

文章编号: 2096-1618(2022)05-0494-07

基于 Himawari-8 卫星数据的青藏高原大气 可降水量反演算法研究

江金昊, 刘海磊, 王乙竹, 张升兰

(成都信息工程大学电子工程学院, 四川 成都 610225)

摘要:大气可降水量对降水形成、水循环、物质能量交换、天气和气候变化均有重要影响。青藏高原的水汽分布、输送特征是重要的高原气象科学问题。新一代静止气象卫星能够获取更高时间、空间和光谱分辨率的观测数据,为高时空分辨率 PWV 探测提供良好的机遇。利用 Himawari-8 卫星的水汽和分裂窗区通道亮温、全球天气预报系统(GFS)的 PWV 预报场和其他辅助数据(卫星观测角、海拔高度、经纬度和时间信息),构建一种基于神经网络的青藏高原 PWV 快速反演算法。结果表明,神经网络模型估算的 PWV 与地基全球定位系统(GPS) PWV 的相关系数、均方根误差和偏差分别为0.957、1.33 mm和-0.004 mm。相比之下,未包含 GFS PWV 模型反演的 PWV 相关系数、均方根误差和偏差分别为0.943、1.52 mm和0.01 mm,意味着引入 GFS PWV 预报场可以有效提高模型的反演精度。该方法适用于其他低水汽环境下的 PWV 反演,也可用于其他静止气象卫星数据。

关键词:青藏高原;Himawari-8;大气可降水量;神经网络;GFS

中图分类号:TP301.6

文献标志码:A

doi:10.16836/j.cnki.jcuit.2022.05.002

0 引言

大气中的水汽及其变化是天气和气候变化的主要驱动力,是影响气候变化和维持地球生态平衡的关键要素^[1],其在降水和灾害性天气预报、大气辐射研究、水循环和全球气候变化研究等方面具有重要应用^[2-3]。此外,大气中的水汽含量也是影响遥感应用的主要物理量之一,如地表参数精确反演、遥感数据大气订正等均需要精确的水汽信息^[4-6]。

大气可降水量(precipitable water vapor, PWV)是表征大气水汽的一个重要参数,指单位面积空气柱里含有的水汽总量^[7]。目前,有多种技术手段可以进行 PWV 的探测,根据探测手段可分为无线电探空、地基遥感和卫星遥感^[8-10]3类。虽然无线电探空、地基遥感探测精度较好,但这两类探测方式仅能给出固定点上空的水汽分布情况,通常无法准确、客观地反映某一地区水平尺度上的水汽含量梯度变化^[11-12]。

青藏高原占中国领土面积的四分之一,平均海拔高度4000 m以上,是世界上海拔最高、地形最复杂的高原^[13]。青藏高原地气作用过程,尤其是能量与水分循环过程对亚洲季风、东亚大气环流及全球气候变化均有重要影响^[14]。因此,高原的水汽分布、来源、输送等一直都是非常关注的高原气象科学问题^[14-15]。

极轨气象卫星每天仅可以提供同一地区一至两次的 PWV 观测,加之青藏高原云量偏多使极轨卫星获取的有效数据非常有限^[16]。相比之下,静止气象卫星具有观测区域大、频次高的优势,是目前获取青藏高原高时空分辨率水汽信息的有效手段^[17]。因此开展基于静止气象卫星的青藏高原高精度水汽探测研究具有重要实际应用价值与现实意义。

目前,静止气象卫星没有近红外和微波水汽探测通道,因此其 PWV 反演算法主要是基于热红外通道数据展开的。PWV 红外反演算法大致可分为线性分裂窗算法、分裂窗方差协方差比值算法和物理分裂窗算法^[18-19],这些算法均是基于水汽在分裂窗区通道吸收差异原理开发的^[9]。线性分裂窗算法和分裂窗方差协方差比值算法通常假定分裂窗区通道发射率相同,且邻近像元需存在一定的温度差异,这一定程度限制了算法的精度和适用性。物理分裂窗算法由于考虑了辐射传输过程,其精度优于线性分裂窗算法^[20]。

