

基于傅里叶神经算子的遥感数据预测方法

卫兰^{1,2}, 朱建璇³, 徐晓斌³, 范存群^{1,2}, 林曼筠^{1,2}, 赵现纲^{1,2}

(1.中国气象局中国遥感卫星辐射测量和定标重点开放实验室/国家卫星气象中心(国家空间天气监测预警中心),
北京 100081;2.许健民气象卫星创新中心,北京 100081;3.北京工业大学 信息学部,北京 100124)

摘要:地球遥感是气象卫星的主要任务,由于受云层遮挡、宇宙射线辐射等因素影响,气象卫星所获取的遥感数据通常存在大量缺失及异常.傅里叶神经算子具有效率高、精度高、分辨率灵活等特性,基于此,提出一种基于傅里叶神经算子的遥感数据预测算法.该算法首先对遥感数据缺失值利用空间均值法和拉格朗日插值法进行填充,之后用傅里叶神经算子训练出空间数值在时间域上的映射关系,最后利用训练出来的模型对于最新的遥感数据进行预测.基于风云 4 号遥感卫星真实遥感数据的仿真实验结果表明,所提出的方法在较长期的时序预测中仍能保持较好的预测精度.

关键词:地球遥感;时序预测;长期预测;傅里叶神经算子

中图分类号:TP79

文献标志码:A

文章编号:1000-2367(2025)01-0082-10

遥感卫星用以对地球环境状态信息进行全面感知,通常从远距离感知地表反射的电磁波、可见光、红外线,对地表环境进行探测和识别.由于地球表面经常受到云层遮挡,卫星轨道中往往面临宇宙射线的辐射,遥感卫星通常以较高的速度围绕地球转动,这些因素使得遥感数据往往缺失严重、异常数据频发,数据质量较差.数据的填充及预测能够有效补充缺失数据,并为天气的预测及预报提供基础支撑.遥感数据的预测算法是遥感数据处理领域的热门问题.

传统的数据预测算法通常采取时序预测模型,每次获取新数据后对时序预测结果进行反馈,并进行模型的更新.当数据缺失严重时,由于缺乏足够的原始数据进行建模,这类算法将会失效.近年来基于机器学习的数据预测算法取得了快速的发展,然而这类算法仍然容易受缺失数据影响导致预测精度变低.

针对当前基于机器学习的数据预测方法中存在的精度较低、训练时间长、泛化性差的问题,本文根据算子的思想提出一种基于傅里叶神经算子的遥感数据预测方法,本方法首先采取时空多维数据填充算法补齐缺失数据,之后采取傅里叶神经算子对遥感数据进行预测.基于风云 4 号气象卫星真实数据集建立仿真实验,并通过与传统方法的对比及参数分析,验证了算法的有效性.

1 相关工作

数据预测通过对已知数据进行建模,估算未知数据.相关方法已经在多种场景中应用,数据的预测方法通

收稿日期:2023-06-30;**修回日期:**2023-08-27.

基金项目:国家重点研发计划项目(2021YFB3901000;2021YFB3901005);北京市自然科学基金(L212032);风云卫星应用先行计划(FY-APP-2021.0501).

作者简介:卫兰(1980—),女,江苏姜堰人,国家卫星气象中心高级工程师,研究方向为卫星数据地面系统、云计算,
E-mail:weilan@cma.cn.

通信作者:范存群, E-mail:fancq@cma.gov.cn.

引用本文:卫兰,朱建璇,徐晓斌,等.基于傅里叶神经算子的遥感数据预测方法[J].河南师范大学学报(自然科学版),
2025,53(1):82-91.(Wei Lan,Zhu Jianxuan,Xu Xiaobin,et al.Prediction method of remote sensing data based on
fourier neural operator[J].Journal of Henan Normal University(Natural Science Edition),2025,53(1):82-91.
DOI:10.16366/j.cnki.1000-2367.2023.06.30.0002.)

常可以分为传统的时序预测方法与基于人工智能的方法两种类型.其中传统的时序预测方法通常实时采集数据建立时序模型,在预测的同时进行模型的修正.这类算法往往结构简单、计算量少,适用于少量数据缺失的实时场景.其中经典算法主要包括最小二乘法、指数平滑法以及自回归积分移动平均预测方法 (ARIMA) 等.近年来,许多研究者在这些经典算法基础上进行了改进,并将之应用于不同的领域之中.MOGHIMI 等^[1]提出一种多元时间序列预测模型解决智能交通系统的红绿灯松弛时间问题.PEREIRA 等^[2]提出了一种使用被动和主动解决方案的混合自动缩放方法,以此提高计算系统的性能.ALIZADEH 等^[3]将自回归集成移动平均和小波神经网络模型相结合,提出了一种混合 ARIMA-WNN 模型,并在车辆行为预测和异常状态检测方面取得了更高的精度.李春等^[4]为了提高时间序列的预测精度,提出了一种基于改进果蝇算法优化直连长短期记忆网络的时间序列预测方法,增强了对目标系统中线性成分的表征.王绪亮等^[5]将 ARIMA 模型用于对未来流量进行预测,实现动态缓存策略,从而提高系统的整体性能.传统的时序预测算法往往需要在实时场景中进行应用,并以短时间内的实时数据建立模型.当前遥感卫星数据通常缺失严重,往往无法提供足够的数据建立时序模型,严重限制了这类算法在遥感数据预测中的应用.

