

引用格式: ZHANG Peng, WENG Jianwen, KANG Qing, et al. Super-resolution Solar Spectral Irradiance Reconstruction Method Based on Convolutional Neural Network[J]. Acta Photonica Sinica, 2025, 54(3):0330001

张鹏,翁建文,康晴,等. 基于卷积神经网络的太阳光谱辐照度超分辨率重建方法[J]. 光子学报, 2025, 54(3):0330001

基于卷积神经网络的太阳光谱辐照度超分辨率重建方法

张鹏^{1,2}, 翁建文², 康晴², 李健军²

(1 中国科学技术大学 物理学院, 合肥 230026)

(2 中国科学院安徽光学精密机械研究所 中国科学院通用光学定标与表征技术重点实验室, 合肥 230031)

摘要: 针对现有天基参考太阳光谱辐照度数据分辨率不足, 限制其应用范围的问题, 提出一种基于卷积神经网络的太阳光谱辐照度超分辨率重建方法。该网络由一个基于物理模型的全连通层、一维卷积层、非线性层和一系列具有跳跃连接的残差网络组成。同时考虑现有均方误差损失函数无法捕捉太阳光谱峰谷特征的问题, 提出将光谱相对于波长的一阶、二阶导数加入损失函数, 使残差的特征更集中于关键的光谱内容。将所提方法应用于 TSIS-1 SIM 测量太阳光谱辐照度可见光波段的超分辨率重建, 结果表明该方法重建光谱与 TSIS-1 HSRs 产品的测量结果质量相当, 且重建耗时仅需 0.942 1 s, 可有效提高天基观测太阳光谱辐照度数据的分辨率。

关键词: 高分辨率; 太阳光谱辐照度; 卷积神经网络; 残差网络; 光谱超分辨率重建

中图分类号: TP79

文献标识码: A

doi: 10.3788/gzxb20255403.0330001

0 引言

太阳光谱辐照度 (Solar Spectral Irradiance, SSI) 是研究太阳内部成分、温度和活动性的重要参量, 也是研究地球大气层内辐射能量传递的关键。对太阳光谱辐照度进行精确的绝对测量, 特别是在可见-近红外波段, 对于全面了解地球大气化学和气候变化至关重要^[1]。任何气候模型都需要准确的太阳光谱辐照度作为输入。根据所选模型的光谱特性, 辐照度的不确定性可能会在大气和气候预测中表现出显著差异^[2]。此外, 太阳光谱辐照度也用于将测量的卫星辐射转换为反射率^[3]。这就是需要高精度参考太阳光谱辐照度数据集的原因^[4]。

由于地球大气 (臭氧、氧气、一氧化氮、水蒸气、二氧化碳、气溶胶等) 的吸收, 在地面测量的 SSI 具有光谱吸收区域且测量精度较低^[5], 因此必须在太空进行准确的 SSI 测量^[6-7]。太阳光谱辐照度的天基观测始于 70 年代末、80 年代初期。比较典型的任务有国际空间站搭载的欧洲科学家研制的太阳光谱辐照度观测系统 SOLSPEC^[8]、SolACES、和 SOVIM, 以及美国航天局 SORCE 太阳观测卫星搭载的太阳光谱辐照度测量系统。为了提高 SSI 测量的准确性和绝对测量精度, 国内外一些研究机构已经启动了空间辐射测量基准任务^[9]。例如欧洲航天局 (European Space Agency, ESA) 的 TRUTHS 计划^[10]、美国国家航天局 (National Administration for Space and Aeronautics, NASA) 的 CLARREO 探路者计划^[11] 和中国气象局 (China Meteorological Administration, CMA) 的 LIBRA 计划^[12]。

与地面观测数据相比, 天基观测具有相对较高的精度和相对较低 (1 nm 或更差) 的光谱分辨率^[13]。为获取同时具有高精度和高光谱分辨率的参考太阳光谱辐照度数据集, DOBBER M 等提出一种将高光谱分辨

基金项目: 国家重点研发计划 (No. 2022YFB3902901), 国家自然科学基金 (No. 42105121)

第一作者: 张鹏, sa23038048@mail.ustc.edu.cn

通讯作者: 翁建文, wengjw@aiofm.ac.cn

收稿日期: 2024-09-03; 录用日期: 2024-11-27

<http://www.photon.ac.cn>

率太阳光谱数据归一化为更高精度和更低分辨率的绝对太阳光谱辐照度数据来创建高精度和高分辨率参考太阳光谱辐照度数据集的方法^[14]。CODDINGTON O M等在此基础上提出了一种改进版的光谱比值法,将地面测量的高分辨率太阳光谱数据调整为美国宇航局在国际空间站托管的TSIS-1 SIM (Total and Spectral Solar Irradiance Sensor-1 Spectral Irradiance Monitor)仪器的SI可溯源辐照度标度,产生一种新的参考光谱,即TSIS-1混合太阳参考光谱(TSIS-1 Hybrid Solar Reference Spectrum, TSIS-1 HSRs)^[15]。TSIS-1 SIM具有优于以往仪器的测量精度($<0.3\%$),可从国际空间站上有利位置采集200~2400 nm光谱辐照度数据^[16]。