传统的分裂窗算法实质是利用水汽在分裂窗区通道吸收差异原理开展的。在干燥环境下(比如 PWV <2.0 cm),水汽吸收差异引起的分裂窗区通道亮温差较小(可小于1.0 K),这可与通道发射率不确定性引起的亮温差、仪器噪声和定标误差相当。算法更容易受到发射率不确定性和观测误差的影响,因此低水汽环境下仅利用分裂窗通道估算 PWV 存在较大的不确定性^[19]。青藏高原平均海拔高度超过4000 m,水汽含

量相比同纬度地区明显偏低,再加之高原地形复杂、发射率等辅助数据缺乏,使仅基于分裂窗区通道无法获取青藏高原可靠的 PWV 信息^[9]。

近年来国际上都在发展新一代静止气象卫星,比如日本的 Himawari-8/9、美国的 GOES-R、中国的 FY-4A/4B 和欧洲的 MTG-I/S 等陆续发射升空^[21-22]。新一代卫星搭载的成像辐射仪在时间、空间、光谱分辨率及观测精度等方面显著提升,可提供更加丰富的大气温度、湿度信息,这为青藏高原高海拔、低水汽环境下的高精度 PWV 反演提供了良好的机遇。

目前,AGRI/FY-4A 和 ABI/GOES-R 已发布了总水汽含量和分层水汽产品。AGRI 和 ABI 的水汽产品算法相似,都是基于一维变分(1DVAR)方法,利用卫星的多通道观测进行物理迭代,实现大气温度和湿度廓线的反演^[7,23]。之后,对反演的大气廓线进行积分获得分层和总水汽含量。由于静止气象卫星成像仪通道较少,这给大气温度和湿度廓线的反演带来较大不确定性。此外,该方法对大气廓线初始场的依赖性较强。已有的研究表明 AGRI 和 ABI 产品在低水汽情况下的误差较大,其中 AGRI 水汽产品在青藏高原的相对误差可达 30%~80%^[7]。

Himawari-8 搭载的高级成像仪(advanced himawari imagers,AHI)除提供 2 个红外分裂窗通道以外,还具备 6.2 μm 、7.0 μm 和 7.3 μm 附近的水汽通道观测能力^[24-25]。这有助于中高层水汽探测,也有利于提高低水汽环境下的 PWV 反演精度。目前,Himawari-8 卫星并未发布官方 PWV 产品,使用 AHI 数据开展青藏高原 PWV 反演的研究较少。本研究将利用 AHI 多通道红外观测和其他辅助数据,基于神经网络技术构建一种适用于青藏高原低水汽情况下的 PWV 反演算法。

1 数据和方法

1.1 数据

1.1.1 Himawari-8 数据

Himawari-8 是日本气象厅的新一代静止气象卫星,于 2014 年 10 月 7 日发射,2015 年 7 月 7 日正式业务化运行,位于 140.7 °E 的赤道上空,覆盖范围为 60 °N~60 °S,80 °E~160 °W。其搭载的成像仪 AHI 共有 16 个光谱通道,包括 3 个可见光通道,3 个近红外通道和 10 个红外通道^[22]。每 10 min 可进行一次全圆盘扫描,每 2.5 min 对日本周边地区进行一次区域扫描。目前,Himawari-8 卫星没有发布 PWV 业务化产品。

AHI 具有 2 个红外分裂窗通道和 6.2 μm 、7.0 μm 和 7.3 μm 3 个水汽通道观测能力。利用中光谱分辨率大气辐射传输模式(MODTRAN5.2)开展这些通道的水汽敏感性分析,图 1 给出了不同高度中纬度冬季标准大气湿度廓线 5% 变化,所引起的通道亮温变化情况。AHI 的 6.2 μm 、7.0 μm 和 7.3 μm 通道权重函数的峰值在 400 hPa、520 hPa 和 580 hPa 附近,通常情况主要提供中上层水汽信息,受地表参数(如地表温度和发射率)的影响较小。11.2 μm 和 12.3 μm 窗区通道主要对低层水汽更为敏感,权重函数峰值为 800 hPa 和 780 hPa 附近。