基于机器学习的预测方法通常不局限于短时间内的线性模型,而是基于大范围内的时空历史数据建立模型,并对较长时间段内的数据进行预测.主要方法包括 BP 神经网络^[6]、LSTM 长短期记忆神经网络^[7-8]等.近年来,基于机器学习的时序数据预测模型在时空数据的预测方面取得了较多的成果.文献[9]提出了一种基于深度学习的方法来预测海冰的运动,该方法优于以前的深度学习网络,并且适用于资源需求型数值的预测.WANG 等^[10]提出了一种基于反向传播神经网络和信息颗粒的长期预测方法,实现了更好的长期预测性能.罗佩等^[11]提出一种均值惩罚随机森林非平稳时序预测方法(PMP-RF),在教学资源请求数据的预测上取得了更高的精度.张忠林等^[12]提出了一种改进萤火虫算法,并用改进后的算法优化了 LSTM 时序预测模型,提高了时序预测精度.DUDEK 等^[13]提出了一种混合、分层的中期负荷预测深度学习模型,并对 35 个欧洲国家的月电力需求时间序列进行仿真实验,验证了该模型的高性能.近年来,基于机器学习的预测方法开始逐渐应用于气象和遥感数据的处理当中.贺圣平等^[14]将卷积神经网络应用到东亚冬季逐月气温的回报试验,并与气候动力模式的回报结果相比较,并取得了较好的实验结果,证明了机器学习方法在气候预测方向的优势.黄小燕等^[15]为了更好地利用大量的卫星云图观测资料来提高台风暴雨的预报能力,解决并提高对台风强降水云系变化的预报精度,延长对未来云系变化的预报时效,构建基于合作对策 Shapley-模糊神经网络的华南区域台风卫星云图非线性智能计算滚动集合预测模型,对增强卫星云图资料在台风暴雨天气预报中的实用性和及时性具有重要意义.杨旭等^[16]针对北斗某星辐射剂量探测数据缺失问题,提出了一种基于线性样条和 CNN-LSTM 神经网络模型的处理方法.在对数据特性分析的基础上,将原始数据分解为线性趋势项和季节波动项.对于线性趋势项,采用基于线性样条的缺失值处理方法;对于季节波动项,根据其时空变化特性,设计 CNN 和 LSTM 组合神经网络结构,完成季节波动项的缺失值处理.

尽管基于机器学习的算法在面对数据缺失时仍能够建立模型,然而预测的精度受数据质量影响较为严重,若原始数据存在较多缺失,则预测结果往往具有较大误差.而如果采用神经网络方法,则会产生巨大的计算开销.如何设计数据预测模型,一方面对缺失数据进行填充,另一方面针对遥感数据的特性对数据进行预测,并且提升算法模型的效率,是地球遥感场景中时序数据预测所面临的关键挑战.为此,本文将傅里叶神经算子算法进行了改进,增加了异常数据的过滤、缺失数据的填充,根据样本的周期特性修改了模型样本输入时间片,使之适用于遥感数据,在此基础上设计了基于傅里叶神经算子的遥感数据时序预测算法.

2 基于傅里叶神经算子的遥感数据时序预测算法

2.1 傅里叶神经算子

对于常见的缺陷度量数据,可以假设它们是由更高层的变量生成,并且这些隐变量满足特定的分布,一般代表着数据的内在结构或者某种抽象.例如,缺陷数据集可以看作是由度量代码的复杂程度、组织结构的混乱程度等隐式特征生成的数据.假设原始缺陷数据集 $X = \{x_i\}_{i=1}^N$ 为包含 N 个独立同分布的连续变量 x , 这些数据是利用未观测到的隐变量 z 通过某些随机过程而生成.这个过程一般包含两个步骤.

傅里叶神经算子(Fourier neural operator,FNO)是 LI 等^[17]提出的一种偏微分方程求解方法.该方法对图神经算子(graph neural operator,GNO)进行了改进,它使用傅立叶变换技术进行卷积,从傅立叶空间中去除较高的模态,只留下较小的模态.之后,逆傅立叶函数与线性变换一起应用.这允许初始化的权重在初始化模型中进行训练,而不依赖于网格,在一定程度上摆脱网格分辨率限制并且大幅提升了求解效率.

傅里叶神经算子模型框图如图 1 所示.




