

DOI: 10.11830/ISSN.1000-5013.202001014



采用径向基神经网络的卫星网络 申报趋势分析方法

石会鹏¹, 潘冀¹, 刘海洋¹, 赵睿², 刘珊杉¹, 韩锐¹

(1. 国家无线电监测中心, 北京 100037;

2. 华侨大学 信息科学与工程学院, 福建 厦门 361021)

摘要: 将径向基函数(RBF)神经网络应用于卫星网络申报趋势分析,构建基于 RBF 神经网络的趋势量化分析方法,改变当前主要依赖专家经验分析申报趋势的现状,为卫星网络申报趋势的评估提供量化指标.首先,梳理当前卫星网络申报的业务特点;然后,对主流预测方法进行分析,提出基于 RBF 神经网络的申报趋势分析方法;最后,通过实际申报数据进行算法验证.结果表明:文中方法对卫星网络申报趋势的预测误差总体小于 20%,对实际申报工作具有指导意义.

关键词: 卫星网络;趋势预测;径向基函数神经网络;量化分析;频谱管理

中图分类号: TP 399

文献标志码: A

文章编号: 1000-5013(2021)02-0268-07

Analysis Method of Satellite Network Declaration Trend Using Radial Basis Function Neural Network

SHI Huipeng¹, PAN Ji¹, LIU Haiyang¹, ZHAO Rui²,
LIU Shanshan¹, HAN Rui¹

(1. State Radio Monitoring Center, Beijing 100037, China;

2. College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China)

Abstract: Radial basis function (RBF) neural network is innovatively applied to the trend analysis of satellite network declaration. A quantitative trend analysis method based on RBF neural network is proposed, which provides quantitative indicators and methods for evaluating the trend of satellite network declaration and changes current situation that mainly depends on expert experience to analyze declaration trend. Firstly, the business characteristics of current satellite network declaration are combed. Then, the widely used prediction methods are analyzed, thus trend analysis method of declaration is proposed based on RBF neural network. Finally, the algorithm by actual declaration data is verified. The results show that prediction error of the proposed method is less than 20% for the trend of satellite network declaration, which has practical guiding significance.

Keywords: satellite network; trend forecasting; radial basis function neural network; quantitative analysis; spectrum management

卫星频率和轨道资源是一种重要的战略资源,世界各国在使用之前需要向国际电联(ITU)进行申

收稿日期: 2020-01-13

通信作者: 韩锐(1984-),高级工程师,博士,主要从事卫星频率轨道资源管理、电磁兼容分析的研究. E-mail: hanrui@srcc.org.cn.

基金项目: 国家自然科学基金资助项目(91738101);中国科学院复杂航天系统电子信息技术重点实验室开放基金资助项目(N201708)

报和协调,其申报流程必须按照 ITU 的《组织法》及《无线电规则》等进行,任何一个国家都不能单方面主宰卫星频率和轨道资源的获取和使用.因此,有效地分析全球卫星网络资料的申报趋势,提前采取必要的申报策略,是抢占轨位资源战略制高点的重要前提^[1].目前,我国在国际电联登记有效的卫星频率和轨道资源的资料数量已经位居世界前列.

卫星网络资料的申报是卫星频率和轨道资源获取,以及频轨战略资源储备的唯一途径.卫星网络资料的申报是一个长期过程,地球同步轨道(GSO)卫星的资源申报竞争尤为激烈^[2-4].在卫星网络申报管理工作中,相关行业的专家很难准确地把握复杂的申报趋势,特别是资料的申报趋势受国际政治形势、经济态势、相关行业政策等多维度因素的影响,而大部分因素无法进行定量分析.因此,当前的卫星网络资料申报工作主要依靠专家的个人经验,缺乏量化分析的指标和方法^[5].基于此,本文从卫星网络资料申报趋势预测的需求出发,将径向基函数(RBF)神经网络应用于卫星网络申报趋势分析,构建基于 RBF 神经网络的趋势量化分析方法.

