据之间复杂的非线性关系,克服了 BP 神经网络较差的学习泛化能力的影响以及 RNNs 的梯度消亡问题,对于处理非线性时间序列有很好的效果. 与传统方法相比,LSTM 神经网络更加灵活,不依赖于输入数据的特性且大多不需要先验知识的储备。

### 2.2 RNNs

#### 2.2.1 RNNs 原理

RNNs 是一种包含循环结构的神经网络. 相对于全连接神经网络和卷积神经网络(CNN),RNNs 的各个隐藏层之间不再是相互独立的,循环结构可以将当前时刻隐藏层的状态传递到下一时刻的隐藏层<sup>[21]</sup>。




图 4 RNNs 隐藏层单元展开图

如图 4 所示,RNNs 隐藏层的输入不仅包括输入层的输出,还包括上一时刻隐藏层的输出. 其中  $X$  为 RNNs 的输入, $h$  为 RNNs 的输出, $C_t$  为隐藏层的状态.  $U, V, W$  分别是输入到隐藏层、隐藏层到输出、隐藏层到隐藏层的权重. 在 RNNs 中,每一层的参数  $U, V, W$  都是共享的,这样的训练方式降低了神经网络需要学习的参数,缩短了训练时间。

#### 2.2.2 RNNs 的缺陷

在实际应用中,RNNs 存在这样一个问题:若 RNNs 需要的几个信息在时间序列上相隔较远,那么较远的信息对输出的影响要么衰减得很小,要么呈指数爆炸增长,这个问题通常被称为“梯度消亡问题”<sup>[8]</sup>。

### 2.3 LSTM 神经网络

#### 2.3.1 LSTM 原理

LSTM 是一种特殊的 RNNs,具有和 RNNs

相似的单元结构,但是它不再只是用一个单一隐藏层的状态  $C_t$ ,而是增加了三个相互作用的门结构,分别是遗忘门、输入门和输出门,如图 5 所示。




图 5 LSTM 的单元结构

#### 2.3.2 遗忘门

遗忘门会根据当前时刻的输入  $X_t$  和上一时刻的输出  $h_{t-1}$  来计算一个 0-1 之间的值  $f_t$  作为上一时刻信息通过的比重,其中 0 表示全部舍弃,1 表示全部保留:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \tag{5}$$

#### 2.3.3 输入门

输入门则会根据当前时刻的输入  $X_t$  和上一时刻的输出  $h_{t-1}$  来决定 LSTM 神经网络获得哪些新信息:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \tag{6}$$

同时输入门会创建一个临时的隐藏层状态  $C'_t$ ,通过与  $i_t$  的结合来更新隐藏层状态  $C_t$ :

$$C'_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c), \tag{7}$$

更新后的隐藏层状态  $C_t$  为

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C'_t, \tag{8}$$

#### 2.3.4 输出门

输出门会根据上一时刻的输出  $h_{t-1}$ 、当前时刻的输入  $X_t$  以及当前时刻的隐藏层状态  $C_t$  共同得出当前时刻神经网络的输出  $h_t$ 。

$$\begin{cases} o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \\ h_t = o_t \cdot \tanh(C_t). \end{cases} \quad (9)$$

根据上述公式进行前向计算得到神经网络的输出后,利用时间反向传播(BPTT)算法进行迭代训练,最终获得神经网络所需要的权重参数。

### 2.4 基于 LSTM 神经网络的 GPS 时序预测模型

由于测量误差、人为操作等原因,在实际工作中获得的 GPS 时间序列含有一定噪声,这些噪声会干扰数据预测的结果,造成不必要的误差。

因此本文在训练前先对 GPS 时序数据进行了阈值降噪处理,然后将降噪后的时序数据输入 LSTM 神经网络使用,迭代训练的方法进行单步预测,并得到预测结果。GPS 时序预测模型流程如图 6 所示。