图 1 不同高度中纬度冬季标准大气湿度廓线 5% 变化引起的通道亮温变化

通道敏感性在不同大气条件下会有所不同,青藏高原平均海拔高度达 4000 m,AHI 水汽吸收通道具备提供整个空气柱水汽含量的潜力。此外,红外分裂窗区通道的差分吸收也能提供 PWV。因此,选用 AHI 的水汽吸收和分裂窗区 5 个红外通道亮温进行水汽反演。表 1 为使用通道的主要特征,使用数据的时间是 2016 年 1 月 1 日~12 月 30 日。此外,还使用了 AHI L2 级云检测产品,主要用于分辨晴空和云天像元。AHI 数据下载于日本宇宙航空研究开发机构地球观测研究中心(<http://www.eorc.jaxa.jp/ptree/index.html>)。由于 JAXA 的 P-Tree 数据网发布的云检测产品只有白天的数据,因此本研究仅使用了 0~12 UTC 的数据,时间间隔为 1 h。

表 1 算法所使用 AHI 通道的主要特征

通道编号	波长/ μm	星下点分辨率/km	等效噪声温差
8	6.2	2	≤ 0.40 @ 240 K
9	7.0	2	≤ 0.10 @ 300 K
10	7.3	2	≤ 0.32 @ 240 K
14	11.2	2	≤ 0.10 @ 300 K
15	12.3	2	≤ 0.10 @ 300 K

1.1.2 GPS PWV 数据

全球定位系统(global positioning system, GPS)地基站点在接收信号时的大气延迟可用于大气水汽反演,精度通常为1~2 mm^[11]。GPS PWV 数据已被广泛应用于卫星水汽产品的评估和验证。选用2016年1月1日-12月30日的逐小时GPS PWV 作为真实参考数据,用于建模和验证AHI反演的PWV精度。

青藏高原24°N~40°N, 80°E~105°E共32个GPS站点(图2), 站点海拔高度从2585~4705 m, 年均PWV变化3.03~10.05 mm。2016年的逐小时PWV变化0.2~35.0 mm。

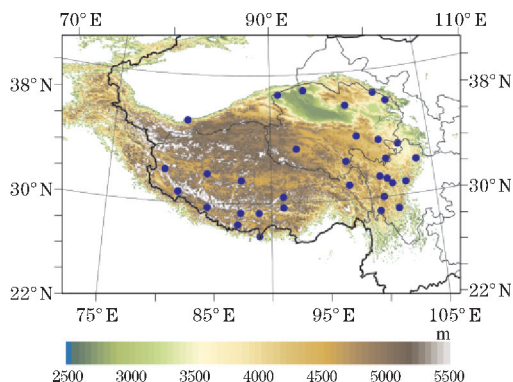


图2 研究区域海拔高度及GPS站点位置信息

1.1.3 GFS PWV 预报场

全球天气预报系统(GFS)可以提供全球范围0.25°, 0.5°和1°的网格PWV数据。预测时间步长分别为0~240(间隔为3 h), 240~384(间隔为12 h)。模式预报每天在UTC 00、06、12和18时运行。根据已有的研究,数值预报可以有效提高基于卫星数据的大气参数估算精度^[26]。将0.25°分辨率的GFS PWV数据作为模型的一个输入,以期待通过融合卫星观测和GFS PWV的预报信息,并减少云污染对卫星反演结果可能的影响,进而提高PWV反演精度。

美国大学大气科学研究联盟(UCAR)提供了非常便捷获得GFS历史数据子集的方式(<https://rda.ucar.edu/datasets/ds084.1/>)。实时的GFS PWV预报数据可从NOAA NCEP下载(<https://www.nco.ncep.noaa.gov/pmb/products/gfs/>)。由于GFS仅提供3 h间隔的数据,根据AHI的观测时间和经纬度信息对GFS PWV进行了时空插值。