1 卫星网络资料申报的特点

卫星网络资料申报的趋势主要分为两类:一是规划业务(planned services);二是非规划业务(non-planned services).其中,非规划业务由于采用“先登先占”原则,竞争态势更加严峻,GSO 卫星频轨资源的竞争获取尤为突出,文中主要针对非规划业务 GSO 卫星网络的申报趋势进行研究.

非规划业务 GSO 卫星网络资料申报流程,如图 1 所示.图 1 中:A,C,N 资料是各国卫星网络协调的接口性文件和依据,是卫星网络申报工作的核心.A 资料是卫星网络提前公布的资料,GSO 卫星网络报送 C 资料时自动生成;C 资料是卫星网络协调资料,描述卫星网络的各项指配及申报参数,如轨道参数、频率指配参数、地面站参数,以及业务和业务区等;N 资料是卫星网络通知资料,进一步细化卫星网络资料参数,同时,涉及协调完成状态等.

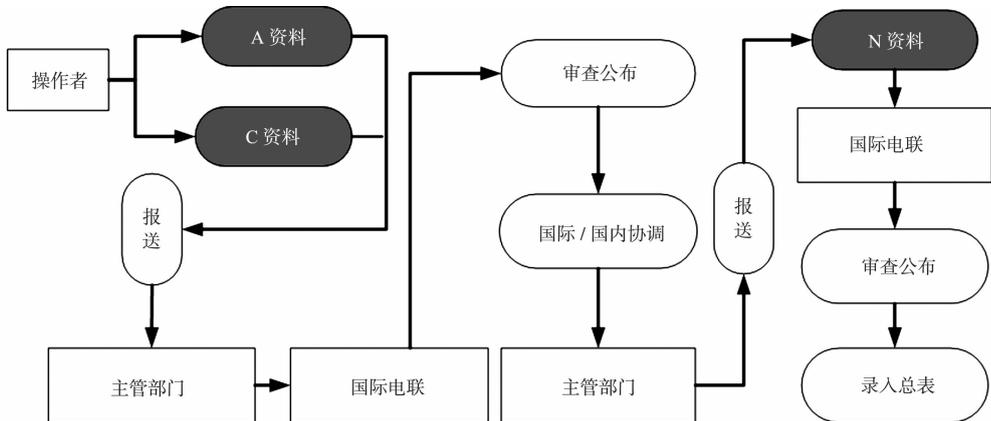


图 1 非规划业务 GSO 卫星网络资料申报流程

Fig. 1 Non-planned services GSO satellite network information declaration process

此外,根据 ITU 的相关规定,卫星网络资料的申报不得早于其计划投入使用时间的前 7 年,即非规划业务频段卫星网络自国际电联收到完整申报材料之日起,须在 7 a 内启用,这就要求卫星网络申报工作具有前瞻性.因此,需要采用科学的预测方法,为申报工作提供量化依据.

对 ITU 卫星网络申报数据库中的历史申报数据进行分析可知,卫星网络的申报趋势评估主要有以下 2 个基本特点.

1) 评估过程具有数学回归特性.无论影响因子是连续量还是离散量,卫星网络申报趋势评估的绝大部分过程对未来趋势的发展程度均具有对应的数学模型回归的特性,时间上具有变化的延续性,可通过相应的数学模型体现出当前的发展与趋势.

2) 影响因子具有多元非线性.影响评估过程的因素非常多,因子的量化分析也极为复杂,某些因子需要通过概率统计等方式进行量化,而量化过程往往具有一定的非线性,同时,部分因子无法直接获取,可能存在隐含的相关性.

2 卫星网络申报趋势分析算法

2.1 算法的分类

对未知事物状态进行预测可采用多种算法模型,例如,朴素贝叶斯算法、 K 邻近聚类预测、支持向量机(SVM)和决策树等,根据各算法采用的输入向量类型进行划分,可将预测方法分为基于时间序列预测方法和基于多因子回归预测方法。