图1 傅里叶神经算子模型框图

Fig.1 The architecture of the Fourier neural operator

图 1 上半部分是神经网络结构整体的框架图, $a(x)$ 作为输入,经过神经网络 P 映射到高维,然后经历 T 个傅里叶层,经过 Q 之后恢复为 $u(x)$.图 1 下半部分则表达了一个傅里叶层内部都经历了哪些过程,其中 $v(x)$ 输入后,经过傅里叶变换,将其转化到傅里叶空间, R 则表示一个线性变换,目的是滤掉高频模态,然后用傅里叶逆变换将其转化回源空间.该模型设计还有一个目的,就是要与分辨率无关,而传统的偏微分方程求解方法之一的谱方法也有可借鉴的思路.因为从傅立叶空间中学习参数,相当于将物理空间投影在以 $e^{2\pi i(x \cdot i)}$ 为基的空间下,而这个空间下是处处良定义的,与离散无关.除此之外,使用快速傅里叶变换(fast Fourier transform,FFT)之后,计算复杂度变成了准线性的,为大规模计算提供了可能.对高阶和低阶模态的处理是该方法与其他傅立叶神经网络的一个区别.另一个区别是,FNO 使用 ReLU(rectified linear unit)激活函数.

FNO 打破了网格之间的传递循环,在卷积模型中,一个网格连接到另一个网格,根据先前的值来创建新的权重或对权重进行调整^[17].

FNO 的定义为, Φ 为函数 $f:D \rightarrow R^{ad}$ 的傅立叶变换,而 Φ^{-1} 为逆变换,表达式如下:

$$(\Phi f)_j(k) = \int_D f_j(x) e^{-2i\pi \langle x, k \rangle} dx, \tag{1}$$

$$(\Phi^{-1} f)_j(x) = \int_D f_j(k) e^{-2i\pi \langle x, k \rangle} dk. \tag{2}$$

该模型可用以求解参数偏微分方程.本文将该模型引入遥感数据的时序预测场景,提出一种新的二维区域数据的时序预测算法.

2.2 基于时空数据填充的遥感数据预处理

受恶劣的宇宙空间环境与不稳定的数据传输链路影响,遥感数据通常异常频发、缺失严重,需要对数据进行预处理,预处理后再进行预测模型的训练.

数据的预处理通常包括异常值去除、空值填充等步骤.遥感数据中的异常值和空值通常远离正常数值范围,可以根据数据的范围进行去除.然而卫星遥感数据的空值在空间域和时间域上都占比很大,数据在时间域或者在空间域大量缺失的情况频繁发生.针对以上情况,本文提出一种时空维度融合的数据填充方法.其中空间维度采取空间均值法,时间维度采取拉格朗日插值法,将二者相结合,对空值进行填充.空值填充具体流程如下:

步骤 1 将卫星遥感数据目标区域的数据格式根据需求规范化为 S ,并根据数据的正常取值范围将其中的异常值和缺省值均用空值表示, S 的数据格式为 $n \times k \times k$,其中 n 为时间间隔数, $k \times k$ 为目标区域根据

分辨率取值后得到的数值矩阵.

步骤 2 每隔 m ($1 < m < n$) 个时间间隔,将目标区域矩阵数据进行空间均值法插值,输出为 SS ,设 d_{ij} ($0 < i < k, 0 < j < k$) 为目标区域的一个数值,若 d_{ij} 的值为异常或者缺省值,则有 d_{ij} 的值为周围 9 个值中正常值的平均数,其中边界部分取相应的相邻值.循环使用空间均值法,直到该时刻目标区域所有值都为正常值,其中 m 的取值根据遥感数据类型而定.用 $mean(d_{ij})$ 表示 d_{ij} 相邻非空值的平均数,空间均值法插值具体过程如算法 1 所示:

```

算法 1:空间均值法
输入:  $S, m$ 
输出:  $SS$ 

count++;
 $S_{a,i,j} = mean(S_{a,i,j})$ 
end if.
end for.
end for.
end while.
end for.
 $SS = S$ ;
return  $SS$ ;

for  $a = 1 : m : n$ , repeat:
count =  $k$ ;
while (count != 0 & count <  $k * k$ )
count = 0;
for  $i = 1 : k$ , repeat:
for  $j = 1 : k$ , repeat:
if  $S_{a,i,j} = \phi$ 

```

步骤 3 对每一个点 d_{ij} ($0 < i < k, 0 < j < k$) 用拉格朗日时序插值法,将空间均值法得到的数据 SS 全部插值为正常值 SST .拉格朗日时序插值法即在时间域上应用拉格朗日插值法,用 $L(d_{ij}, r)$ 表示 d_{ij} 这个点在时序上前各取 r ($1 \leq r \leq m$) 个值进行拉格朗日插值,具体过程如算法 2 所示:

```

算法 2:拉格朗日时序插值法
输入:  $SS, r$ 
输出:  $SST$ 

 $S_{a,i,j} = L(S_{a,i,j}, r)$ 
end if.
end for.
end for.
end for.
 $SST = SS$ ;
return  $SST$ ;

for  $i = 1 : k$ , repeat:
for  $j = 1 : k$ , repeat:
for  $a = 1 : n$ , repeat:
if  $S_{a,i,j} = \phi$ 

```

经过以上步骤,从时间与空间两个维度对缺失遥感数据进行插值.