1.2 神经网络模型

神经网络是由多个神经元构成的非线性模型,其可以较好地描述训练数据的输入和输出变量的非线性

和复杂关系,也被广泛应用于地球物理参数的反演和估算^[26-27]。本研究选用多层前馈神经网络来构建青藏高原PWV快速反演模型。

模型的输入主要包括AHI的5个红外亮温、卫星观测角、GFS PWV 预报场、海拔高度、经度、纬度、儒略日和小时。利用最近邻方法提取与GPS站点时空匹配的AHI像元多通道亮温,对GFS数据进行时空插值以匹配AHI观测。经过时空匹配和云检测处理,最终形成21156组样本。为分析GFS PWV 预报场对反演模型的影响,将建立2个模型,模型1是基于全部预测因子的NN模型;模型2则为未包含GFS PWV的NN模型。针对2个模型均随机选择一半数据作为训练数据,余下的数据作为验证数据集。

1.3 误差分析

为验证方法的可靠性和评价结果的质量,使用相关系数(R)、均方根误差(RMSE)和偏差(Bias)3个统计指标:

$$R = \frac{\sum_{i=1}^N (PWV_{NN} - \overline{PWV_{NN}}) (PWV_{GPS} - \overline{PWV_{GPS}})}{\sqrt{\sum_{i=1}^N (PWV_{NN} - \overline{PWV_{NN}})^2 (PWV_{GPS} - \overline{PWV_{GPS}})^2}} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (PWV_{NN} - PWV_{GPS})^2} \quad (2)$$

$$Bias = \frac{1}{N} \sum_{i=1}^N (PWV_{NN} - PWV_{GPS}) \quad (3)$$

其中, PWV_{NN} 和 PWV_{GPS} 分别是神经网络模型反演和GPS站点的 $\overline{PWV_{NN}}$ 和 $\overline{PWV_{GPS}}$ 分别是神经网络模型反演和GPS站点的PWV平均值, N 是数据样本总数。

2 结果与讨论

2.1 误差分析

图3给出了模型1和2反演结果与GPS PWV的二维直方分布图。两模型反演值与GPS PWV数据的相关系数大于0.94, RMSE小于1.52 mm,这意味两个模型均能有效反演PWV。模型1的PWV数据比模型2更集中于1:1线,这说明模型1估算值与GPS PWV吻合度更高。模型1的 R 、RMSE和Bias分别为0.957、1.33 mm和-0.004 mm,模型2则分别为0.943、1.52 mm和0.01 mm。模型1和2输入数据的差异是有无GFS PWV,这意味着引入GFS PWV 预报场数据可以提高PWV反演精度。

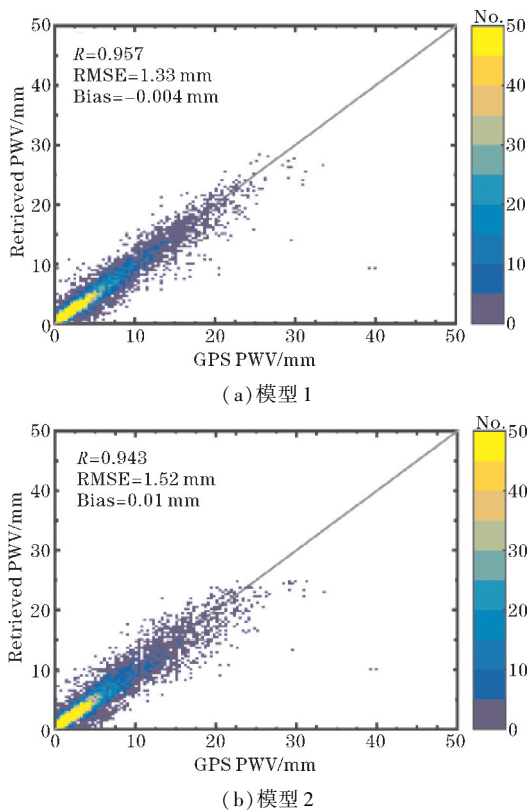


图3 模型1和2 PWV反演结果与GPS PWV的二维直方分布图

图4为两个模型PWV反演误差(反演值-GPS PWV)直方分布图,两模型误差均呈现正态分布,绝大部分误差在 ± 4.0 mm以内(>97.3%样本)。模型1和2的PWV反演误差小于2.0 mm的数据点分别占90.75%和87.51%,误差小于1.0 mm的数据点则分别为72.1%和67.1%。Lee等^[27]利用AHI多通道亮温、