光谱比值法已作为国际上生成参考太阳光谱的通用方法,但光谱比值法很难获取与高精度太阳光谱辐照度同时间、同位置测量的高分辨率太阳光谱辐照度。为摆脱光谱比值法对高分辨率光谱数据依赖,更多学者尝试应用数学反卷积算法提升测量光谱数据分辨率。信号复原或反卷积最早起源于50年代数学界对求解逆问题的研究,是对逆问题的一种统称^[17],该技术从60年代至今不断发展。在国外,美国JANSSON P A提出了Jansson算法^[18]、芬兰KAPPINEN J提出了一种傅里叶自反卷积方法^[19]、德国EICHSTADT S、SCHMAHLING F等提出了基于最大先验理论的迭代反卷积算法。在国内,光谱反卷积算法主要研究方向在盲反卷积算法上,虽然此类算法在复原效果上往往差于非盲反卷积算法,但是其最大的特点就是不需要提前获取仪器响应函数作为先验信息,而改为使用一个仪器响应函数的猜测值,这种特点使得该算法可以快速地运用到任何一种仪器中。清华大学杨怀栋提出了基于维纳逆滤波的盲反卷积算法^[20]。华中师范大学YAN Luxin、LIU Hai等进一步进行了光谱仪盲反卷积算法的相关研究,提出了基于自适应Tikhonov正则化的半盲光谱仪反卷积算法^[21]、基于泊松噪声模型的拉曼光谱盲反卷积算法^[22]、基于泊松噪声模型的光谱盲复原算法^[23]。

不论是哪一种类型的反卷积算法都或多或少需要提前获取仪器的响应函数作为先验信息。对于仪器响应函数先验信息掌握的程度,直接决定了反卷积效果的好坏,因此对于仪器响应函数的理论建模就变得非常重要,目前在光谱分析学领域通常将光谱仪的仪器响应模型近似为高斯模型去处理,且一般认为光谱仪的仪器响应函数不随测量波长改变而改变,光谱复原相关算法研究大多数也都建立在这两种假设的基础之上。传统反卷积方法的性能极大程度受限于测量光谱的准确性和反卷积算法的可靠性,实际测量过程的不可预见性和高维病态逆问题求解的复杂性已成为数学反卷积算法进一步发展的瓶颈问题。

针对现有方法的不足,本文提出一种基于光谱下采样模型和卷积神经网络的高精度太阳光谱辐照度超分辨率重建方法,探索利用深度学习来实现对测量仪器编码采集太阳光谱辐照度逆过程的学习,获取太阳光谱辐照度超分辨率重建模型参数,并通过仿真数据集和SIM载荷数据验证提出方法的可行性。

1 提出的方法

1.1 测量原理

在 λ_{\min} 至 λ_{\max} 的波长范围内,高分辨率太阳光谱辐照度仪在 M 个中心波长为 $\lambda_1, \dots, \lambda_M$ 的波段测量连续太阳光谱得到一个高分辨率的离散信号 $E^h = [E_1^h, \dots, E_M^h]$,并计算测量光谱辐照度 $E(\lambda)$ 。 E_i^h 是第 i 个波长点测得的光谱辐照度。如果假设高分辨率太阳光谱辐照度仪测量波段的数目非常大、波段分辨率极高且相邻,即 $\lambda_{i+1} - \lambda_i \rightarrow 0, i \in \{1, \dots, M-1\}$,则各波段的响应函数可用 δ 函数来近似,例如 i 波段响应为 $\delta(\lambda - \lambda_i)$ 。那么,测量光谱辐照度 $E(\lambda)$ 可近似为

$$E(\lambda) \approx \sum_{i=1}^M E_i^h \delta(\lambda - \lambda_i) \quad (1)$$

让测得的 $E(\lambda)$ 通过低分辨率太阳光谱辐照度仪,在 N 个波长点再次测量,以获得低分辨率离散信号 $E^l = [E_1^l, \dots, E_N^l]$ 。 E_j^l 是第 j 个波长点测得的光谱辐照度。低分辨率太阳光谱辐照度仪测量波段的数量远少于高分辨率波段(即 $N \ll M$)。假设低分辨率太阳光谱辐照度仪在各波长点的光谱响应函数为 $R(\lambda_j)$,则每个低分辨率波段测量到的信号为

$$E_j^l = \int_{\lambda_{\min}}^{\lambda_{\max}} E(\lambda) R(\lambda_j) d\lambda, \forall j \in \{1, \dots, N\} \quad (2)$$

结合式(1)、(2),可得到

$$E_j^l \approx \sum_{i=1}^M E_i^h R(\lambda_{j,i}), \forall j \in \{1, \dots, N\} \quad (3)$$

式(3)可以用矩阵形式表示为

$$E_{1 \times N}^l = E_{1 \times M}^h R_{M \times N} \quad (4)$$

式中, $R_{i,j}$ 是响应矩阵 R 的第 i 行和第 j 列元素。

式(4)为从低分辨率光谱辐照度 E^l 重建高分辨率光谱辐照度 E^h 的理论基础。然而,待求高分辨率光谱辐照度 E^h 的元素数 M 总是远大于实测低分辨率光谱辐照度 E^l 的元素数 N , 这使问题变得难以解决, 即式(3)在数学上无稳定解。不过太阳辐射具有光谱特征, 可以通过构建卷积神经网络来学习这种特征, 从而解决从 E^l 重建 E^h 的不适定问题。

1.2 网络结构

在所提网络中, 利用残差网络架构来学习光谱特征, 从而实现从 E^l 重建 E^h , 设计的网络架构如图1所示。网络由全连通层、一维卷积层、非线性层、一系列残差块、一维卷积层和非线性层组成。网络的输入是低分辨率的光谱辐照度 E^l , 输出是重建的高分辨率光谱辐照度 E^h 。全连通层将 N 维的低分辨率光谱转换为 M 维的高分辨率光谱, M 为最终输出的高精度、高分辨率光谱辐照度的维数。在全连接层之后, 所提出的网络由带 F 个一维滤波器的卷积层和非线性层组成, 目的是获得长度为 M 的 F 个特征图 $x^{(1)}$ 。使用 PReLU 函数作为整个网络中的非线性层激活函数, 并且所有卷积层中使用的滤波器长度均为 3。在非线性层之后, 有 L 个残差块, 每个残差块由一个卷积层和一个非线性层组成, 还有一个从第一个残差块的输入端到最后一个残差块的输出端的跳跃连接。在最终残差块之后, 与一个长度为 K 的滤波器进行卷积, 随后使用非线性层以获得最终的高分辨率光谱辐照度 $E_{1 \times M}^h$ 。