2.3 基于傅里叶神经算子的遥感数据预测方法

对遥感数据进行插值后,得到较为完整的数据集 SST 将此时的数据作为输入,根据具体时序预测需求,滚动生成训练和测试样本 $SSTS$,设时序预测区间为 t ,则生成的样本格式为 $2t \times x \times x$,即用前 t 个时间内 $x \times x$ 区域的数据来预测后 t 个时间内 $x \times x$ 区域的数据.具体步骤如下:

步骤 1 将生成的训练样本作为训练模型的输入,进行训练和测试,得出平均绝对误差(mean absolute error, MAE)和训练时间,并根据 MAE 和训练时间调节参数,得到最优训练模型.

步骤 2 将需要预测的数据经过预处理,得到预测样本 SP , SP 的格式为 $t \times y \times y$ ($1 \leq y \leq x$),其中 t 为时序预测区间, $y \times y$ 为预测样本的分辨率,然后将 SP 作为输入进行预测,得到需要的预测值.用 $FNO(M, SP)$ 表示对 SP 样本在傅里叶神经算子预测模型 M 上进行时序预测,最终得到预测数据 SPY , SPY 的格式为 $t \times y \times y$ ($1 \leq y \leq x$),表示目标区域 $t \times y \times y$ ($1 \leq y \leq x$) 分辨率下, t 个时间间隔后的数据.

经过以上过程,得到遥感数据的预测结果.该算法在实际应用场景中的具体过程为:遥感卫星获取数据,把一段时间数据发到地面,地面接收后,传输到数据服务器中进行集中存储.在这个服务器中,进行数据的填充和数据的预测,并把预测的结果实时更新至数据中心.

以本文所选实验数据为例,数据流向图如图 2 所示.

3 实验分析

本节在 Python 3.8.8 中实现本文所提出的算法与对比算法,建立若干组实验以评估算法的预测准确度,与 6 种现有数据预测算法的预测结果进行了对比,并对算法参数进行了分析,然后针对本文算法灵活性做了

不同分辨率训练样本的实验对比,最后做了消融实验验证了本文所用插值算法在卫星遥感数据上的有效性.




图2 卫星遥感数据流向图
Fig.2 The procession of Satellite remote sensing data flowing

3.1 实验数据

实验采用风云四号卫星(FY4A)真实遥感数据,选择 2021 年 12 月 1 日至 2021 年 12 月 7 日的遥感数据.选取其中点间隔 4 km,时间间隔 1 h,区域大小为 100×100 的地表温度产品数据进行实验验证.实验最终用前 6 d 数据进行训练,第 7 d 数据进行预测,预测模式为用前一天 24 h 的数据来预测后一天 24 h 的数据.本文方法模型为时间段之间区域数据的映射,所涉及变量为:训练样本时长 T_t ,训练样本分辨率 R_t ;预测样本时长 T_p ,预测样本分辨率 R_p .

3.2 预测结果分析

为了评价预测算法的效果,本文使用平均绝对误差(MAE)来评估数据预测的误差.为了找到算法合适的参数设置,本节进行了多轮仿真实验,得到数据预测的结果,并将预测值与真实值进行对照,得出数据预测的误差.在实验结果中,误差与学习率和训练轮数两个设定相关性最大.当学习率在 0.003 5~0.003 9 附近时,训练结果最佳,误差最小.当训练轮数在 5 附近时,误差接近最低,之后逐渐趋于稳定.图 3 为最佳训练结果的误差与参数之间的关系.

从图 3 中可以看出,在训练轮数少于 5 轮时,随着轮数增加,训练误差降低较为明显;继续




图3 预测误差随学习率和训练轮数的变化
Fig.3 Change of prediction mean absolute error with learning rate and epochs

增加轮数,则训练误差基本趋于稳定.学习率过高或者过低时,预测具有较高误差,当学习率在 0.004 附近时,训练误差总体较小.

为了进一步验证本文方法在区域遥感数据时序预测的精度和效率方面的综合优势,选取了弹性网回归方法、支持向量回归(support vector regression,SVR)高斯核方法、SVR 线性核方法、随机森林方法、线性回归方法、BP 神经网络方法进行对比,主要对比平均绝对误差(MAE)和训练时长.对比方法参数选取为实验误差最低时的参数.本文方法参数设定为:学习率为 0.003 7,训练轮数为 5.对比试验参数设置如下:线性回归为基本模型;弹性网回归所用参数: $\alpha=0.000\ 1,l1_ratio=0.1$;SVR 高斯核所用参数: $\gamma=0.18,C=1$;SVR 线性核所用参数: $C=0.355$;随机森林所用参数: $n_estimators=100,criterion='mae'$;BP 神经网络所用参数:输入层参数为 *Dense*(16,*input_dim=input_size,kernel_initializer='uniform'*),激活函数为'tan h',训练参数为 *epochs*=1 000,*batch_size*=32.实验结果对比如表 1 所示.

