

基于 SWGU-ConvLSTM 模型的温度偏差订正

周旺亮 秦华旺

(南京信息工程大学电子与信息工程学院 南京 210044)

摘 要: 偏差订正是为了优化传统数值天气预报模型的预测精度,在气象学中,温度是一个至关重要的指标,它对天气现象、大气循环、气候模式以及人类活动等方面有着深远的影响,与此有必要对传统数值天气预报产品进行温度偏差订正。本文设计了一种适用于温度偏差订正的新型深度学习网络模型 SWGU-ConvLSTM,采用了 unet 和双向对抗网络架构。该模型使用 ConvLSTM 模块提取局部信息,使用 SwinTransform 模块提取全局信息,然后使用 IAFF 模块将 ConvLSTM 和 SwinTransform 模块的输出特征进行融合,并且对融合后的特征信息使用 U 形连接和跳跃连接,以更好的拼接浅层信息和深层信息,并提取不同尺度的信息,最后将上述融合模块作为生成器和判别器进行双向对抗训练,以此来增强模型的学习和预测能力。本文使用 ECMWF 平台公开的 TIGGE 数值模式数据作为被订正数据,使用 ERA5 再分析资料作为标签数据,订正 6 小时预报气温,实验结果表明,提出的 SWGU-ConvLSTM 模型在 MSE、MAE、SSIM 等指标上明显优于其他对比模型,相比较于 simvp 模型,他的 MSE 和 MAE 误差分别下降了 30% 和 27%,提高了温度订正的准确率。

关键词: 深度学习;偏差订正;对抗网络;天气预报

中图分类号: TN3;TP183 **文献标识码:** A **国家标准学科分类代码:** 170.15

The temperature bias correction based on the SWGU-ConvLSTM model

Zhou Wangliang Qin Huawang

(Electronics and Information Engineering College, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Bias correction is crucial for optimizing the prediction accuracy of traditional numerical weather prediction models. In meteorology, temperature is a vital parameter that significantly influences weather phenomena, atmospheric circulation, climate patterns, and human activities. Therefore, it is essential to perform temperature bias correction on traditional numerical weather prediction products. This paper designs a novel deep learning network model, SWGU-ConvLSTM, for temperature bias correction, which adopts the U-Net and bidirectional adversarial network architectures. The model uses the ConvLSTM module to extract local information and the SwinTransform module to capture global features. The outputs of the ConvLSTM and SwinTransform modules are then fused using the IAFF module. Furthermore, the fused feature information is processed with U-shaped connections and skip connections to better combine shallow and deep features and capture multi-scale information. Finally, the fusion module is employed as both the generator and discriminator in a bidirectional adversarial training framework to enhance the model's learning and prediction capabilities. In this study, the TIGGE numerical model data from the ECMWF platform is used as the input data to be corrected, and ERA5 reanalysis data is used as the target data. The model is applied to correct 6-hour temperature forecasts. Experimental results show that the proposed SWGU-ConvLSTM model outperforms other comparison models in terms of MSE, MAE, and SSIM. Compared to the simvp model, its MSE and MAE errors are reduced by 30% and 27%, respectively, improving the accuracy of temperature bias correction.

Keywords: deep learning; bias correction; adversarial networks; weather forecasting

0 引 言

全球气候变化对地球生态系统和人类社会产生了广泛

而深远的影响,并且由于极端气候情况的频发给人们的生活带来了极大的损害,所以迫切需要其提高预报产品的性能,其中文献[1-2]对如何提高预报产品的性能做出了阐

述。其中,温度作为气候系统中最重要的参数之一,文献[3]将温度视为是气候模式的建立和预测工作中十分主要的一个因素。然而,地面 2 m 温度的准确性和精度在气候研究中占据着至关重要的地位。数值模式预测已经成为天气预报的十分重要的技术手段,它通过对大气当中的各种复杂的运动过程进行数值模拟和预测,在灾害预警,保护人们的人身安全和财产安全等方面发挥着重要作用。但数值模式的初始的气温等各大要素的值不可能完全达到真实的大气状况,而且真实的大气不是一个独立,密闭的系统,他是各种作用,各种气象要素之间相互影响,这会使得大气这个系统里面的运动更加复杂,与此同时在计算和预测的过程中产生的误差也使得预报与真实值存在一定的偏差。

由于大气系统的复杂性和数值模式的自身的缺陷性会导致模式预报存在误差,对模式预报产品进行偏差订正处理是来减小模式预报误差,提高预报的准确率的途径之一。对此,国内外的学者在对模式预测的偏差订正做了大量的研究,其中针对模式温度预报偏差订正的传统方法主要有模式输出统计法(mode statistical output method, MOS)^[4]、统计订正方法(statistical correction method, SCM)及卡尔曼滤波法。这些模式和统计订正方法都是使用统计学的方法对数据进行统计集合,然后在使用回归方程建立模式输出和观测数据之间的关系模型。但是由于统计法对于大量的样本进行统计,对模式的变化很难做到对应的精准预测,具有非灵活性。而卡尔曼滤波法是一个基于线性动态系统的预测模型,对于极端的和复杂的天气温度变化情况订正效果不尽人意。此外还存在其他的机器学习方法,比如支持向量机和随机森林等。孙全德等^[5]利用最小绝对收缩和选择算法来融合随机森林来订正风速,他的效果会好于传统的模式预测。但是上述方法很难适应复杂的天气情况,无法充分利用其他气象要素的情况,且模型结构简单,有限的参数无法更好的提取大气这一复杂紧密的系统的有效信息。

近年来,由于深度学习的快速发展,出现了很多在图像领域取得优异效果的网络模型如 Takano 等^[6]提出的超分辨率生成对抗网络(super-resolution generative adversarial network, SRGAN),Çiçek 等^[7]提出的三维卷积神经网络(3D u-net for medical image segmentation, UNet3d),Dosovitskiy^[8]等提出的视觉自注意力网络(vision transform, VIT)在图像任务重的应用等,这些模型的提出大大的推动了社会的发展和进步。与此同时,其深度学习在偏差订正方向也展现了其优越的性能。例如郑祥明等^[9]提出的三维 U 形平移窗口自注意力网络(3D unet shifted window transform, 3DUST)使用 UNet3D 融合平移窗口自注意力网络(shifted window transform, SwinTransform)来处理降水的降尺度问题,很好的解决了气象特征丢失问题,对温度要素的处理提供了新的思路。例如 Wang 等^[10]使