图 6 GPS 时序预测模型流程图

## 3 实验结果与比较

### 3.1 评价指标

本文采用平均百分比误差(MAPE)和均方根误差(RMSE)作为评价预测结果好坏的两个指标:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{observed_i - predicted_i}{observed_i} \right| \times 100, \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (observed_i - predicted_i)^2}. \quad (11)$$

式中:  $observed_i$  为第  $t$  天的真实值;  $predicted_i$  为第  $t$  天的预测值;  $n$  为预测总天数。平均百分比误差和均方根误差越小,代表模型预测的结果越好。


### 3.2 实验结果与比较

本程序运行环境:Windows 10 64 位操作系统, Tensorflow1.4; CPU Intel Core i7 2.80 GHz, RAM 8.00 GB。按照前人研究经验,将 LSTM 神经网络训练参数设置为: Learning-rate、batch-size 和 time-step 分别为 0.0008、60 和 10。


实验数据采用中国地震局 GNSS 数据产品服

务平台下载的 GAMIT 解算的 IGS 基准站 SHAO 的 2007 年 9 月 29 日到 2014 年 4 月 18 日的站心坐标系高程数据。其中以 2007 年 9 月 29 日到 2014 年 2 月 17 日的数据作为训练数据,以 2014 年 2 月 18 日至 2014 年 4 月 18 日的数据作为测试数据。

降噪前后的 GPS 时序数据如图 7(a)、7(b)、7(c)、7(d)所示。图 7(a)示出的是未经过降噪处理的原始 GPS 高程时序数据,由图可以看出,原始数据的曲线形态较差,含有大量毛刺、波动较大。7(b)示出了经过经验模式分解降噪后的 GPS 高程时序曲线。图 7(c)、(d)则是分别使用软阈值函数和平滑阈值函数对 GPS 高程时序数据进行降噪处理后的时序曲线。与原始数据相比,经过处理后的时序曲线更加圆滑,毛刺大量减少并且波动范围更小。




(a)原始 GPS 时序数据




(b)经验模式分解(EMD)降噪后的 GPS 时序数据





(c) 提升小波软阈值函数降噪后的 GPS 时序数据



(d) 提升小波平滑阈值函数降噪后的 GPS 时序数据

图 7 GPS 时序数据降噪效果图

图 8 为 LSTM 神经网络训练误差下降曲线图,以同样训练 1000 轮为例,可以看出时序数据采用 EMD 降噪法或提升小波降噪法后训练的收敛速度均快于原始数据,并且在 500 轮左右基本完成收敛。




图 8 LSTM 神经网络训练误差下降曲线

经过提升小波降噪后的 GPS 时序数据在最终 1000 轮完成后的训练误差小于原始 GPS 时序数据和 EMD 降噪后时序数据的训练误差,可见当训练数据的相关性增强后,LSTM 神经网络的学习效率也随之提高。

图 9 为原始的 GPS 高程时序数据通过 ARIMA 模型进行建模预测得到的预测数据(点线)与原始数据(直线)的曲线图。




图 9 ARIMA 模型未降噪数据预测图

图 10 示出的是原始 GPS 高程时序数据未经任何降噪处理直接送入双层 LSTM 神经网络进行建模训练得到的预测结果。




图 10 LSTM 神经网络未降噪数据预测图

图 11 所示的是 GPS 高程时序数据经过软阈值函数,将小于阈值的数值置零,大于阈值的数值保留,得到的时序数据曲线.图 12 则是 GPS 高程时序数据经过平滑阈值函数降噪后得到的时序数据曲线图,再将上述两种降噪方法得到的时序数据分别送入双层 LSTM 神经网络进行建模预测,得

到的预测结果图。




图 11 软阈值函数降噪的 LSTM 神经网络模型数据预测图




图 12 平滑阈值函数降噪的 LSTM 神经网络模型数据预测图

对比不同方法实验的结果如图 13 和表 1 所示:





图 13 不同方法对比图


表 1 MAPE 和 RMSE 的比较

模型	MAPE %	RMSE
ARIMA 模型(时序数据未降噪)	9.15	0.004 82
单一 LSTM 神经网络模型(时序数据未降噪)	8.83	0.004 35
软阈值降噪 + LSTM 神经网络模型	2.07	0.000 74
平滑阈值降噪 + LSTM 神经网络模型	1.66	0.000 70