1) 基于时间序列预测方法. 时间序列预测方法是给定一个历史时间序列 $X=(X_1, X_2, \dots, X_T)$, 其中, T 表示时间序列的长度, 对未来时间序列 $X'=(X_{T+1}, X_{T+2}, \dots, X_{T+k})$ 中的每个变量取值进行估计. 按照变量取值的估计方法进行分类, 时间序列预测方法可分为线性预测方法和非线性预测方法. 线性预测方法主要基于统计学模型, 如自回归(AR)模型、滑动平均(MA)模型和自回归滑动平均(ARMA)模型等; 非线性预测方法主要指以各种人工神经网络结构为基础的预测方法, 文中主要采用径向基函数神经网络进行时间序列预测。

基于时间序列预测方法是将预测目标的历史记录数据以时间为自变量, 以预测对象为因变量形成时间序列, 拟合出变化趋势的神经网络模型, 并根据拟合模型预测目标对象的未来值, 其本质是将多维度的影响因素包含在时间这个唯一的因素内^[6]. 时间序列预测方法具有简单、直观的特点, 但对于目标对象的长期预测, 往往误差较大, 需要不断地通过实际数据进行修正, 从而获得较好的长期预测效果。

2) 基于多因子回归预测方法. 基于多因子回归预测方法建立在结果与影响因素的关系上, 通过研究影响预测结果的因素来预测目标对象^[7]. 基于时间序列预测方法与基于多因子回归预测方法的区别在于前者的自变量是时间, 而后者能涵盖除时间之外的多种因素. 基于多因子回归预测方法能最大限度地多种影响因素融入预测过程中, 但该方法需要用户根据经验明确并量化预测具体的影响因素^[8].

2.2 算法的筛选

结合上述卫星网络资料申报趋势分析过程的特点, 采用基于多因子回归预测方法对卫星网络资料申报的发展趋势进行分析, 往往需要设定卫星网络资料申报的影响因素, 如申报卫星的轨位、频段等信息, 这些信息都将对未来申报趋势的判断结果产生影响. 此外, 影响因子多而复杂, 有些因素无法量化, 例如, ITU 的政策必然会影响到申报趋势, 但这一影响因素目前仅能凭借领域专家的直觉经验, 而无公认的量化指标, 故无法作为算法的输入. 因此, 若采用基于多因子回归预测的方法对卫星网络资料申报趋势进行分析, 影响因子无法全面量化, 必将增加分析方法的复杂度。

考虑到 ITU 数据库中存在全球卫星网络申报资料的信息, 如果以单位时间周期内的资料申报数量为基准, 对特定类型卫星网络资料进行统计, 可以直观地表现出该类型卫星网络资料申报的变化情况. 例如, 按月对全球 GSO 卫星网络申报资料数量进行统计, 可以得到以“份·月⁻¹”为单位的资料申报数量变化曲线, 该统计量是对申报趋势的直观表达. 因此, 采用单位时间周期内的资料申报数量作为卫星网络资料申报趋势的评价指标, 不但可以直观地量化申报趋势, 同时, 所需考虑的影响因子也极少, 仅需考虑时间这一维度. 综上, 采用基于时间序列预测方法对卫星网络申报趋势进行分析。

2.3 RBF 神经网络预测算法

在面向时间序列的预测方法中, 人工神经网络算法是一种有效的预测算法. 目前, 人工神经网络的结构设计主要是受生物学原理的启发, 但有一类神经网络模型的建立是基于数学原理的指导, RBF 神经网络是典型的代表. 目前, 大部分传统人工神经网络的应用都是基于反向传播(BP)神经网络, 但 BP 神经网络具有局限性, 容易陷入局部极小值, 而 RBF 神经网络因其结构特点而具有更好的函数逼近能力, 能有效地克服 BP 神经网络的部分缺陷^[9]. RBF 神经网络是一种前馈神经网络, 仅有 3 层网络结构, 如图 2 所示. 图 2 中: $\mathbf{X}=(x_1, \dots, x_p)$ 为网络的输入向量; $\mathbf{Y}=(y_1, \dots, y_L)$ 为网络的输出向量; 而 $\phi_1(\mathbf{X}) \sim \phi_M(\mathbf{X})$ 为激活函数(一般采用高斯函数)。