用 SRDRN 模型堆叠全球变化模型(global change model, GCM)来对温度进行偏差订正,取得了很好的效果。张延彪等^[11]提出的融合上下文卷积神经网络(fusion context unet, Fuse-CUNet),将上下文卷积神经网络(context unet, CU-Net)和密集山下文卷积神经网络(dense context unet, Dense-CUNet)相结合,并在此基础上将多个气象要素和地形因素加入到 2 m 温度的偏差订正中,使用稠密卷积块来提升 2 m 温度订正效果。Hao 等^[12]使用双向卷积长短期记忆网络(bidirectional convl long short-term memory, Bi-Conv-LSTM)对地面 2 m 温度进行偏差订正。Wang 等^[13]使用循环一致性对抗网络(cycle-consistent generative adversarial network, CycleGAN)网络来校正通用地球系统模式的日海表温度,大大降低了温度偏差,而且在极端天气也有不错的订正效果。胡莹莹等^[14]使用 U-Net 来进行 7~15 d 温度格点预报偏差订正,由于 U-Net 可以很好的提取不同尺度的特征信息,可以达到比较好的偏差订正效果。Amemiya 等^[15]使用递归神经网络(long short-term memory, LSTM)和(gene regulatory network, GRU)等来进行气候模型偏差订正。Sun 等^[16]使用数值神经卷积网络(base unet, BU-Net)对海浪进行偏差订正,将数值模型和深度学习相结合,起到了极好的效果。Han 等^[17]使用 CU-Net 对 2 m 温度进行预报订正,效果比自动化数值预报输出(automatic numerical output, ANO)的预报更好。综上所述,深度学习在气候情况预报订正有着极大的应用前景。

然而尽管当前的温度偏差订正研究方法取得了一定的进展,但仍然存在复杂天气温度情况难以订正、面对不同区域或不同气候条件泛化能力差、传统模型需要大量数据积累从而导致订正无法及时响应等问题。

本文提出的 SWGU-ConvLSTM 模型首先将 Shi 等^[18]提出的卷积长短时记忆网络(convolutional long short-term memory, ConvLSTM)每一层的输出会通过俩个通道,分别是通过 Liu 等^[19]提出的 SwinTransform 模块、下采样、卷积和通过下采样、卷积得到俩个输出,然后将俩个输出通过迭代注意力特征融(iterative attentional feature fusion, IAFF)模块进行融合, SwinTransform 模块可以更好的捕捉全局信息和位置信息, IAFF 模块可以将初始的特征融合与注意力模块交替集成,实现更有效的特征融合。接着将该融合特征作为下一层 SW-ConvLSTM 模块的输入,通过 U 形连接可以更好的获得多尺度信息,其中跳跃连接将不同深度的信息进行融合提取。然后将 SW-ConvLSTM 模块以 U 形连接的方式集成到 SWU-ConvLSTM 模块当中,再将该模块作为生成器和判别器,采取 Yi 等^[20]提出的双生成对抗网络(dual generative adversarial network, DualGan)的形式进行偏差订正地面 2 m 温度。

对于现有研究存在的复杂天气温度情况难以订正;面对不同区域或不同气候条件泛化能力差;传统模型需要大量数据积累从而导致订正无法及时响应等问题,本文设计

了 3 个创新点来进行优化处理:1)使用 IAFF 模块融合 SwinTransform 模块的全局特征和 ConvLSTM 模块的局部特征;2)将该融合模块进行 U 形连接和跳跃连接,进行多尺度特征提取融合;3)将该 U 形连接网络进行双向对抗训练,并且在该双向对抗网络当中提出了双向生成器和三向判别器的对抗机制,通过该对抗机制来优化模型和提高模型的学习能力。通过实验评估,该结合了 unet、swintransform、convlstm1 的多向对抗生成网络 (swintransform generative adversaria unet-convlstm, SWGU-ConvLSTM)模型可以大大提高订正效果。

1 研究方法

1.1 整体结构

SWGU-ConvLSTM 模型提高了对特征信息的提取,促进了对不同尺度的特征信息相融合,增强了对复杂要素信息的学习能力。该模型首先由 5 层移动窗口卷积长短期神经网络 (swintransform convlstm network, SW-ConvLSTM)模块进行 U 形连接组成的 SWU-ConvLSTM 模块,再将其作为双向对抗网络模型当中的生成器和判别器。

首先 SW-ConvLSTM 模块是在 ConvLSTM 的基础上进行改进,ConvLSTM 是一个编码-解码的结构,他的层与层之间使用下采样和卷积或者上采样和卷积的方式来进行连接,这种连接方式可以很好的提取特征信息。而 SW-ConvLSTM 模块是将每一层 ConvLSTM 的输出分别通过 2 个通道,分别是通过 SwinTransform 模块、下采样、卷积和通过下采样、卷积得到俩个输出特征图。前 3 层是进行下采样,后俩层是进行上采样和跳跃连接。由于 SwinTransformer 模块进一步提升了全局特征的提取能力,因此这两个输出特征图分别包含丰富的全局特征和局部特征。接着,通过 IAFF 模块对这些特征进行融合,该模块实现了全局特征与局部特征的初步结合,并采用双重注意力机制对全局特征和局部特征图进行加权平均。这种方法有效地整合了不同层次的特征,提升了整体表现。然后将融合得到的特征图作为每一层的输出特征图即隐藏状态 H^1 ,该输出特征图也会作为下一层 SW-ConvLSTM 模块的输入。在经过 5 层这样的操作后,将最后一层的隐藏状态 H^5 作为最后的特征图输出。这 5 层 SW-ConvLSTM 模块以 U 形连接的方式集成到移动窗口 u 形卷积长短期神经网络 (swintransform unet convlstm, SWU-ConvLSTM)模块当中去。该模块将 IAFF 模块融合 ConvLSTM 模块的局部特征和 SwinTransform 模块的全局特征,并且通过 U 形连接和跳跃连接进行多尺度特征提取融合,提高了对复杂天气温度特征的提取能力。