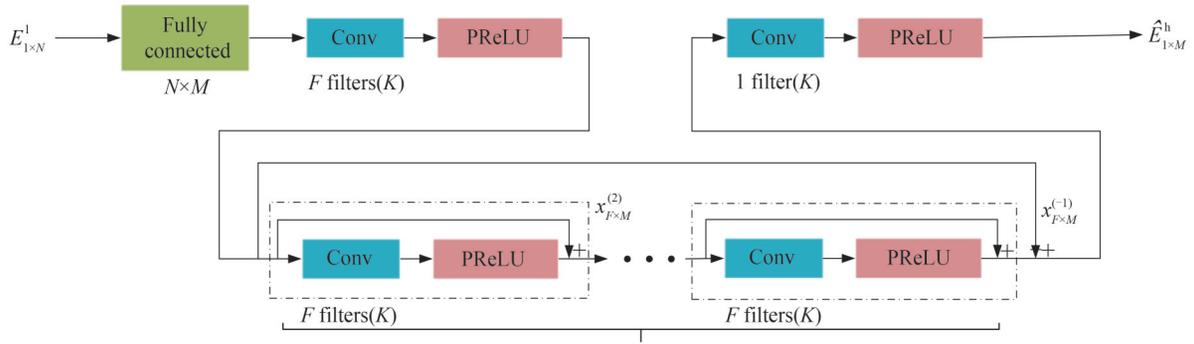


图1 网络架构

Fig.1 Neural network architecture

从编码器-解码器网络的角度来看, 测量过程相当于将高分辨率光谱信号投射到非线性子空间编码上, 而本文提出的网络相当于一个解码器, 将非线性子空间编码低分辨率光谱信号投射到原始的高维空间上。通过反向传播联合优化超分辨率残差网络的参数, 在实测光谱辐照度数据集上对网络进行训练, 以找到最优超分辨率网络。网络训练完成后, 可以通过超分辨率网络将低分辨率光谱辐照度数据投影成高分辨率光谱。

1.3 光谱损失函数

均方误差 (Mean Squared Error, MSE) 是一种较差的损失函数, 往往会产生较模糊、平滑的重建。MSE 用于评价重建的高分辨率太阳光谱辐照度精度存在问题, 这是因为关于太阳光谱特征的信息表现为高分辨率太阳光谱辐照度曲线上尖锐的谷和峰。前期研究表明, 光谱相对于波长的一阶、二阶导数可以捕捉这些光谱特征^[24], 如图2所示, 考虑一阶导数和二阶导数作为损失函数的一部分后得到的重建光谱 h_2 , 在峰值处相较于仅用 MSE 作为损失函数得到的重建光谱 h_1 更加接近参考光谱 h 。基于这一研究结果, 采用 $L_{\text{spectral}}(E, \hat{E})$ 函数评估预测光谱值和真实光谱值之间的差异, 表达式为

$$L_{\text{spectral}}(E, \hat{E}) = \|E - \hat{E}\|^2 + \omega_1 \left\| \frac{dE}{d\lambda} - \frac{d\hat{E}}{d\lambda} \right\|^2 + \omega_2 \left\| \frac{d^2E}{d^2\lambda} - \frac{d^2\hat{E}}{d^2\lambda} \right\|^2 \quad (5)$$

式中, ω_1 和 ω_2 是超参数。 $L_{\text{spectral}}(E, \hat{E})$ 是预测光谱和真实光谱、一阶导数、二阶导数之间的欧氏距离加权, 和,