为验证所提出的高程 GPS 时序预测模型的适用性,将临沧(YNLC)台站 2010—2016 年测得的高程 GPS 时序数据用于训练本文提出的神经网络预测模型,其模型参数设置完全相同.以 2017 年 7 月 9 日至 2017 年 9 月 8 日的高程时序数据做测试, GPS 高程时序预测模型得到的预测结果如图 14(a), (b), (c)所示.其中图 14(a)示出的是 YNLC 的高程时序数据未经过任何降噪处理而得到的预测结果,图 14(b)则示出了将 YNLC 站高程时序数据通过平滑阈值降噪处理后再通过预测模型得到的预测效果.图 14(c)则将原始数据与两种预测方法得到的预测数据共同展示,从图中可以看出,经过降噪处理得到的预测曲线更加圆滑及贴合原始高程时序数据的走势.



(a)时序数据未降噪处理



(b) 时序数据经过降噪处理



(c) 效果对比图

图14 YNLC站不同方法对比图

预测结果的好坏需参考预测结果的评价指标值和得到的预测序列的曲线形态。对比分析图9~13以及表1可以看出,对未降噪数据进行预测的ARIMA模型与单一LSTM神经网络模型,其预测结果的MAPE相近,分别为9.15%和8.83%。同时两种方法的RMSE也十分接近,分别为0.00482与0.00435。其中ARIMA模型建模复杂,运算量大,且需要大量先验知识的积累,而LSTM神经网络则具有良好的自适应性,建模训练简单、资源占用较少。提升小波软阈值降噪技术或平滑阈值降噪技术分别与LSTM神经网络相结合后,得到预测结果的平均百分比误差以及均方根误差均小于时序数据没有经过降噪处理的单一神经网络预测模型,表明噪声是影响预测结果准确度的一个因素。其中基于提升小波平滑阈值降噪技术的LSTM神经网络预测模型的两个评价指标分别为1.66%和0.00070,均小于传统软阈值函数降噪的

方法,并结合图14(a),(b),(c),证明该模型在使用效果上具有更好的准确性与适用性。

## 4 结束语

本文利用LSTM神经网络对GPS高程时序数据进行预测,并借助提升小波阈值降噪技术对原始时序数据中的噪声进行剥离,解决了由于噪声弱化了数据间的相关性而影响预测结果的问题。实验结果表明,本文提出的基于提升小波平滑阈值降噪技术和神经网络的GPS高程时序预测模型结果的平均百分比误差和均方根误差分别为1.66%和0.0007,均小于ARIMA模型、单一LSTM神经网络模型以及基于软阈值函数降噪的神经网络模型的预测结果MAPE和RMSE,这表明本文模型对预测结果的准确度较高。预测时通过当天的数值预测出下一天的数值,使得预测模型不需要保存之前大量的运算数据,大大降低了因为保存数据带来的额外开销,减少了对系统资源的占用,具有良好的适用性。

## 参考文献

- [1] 张哈,王霞. 基于小波分解的网络流量时间序列建模与预测[J]. 计算机应用研究, 2012, 29(8):3134-3136.
- [2] 王书芹,华钢,郝国生,等. 基于灰狼优化算法的长短期记忆网络在时间序列预测中的应用[J]. 中国科技论文, 2017, 12(20):2309-2314.
- [3] 吴志华,丁杨斌,申功勋. 非平稳时序分析在GPS伪距观测值建模中的应用[J]. 系统仿真学报, 2008, 20(16):4252-4254,4260.
- [4] 魏鸿浩,贾云峰. 一种非平稳非线性频谱占用度时间序列分析方法[J]. 电子学报, 2017, 45(8):2026-2030.
- [5] 龙勇,苏振宇,汪於. 基于季节调整和BP神经网络的月度负荷预测[J]. 系统工程理论与实践, 2018, 38(4):1052-1060.
- [6] COULIBALY P, BALDWIN C K. Nonstationary hydrological time series forecasting using nonlinear dynamic methods[J]. Journal of Hydrology, 2005, 307(1-4): 164-174. DOI: 10.1016/j.jhydrol.2004.10.008.
- [7] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780. DOI:10.1162/neco.1997.9.8.1735. Source: PubMed.
- [8] GRAVES A. Supervised sequence labelling with recurrent neural networks[M]. Springer Berlin Hei-