然后将这个 SWU-ConvLSTM 模块作为生成器和判别器,去进行双向对抗训练,且该双向对抗网络提出了将双向生成器与三向判别器进行对抗训练,提高了模型的学习性

能。该双向对抗网络有双向生成器和三向判别器,将输入 A 通过生成器 G-A 得到输出 fakeB,将输出 B 通过生成器 G-B 得到 fakeA,同时将 fakeB 和 A 在特征要素那个维度进行拼接得到 A 假 B,并且将其与输出 B 同时送到判别器 D-A 里进行训练;将 fakeA 与 B 在特征要素那个维度进行拼接得到 B 假 A,并且将其与输入 A 同时送到判别器 D-B 进行训练;将 fakeA 和 fakeB 在特征要素那个维度进行拼接得到假 AB,将 A 和 B 在特征要素那个维度进行拼接得到 AB,并将假 AB 和 AB 送到判别器 D-C 里进行训练。生成器 G-A 的目的是尽可能地生成与真实数据 B 相似的假数据 fakeB,判别器 D-A 的目的是辨别 fakeB 是假的,B 是真的,以此来和生成器 G-A 进行对抗训练而达到促进生成器 G-A 不断迭代增强的效果。并且之所以将 fakeB 和 A 进行拼接是为了给 fakeB 增加一个条件使得生成的图片更加清晰,提高分辨率,同时可促进生成器 G-A 优化和迭代。生成器 G-B 的目的是尽可能的生成与真实数据相似的假数据 fakeA,判别器 D-B 的目的是辨别 FakeA 是假的,A 是真的,以此来和生成器 G-B 进行对抗训练而达到促进生成器 G-B 不断迭代增强的效果。并且之所以将 fakeA 和 B 进行拼接是为了给 fakeA 增加一个条件使得生成的特征图更加清晰,提高分辨率,同时可促进生成器 G-B 进行优化和迭代。判别器 D-C 的目的是辨别 AB 是真的,fakeAB 是假的,D-C 判别器可以有效的促进 G-A 和 G-B 模型的迭代增强,同时使得 G-A 和 G-B 模型相互对抗从而促进生成器的训练,形成一个稳定的对抗系统,以此来增强该对抗网络模型的高效性和稳定性。最后将输入通过训练好的 G-A 生成器得到订正好输出特征图。其整体架构如图 1 所示。

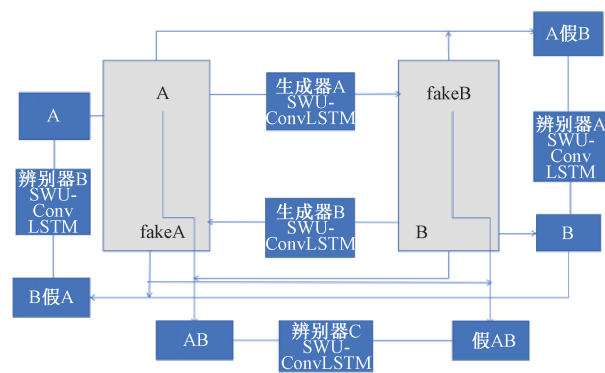


图 1 SWGU-ConvLSTM 模型架构

Fig. 1 The architecture of the SWGU-ConvLSTM model

1.2 SWU-ConvLSTM 模型架构

SWU-ConvLSTM 网络结构由 5 层 SW-ConvLSTM 结构组成,该网络架构输入从左端开始,将输入通过第一层 SW-ConvLSTM 细胞结构输出隐藏状态 H^1 ,通道数为 16,然后将其分别通过下采样、卷积和 SwinTransform 模块、下采样、卷积得到俩个输出特征图,将这俩个输出特征图通过

IAFF 模块进行融合,融合后得到的输出特征图通道数变为 32,特征图大小变为原来的一半,卷积核的大小为 3×3 ,步长大小为 1,填充为 1。将这个输出作为第 2 层的 SW-ConvLSTM 细胞结构的输入输送进去,得到隐藏状态 H^2 ,通道数为 32,然后将其分别通过下采样、卷积和 SwinTransform 模块、下采样、卷积得到俩个特征图,将这两个特征图通过 IAFF 模块进行融合,融合得到的输出特征图通道数变为 64,特征图大小变为原来的一半,卷积核的大小为 3×3 ,步长大小为 1,填充为 1。将这个输出作为第 3 层的 SW-ConvLSTM 细胞结构的输入输送进去,得到隐藏状态 H^3 ,通道数为 64,然后将其分别通过下采样、卷积和 SwinTransform 模块、下采样、卷积得到俩个特征图,将这两个特征图通过 IAFF 模块进行融合,融合得到的输出特征图通道数变为 128,特征图大小变为原来的一半,卷积核的大小为 3×3 ,步长大小为 1,填充为 1。将这个输出作为第 4 层的 SW-ConvLSTM 细胞结构的输入输送进去,得到隐藏状态 H^4 ,通道数为 128,然后将其分别通过上采样、跳跃连接、卷积和 SwinTransform 模块、上采样、跳跃连接、卷积得到俩个特征图,该跳跃连接是将 H^4 和 H^3 在通道维度进行拼接,通道数变为 196,将俩个特征图通过 IAFF 模块进行融合,融合得到的输出特征图通道数变为 64,特征图大小变为原来的俩倍,卷积核的大小为 3×3 ,步长大小为 1,填充为 1。将这个输出作为第 5 层的 SW-ConvLSTM 细胞结构的输入输送进去,得到隐藏状态 H^5 ,通道数为 64,然后将其分别通过上采样、跳跃连接、卷积和 SwinTransform 模块、上采样、跳跃连接、卷积得到俩个输出特征图,该跳跃连接是将 H^5 和 H^4 在通道维度进行拼接,通道数变为 96,将俩个输出特征图通过 IAFF 模块进行融合,融合得到的输出特征图通道数变为 32,特征图大小变为原来的俩倍,卷积核的大小为 3×3 ,步长大小为 1,填充为 1。最后在该输出通过一个 3×3 的卷积核,得到最后的订正好的特征图。其整体结构如图 2 所示。