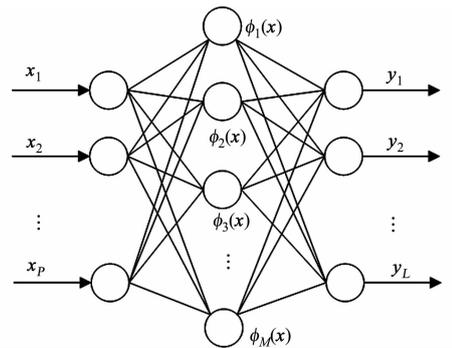


图 2 RBF 神经网络结构

Fig. 2 RBF neural network structure

由于 RBF 神经网络各层使用的激活函数与 BP 神经网络不同, 因此, RBF 神经网络的逼近性能更好. 此外, 采用局部激活函数的 RBF 神经网络能在很大程度上克服 BP 神经网络容易陷入局部极小值的问题, 并且在网络结构设计上可以更好地采用量化分析方法, 而不是依赖设计人员的经验, 训练效率也较 BP 神经网络更高^[10-12]. 采用 RBF 神经网络的文中算法设计如下.

1) 网络结构设计. RBF 神经网络的结构设计方法一般有聚类算法、梯度训练方法和资源分配网络 (RAN) 算法^[13]. 因资源分配网络算法具有较好的训练效率, 故将其作为 RBF 网络结构设计算法, 具体有以下 5 个步骤.

步骤 1 设置网络输出误差期望值 D (不同应用可根据样本拟合情况进行调整).

步骤 2 引入 2 个训练样本数据, 对隐层节点中心和权值进行初始化赋值.

步骤 3 再输入 1 个样本数据, 计算网络输出, 如果网络输出符合新颖性要求, 则引入该节点, 新颖性的定义是新输入的样本点需满足两个条件, 即

$$|e(i)| = \|y(i) - \hat{y}(i)\| > \epsilon, \quad (1)$$

$$d_i = \min_{1 \leq j \leq m} \|x(i) - C_j\| > \delta_j. \quad (2)$$

式(1), (2)中: $x(i)$ 为第 i 个新增样本的输入向量; $y(i)$ 为网络的实际输出向量; $\hat{y}(i)$ 为样本的输出向量 (期望值); $e(i)$ 为输出误差向量; C_j 为隐层第 j 个高斯单元的中心向量, 与 $x(i)$ 具有相同维数; ϵ 为估计误差值; d_i 为 $x(i)$ 与距离其最近的隐层中心的欧式距离; $\delta_j = \max\{\gamma^i \delta_{\max}, \delta_{\min}\}$, $\delta_{\max}, \delta_{\min}$ 分别为输入样本数据 $x(i)$ 之间的最大和最小距离, γ 为衰减系数^[14], $0 < \gamma < 1$.

步骤 4 若新输入的样本数据不符合新颖性要求, 则采用最小均方 (LMS) 算法调整中心和权值.

步骤 5 循环执行步骤 3, 4, 直到所有样本输入完成, 或网络输出误差小于预测值 D 时, 完成网络结构设计^[15-17].

2) 样本集预处理. 从上述网络结构设计可以看出, 样本数据对网络结构的设计有直接的影响. 因此, 科学地选取和处理样本, 可有效提高分析结果的准确性. 根据卫星网络资料申报的特点, 采用时间序列形式的样本数据. 为了使卫星网络资料的样本数据可以被 RBF 神经网络识别, 需对样本数据进行样本序列化、数据清洗和队列抗劣, 具体有以下 3 个步骤.

步骤 1 样本序列化. 采用单位时间周期内的资料申报数量 (如份 \cdot 月⁻¹) 作为卫星网络资料申报趋势的评价指标, 在相关数据库中, 按照待预测的卫星网络资料类型 (如全球 GSO 卫星网络或 Ka 频段卫星网络等) 进行统计, 获得以份 \cdot 月⁻¹ 为单位的卫星网络资料统计值, 并对申报时间进行自然数序列化处理, 将其作为算法模型的输入.

步骤 2 数据清洗. 由于 ITU 等数据库中统计的样本数据时间跨度较长, 以全球 GSO 卫星网络 N 资料申报趋势预测为例, 在数据库中, 该类资料在 1990 年前已有记录, 但在实际使用中, 跨度过长的历史数据样本会造成更大的误差, 产生过拟合现象. 为减少久远的历史数据样本对当前趋势产生过拟合的影响, 经过对不同样本数据的迭代计算可知, 以趋势预测时间点前 9 年的数据作为样本的效果最好.