经纬度和观测角数据,基于机器学习模型估算了东北亚地区的PWV。模型加入了更多与水汽相关的影响因子(比如海拔高度、时间信息和PWV预报场),因此展现了与GPS PWV的更好的吻合度。




图4 两模型PWV反演误差二维直方分布图

2.2 误差时空分布特征

通常情况下,卫星反演PWV的精度会受大气含水量、海拔高度、经纬度和地表类型等多种因素影响,进而呈现一定的时空分布特征。为进一步分析本文模型的精度,逐个站点评估了PWV反演的精度。图5给出了模型1和2的R和RMSE空间分布图。总体而言,两个模型在大部分站点均有较好的表现, RMSE主要在0.5~2.5 mm,相关系数主要在0.9~0.98。相比之下,由于引入了GFS PWV预报场,模型1在各站点均比模型2精度好,展现了较高的R和较小的RMSE。值得注意的是,也存在个别站点误差偏大, RMSE可达3.0 mm,这可能跟云污染或训练样本代表性有限有关。

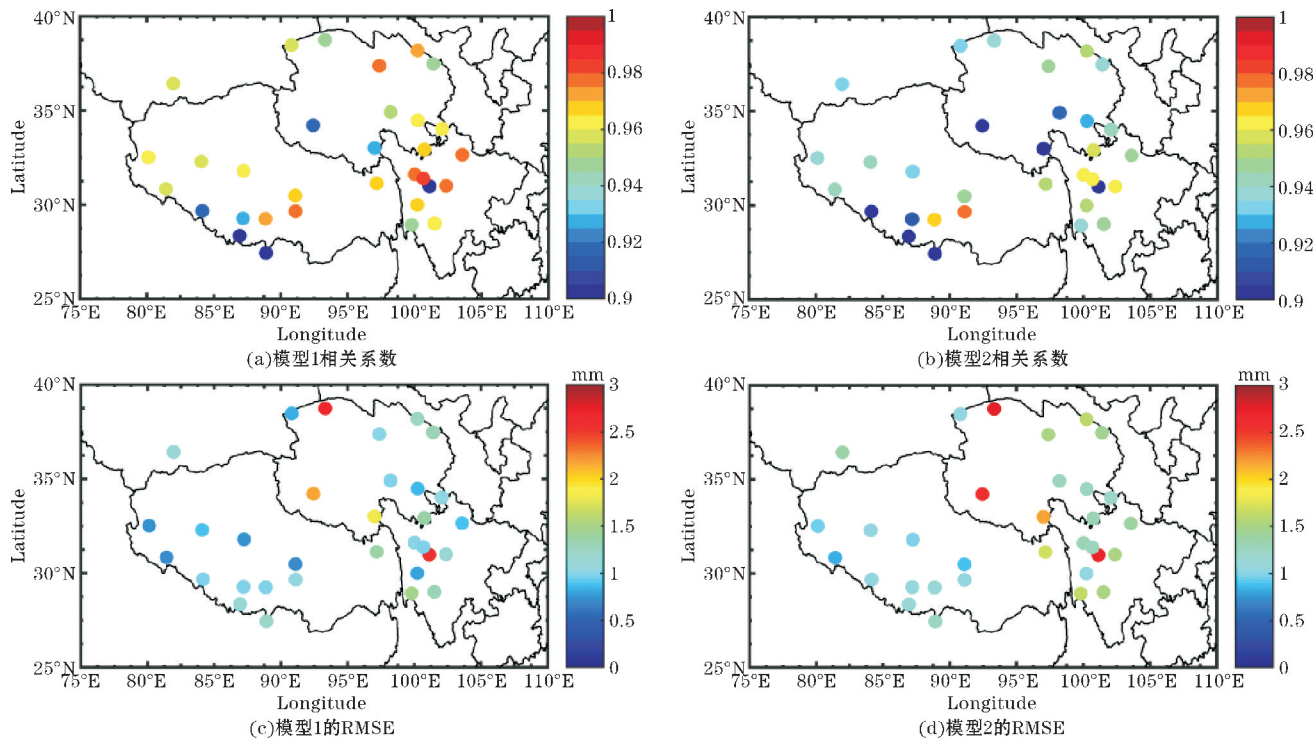


图5 模型1和2的月平均相关系数和均方根误差空间分布图

此外,对模型误差的季节变化特征进行分析。图6给出了模型的月平均相关系数、均方根误差和偏差的时间序列。两个模型的月平均 RMSE 和 R 展现了相似的季节变化特征。模型 RMSE 均从1月1.0 mm 开始上升,7月达到最大值3.0 mm,然后又逐渐下降。整体来说,夏季呈现出较大的 RMSE,冬季 RMSE 较小。RMSE 趋势跟 PWV 的季节变化特征相似,意味着水汽含量数值对 RMSE 有明显影响,这与之前的研究结果是一致的^[7,23]。冬季模型的相关系数低于其他季节,这可能跟冬季 PWV 动态变化范围小有关。两模型的月平均偏差小于0.25 mm,说明没有明显的高估或者低估。

总体而言,神经网络模型反演结果与 GPS PWV 吻合度较好,具体表现在较高的相关系数、较低的均方根误差和平均偏差,说明该算法可以有效反演青藏高原 PWV。