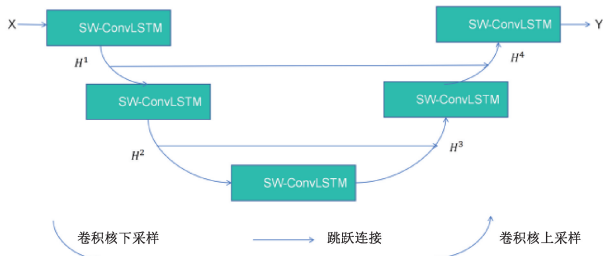


图 2 SWU-ConvLSTM 模型架构

Fig. 2 The architecture of the SWU-ConvLSTM model

1.3 SW-ConvLSTM 模型架构

SW-ConvLSTM 结构在 ConvLSTM 结构的基础上进行改进,ConvLSTM 网络能够学习到长期依赖性,但是由于他的卷积结构过于简单,无法很好的捕捉不同尺度图片

的全局特征,于是采用了将隐藏状态 H^i 分别通过两个通道输出,再将两个输出特征图进行融合的方式来提取不同尺度的全局特征和局部特征。首先是将输入通过 SW-ConvLSTM 细胞结构得到的隐藏状态 H^i ,然后将 H^i 通过 SwinTransform 模块得到输出 H_{sw}^i ,再将其通过下采样、卷积得到特征图 H^{i1} ,该特征图大小变成原来大小的一半。与此同时,将隐藏状态 H^i 单独通过下采样、卷积使得特征图变为原来大小的一半为 H^{i2} 。然后将 H^{i1} 和 H^{i2} 使用 IAFF 模块进行融合,IAFF 模块使用俩次双注意力机制可以将全局特征和局部特征融合起来。IAFF 模块将 H^{i1} 与 H^{i2} 相加,使用局部注意力机制对其进行提取,然后将其俩个输出特征图进行拼接,再通过 sigmoid 函数得到注意力权重 w ,然后使用 H^{i1} 乘以 w 加上 H^{i2} 乘以 $(1-w)$ 得到新的输出 H^{i3} ,再分别使用局部注意力机制和全局注意力机制对 H^{i3} 进行提取,并且将输出结果相拼接,再通过 sigmoid 函数得到注意力权重 w_i ,再将 H^{i1} 乘以 w_i 加上 H^{i2} 乘以 $(1-w_i)$ 得到最后的输出 H^{i+1} ,具体结构如图 3 所示。

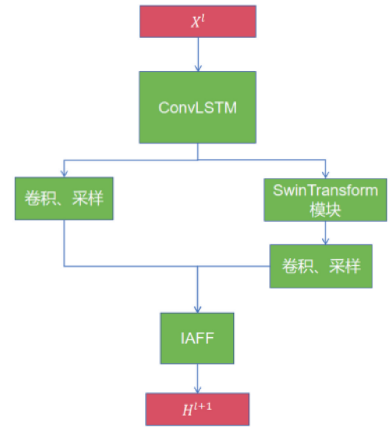


图 3 SW-ConvLSTM 模型架构

Fig. 3 The architecture of the SW-ConvLSTM model

1.4 SW-ConvLSTM 细胞结构

SW-ConvLSTM 细胞结构是沿用之前的 ConvLSTM 细胞结构作为主体框架,ConvLSTM 网络能够学习到长期依赖性,对于细胞结构中的输入门、遗忘门、更新门、输出门,都是采取相同的卷积核来学习,但是对不同的图片,不同类型的图片,他的卷积核大小应该有所不同。故经过测试,发现输入门和遗忘门采用 3×3 的卷积核大小,更新门和输出门采用 1×1 的卷积核大小效果比较好。如图 4 所示 SW-ConvLSTM 细胞结构,输入细胞结构的主要有上一时刻的记忆细胞 C^L ,上一时刻的隐藏状态 H^i ,同时还有输入 X^L ,经过门控单元,进行对输入和隐藏状态的特征提取,最终输出更新后的记忆细胞 C^{i+1} 和输出隐藏状态 H^{i+1} 。下面具体给出 SW-ConvLSTM 细胞结构具体公式表示,公式具体如下:

$$i^l = \sigma[W_{i3 \times 3} * [X^l, H^l]] \quad (1)$$

$$f^l = \sigma[W_{f3 \times 3} * [X^l, H^l]] \quad (2)$$

$$C^l = \tanh[W_{c3 \times 3} * [X^l, H^l]] \quad (3)$$

$$o^l = \sigma[W_{o3 \times 3} * [X^l, H^l]] \quad (4)$$

$$C^{l+1} = f^l C^l + i^l C^l \quad (5)$$

$$H^{l+1} = o^l \tanh(W_{3 \times 3} * C^{l+1}) \quad (6)$$

其中, $*$ 表示 2D 卷积操作, \odot 表示 Hadamard 乘积运算, σ 表示 Sigmoid 激活函数, \tanh 表示双曲正切激活函数。




图 4 SW-ConvLSTM 细胞结构

Fig. 4 Cell structure of SW-ConvLSTM

1.5 IAFF 模块结构

该 IAFF 模块可以很好的融合局部特征和全局特征, 并且很好的解决了一般注意力融合机制会出现的初始特征融合瓶颈问题, 具体结构如图 5 所示。该模块首先将输入的局部特征图 x 和全局特征图 y 相拼接, 然后将其分别通过 2 个通道, 首先将其通过 GlobalAvgPooling(全局平均池化), 使得可以减少计算量, 然后将其通过点对点卷积 (point-wise conv), 该卷积采用的是 1×1 的点卷积, 可以更好的关注不同尺度, 不同层级的特征信息, 然后经过批量归一化 (batch normalization, BN 层)、激活函数 (Relu 函数)、Point-wise Conv、BN 层得到输出特征图。特征图通过 Point-wise Conv 这个 1×1 的卷积核时, 它的特征图大小不变, 通道数变为卷积核的数量; 随后通过 BN 层, 加速网络的收敛效率, 特征图大小和通道数不变; 最后通过 Relu 激活函数, 提升非线性能力, 避免梯度爆炸, 特征图大小和通道数不变。与此同时将拼接的特征图通过 Point-wise Conv、BN 层、Relu 函数、Point-wise Conv、BN 层得到输出特征图。然后将两个特征图拼接, 将该特征图通过 sigmoid 函数得到权重 w , 然后将 x 乘以 w 加上 y 乘以 $(1-w)$ 得到第一次注意力机制融合得到的特征图, 该模块为了解决初始特征融合的瓶颈问题, 所以做了两次注意力机制融合。于是继续将输入特征图 z 分别通过两个通道, 首先将其通过 GlobalAvgPooling、Point-wise Conv、BN 层、Relu 函数、Point-wise Conv、BN 层得到输出特征图。与此同时将特征图 z 通过 Point-wise Conv、BN 层、Relu 函数、Point-wise Conv、BN 层得到输出特征图。然后将两个特征图其拼接