步骤 3 队列抗劣. 由于卫星网络申报资料的样本不可避免地受到短时波动因素的影响, 该类影响并不是卫星网络资料申报趋势的主要内因, 且会对样本数据产生噪声. 因此, 采用最小二乘平滑 (OLS) 对样本进行抗劣去噪处理, 具体流程如下.

输入: 样本集合 (Z_i, K_i) , Z_i 为序列索引号, K_i 为待预测类型的卫星网络资料的每月申报数量, i 取值为 $[1, n]$, n 为样本项目数量.

输出: 输出抗劣去噪后的新样本集合 O_i .

I) 按照一定尺度 m 开辟先进先出 (FIFO) 队列滑动窗口为 $[(Z_1, K_1), (Z_2, K_2), \dots, (Z_m, K_m)]$.

II) 将该窗口从样本时间序列的前端开始滑动, 每滑动一次样本点, 就进行一次最小二乘拟合计算, 即获得多项式方程 $\varphi(Z) = \alpha_0 + \alpha_1 Z + \dots + \alpha_l Z^l$, 使窗口内各样本点与其偏差 σ 的平方和最小, 即

$$\sigma = \sum_{i=1}^m [K_i - \varphi(Z_i)]^2.$$

III) 按多项式方程 $\varphi(Z)$ 计算新样本点的 K_i 值.

IV) 重复 II), III), 直至处理完所有样本点, 生成新样本集合 O_i .

用预处理后的样本对网络模型进行训练, 即可得到卫星网络申报趋势预测的 RBF 神经网络模型. 申报趋势预测流程, 如图 3 所示.

3 分析方法与验证

卫星网络资料申报状态的统计及申报趋势发展的预测评估可以指导相关部门或卫星操作者进行判断. 主要评估集有卫星网络资料数量的增长趋势、GSO 轨道资源的竞争趋势和非地对地静止轨道(NGSO)资料的增长趋势等. 按照节 2 的算法, 以 ITU 数据库 2008—2016 年的卫星网络申报数据为训练集, 以 2017 年的申报数据为测试集, 构建申报趋势的 RBF 神经网络预测模型, 并对模型进行测试验证. 以 2017 年 1 月全球 GSO 卫星网络 N 资料申报的趋势预测为例, 进行算法验证.

1) 样本序列化. 根据 ITU 数据库的查询规则, 从数据库中提取全年的 N 资料, 按照资料申报时间, 按月份进行统计, 以 2016 年上半年为例, 得到以份·月⁻¹为统计单位的全球卫星申报 N 资料数 k_N (表 1). 对“年-月”字段进行序列化(表 2), 以自然数序列代替“年-月”的形式, 因为神经网络的输入节点一般要求为连续或离散的数值形式.

表 1 N 资料库表
Tab. 1 Table of N database

时间	k_N /份·月 ⁻¹	时间	k_N /份·月 ⁻¹
2016-01	29	2016-04	20
2016-02	26	2016-05	37
2016-03	20	2016-06	16

表 2 序列化后 N 资料库表
Tab. 2 Table of serialized N database

时间序列号	k_N /份·月 ⁻¹	时间序列号	k_N /份·月 ⁻¹
361	29	364	20
362	26	365	37
363	20	366	16

在程序中导入序列化后的库表数据, 以序列化后的时间为横坐标, 以 GSO 卫星网络 N 资料每月申报数为纵坐标, 可得申报资料统计曲线(1986—2018 年), 如图 4 所示.

由图 4 可知: 在序列号 270(2008 年)附近产生了申报趋势上的变化, 这是由于申报趋势的影响因素(如商业航天兴起)发生了变化, 为减少历史数据造成的过拟合, 增加影响因素变化后的样本数据比重, 需对样本数据进行清洗.