图6 模型1和2的月平均相关系数、均方根误差和偏差时间序列

神经网络建模时使用了 GPS 站点数据。当有 GPS PWV 参考数据可用时,推荐使用模型1进行 PWV 的反演。没有 GPS PWV 可用时,构建模型1将变得非常困难。此时,可以使用模型2进行 PWV 反演。具体操作如下:(1)收集研究区域有代表性的地表、大气廓线数据(如月平均的同化模型数据);(2)利用辐射传输模型(如 MODTRAN 或者 RTTOV)模拟卫星观测的多通道亮温;(3)基于模拟的多通道亮温、大气廓线积分的 PWV 以及模拟计算的输入各种辅助参数,构建 PWV 神经网络反演模型。模型2精度略差于模型1,其优点是在无 GPS PWV 数据可用时,可以通过模拟数据来构建模型。

3 结论

新一代静止气象卫星为高时空分辨率 PWV 探测

提供了良好的机遇。利用 Himawari-8 AHI 多通道红外亮温、GFS PWV 预报场和其他辅助数据,基于神经网络技术构建了适用于青藏高原低水汽环境下的 PWV 快速反演方法。引入水汽吸收通道和 GFS PWV 预报场,可以有效提高低水汽情况下的 PWV 反演精度。基于 GPS PWV 数据的验证结果表明,反演的 PWV 的 R 和 RMSE 分别为0.957和1.33 mm,这意味着模型能够提供青藏高原较高精度的 PWV。此外,由于反演过程不需要辐射传输计算,因此算法速度远高于物理反演算法,适合于实时的 PWV 反演。

分析了模型误差的时空变化特征,大部分站点 RMSE 误差小于2.0 mm,说明算法表现较稳定可靠。模型 RMSE 和 R 展现了一定的季节变化特征,夏季误差大于冬季,与大气水汽含量变化展现了相似的变化趋势。冬季 R 小于其他季节,这可能跟冬季 PWV 动态范围小有关。仅利用青藏高原地区32个台站数据进行建模,没有进行基于无线电气象探空的 PWV 数据的验证、对比,在其他地区的适用性有待于进一步验证。FY-4A/B 的星载成像仪与 AHI 通道配置相近,算法也适用于 FY-4A/B 数据。