表 1 不同时序预测方法平均绝对误差及训练时长对比

Tab. 1 Comparison of mean absolute error and training time of different prediction methods		
预测方法	平均绝对误差/℃	训练时间/s
本文方法	2.330 513 666 073 481	42.861 846 685 409 546
随机森林	3.369 664 892 781 462	4 572.306 855 678 558
弹性网回归	3.210 047 935 972 577 5	34.339 182 853 698 73
BP 神经网络	3.466 653 763 224 033 7	40 170.884 014 606 4
线性回归	3.220 636 351 873 346 3	30.443 443 536 758 423
SVR 高斯核	3.009 830 989 862 728	29.397 406 339 645 386
SVR 线性核	3.009 889 459 307 798 3	29.211 894 273 757 935

由表 1 可以看出,在以上算法中本文算法 MAE 最低,且训练时间可以接受.说明本文方法在保证训练效率的同时,提升了预测精度.除此之外,本文方法与对比方法不同,本文方法不是单点时序预测,而是对整个区域内全天的数据进行预测,一次性生成全天 $100\times100\times24$ 个温度数据的预测结果.这使得本文方法相比单点时序预测方法具有更高的预测效率.

为了对本文算法的预测准确度进行进一步验证,本文设计了第二组对比实验,用以评估算法在不同分辨率下的数据训练及预测效果.具体步骤为:首先将 100×100 个位置点按照 10×10 、 50×50 等大小,均匀划分为 100、4 个区域.在每个区域内,采取不同分辨率的模型分别进行训练和预测,并与实际温度数值进行对比,实验中每种模型的训练样本分辨率 R_t 与预测样本分辨率 R_p 相等,分析不同训练轮数情况下的预测误差,结果如图 4 所示.

如图 4 所示,当分辨率降低时,预测准确度有所下降.这一结果主要是由于训练过程中较多位置点的温度数据可以为总体温度分布情况提供参考,从而获得更高的预测准确度.

3.3 训练及预测时间范围对比分析

本文方法首先基于多组训练样本进行训练,之后对未来一段时间的数据进行预测.为了找到合理的参数设置,本节对训练及预测时间范围进行了对比分析.首先,将训练样本时长 T_t 与预测样本时长 T_p 设置为相同的数值,并构建仿真实验.实验结果如图 5 所示.

由图 5 可以看出,当训练样本时长与之预测样本时长相同时,二者均为 24 h,预测误差最小,这是因为影响地表温度的关键因素就是太阳照射,即和地球自转关系很大,所以 24 h 接近于地表温度的最小变化周期.与此同时,本文也对不同样本的训练所用时间进行了实验对比,如图 6 所示.

由图 6 可以看出,随着训练和预测样本时长变大,同样的数据量训练时间也会变长.而且在数据量相同的情况下,训练样本时长和预测样本时长变大会导致相应的样本数量变小,所以尽管地表温度变化周期有很多,但是取最小周期 24 h 作为训练样本时长是最合适的.

为了对算法性能进行更全面的分析,本文在训练样本时长与预测样本时长不同的情况下构建了仿真实验,实验结果如图 7 所示.




图4 不同分辨率下预测误差
Fig.4 Prediction error at different resolutions




图5 不同训练和预测样本时长下预测误差对比
Fig.5 Comparison of prediction errors under different training and prediction sample durations




图6 训练时间随训练和预测样本时长变化情况
Fig.6 Change of training time with different training and prediction sample durations




图7 不同预测样本时长下预测误差对比
Fig.7 Comparison of prediction errors under different prediction sample durations

在训练样本时长相同的情况下,预测误差随着预测样本时长逐渐上升,然而预测任务的实用性要求预测样本时长越大越好,所以结合误差大小和实用性要求,24 h 作为预测样本时长是较为合理的选择。

3.4 训练时间参数分析

为了对本文算法的预测效率进行分析,本文设计了对比实验,用以比较不同分辨率、不同训练轮数情况下的训练时间.分辨率分别设置为 10×10 、 25×25 、 50×50 、 100×100 大小,实验中每种模型的训练样本分辨率 R_t 与预测样本分辨率 R_p 相等.不同分辨率及训练轮数设定下,训练时间如图 8、9 所示。




图8 训练时间随训练轮数变化情况
Fig.8 Change of training time with epochs




图9 训练时间随分辨率变化情况
Fig.9 Change of training time with different resolution

由图 8 可以看出,随着训练轮数的增多,训练时间以直线形式增长,这是由于对于相同分辨率的数据而言,每轮训练所执行的运算基本相同,因而其时长呈现线性方式增长.当算法基于不同分辨率的数据块进行训练时,分辨率越低,训练时间越长,具体关系如图 9 所示。

在图 9 中,可以看出随着分辨率的降低,训练总时长急剧增大.造成这一结果的原因为:当分辨率降低时,训练过程需要在多个数据块中进行,总的训练时间需要对多次训练的时间叠加,而每次训练均需进行算

法的初始化与数据的预处理,这一过程在多个数据块中进行叠加,因而大大增加了训练总时间.综上,本文方法在尽量高的分辨率情况下进行训练能够取得较好的效果.