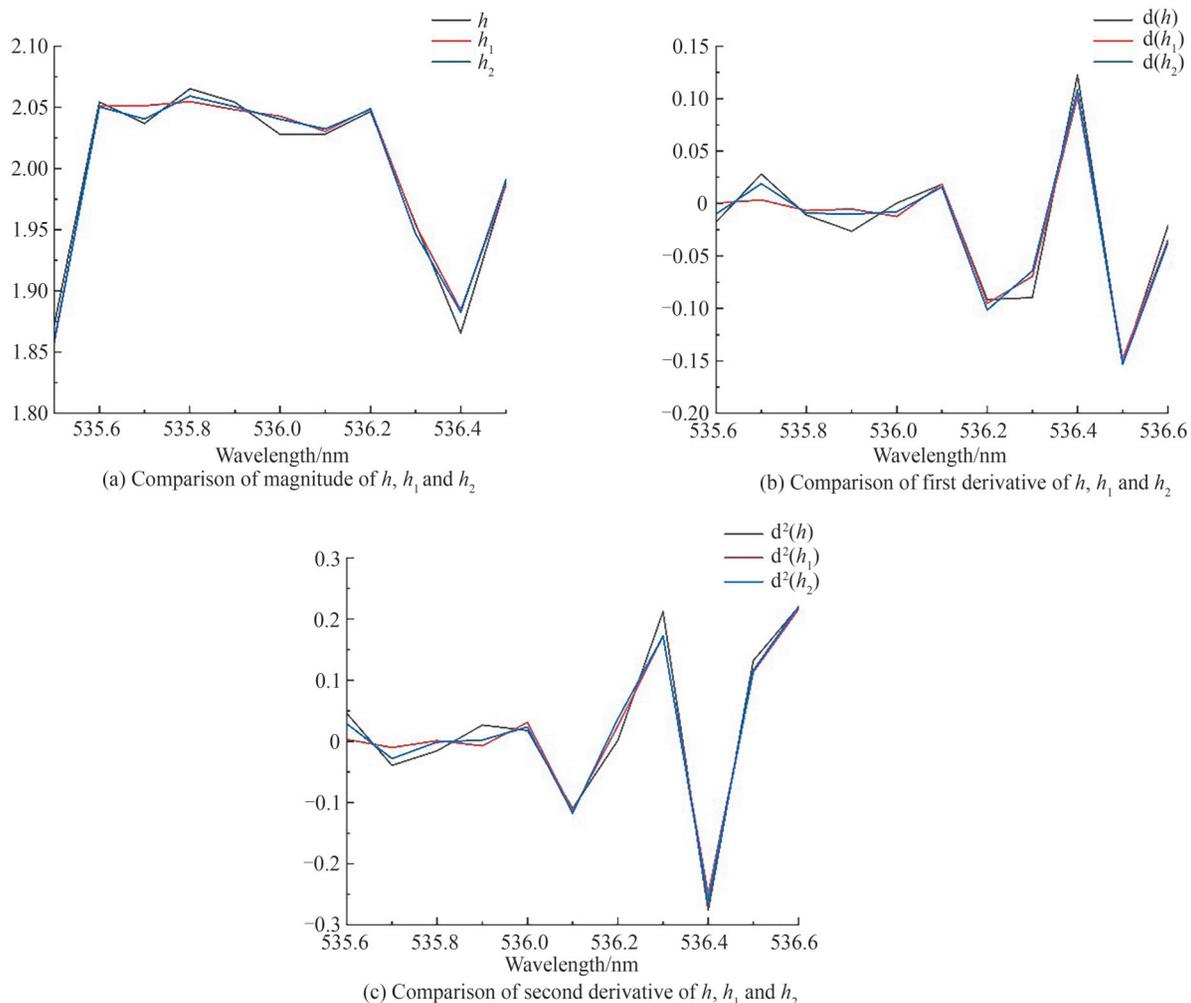


图2 原始光谱 h 的幅度、一阶导数和二阶导数与两个重建光谱 h_1 和 h_2 的比较

Fig.2 Comparison of magnitude, first derivative, and second derivative of the original spectrum h and two reconstructions spectra h_1 and h_2

将此函数作为参数寻优过程中的损失函数。

光谱角制图 (Spectral Angle Mapper, SAM) 算法^[25] 把图像中每个像素的光谱视为一个高维向量, 通过计算两向量间的夹角来度量光谱间的相似性。如图 3 所示, 夹角越小, 两光谱越相似, 因而可根据光谱角的大小来判断训练模型的优劣, 即

$$\text{SAM}_e = \cos^{-1} \left(\frac{\mathbf{t} \cdot \mathbf{r}}{\|\mathbf{t}\| \cdot \|\mathbf{r}\|} \right) \quad (6)$$

式中, \mathbf{t} 和 \mathbf{r} 分别为测试光谱和参考光谱投影向量。采用 SAM 角作为最优模型选择标准, 如果网络训练过程中出现更小的 SAM 角, 则保存此时模型作为最优模型。

2 实验验证

2.1 验证数据集

2.1.1 TSIS-1 SIM

总太阳辐照度和光谱太阳辐照度传感器 (TSIS-1) 中的光谱辐照度监测仪 (SIM) 是一个棱镜光谱仪, 用于测量 0.2~2.4 μm 光谱范围内的太阳光谱辐照度, 光谱分辨率约为 0.25~42 nm。TSIS-1 SIM 与传统的

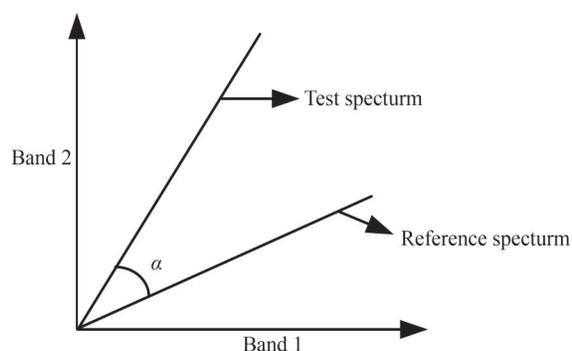


图3 参考光谱和测试光谱 SAM 角
Fig.3 Reference spectra and test spectra SAM angles

SORCE SIM 仪器同名,但有多项关键性的升级。TSIS-1 SIM 相比传统 SORCE SIM 取消了中继镜结构,增加了用于在轨校正的通道,具有更好的噪声性能、更优的稳定性和更高的绝对定标精度。采用美国国家标准与技术研究院研发的 SIRCUS(Spectral Irradiance and Radiance responsivity Calibrations with Uniform Sources)定标装置^[16]对整个系统的光谱辐照度进行检验和绝对校准,将发射前的相对不确定度降低为 0.24%(>460 nm)到 0.41%(<460 nm)。利用以不同占空比暴露于太阳的冗余和独立仪器通道进行观测来监测和纠正仪器退化,以保持在校准的稳定性。对于以往太阳辐照度参考光谱来讲,TSIS-1 SIM 辐射精度的不确定性降低了一个数量级。TSIS-1 SIM 自 2018 年 3 月起从国际空间站测量每日太阳光谱辐照度,数据可从 <https://lasp.colorado.edu/home/tsis/data/ssi-data/> 获取。

2.1.2 TSIS-1 HSRs

TSIS-1 混合太阳参考光谱(Hybrid Solar Reference Spectrum, HSRs)是一个跨度为 0.2~2.73 μm 的复合参考光谱^[26],它是通过将光谱分辨率至少为 0.01 nm 的低精度独立太阳谱线观测数据归一化为 TSIS-1 SIM 和紧凑型光谱辐照度监测仪(Compact Spectral Irradiance Monitor, CSIM)观测数据的高精度绝对辐照度标度而开发的。CSIM 是一项立方体卫星技术演示任务,观测 210~2 800 nm 的太阳光谱辐照度。CSIM 在与 TSIS-1 SIM 相同的设备中进行校准,但采用的是标准传递而非绝对校准验证。CSIM 在 0.3~2.0 μm 范围内的测量不确定性小于 1%,在 2.0 μm 以上增加到 1.26%^[6]。HSRS 参考的高分辨率太阳谱线观测数据主要由美国空军地球物理实验室的太阳辐照度观测结果和基特峰国家天文台获得的太阳透射光谱组成。