之后通过 sigmoid 函数之后得到新的权重 w^i , 然后将该权重作为最后得到的权重结果, 将 x 乘以 w^i 加上 y 乘以 $(1-w^i)$ 得到最后的输出特征图。该特征图充分的融合了局部特征和全局特征。具体公式如下:

$$w = \text{sigmoid}[\alpha * (X + Y) + \beta * (X + Y)] \quad (7)$$

$$X_1 \uplus Y_1 = w \otimes X + (1 - w) \otimes Y \quad (8)$$

$$w^i = \text{sigmoid}[\alpha * (X_1 \uplus Y_1) + \beta * (X_1 \uplus Y_1)] \quad (9)$$

$$X_2 \uplus Y_2 = w^i \otimes X + (1 - w^i) \otimes Y \quad (10)$$

其中, $X_1 \uplus Y_1$ 表示俩个输入特征图进行第一次注意力特征融合之后的输出特征图, \uplus 表示进行将俩个特征图进行融合, X 和 Y 表示输入的局部和全局特征图, \otimes 表示乘积, w 表示经过第 1 次注意力机制融合之后的权重, sigmoid 表示激活函数, α 表示全局注意力机制, β 表示本地注意力机制, $*$ 表示卷积操作, w^i 表示经过第二次注意力机制融合之后的权重, $X_2 \uplus Y_2$ 表示俩个输入特征图进行第 2 次注意力特征融合之后的输出特征图。

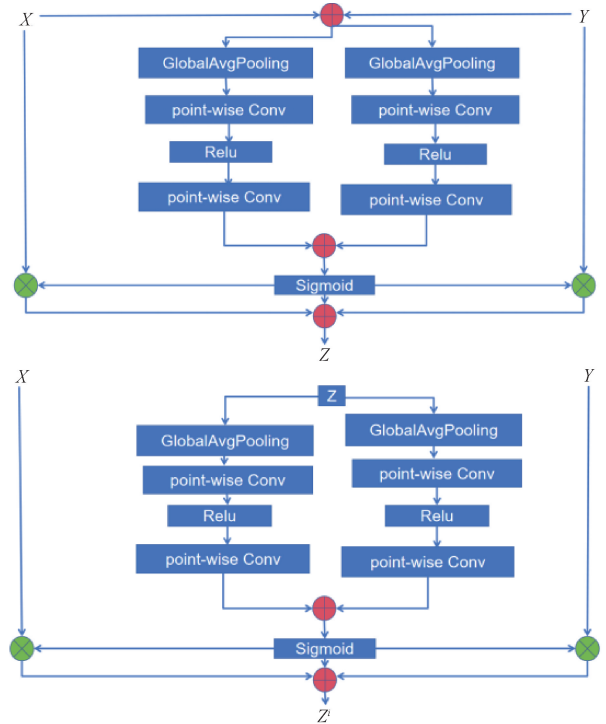


图 5 IFFA 模块架构

Fig. 5 The architecture of the IFFA module

1.6 Swin Transformer 模块结构

Swin Transformer 模块会将特征图进行分块, 分成很多的 patch 块, 并且对这些 patch 块进行编码解码, 然后将这些块作为输入通过模块得到输出。该模块采用了标准多头自注意力机制 (MSA), 引入局部注意力机制和移位窗口的机制, 然后通过窗口的多头自注意力机制 (W-MSA) 和基于移位窗口的多头自注意力机制 (SW-MSA) 的交替使用, 来实现跨窗口的信息交互, 以此来获取全局特征。对于

输入,先经过分块的形式将输入重塑为 $\frac{HW}{P^2} \times P^2 \times C$ 大小, H 表示特征图的高度, W 表示特征图的深度, C 为通道数, P 为分块的大小。此时他的输入应该是 $P \times P$ 大小的局部窗口, $\frac{HW}{P^2}$ 为本文进行划分之后窗口的总数量。对于每个窗口, Swin Transformer 需要并行进行多次注意力机制,其中在本次研究当中发现 $\text{num_heads} = 8$ 效果比较好,具体结构如图 6 所示。多头注意力的每个头的注意力计算如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{SoftMax}\left(\frac{\mathbf{QK}^T}{\sqrt{d}} + \mathbf{B}\right) \quad (11)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询、键、值矩阵, d 为向量维度, \mathbf{B} 为偏置矩阵, SoftMax 为多分类激活函数。而且他的多头窗口注意力机制可以很好的捕捉不同窗口互相间的信息和关联,并且大大的减少了计算量,提高效率,公式具体如下:

$$\Omega(\text{MSA}) = 4HWC^2 + 2(HW)^2C \quad (12)$$

$$\Omega(W - \text{MSA}) = 4HWC^2 + 2P^2HWC \quad (13)$$

其中, H 表示特征图的高度, W 表示特征图的深度, P 表示每个窗口的大小, C 为通道数。




图 6 Swin Transformer 模块架构

Fig. 6 The architecture of the swin Transformer module

2 实验结果与分析

2.1 偏差订正实验数据集

本研究采用 ECMWF 平台公开的 TIGGE 数值模式数据作为被订正数据,该数据集完全利用和结合了各国业务集合预报数据,对提高业务集合预报水平含有十分重要的意义。ERA5 再分析资料是欧洲中期天气预报中心 (ECMWF) 最新发布的一代再分析数据,具有更高的时空分辨率和更广泛的时间范围,为研究气象现象和气候变化提供了宝贵的信息。ERA5 提供了 0.25° 的水平分辨率和 137 个垂直层次,涵盖了从 1979 年至今的气象要素。这包括温度、降水、风速等多个关键气象变量。相比上一代, ERA5 在精度和全球范围内的数据质量上有显著提升。因此,选取 ERA5 再分析资料作为实况数据。俩套数据集的时间长度为 2020 年 1 月 1 日~2022 年 1 月 1 日,空间分布范围为 $102^\circ \sim 122^\circ \text{ E}$, $19^\circ \sim 39^\circ \text{ N}$, 空间分辨率为 $0.25^\circ \times$