2) 数据清洗. 以 9 年为一组数据进行数据清洗, 对 2017 年 1 月 GSO 卫星网络 N 申报数量进行预测, 即以 2008 年 6 月为起点, 以 2016 年 12 月为终点, 统计 GSO 卫星网络 N 资料申报情况, 可得申报资料统计曲线, 如图 5 所示. 清洗后样本数据序列号(2016 上半年)也相应地发生变化, 如表 3 所示.

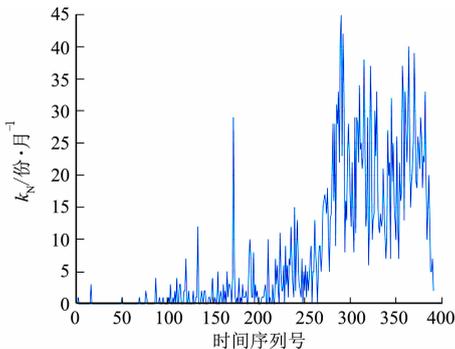


图 4 N 资料统计曲线(1986—2018 年)

Fig. 4 Statistical curve of N data (1986 to 2018)

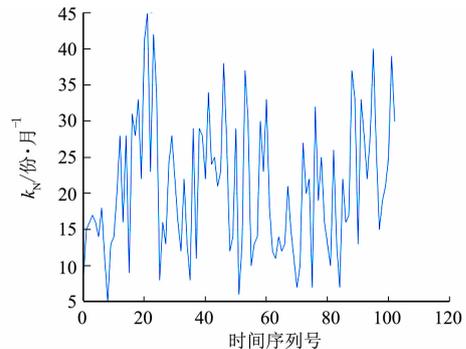


图 5 数据清洗后的 N 资料统计曲线(2008—2016 年)

Fig. 5 Statistical curve of N data after data cleaning (2008 to 2016)

3) 队列抗劣. 由于样本存在噪声, 需对样本数据进行队列抗劣处理, 结果如表 4 所示. 截取 2008 年 6 月至 2016 年 12 月的数据作为 RBF 网络模型的训练样本, 队列抗劣后的样本, 如图 6 所示.

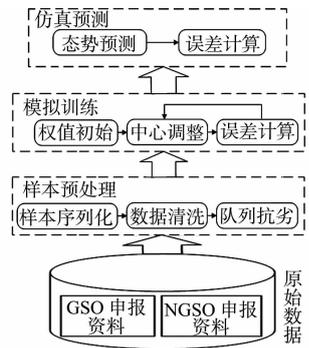


图 3 申报趋势预测流程

Fig. 3 Declaration trend forecasting process

表 3 数据清洗后的数据示意表

Tab. 3 Data diagram after data cleaning

时间序列号	$k_N/\text{份} \cdot \text{月}^{-1}$	时间序列号	$k_N/\text{份} \cdot \text{月}^{-1}$
92	29	95	20
93	26	96	37
94	20	97	16

表 4 队伍抗劣后的数据示意表

Tab. 4 Data diagram of queue after anti-inferior

时间序列号	$k_N/\text{份} \cdot \text{月}^{-1}$	时间序列号	$k_N/\text{份} \cdot \text{月}^{-1}$
92	26.96	95	27.58
93	27.26	96	26.25
94	27.80	97	25.07

4) 网络初始化. 完成数据样本的采集后, 可以开始 RBF 神经网络结构的设计, RBF 网络结构的构建采用资源分配网络学习算法.

5) 中心调整. 首先, 选取两个输入样本, 将其作为 RBF 神经元的结构参数代入网络结构中, 得到相应的输出结果; 然后, 重新设计网络线性层, 逐步减小误差.

6) 误差计算. 如果网络输入误差未达到预期值, 则根据下一个最大误差的样本, 再增加一个神经元, 如此反复, 使误差减小, 直至误差达到规定的误差性能, 或神经元数量达到上限时, 整个建网结束.

RBF 神经网络模型对样本集的拟合曲线, 如图 7 所示. 该模型在完成 100 次反向传播训练后, 模型训练的均方误差为 0.015 4.