3.5 预测灵活度分析

除此之外,传统方法通常选择相同的分辨率进行训练及预测,倘若需要对不同分辨率的数据进行预测,则需要重新训练模型,而本文算法可以用更高分辨率数据进行训练,用较小的不同分辨率分别进行预测,以适用不同的现实需求,而不用对每种分辨率的数据都进行训练.即应用本文算法可以在预测过程中灵活选取合适的分辨率,算法的适用性更强.比如对一个地区的数据进行预测,实际应用场景中可能需要更细致的数据,例如 100×100 分辨率的数据,也可能需要较为模糊的大致数据分布,比如整个区域 10×10 分辨率的数据.若用传统方法进行预测,则需要重新对此格式进行训练.本文方法可以用大的分辨率进行训练,预测采用更小的不同的分辨率以适用各种现实需求,而不必对每个需求的分辨率格式都训练一遍.为了证明这种方式的有效性,对 100×100 分辨率的训练样本进行按比例采样得到 50×50 分辨率、 33×33 分辨率、 25×25 分辨率、 10×10 分辨率的数据.实验结果如表 2 所示,表 2 为训练样本分辨率 R_t 为 100×100 情况下不同采样分辨率作为预测样本分辨率 R_p 的预测结果误差与训练样本分辨率 R_t 等于预测样本分辨率 R_p 时不同采样分辨率的预测结果误差对比.

表 2 不同采样分辨率温度预测平均绝对误差对比

Tab. 2 Comparison of mean absolute error of temperature prediction with different sampling resolutions

预测样本分辨率 R_p	平均绝对误差/ $^{\circ}\text{C}$ (训练样本分辨率 $R_t=100\times100$)	平均绝对误差/ $^{\circ}\text{C}$ (训练样本分辨率 R_t =预测样本分辨率 R_p)
100×100	<u>2.330 622 474 352 51</u>	<u>2.330 622 474 352 51</u>
50×50	2.844 174 230 556 08	3.105 430 910 984 675
33×33	2.895 557 212 798 21	3.055 579 711 993 535 5
25×25	3.097 636 050 862 99	3.341 281 761 725 743 8
10×10	3.561 276 719 069 54	3.727 368 901 173 273 6

由表 2 和表 3 可以看出,同样区域的数据,用高分辨率采样的数据进行训练,然后用低分辨率采样进行预测,比用低分辨率采样得到的数据直接进行训练和预测的效果更好.

3.6 插值算法有效性分析

卫星遥感数据具有大量的缺失值和异常值,倘若不进行插值处理,则会极大影响预测算法的结果,如果只用基于空间的插值方法则会让数据失去一些时序信息,若只用时序插值方法,则会因为缺失值过多导致部分空间点无法插值.为了证明本文所使用的插值算法在卫星遥感地表温度数据上适用性更好,本文对原始样本数据、异常值用 0 代替数据、只用空间均值法插值数据、空间均值法和时间序列插值法(拉格朗日插值法、牛顿插值法、三样条插值法)结合插值的数据分别用本文方法进行预测实验,得到的实验结果如表 3 所示.

表 3 不同插值处理数据温度预测平均绝对误差对比

Tab. 3 Comparison of mean absolute error of temperature prediction with different interpolation data

插值方法	平均绝对误差/ $^{\circ}\text{C}$
无插值	26 100.840 413 411 457
0-插值	97.077 433 268 229 17
空间均值法	2.799 791 892 369 588 4
空间均值法-拉格朗日时序插值	<u>2.330 513 666 073 481</u>
空间均值法-牛顿时序插值	2.405 933 494 369 189
空间均值法-三样条时序插值	2.608 033 984 899 521

同时为了验证算法 1 和算法 2 两种插值方法对实验数据本身的有效性,采用多种预测方法在不同插值数据上进行了对比实验,实验结果如表 4 所示.

由表 3 和表 4 中的实验数据可知,原始数据有很多异常值和缺失值,如果不进行插值,则会产生非常大的误差,同时经过消融实验验证,本文选择的空间均值法和拉格朗日时序插值法结合的插值数据预测效果更

好,同时无论用何种插值数据,本文方法的最终预测效果最好.