0.25° 。该数据集总共包括 6 个气象要素,除地面 2 m 气温之外的 5 个气象要素分别为,对流有效位能、10 m 地面 U 型风、10 m 地面 V 型风、地面 2 m 以上露点温度、土壤温度。订正气象要素为研究区域内的 6 h 地面 2 m 温度。本文将地面 2 m 气温真实数据作为标签数据分别合并到预报的 6 h。并且将合并后的数据按照 8:2 的比例区分为训练集与验证集。由于深度学习训练需要大量的样本,且为了保证气象特征训练的多样性,对数据训练样本进行数据增强,使得样本格点数 80×80 进行随机数据切割为 40×40 大小的格点数据,将每张图切割 30 次,相当于将训练样本增加 30 倍。而对于验证集,将会设置一个随机种子数,使得每次切割的图像以固定的规律进行切割为 10 张子图,使得验证集的数据集增大 10 倍。

2.2 数据预处理

气象数据采集和下载过程中,经常会遇见一些由于系统出现什么故障或者存储数据的时候的一些意外因素造成数据丢失,比如缺失值和异常值等。因此,需要对数据进行一些预处理。对于异常值,即超出气象数据一般范围的值,直接将给数据进行删除,变为缺失值,然后通过对于缺失值的填充来保证数据的完整性。对于缺失值,本文采用双线性插值法建立一个插值器,使用插值器对缺失数据进行填充。通过这些步骤可以保证数据的完整性和严谨性,以便于更好的适应于模型的训练和验证。

2.3 实验参数设置

实验所使用的深度学习框架为 Pytorch2.1,编程语言为 Python3.9,软件环境为 CUDA10.8,在单个 NVIDIA Tesla V100 进行训练。在训练阶段,批次大小为 16,训练 60 个 epoch。用 RMSprop 优化器进行训练,生成器的学习率设置为 0.0005,判别器的学习率为 0.0001,衰减率参数为 0.99。损失函数使用的是 MSE 和 MAE 的组合。

2.4 评价指标

本文采用均方误差 (MSE)、平均绝对误差 (MAE) 和结构相似性 (SSIM) 这 3 个评价指标来评价算法性能从而来验证模型的效果。

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2 \quad (14)$$

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (15)$$

式中: m 表示样本总数, y_i 表示第 i 个样本的真实值, \hat{y}_i 表示第 i 个样本的预测值。

MAE 和 MSE 数值越低代表性能越好,它们反映了预测值与真实值像素之间的误差情况。

$$\text{SSIM}(m, n) = \frac{(2u_m u_n + C_1)(2\sigma_{mn} + C_2)}{(u_m^2 + u_n^2 + C_1)(\sigma_m^2 + \sigma_n^2 + C_2)} \quad (16)$$

式中: m 和 n 分别表示生成图像和真实图像, u_m 和 u_n 分别表示图像 m 和 n 的均值, u_m^2 和 u_n^2 分别为 m 和 n 的方差, σ_{mn} 为 m 和 n 的协方差, σ_m 为 m 的方差, σ_n 为 n 的方差, $C_1 =$

$(s_1L)^2, C_2 = (s_2L)^2, s_1$ 和 s_2 默认值分别为 0.01 和 0.03, L 为像素值的动态范围。

由于 MSE 和 MAE 都只能观察俩张图片的像素差异,而忽略了图像的结构差异。为了更好的衡量图像的信息,采的结构相似性(structural similarity,SSIM)指标,用于衡量两图像的相似程度,其值为 0~1,值越大表示两图像越相似。

2.5 实验结果

本文采用 MSE,MAE,SSIM 作为评价指标对模型进行评估,并对于原始的 ECMWF 模式数据和 ConvLSTM, DualGAN,UNet3d PAGEREF_Ref581\h PAGEREF_Ref581\h, SimVP^[21],这 4 种模型,来充分验证本模型性能。所有实验都客观公正。实验结果如表 1 所示。

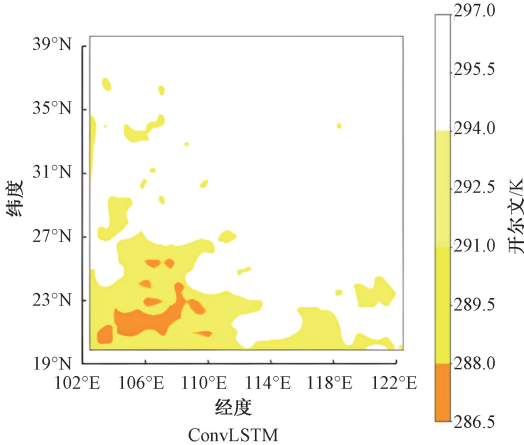
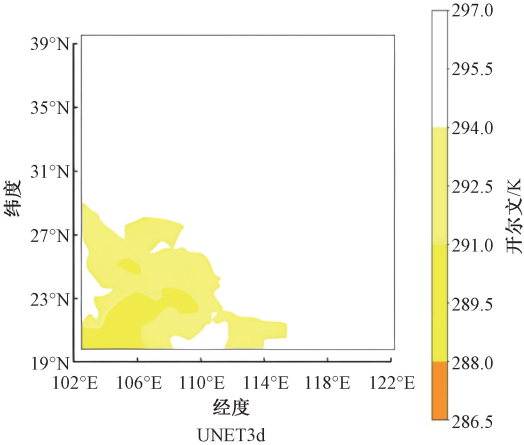
表 1 地面 2 m 温度订正实验结果比较
Table 1 Comparison of ground 2 m temperature correction Experiment Results

方法名称	MSE	MAE	SSIM
ECMWF	0.874	0.986	0.574
DualGAN	0.401	0.512	0.899
ConvLSTM	0.458	0.561	0.962
UNet3d	0.467	0.573	0.990
SimVP	0.360	0.448	0.986
SWGU-ConvLSTM	0.252	0.324	0.994