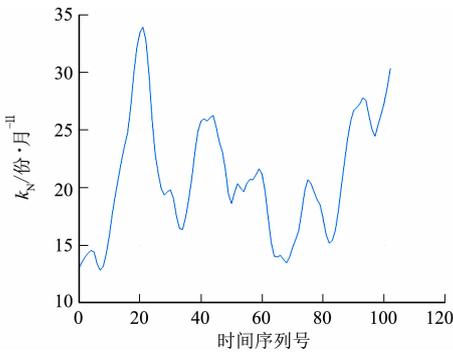


图 6 队列抗劣后的样本

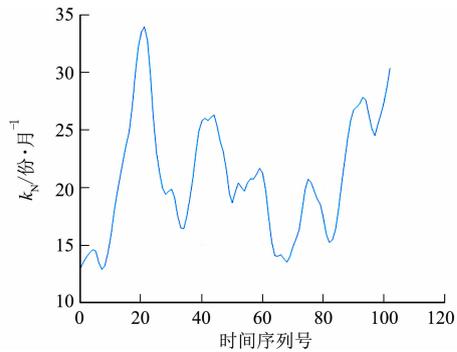


图 7 RBF 神经网络模型对样本集的拟合曲线

Fig. 6 Sample after anti-inferior of queue Fig. 7 Fitting curve of RBF neural network model to sample set

7) 趋势预测. 获得训练后的 RBF 神经网络模型后, 输入序号 103(2017 年 1 月) 可得 2017 年 1 月全球 GSO 卫星网络 N 资料申报趋势预测为 22.4 份 · 月⁻¹.

8) 误差对比. 2017 年 1 月实际统计的全球 GSO 卫星网络 N 资料申报为 19 份, 与预测结果 22.4 份 · 月⁻¹ 对比, 相对误差约为 18%.

按照申报趋势的预测流程, 选取对应的样本集, 重复计算, 可得 2017 年 GSO 及 Ku/Ka 波段等卫星网络 N 资料的预测验证结果, 如表 5 所示. 表 5 中: $k_{N,t}$ 为 N 资料数的预测值; $k_{N,r}$ 为实际值; η 为误差.

表 5 预测验证结果

Tab. 5 Forecast verification results

时间	GSO 全球卫星网络 N 资料			Ku/Ka 波段卫星网络 N 资料		
	$k_{N,t}/\text{份} \cdot \text{月}^{-1}$	$k_{N,r}/\text{份} \cdot \text{月}^{-1}$	$\eta/\%$	$k_{N,t}/\text{份} \cdot \text{月}^{-1}$	$k_{N,r}/\text{份} \cdot \text{月}^{-1}$	$\eta/\%$
2017-01	22.4	19	18	21.7	16	35
2017-02	19.0	18	21	16.0	14	14
2017-03	23.9	26	8	20.0	23	12
2017-04	24.9	24	4	20.3	12	69
2017-05	24.2	21	15	14.8	13	13
2017-06	20.2	29	30	18.2	19	3
2017-07	20.8	26	19	18.1	20	9
2017-08	25.0	18	39	14.6	11	33
2017-09	23.9	23	4	17.0	23	25
2017-10	24.2	22	10	17.7	19	6
2017-11	24.4	33	25	14.0	24	41
2017-12	24.7	20	23	18.6	10	86

按照全年算术平均值计算全年预测月平均误差 $\bar{\eta}$,即

$$\bar{\eta} = \sum_{i=1}^{12} \eta_i / 12. \quad (3)$$

式(3)中: η_i 为第*i*月的预测误差值.

将表5的误差数据代入式(3),可得GSO全球卫星网络N资料2017年月平均误差约为18%.

4 结束语

基于RBF神经网络算法构建卫星网络资料申报趋势的预测模型,结合真实的历史申报数据进行实验验证.结果表明:GSO全球卫星网络N资料单月预测结果误差基本小于20%,全年平均约为18%,准确度较高,验证了该模型的有效性 with 评估效能,而Ku/Ka波段等卫星网络N资料中部分误差较大的月份也可为频率协调操作者提供有针对性的申报趋势影响因素的分析方向.