表 4 不同插值处理温度数据在不同方法下预测平均绝对误差对比

Tab. 4 Comparison of mean absolute error of temperature data predicted by different interpolation methods

预测方法	平均绝对误差/℃	平均绝对误差/℃	平均绝对误差/℃
	(空间均值法-拉格朗日时序插值)	(空间均值法-牛顿时序插值)	(空间均值法-三样条时序插值)
本文方法	<u>2.330 513 666 073 481</u>	<u>2.405 933 494 369 189</u>	2.608 033 984 899 521
随机森林 ^[18]	3.369 664 892 781 462	3.707 553 688 755 048	3.902 519 941 950 681
弹性网回归 ^[19]	3.210 047 935 972 577	3.315 747 792 011 497 3	3.423 141 023 190 014
BP 神经网络 ^[20]	3.466 653 763 224 033	3.548 782 280 703 350 4	3.736 373 701 415 625
线性回归 ^[21]	3.220 636 351 873 346	3.359 225 485 925 185 8	3.504 985 656 065 475
SVR 高斯核 ^[22]	3.009 830 989 862 728	3.396 101 197 171 274	3.586 676 798 137 679
SVR 线性核 ^[23]	3.009 889 459 307 798	3.224 485 854 376 596	3.377 939 013 980 043

4 结论与展望

针对当前遥感数据缺失严重、现有数据预测算法精度较低等问题,本文设计了一种基于傅里叶神经算子的遥感数据预测算法.该算法在地面服务器获取遥感数据后对数据进行预处理,填补缺失数据,之后采取傅里叶神经算子进行数据的训练与预测.仿真结果表明该算法具有较高的预测精度与较高的预测效率.该算法可以在风云系列遥感卫星地面系统中进行部署,具有较强的实际应用价值.本文采用的实验数据为遥感数据中常见的周期性标量数值型数据,本文方法在没有明显周期的遥感数据以及矢量型遥感数据的预测上的适用性将会是未来工作的重要方向.

参 考 文 献

[1] MOGHIMI B,SAFIKHANI A,KAMGA C,et al.Short-term prediction of signal cycle on an arterial with actuated-uncoordinated control using sparse time series models[J].IEEE Transactions on Intelligent Transportation Systems,2019,20(8):2976-2985.

[2] PEREIRA P,ARAUJO J,MACIEL P.A hybrid mechanism of horizontal auto-scaling based on thresholds and time series[C]//2019 IEEE International Conference on Systems,Man and Cybernetics(SMC).[S.l.]:IEEE,2019.

[3] ALIZADEH M,RAHIMI S,MA J F.A hybrid ARIMA-WNN approach to model vehicle operating behavior and detect unhealthy states [J].Expert Systems with Applications,2022,194:116515.

[4] 李春,高飞,王会青.改进果蝇算法优化 CIAO-LSTM 网络的时序预测模型[J].计算机工程与应用,2020,56(11):129-134.

LI C,GAO F,WANG H Q.Improved fruit fly optimization algorithm for optimizing time series prediction model of CIAO-LSTM network [J].Computer Engineering and Applications,2020,56(11):129-134.

[5] 王绪亮,聂铁铮,唐欣然,等.流式数据处理的动态自适应缓存策略研究[J].计算机科学,2020,47(11):122-127.

WANG X L,NIE T Z,TANG X R,et al.Study on dynamic adaptive caching strategy for streaming data processing[J].Computer Science,2020,47(11):122-127.

[6] 郭怡然,王秀利.基于 BP 神经网络的股市大小盘风格轮动预测[J].计算机仿真,2019,36(3):239-242.

GUO Y R,WANG X L.Stock market style rotation prediction based on BP nerve network[J].Computer Simulation,2019,36(3):239-242.

[7] 曾安,聂文俊.基于深度双向 LSTM 的股票推荐系统[J].计算机科学,2019,46(10):84-89.

ZENG A,NIE W J.Stock Recommendation System Based on Deep Bidirectional LSTM[J].Computer Science,2019,46(10):84-89.

[8] WANG T,LEUNG H,ZHAO J,et al.Multiseries Featural LSTM for Partial Periodic Time-Series Prediction:A Case Study for Steel Industry[J].IEEE Transactions on Instrumentation and Measurement,2020,69(9):5994-6003.

[9] PETROU Z I,TIAN Y.Prediction of Sea Ice Motion With Convolutional Long Short-Term Memory Networks[J].IEEE Transactions on Geoscience and Remote Sensing,2019,57(9):6865-6876.

[10] WANG W,LIU W,CHEN H.Information Granules-Based BP Neural Network for Long-Term Prediction of Time Series[J].IEEE Transactions on Fuzzy Systems,2021,29(10):2975-2987.

[11] 罗佩,袁景凌,陈旻骋,等.面向教学资源的均值惩罚随机森林非平稳时序预测方法[J].小型微型计算机系统,2021,42(10):2089-2094.

LUO P,YUAN J L,CHEN M C,et al.Mean Penalty Random Forest Nonstationary Time Series Prediction Method for TeachingResources[J].Journal of Chinese Mini-Micro Computer Systems,2021,42(10):2089-2094.