- delberg, 2012. DOI: 10.1007/978-3-642-24797-2.
- [9] LOPEZ E, VALLE C, ALLENDE H, et al. Wind power forecasting based on echo state networks and long short-term memory[J]. *Energies*, 2018, 11(3):526. DOI: 10.3390/en11030526.
- [10] 李基武,符强,孙希延,等.一种改进扩展卡尔曼滤波算法的GPS多径抑制应用[J]. *测绘科学*, 2018(6):167-172.
- [11] 江虹,苏阳.一种改进的小波阈值函数去噪方法[J]. *激光与红外*, 2016, 46(1):119-122.
- [12] MALLAT S. A theory for multi-resolution vision model applied to astronomical images[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 1989(40):495-520.
- [13] CAO X, ZHANG Z. Method of radar signal de-noising based on lifting wavelet improved threshold[J]. *Computer Engineering and Applications*, 2012, 48(14):143-147.
- [14] 周风波,李长庚,朱红求.基于提升小波变换的阈值改进去噪算法在紫外可见光谱中的研究[J]. *光谱学与光谱分析*, 2018, 38(2):506-510.
- [15] 李明迅,孟相如,袁荣坤,等.融合提升小波降噪和LSSVM的网络流量在线预测[J]. *计算机应用*, 2012, 32(2):340-346,346.
- [16] 方志军,石恒麟,毛微微.基于小波降噪的RLS算法在股票预测中的应用[C]//International Conference on Management Science and Engineering, 2010.
- [17] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation by wavelet shrinkage[J]. *Biometrika*, 1994, 81(3):425-455. DOI: 10.1093/biomet/81.3.425.
- [18] DONOHO D L. De-noising by soft-thresholding[J]. *IEEE Transactions on Information Theory*, 1995, 41(3):613-627. DOI: 10.1109/18.382009.
- [19] 符养.中国大陆现今地壳形变与GPS坐标时间序列分析[D].上海:中国科学院研究生院(上海天文台),2002.
- [20] 张鹏,蒋志浩,秘金钟,等.我国GPS跟踪站数据处理与时间序列特征分析[J]. *武汉大学学报(信息科学版)*, 2007, 32(3):251-254.
- [21] 张剑,屈丹,李真.基于词向量特征的循环神经网络语言模型[J]. *模式识别与人工智能*, 2015, 28(4):299-305.

#### 作者简介

张仕森 (1993—),男,硕士研究生,研究方向为机器学习和数据处理。

孙宪坤 (1972—),男,博士,副教授,研究方向为计算机应用。

尹玲 (1986—),女,博士,讲师,研究方向为计算机应用和智能信息处理。

## GPS elevation time series prediction model based on wavelet denoising technique and neural network

ZHANG Shisen, SUN Xiankun, YIN Ling, LI Shixi

(College of Electronic and Electric Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

**Abstract:** In the work of GPS time series data prediction, it is found that the noise contained in the time series data usually interferes with the results of data prediction. In order to minimize the negative impact of noise on prediction results in time series data as much as possible, a GPS time series data denoising prediction model is realized by combining lifting wavelet threshold denoising technology with long Short-Term Memory (LSTM). The model first uses lifting wavelet and smoothing threshold function to remove noise from GPS time series data before prediction, and then constructs a multi-layer LSTM neural network to predict time series data in one step. Compared with many time series prediction models, the results show that the proposed LSTM prediction model has strong applicability and higher accuracy for GPS time series prediction.

**Keywords:** lifting wavelet transform; threshold; global position system (GPS); time series; long-term and short-term memory neural network