Coddington 等^[15]全面详细地介绍了 HSRs 的推导过程。TSIS-1 HSRs 的不确定性在 0.4~0.46 μm 波长之间为 0.5%,在 0.46~2.365 μm 之间为 0.3%,在 400 nm 以下和 2 365 nm 以上为 1.3%,HSRS 的不确定性已考虑了 TSIS-1 SIM 和 CSIM 观测数据不确定性的贡献。HSRS 数据可从 https://lasp.colorado.edu/lisird/data/tsis1_hsr_files 获取,如表 1 所示,本文使用的 HSRs 数据光谱分辨率为 0.1 nm。

表 1 使用的太阳光谱
Table 1 The used solar spectra

| Data product | Spectral resolution | Uncertainty |
|--------------|---------------------|-------------|
| TSIS-1 SIM | 0.25~42 nm | 0.24%~0.41% |
| TSIS-1 HSRs | 0.1 nm | 0.3%~1.3% |

2.2 验证方法与流程

2.2.1 训练数据集生成

由于表 1 中列出的 SSI 数据集仅有一组,因此直接采用获取的 TSIS-1 HSRs 和 TSIS-1 SIM 数据进行训练是不可行的。截取 TSIS-1 HSRs 数据光谱数据中的可见光波段(311.4~949.4 nm),添加不同类型的噪声来扩充数据至 5 000 条光谱,增加训练数据集的同时提高模型对噪声变化的适应能力。然后将所有扩充后的 TSIS-1 HSRs 数据与 SIM 仪器的线形函数(LSF)进行卷积,将其重新采样为与 TSIS-1 SIM 的光谱分辨率一致的光谱数据,具体流程如图 4 所示。TSIS-1 SIM 的 LSF 可从 https://lasp.colorado.edu/tsis/data/ssi-data/#tsis_sim_lsf 获取,波长范围为 200~2 400 nm,采样间隔为 0.1 nm。图 5(a)为 TSIS-1 HSRs 0.1 nm 高分辨率太阳光谱辐照度和卷积至 TSIS-1 SIM 分辨率太阳光谱辐照度数据曲线,图 5(b)为 443 nm 处 TSIS-1 SIM 的线形函数(TSIS-1 SIM LSF 的形状为三角形)。

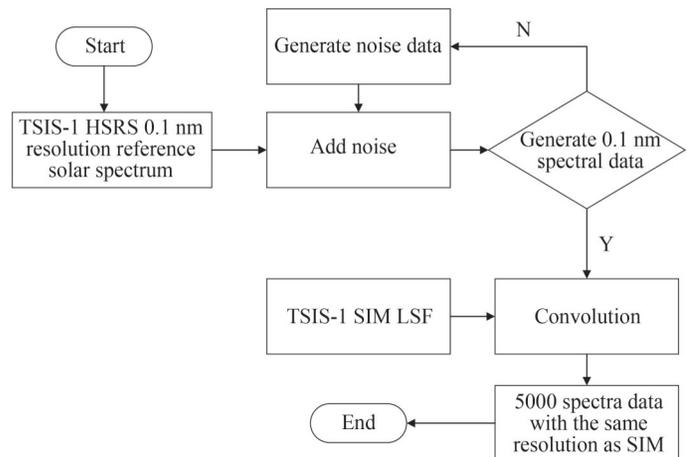


图 4 训练数据集生成流程

Fig.4 Training data set generation process

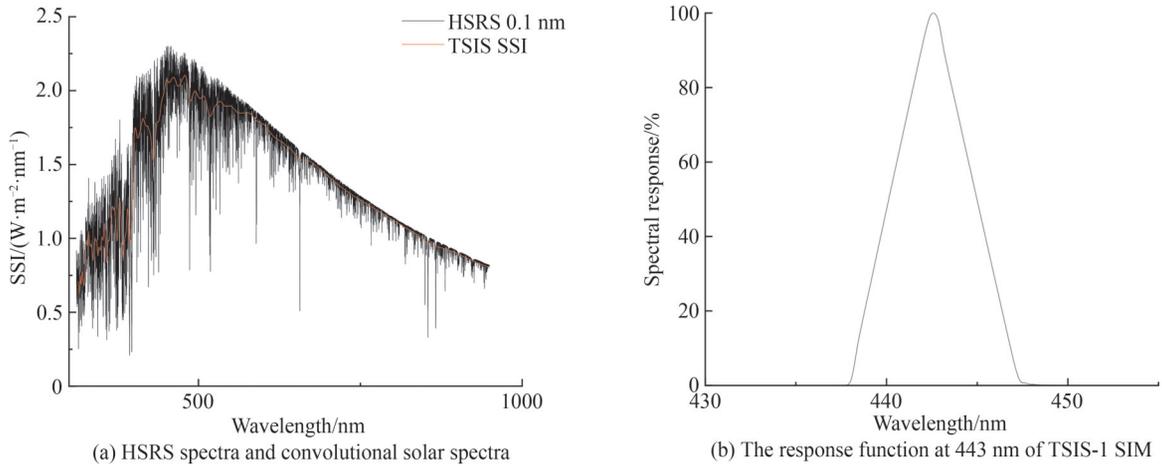


图5 HRSR光谱与卷积后的太阳光谱和TSIS-1 SIM在443 nm处的响应函数
Fig.5 HRSR spectra and convolutional solar spectra and the response function at 443 nm of TSIS-1 SIM