参考文献:

- [1] 潘冀,刘卓然,李健欣,等.空间无线电业务国际协调手册[M].北京:人民邮电出版社,2013.
- [2] STEIGENBERGER P, HUGENTOBLE U, HAUSCHILD A, *et al.* Orbit and clock analysis of compass GEO and IGSO satellites [J]. *Journal of Geodesy*, 2013, 87(6): 515-525. DOI: 10. 1007/s00190-013-0625-4.
- [3] CHRISTENSEN J. ITU regulations for Ka-band satellite networks[C]//30th AIAA International Communications Satellite System Conference. Ottawa: AIAA, 2012: 1-18. DOI: 10. 2514/6. 2012-15179.
- [4] MAN P D. Orbits and the ITU[M]//Exclusive use in an inclusive environment. Cham: Springer International Publishing, 2016. DOI: 10. 1007/978-3-319-38752-9_4.
- [5] 周鑫林, 巩应奎, 韩朝晖. 面向 GEO 卫星频轨协调风险的定量化评估[J]. *计算机仿真*, 2018, 35(2): 410-416.
- [6] ITU Radio Communication. Radio regulations articles edition of 2016[S]. Geneva: ITU, 2016: 271-289.
- [7] GIVEKI D, RASTEGAR H. Designing a new radial basis function neural network by harmony search for diabetes diagnosis[J]. *Optical Memory and Neural Networks*, 2019, 28(4): 321-331. DOI: 10. 3103/S1060992X19040088.
- [8] FISCHER T, KRAUSS C. Deep learning with long short-term memory networks for financial market predictions [J]. *European Journal of Operational Research*, 2018, 270(2): 654-669. DOI: 10. 1016/j. ejor. 2017. 11. 054.
- [9] RAMASAMY P, CHANDEL S S, YADAV A K. Wind speed prediction in the mountainous region of India using an artificial neural network model[J]. *Renewable Energy*, 2015, 80(8): 338-347. DOI: 10. 1016/j. renene. 2015. 02. 034.
- [10] JI Jie, KHAJEPOUR A, MELEK W W, *et al.* Path planning and tracking for vehicle collision avoidance based on model predictive control with multiconstraints[J]. *IEEE Transactions on Vehicular Technology*, 2017, 66(2): 952-964. DOI: 10. 1109/tvt. 2016. 2555853.
- [11] 王成, 代祥, 刘飞, 等. 基于 RBF 神经网络的电力系统负荷预测[J]. *电力学报*, 2018, 33(5): 399-407. DOI: 10. 13357/j. cnki. jep. 002747.
- [12] 刘智. 径向基神经网络算法在车牌字符识别中的应用[J]. *华侨大学学报(自然科学版)*, 2017, 38(1): 113-116. DOI: 10. 11830/ISSN. 1000-5013. 201701022.
- [13] 常雨芳, 张力, 谢昊, 等. 采用小波分析和神经网络的短期风速组合预测[J]. *华侨大学学报(自然科学版)*, 2019, 40(4): 556-560. DOI: 10. 11830/ISSN. 1000-5013. 201806023.
- [14] 陈忠辉, 凌献尧, 冯心欣, 等. 基于模糊 C 均值聚类和随机森林的短时交通状态预测方法[J]. *电子与信息学报*, 2018, 40(8): 1879-1886. DOI: 10. 11999/JEIT171090.
- [15] WANG Jiahai, CAI Yiqiao, YIN Jian. Multi-start stochastic competitive Hopfield neural network for frequency assignment problem in satellite communications[J]. *Expert Systems with Applications*, 2010, 38(1): 131-145. DOI: 10. 1016/j. eswa. 2010. 06. 027.
- [16] 王亚男, 雷英杰, 王毅, 等. 一种启发式变阶直觉模糊时间序列预测模型[J]. *电子与信息学报*, 2016, 38(11): 2795-2802. DOI: 10. 11999/JEIT160013.
- [17] 王英博, 闫吉府, 李仲学. 遗传算法优化径向基神经网络的尾矿库安全预测[J]. *计算机应用与软件*, 2015, 32(3): 182-184. DOI: 10. 3969/j. issn. 1000-386x. 2015. 03. 042.

(责任编辑: 钱筠 英文审校: 吴逢铁)