[12] 张忠林,张艳,改进 FA 优化 LSTM 的时序预测模型[J].计算机工程与应用,2022,58(11):125-132.
ZHANG Z L,ZHANG Y.Improved FA Opmtizing LSTM Time Series Prediction Model[J].Computer Engineering and Applications, 2022,58(11):125-132.

[13] DUDEK G,PELKA P,SMYL S.A Hybrid Residual Dilated LSTM and Exponential Smoothing Model for Midterm Electric Load Forecasting[J]IEEE Transactions on Neural Networks and Learning Systems,2022,33(7):2879-2891.

[14] 贺圣平,王会军,李 华,等.机器学习的原理及其在气候预测中的潜在应用[J].大气科学学报,2021,44(1):26-38.
HE S P,WANG H J,LI H,et al.Machine learning and its potential application to climate prediction[J].Transactions of Atmospheric Sciences,2021,44(1):26-38.

[15] 黄小燕,何立,赵华生,等.Shapley-模糊神经网络方法在华南台风卫星云图的长时效滚动预测中的应用[J].气象学报,2021,79(2):309-327.
HUANGX Y,HE L,ZHAO H S,et al.Application of Shapley-fuzzy neural network method in long-time rolling forecasting of typhoon satellite image in South China[J].Acta Meteorologica Sinica,2021,79(2):309-327.

[16] 杨旭,崔瑞飞,田超,等.基于线性样条和 CNN-LSTM 的北斗卫星缺失数据处理方法[J].空间科学学报,2022,42(1):163-169.
YANG X,CUI R F,TIAN C,et al.Linear Spline and CNN-LSTM for Missing Values Imputation of Beidou Satellite Radiation Dose Data [J].Chinese Journal of Space Science,2022,42(1):163-169.

[17] LI Z,KOVACHKI N,AZIZZADENESHELI K,et al.Fourier neural operator for parametric partial differential equations[C]//Proc.9th Int.Conf.Learn.Represent.(ICLR).[S.l.:s.n.],2021.

[18] HUANG D.An Optimized Method for Battery Swapping Demand Prediction based on Random Forest Regression[C]//2021 IEEE 5th Information Technology,Networking,Electronic and Automation Control Conference(ITNEC).[S.l.]:IEEE,2021.

[19] LI S,LI X,ZUOY,et al.Prediction of ship fuel consumption based on Elastic network regression model[C]//2021 8th International Conference on Information,Cybernetics,and Computational Social Systems(ICCSS).[S.l.]:IEEE,2021.

[20] MENG H H,YIAN L.Short-term prediction of BP neural network based on difference method[C]//2020 19th International Symposium on Distributed Computing and Applications for Business Engineering and Science(DCABES).[S.l.]:IEEE,2020.

[21] VIJAYALAKSHMI C,SANGEETH K,JOSPHINELEELA R,et al.Rainfall Prediction using ARIMA and Linear Regression[C]//2022 International Conference on Computer,Power and Communications(ICPC).[S.l.]:IEEE,2022.

[22] ANDRIYANI C,UTAMI E,Al F H.Prediction of Investment Realization Value Using Support Vector Regression(SVR)Methods[C]// 2021 International Conference on Artificial Intelligence and Computer Science Technology(ICAICST).[S.l.]:IEEE,2021.

[23] LONG Y,SHIX,YANG Y,et al.Exhaust Temperature Margin Prediction Based on Time Series Reconstruction[C]//2021 CAA Symposium on Fault Detection,Supervision,and Safety for Technical Processes(SAFEPROCESS).[S.l.]:IEEE,2021.

Prediction method of remote sensing data based on fourier neural operator

Wei Lan^{1,2}, Zhu Jianxuan³, Xu Xiaobin³, Fan Cunqun^{1,2}, Lin Manyun^{1,2}, Zhao Xiangang^{1,2}

(1. Key Laboratory of Radiometric Calibration and Validation for Environmental Satellites, National Satellite Meteorological Center (National Center for Space Weather), China Meteorological Administratio, Beijing 100081, China; 2. Innovation Center for FengYun Meteorological Satellite(FYSIC), Beijing 100081, China; 3. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China)

Abstract: Remote sensing of the earth is the main task of meteorological satellites. Due to factors such as cloud cover and cosmic ray radiation, remote sensing data obtained by meteorological satellites often have a large number of missing and abnormal data. Fourier neural operators have the characteristics of high efficiency, high accuracy, and flexible resolution. This paper proposes a remote sensing data prediction algorithm based on Fourier neural operators. The algorithm first fills in the missing values of remote sensing data using the spatial mean method and Lagrange interpolation method, and then trains the mapping relationship of spatial values in the time domain using Fourier neural operators. Finally, the trained model is used to predict the latest remote sensing data. Simulation experiments based on real remote sensing data of Fengyun-4 remote sensing satellite show that the method proposed in this paper is more effective than others. Good prediction accuracy can still be maintained in long-term time series forecasting.

Keywords: earth remote sensing; time series prediction; long-term prediction; fourier neural operator