参考文献:

- [1] Zveryaev I I, RP Allan. Water vapor variability in the tropics and its links to dynamics and precipitation[J]. Journal of Geophysical Research-Atmospheres, 2005, 110(D21).
- [2] Dessler A E, Zhang Z, Yang P. Water-vapor climate feedback inferred from climate fluctuations, 2003–2008[J]. Geophysical Research Letters, 2008. 35(20):293–210.
- [3] Ji D B, Shi J C, Xiong C, et al. A total precipitable water retrieval method over land using the combination of passive microwave and optical remote sensing[J]. Remote Sensing of Environment, 2017, 191:313–327.
- [4] Jimenez-Munoz J C, Sobrino J A, Skokovic D, et al. Land Surface Temperature Retrieval Methods From Landsat-8 Thermal Infrared Sensor Data[J]. Ieee Geoscience and Remote Sensing Letters, 2014, 11(10):1840–1843.
- [5] Vermote E F, Saleous N, Justice C O. Atmospheric correction of MODIS data in the visible to middle infrared: first results[J]. Remote Sensing of Environment, 2002, 83(1):97–111.

- [6] Li Z L, Tang B H, Wu H, et al. Satellite-derived land surface temperature: Current status and perspectives [J]. *Remote Sensing of Environment*, 2013, 131: 14–37.
- [7] Liu H L, Tang S H, Zhang S L, et al. Evaluation of MODIS water Vapour Products over China using radiosonde data [J]. *International Journal of Remote Sensing*, 2015, 36(2): 680–690.
- [8] Vaquero-Martinez J, Anton M, Galisteo J, et al. Inter-comparison of integrated water vapor from satellite instruments using reference GPS data at the Iberian Peninsula [J]. *Remote Sensing of Environment*, 2018, 204: 729–740.
- [9] Liu H L, Tang S H, Hu J Y, et al. An improved physical split-window algorithm for precipitable water vapor retrieval exploiting the water vapor channel observations [J]. *Remote Sensing of Environment*, 2017, 194: 366–378.
- [10] 王永前, 施建成, 曾巧林, 等. TRMM/VIRS 热红外通道陆地大气可降水汽总量分裂窗反演 [J]. *遥感学报*, 2016, 20(1): 94–102.
- [11] Alshawaf F, Fuhrmann T, Knopfler A, et al. Accurate Estimation of Atmospheric Water Vapor Using GNSS Observations and Surface Meteorological Data [J]. *Ieee Transactions on Geoscience and Remote Sensing*, 2015, 53(7): 3764–3771.
- [12] Niell A E, Coster A J, Solheim F S, et al. Comparison of Measurements of Atmospheric Wet Delay by Radiosonde, Water Vapor Radiometer, GPS, and VLBI [J]. *Journal of Atmospheric and Oceanic Technology*, 2001, 18(6): 830–850.
- [13] 黄荣辉. 青藏高原对我国及世界气候环境的影响 [J]. *地球科学信息*, 1988(6): 25–27.
- [14] 徐祥德. 青藏高原“敏感区”对我国灾害天气气候的影响及其监测 [J]. *中国工程科学*, 2009, 11(10): 96–107.
- [15] 敬文琪, 崔园园, 刘瑞霞, 等. 影响长江中下游夏季降水的青藏高原水汽抽吸作用和水汽路径的量化研究 [J]. *高原气象*, 2017, 36(4): 900–911.
- [16] 刘屹岷, 燕亚菲, 吕建牟, 等. 基于 CloudSat/CALIPSO 卫星资料的青藏高原云辐射及降水的研究进展 [J]. *大气科学*, 2018, 42(4): 847–858.
- [17] 卢乃锰, 范锦龙, 刘健, 等. 卫星遥感在青藏高原大气科学研究中的应用前景 [J]. *气象科技进展*, 2013, 3(3): 29–33.
- [18] Lee Y L, Li Z L, Li J, et al. Evaluation of the GOES-R ABI LAP Retrieval Algorithm Using the GOES-13 Sounder [J]. *Journal of Atmospheric and Oceanic Technology*, 2014, 31(1): 3–19.
- [19] Guillory A R, Jedlovec G J, Fuelberg H E. A Technique for Deriving Column-integrated Water Content Using VAS Split-Window Data [J]. *Journal of Applied Meteorology and Climatology*, 1993, 32(7): 1226–1241.
- [20] Suggs R J, Jedlovec G J, Guillory A R. Retrieval of Geophysical Parameters from GOES: Evaluation of a Split-Window Technique [J]. *Journal of Applied Meteorology*, 1998, 37(10): 1205–1227.
- [21] Schmit T J, Gunshor M M, Menzel W P, et al. Introducing the next-generation Advanced Baseline Imager on goes-R [J]. *Bulletin of the American Meteorological Society*, 2005, 86(8): 1079–1096.
- [22] Bessho K, Date K, Hayashi M, et al. An Introduction to Himawari-8/9-Japan's New-Generation Geostationary Meteorological Satellites [J]. *Journal of the Meteorological Society of Japan*, 2016, 94(2): 151–183.
- [23] Schmit T J, Li J, Lee S J, et al. Legacy Atmospheric Profiles and Derived Products From GOES-16: Validation and Applications [J]. *Earth and Space Science*, 2019, 6(9): 1730–1748.
- [24] Di D, Ai Y F, Li J, et al. Geostationary satellite-based 6.7 μm band best water vapor information layer analysis over the Tibetan Plateau [J]. *Journal of Geophysical Research-Atmospheres*, 2016, 121(9): 4600–4613.
- [25] Wu Y, Zhang F, Wu K, et al. Best Water Vapor Information Layer of Himawari-8-Based Water Vapor Bands over East Asia [J]. *Sensors*, 2020, 20(8): 1–16.
- [26] Liu H L, Zhou Q, Zhang S L, et al. Estimation of Summer Air Temperature over China Using Himawari-8 AHI and Numerical Weather Prediction Data [J]. *Advances in Meteorology*, 2019(1): 1–10.
- [27] Lee Y, Han D, Ahn M H, et al. Retrieval of Total Precipitable Water from Himawari-8 AHI Data: A Comparison of Random Forest, Extreme Gradient Boosting, and Deep Neural Network [J]. *Remote Sensing*, 2019, 11(15): 1–18.