根据实验结果可知,本文提出的 SWGU-ConvLSTM 模型在 6 h 的预报订正下,他的订正效果相比较于其他 5 个模型在 MSE,MAE,SSIM 这几个指标上均是最优。SWGU-ConvLSTM 模型在 MSE 这个指标上,相比较于其他 5 个模型当中效果最好的 simvp,MSE 下降了 0.108,他的订正效果提高了 30%。并且在 MAE 这个指标上,相比较于其他 5 个模型当中效果最好的 simvp(simpler but better video prediction),MAE 下降了 0.124,他的订正效果提高了 27%。这俩个指标的结果表明 SWGU-

ConvLSTM 模型偏差订正得到的温度和真实的温度更为接近。在 SSIM 这个指标上,SWGU-ConvLSTM 模型,相比较于其他 5 个模型当中效果最好的 UNet3d,SSIM 提高了 0.004,这个结果表明 SWGU-ConvLSTM 模型在 6 h 的预报订正下,它的温度图和真实的温度图更加相似。

为了更好的体现出该模型的订正效果,选取验证集最后一天的真实标签的温度数据和多要素输入通过 SWGU-ConvLSTM、ConvLSTM、SimVP、DualGAN、UNet3d 这 5 种模型得到的 6 h 订正预报气温数据进行可视化,如图 7 所示。该数据贯穿东亚以及东南亚的部分地区,经纬度横跨范围和气候带差异较大,有热带气候带、亚热带气候带、温带气候带和季风气候带等。而不同的气候带对温度的偏差订正具有不同的影响,例如热带和亚热带温度比较稳定,偏差订正难度较低,而季风气候带在不同季节和昼夜温差较大,偏差订正难度较大。在 102°~110° E,19°~27° N 这个区域,该区域主要以季风气候带为主,温度变化情况复杂,不同季节温差较大等,从图 7 可以看出,SWGU-ConvLSTM 模型在该区域的温度偏差订正效果最好,与实际温度图的差异最小,而其他模型在该区域的温度订正效果较差,与实际温度图的差异较大,凸显出在极端和复杂温度情况下,SWGU-ConvLSTM 模型具有更好的效果,更能适应各种气候下的温度偏差订正。而与此同时,将验证集最后一天的 ECMWF 模式数据进行可视化,如图 8 所示,以此来对比不同模型订正之后的效果。图像对各个值区间定义色彩颜色,并且在地图上进行投影。图像将温度转化为开尔文,以开尔文为单位,从低到高,表示为从橙色到白色,通过图像可以看出,SWGU-ConvLSTM 模型的温度图与真实标签的 era5 的温度图更为贴近,并且订正的 ECMWF 模式数据最好。同时将这 60 轮训练的各模型的 MSE 指标进行记录并通过折线图表示出来,如图 9 所示。从图 9 可以看出,该 SWGU-ConvLSTM 模型的收敛性更持久,从第 10 轮到第 50 轮这个训练区间 MSE 收敛更快,训练效果更好。



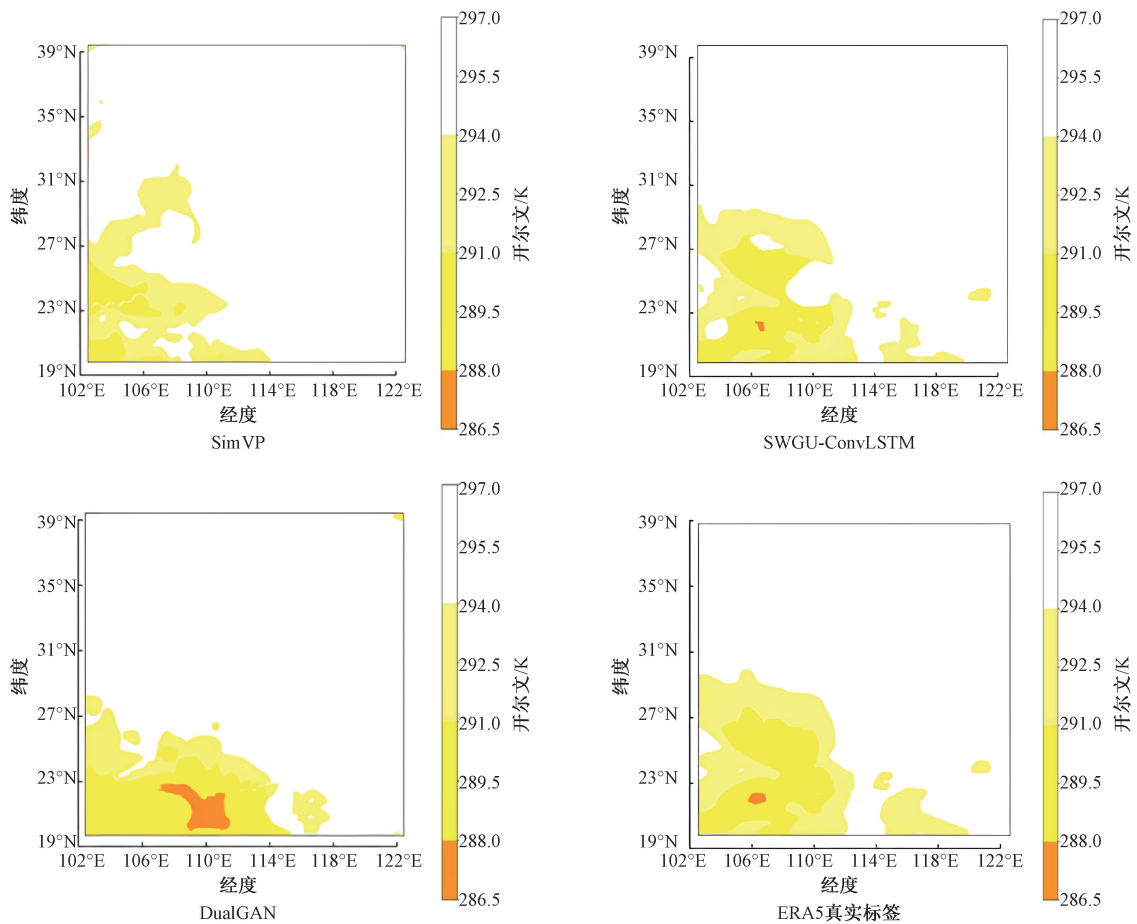


图 7 不同模型订正之后和真实标签的图像比较

Fig. 7 Comparison of corrected images by different mode with the real labels




图 8 ECMWF 模式数据可视化

Fig. 8 ECMWF model data visualization

2.6 消融实验

为了验证加入双向对抗网络进行对抗训练的有效性，




图 9 不同模型在训练集的实验结果对比

Fig. 9 Comparison of experimental results of different models on the training set