2.2.2 模型训练

根据2.2.1节生成的5 000组光谱数据,将70%组光谱数据作为训练数据集加入训练集,选取其中30%组光谱序列作为验证集。网络的训练和测试环境为Intel i7-12650H 2.30 GHz处理器和NVIDIA RTX 4060显卡。在训练神经网络时,使用Adam^[27]作为优化器,通过贝叶斯优化得到学习率为 9.41×10^{-5} ,批次数量batch-Size为8,卷积层的特征数量 F 为16,滤波器大小 K 为11,步长为1,残差层数 L 为9, w_1 为0.103 7, w_2 为0.645 2,每1 000次Adam迭代后提前停止并验证。验证次数与训练、验证误差关系如图6所示,从图中可知,随着Adam迭代次数增加,训练损失函数值逐渐趋于0,验证SAM角在20次验证后趋于稳定,训练和验证RMSE值相同且波动较大,最终与验证SAM角趋于重合,说明采用损失函数能够很好地对模型参数进行寻优。

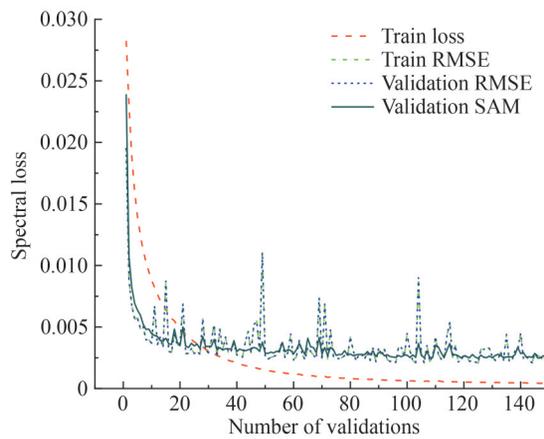


图6 训练误差
Fig.6 Training error

2.2.3 验证结果

将TSIS-1 SIM在2019年12月1日至7日的可见光波段(311.4~949.4 nm)太阳光谱辐照度测量数据的平均值输入到本文训练网络进行重建,得到0.1 nm分辨率重建太阳光谱辐照度,重建结果如图7所示。从图7可知,采用本文方法重建的0.1 nm太阳光谱辐照度与官方采用光谱比值法重建的0.1 nm太阳光谱辐照度曲线基本重合。

采用均方根误差(Root Mean Square Error, RMSE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、平均光谱角SAM、峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性指数(Structural Similarity Index, SSIM)表征重建光谱的质量,并与Janssen迭代方法^[18]和Richardson-Lucy带宽

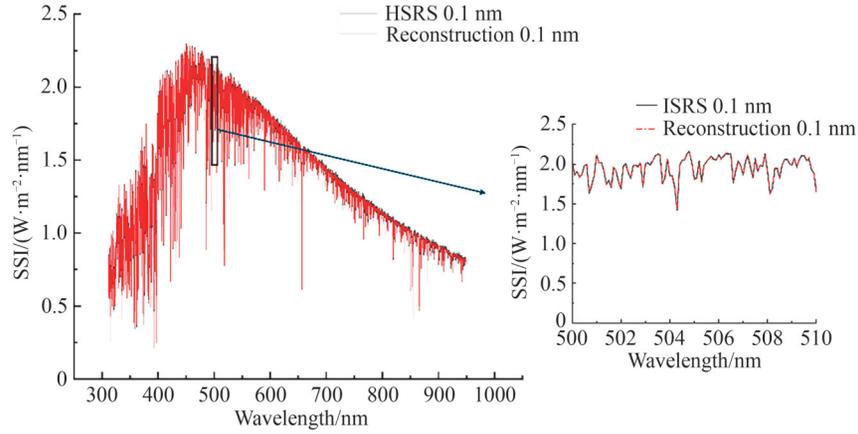


图7 0.1 nm分辨率重建太阳光谱辐照度

Fig.7 0.1 nm resolution reconstruction of solar spectral irradiance

矫正方法^[28]所得到的重建光谱质量进行对比, RMSE的表达式为

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_{\text{sun, hrsr}}(i) - E_{\text{sun, super}}(i))^2} \quad (7)$$

式中, $E_{\text{sun, hrsr}}$ 是 HRSR 光谱辐照度, $E_{\text{sun, super}}$ 是重建光谱辐照度。MAPE的表达式为

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{E_{\text{sun, hrsr}}(i) - E_{\text{sun, super}}(i)}{E_{\text{sun, hrsr}}(i)} \right| \times 100\% \quad (8)$$

PSNR的表达式为

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (9)$$

式中, MAX 是 HRSR 光谱辐照度最大值, MSE 是 HRSR 光谱辐照度与重建光谱辐照度之间的均方误差。SSIM的表达式为

$$\text{SSIM}(x, y) = \frac{(2u_x u_y + C_1)(2\sigma_{xy} + C_2)}{(u_x^2 + u_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (10)$$

式中, x 和 y 分别是参考光谱和重建光谱, u_x 和 u_y 分别表示这两个光谱的均值, σ_x^2 和 σ_y^2 分别表示这两个光谱的方差, σ_{xy} 表示这两个光谱的协方差, C_1 和 C_2 是常数, 用于避免分母为 0 的情况。

最终计算得到的重建光谱质量如表 2 所示, 其中 MAPE 值为 0.636 6, 与 TSIS-1 HRSR 给出的不确定度水平相当, 表明本文方法重建光谱具有一定的可行性。另外, 本文方法重建单条光谱平均耗时(全部数据)仅为 0.942 1 s, 可认为是一种快速重建方法, 满足光谱重建的实时性需求。

表 2 TSIS-1 SIM 数据产品重建质量
Table 2 TSIS-1 SIM data product reconstruction quality

| Method | RMSE | MAPE | SAM | PSNR | SSIM |
|----------------------|---------|---------|---------|----------|---------|
| Bandwidth correction | 0.222 4 | 6.219 8 | 0.082 3 | 25.620 2 | 0.482 2 |
| Janssen iteration | 0.208 1 | 5.496 5 | 0.077 0 | 26.190 4 | 0.485 9 |
| CNN | 0.009 9 | 0.636 6 | 0.002 1 | 47.270 9 | 0.970 9 |