Precipitable Water Vapor Retrieval Using Himawari-8
Satellite Observations over Tibetan Plateau

JIANG Jinhao, LIU Hailei, WANG Yizhu, Zhang Shenglan

(College of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: Precipitable water vapor (PWV) plays an important role in precipitation formation, water cycle, energy exchange, weather and climate change. The characteristics of water vapor distribution and transportation over the Tibetan Plateau are important issues in plateau meteorology. The new generation of geostationary meteorological satellites can obtain observation data with higher temporal, spatial and spectral resolution, which provides a good opportunity for PWV retrieval with high temporal and spatial resolution. In this study, a fast neural network based algorithm for PWV retrieval over the Tibetan Plateau was proposed. The inputs of model mainly include the water vapor absorption and split window channels brightness temperature of Advanced Himawari Imagers (AHI) onboard Himawari-8, Global Forecast System (GFS) PWV forecasts and other auxiliary data (satellite observation angle, elevation, longitude and latitude, and time information). The correlation coefficient (R), root mean square error (RMSE) and Bias of PWV estimated by neural network model with GPS (Global Positioning System) PWV are 0.957, 1.33 mm and -0.004 mm, respectively. In contrast, the R , RMSE and Bias of the model without GFS PWV are 0.943, 1.52 mm and 0.01 mm. This indicates that the introduction of GFS PWV can improve the inversion accuracy. The proposed method is suitable for PWV retrieval in other area with low water vapor content and can be also used for other geostationary meteorological satellite data.

Keywords: Tibetan Plateau; Himawari-8; precipitable water vapor; neural network; GFS