3 结论

本文结合太阳光谱辐照度测量的完整物理过程, 提出了一种基于卷积神经网络的光谱辐照度超分辨率重建方法。该方法从太阳光谱辐照度测量逆过程的角度考虑高性能光谱非线性重建问题, 采用残差网络学习光谱非线性特征。将预测光谱和真实光谱之间的一阶导数、二阶导数欧氏距离加入损失函数, 构建了兼顾精度与光谱特征的模型综合评价指标作为模型参数寻优过程中的损失函数。通过对 TSIS-1 HRSR 数据

添加噪声方法实现小样本数据的扩充,结合 TSIS-1 SIM 仪器线形函数,生成训练数据集并完成模型训练。最后采用 TSIS-1 SIM 测量太阳光谱辐照度对模型有效性进行验证,验证结果表明,获取的超分辨率结果与 TSIS-1 HSRs 官方结果接近,但重建时间仅为 0.942 1 s,同时避免了现有的光谱比值重建法对地面测量高分辨率太阳光谱辐照度数据集的依赖。深度学习方法的局限性往往体现在数据集的获取上,不过在其他方向已经有了一些不需要过多数据集就能够得到训练模型的方法(如预学习模型、生成对抗网络等),未来可能的改进方向就是减少模型对数据集的依赖。本研究表明,卷积神经网络能够很好地学习太阳光谱辐照度及其测量仪器特征,有利于加快太阳光谱辐照度的重建速度,扩展了高精度天基观测太阳光谱辐照度的应用范围。

参考文献

- [1] HAIGHT J D. The Sun and the Earth's climate[J]. Living Reviews in Solar Physics, 2007, 4: 2.
- [2] THUILLIER G, ZHU Ping, SNOW M, et al. Characteristics of solar-irradiance spectra from measurements, modeling, and theoretical approach[J]. Light: Science & Applications, 2022, 11(4): 565-579.
- [3] WIELICKI B A, YOUNG D F, MLYNCZAK M G, et al. Achieving climate change absolute accuracy in orbit[J]. Bulletin of the American Meteorological Society, 2013, 94(10): 1519-1539.
- [4] YAO Baoli, LEI Ming, XUE Bin, et al. Progress and applications of high-resolution and super-resolution optical imaging in space and biology[J]. Acta Photonica Sinica, 2011, 40(11): 1607.
姚保利, 雷铭, 薛彬, 等. 高分辨和超分辨光学成像技术在空间和生物中的应用[J]. 光子学报, 2011, 40(11): 1607.
- [5] THUILLIER G, HARDER J W, SHAPIRO A, et al. The infrared solar spectrum measured by the SOLSPEC spectrometer onboard the international space station[J]. Solar Physics, 2015, 290(6): 1581-1600.
- [6] RICHARD E, HARBER D, DRAKE G, et al. Compact spectral irradiance monitor flight demonstration mission[C]. SPIE, 2019, 11131: 15-34.
- [7] HILBIG T, WEBER M, BRAMSTEDT K, et al. The new SCIAMACHY reference solar spectral irradiance and its validation[J]. Solar Physics, 2018, 293(8): 1-26.
- [8] MEFTAH M, DAMÉ L, BOLSÉE D, et al. SOLAR-ISS: A new reference spectrum based on SOLAR/SOLSPEC observations[J]. Astronomy & Astrophysics, 2018, 611: A1.
- [9] ELSEY J, COLEMAN M D, GARDINER T, et al. Can measurements of the near-infrared solar spectral irradiance be reconciled? A new ground-based assessment between 4,000 and 10,000 cm^{-1} 10,000 cm^{-1} [J]. Geophysical Research Letters, 2017, 44(19): 10071-10080.
- [10] GREEN P D, FOX N P, LOBB D, et al. The traceable radiometry underpinning terrestrial and helio studies (TRUTHS) mission[C]. Toulouse: Proceedings Volume 9639, Sensors, Systems, and Next-Generation Satellites XIX, 2015, 9639: 367-376.
- [11] TOBIN D, HOLZ R, NAGLE F, et al. Characterization of the climate absolute radiance and refractivity observatory (CLARREO) ability to serve as an infrared satellite intercalibration reference[J]. Journal of Geophysical Research Atmospheres, 2016, 121(8): 4258-4271.
- [12] ZHANG Peng, LU Naimeng, LI Chuanrong, et al. Development of the Chinese space-based radiometric benchmark mission LIBRA[J]. Remote Sensing, 2020, 12(14): 2179.
- [13] THUILLIER G, FLOYD L, WOODS T N, et al. Solar irradiance reference spectra[J]. Geophysical Monograph Series, 2013, 141: 171-194.
- [14] DOBBER M, VOORS R, DIRKSEN R, et al. The high-resolution solar reference spectrum between 250 and 550 nm and its application to measurements with the ozone monitoring instrument[J]. Solar Physics, 2008, 249(2): 281-291.
- [15] CODDINGTON O M, RICHARD E C, HARBER D, et al. The TSIS-1 hybrid solar reference spectrum[J]. Geophysical Research Letters, 2021, 48(12): e2020GL091709.
- [16] RICHARD E, HARBER D, CODDINGTON O, et al. SI-traceable spectral irradiance radiometric characterization and absolute calibration of the TSIS-1 Spectral Irradiance Monitor (SIM)[J]. Remote Sensing, 2020, 12(11): 1818.
- [17] 邹谋炎. 反卷积和信号复原[M]. 国防工业出版社, 2001.
- [18] JANSSON P A, JANSSON T L J H, IIR J M. Deconvolution of images and spectra[M]. Academic Press, Inc. 1996.
- [19] KAUPPINEN J K, MOFFATT D J, MANTSCH H H, et al. Fourier transforms in the computation of self-deconvoluted and first-order derivative spectra of overlapped band contours[J]. Analytical Chemistry, 1981, 53(9): 1454-1457.
- [20] YANG Huaidong, XU Li, CHEN Kexin, et al. Blind deconvolution algorithm for spectrogram super-resolution restoration[J]. Spectroscopy and Spectral Analysis, 2007(7): 1249-1253.
杨怀栋, 徐立, 陈科新, 等. 盲目反卷积光谱图超分辨复原算法[J]. 光谱学与光谱分析, 2007(7): 1249-1253.
- [21] YAN L, LIU H, ZHONG S, et al. Semi-blind spectral deconvolution with adaptive Tikhonov regularization[J]. Applied Spectroscopy, 2012, 66(11): 1334-1346.

- [22] LIU Hai, ZHANG Zhaoli, SUN Jianwen, et al. Blind spectral deconvolution algorithm for Raman spectrum with Poisson noise[J]. *Photonics Research*, 2014, 2(6):168-171.
- [23] LIU Hai, LI Youfu, ZHANG Zhaoli, et al. Blind Poissonian reconstruction algorithm via curvelet regularization for an FTIR spectrometer[J]. *Optics Express*, 2018, 26(18): 22837-22856.
- [24] TSAI F, PHILPOT W. Derivative analysis of hyperspectral data[J]. *Remote Sensing of Environment*, 1998, 66(1): 41-51.
- [25] KRUSE F A, LEFKOFF A B, BOARDMAN J W, et al. The spectral image processing system (SIPS)—Interactive visualization and analysis of imaging spectrometer data[J]. *Remote Sensing of Environment*, 1993, 44(2-3): 145-163.
- [26] CODDINGTON O M, RICHARD E C, HARBER D, et al. Version 2 of the TSIS-1 hybrid solar reference spectrum and extension to the full spectrum [J]. *Earth and Space Science*, 2023, 10(3): e2022EA002637.
- [27] KINGMA D P, BA J. Adam: a method for stochastic optimization[C]. *Computer Science*, 2014.
- [28] GARDNER J L. Spectral deconvolution applications for colorimetry [J]. *Color Research & Application*, 2014, 39(5): 430-435.

Super-resolution Solar Spectral Irradiance Reconstruction Method Based on Convolutional Neural Network

ZHANG Peng^{1,2}, WENG Jianwen², KANG Qing², LI Jianjun²

(1 *School of Physical Sciences, University of Science and Technology of China, Hefei 230026, China*)

(2 *Key Laboratory of Optical Calibration and Characterization, Anhui Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Hefei 230031, China*)

Abstract: Obtaining accurate, resolved and traceable reference solar spectral irradiance variations is of great research significance and application value in the fields of solar physics, atmospheric physics and environmental science. However, the high-precision solar spectral irradiance data available domestically and internationally generally has a low resolution, while the high-resolution reference solar spectral irradiance has a low precision, and the acquisition of high-resolution solar spectral irradiance data usually faces the problems of sampling difficulty, time-consuming sampling, and limited data precision.

To address this problem, we propose a deep learning-based approach to reconstruct high-resolution spectral irradiance by analyzing a large amount of low-resolution spectral irradiance data. Our approach is based on a novel end-to-end fully convolutional residual neural network architecture that employs a new loss function, and by training the CNN model, we can learn the spectral features of the solar radiation to achieve high-resolution reconstruction of the solar spectral irradiance. This method utilizes the advantage of CNN in spectral feature extraction, which can fully exploit the feature information of high-resolution spectra. In our experiments, we first select the visible band (311.4~949.4 nm) of the HSRS high-resolution spectral dataset to add noise to expand the data to 5 000 spectra, and then convolve all the data with the Line Shape Function (LSF) with the SIM instrument to resample them into spectral data consistent with the low-resolution spectral resolution of the TSIS-1 SIM. Our CNN model is designed with some key improvement strategies to better accommodate the feature extraction requirements of high-resolution spectral reconstruction. The CNN spectral super-resolution network consists of a fully connected layer, a one-dimensional convolutional layer, a nonlinear layer, eight residual blocks, a one-dimensional convolutional layer and a cascade of nonlinear layers. The network was trained and tested on an Intel i7-12650H 2.30 GHz processor and an NVIDIA RTX 4060 graphics card, and the TensorFlow was used as a development framework for neural networks. In the training phase, a new loss function was used to better reconstruct the features of the spectra, which is a weighted sum between the Euclidean distances of the original and reconstructed spectra as well as their first and second order derivatives. The loss function was optimized using the Adam optimizer to optimize the loss function, with every 8 sets of spectral data as a batch, and every 1 000 batches for validation. If there is no improvement after more than 10 validation attempts, stop the training. Validation was performed on a randomly selected batch of spectra in the validation set and the average Spectral Angle Mapping (SAM) between the input and the reconstruction was used as a metric for validation loss. The reason for using the average SAM rather than the Root Mean

Square Error (RMSE) as a measure of validation performance is that the SAM better compares the metric of spectral shape. During the testing phase, the reconstruction was performed using the average of the TSIS-1 SIM solar spectral irradiance measurements in the visible band from December 1-7, 2019, fed into a neural network. The reconstructed 0.1 nm solar spectral irradiance essentially overlapped with the official 0.1 nm solar spectral irradiance curve reconstructed using the spectral ratio method, with a SAM of 0.002 1, a MAPE of 0.636 6%, and the reconstruction time is only 0.942 1 s. This study shows that the proposed convolutional neural network can learn the solar spectral irradiance and its measurement instrument features well, which is conducive to accelerating the reconstruction speed of the solar spectral irradiance and expanding the scope of application of the solar spectral irradiance for high-precision space-based observation.

Key words: High resolution; Solar spectral irradiance; Convolutional neural networks; Residual networks; Spectral super-resolution reconstruction

OCIS Codes: 300.6170; 300.6320; 300.6190

CSTR: 32255.14.gzxb20255403.0330001