本文做了消融实验。原本是在使用 ConvLSTM 网络的基础上融合了 Swin Transformer 结构使其更好的获取全局特征信息。每一层 ConvLSTM 的输出分别通过两个通道，分别是通过 SwinTransform 模块、下采样、卷积和通过下采样、卷积得到两个输出特征图。然后将两个输出特征图

通过 IAFF 模块进融合,这样可以更好的融合局部特征和全局特征。同时将该模块通过 U 形连接的方式集成到 SWU-ConvLSTM 模型。实验表明他的 MSE 和 MAE 值虽然相比较于其他几个模型仍然是偏低的,但是相比较来说改进效果不大,它的 MSE 值相对于 SimVP 模型效果只提高了 10%他的 MAE 值只提高了 7%,效果不明显,而且他的 SSIM 指标低于 UNET3d。于是选择加入双向对抗网络进行对抗训练,通过不断的双向对抗来优化模型,得到最优参数。实验表明,加入双向对抗网络之后,MSE 下降了 0.072,SSIM 提高了 0.006,同时 MAE 指标也有所降低。实验结果如表 2 所示。

表 2 消融实验结果对比

Table 2 Comparison of ablation experiment results			
方法	MSE	MAE	SSIM
SWGU-ConvLSTM	0.252	0.324	0.994
SWU-ConvLSTM	0.324	0.416	0.988

实验表明加入了双向对抗网络结构后,MSE,MAE,SSIM 这些指标性能均有所提高。并且将验证集最后一天的真实标签的温度数据和多要素输入通过不加双向对抗网络的 SWU-ConvLSTM 模型和加入了双向对抗网络的 SWGU-ConvLSTM 模型得到的 6 h 订正预报气温数据进行可视化,如图 10 所示,可以明显的观察到 SWGU-ConvLSTM 的图像与真实图像更为接近,虽然 SWU-ConvLSTM 模型相对于其他模型而言温度订正效果较好,且在 102°~110° E,19°~27° N 这个区域订正效果也有明显的提高,但是相比于 SWGU-ConvLSTM,该模型订正后的温度图更加贴切于真实图像,且在 102°~110° E,19°~27° N 这个区域的复杂温度情况下订正温度的效果更好。同时将俩个模型训练时的 60 轮 MSE 值记录下来并进行折线图绘制,如图 11 所示,SWGU-ConvLSTM 模型的损失函数 MSE 收敛的更快,且具有更好的拟合效果,说明他的学习能力更好。

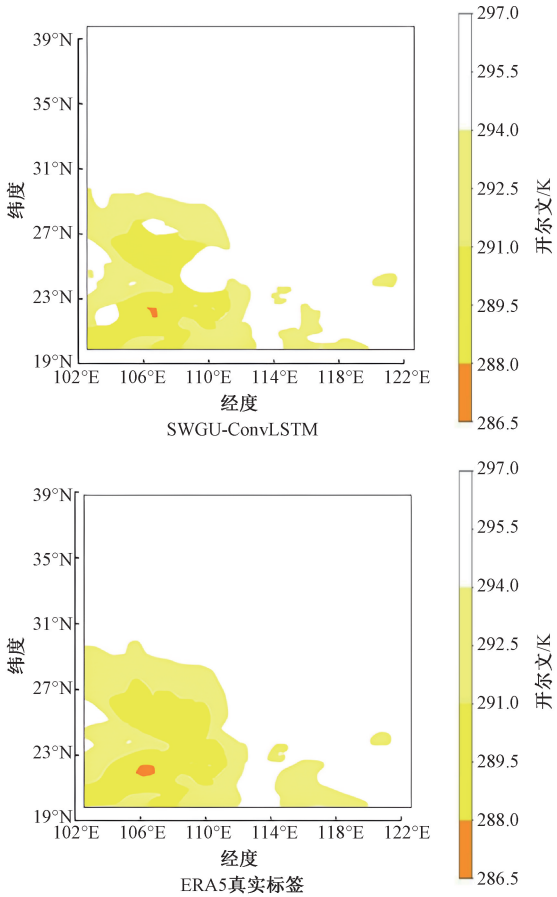
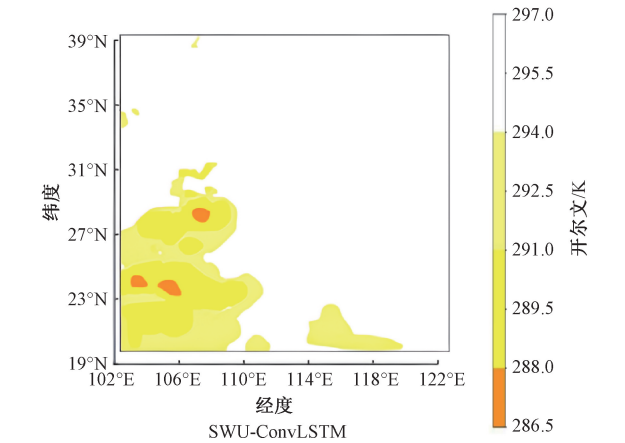


图 10 消融实验订正之后和真实标签图像比较
Fig. 10 Comparison of ablation experiment correction and ground truth images

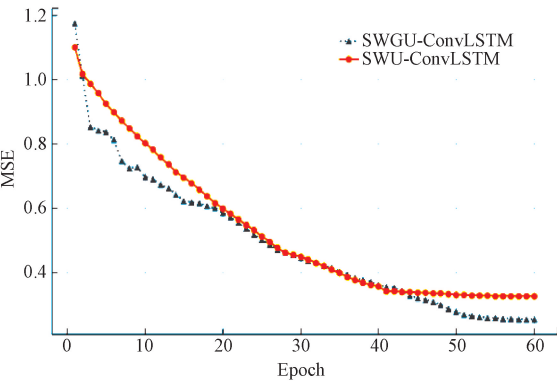


图 11 消融实验在训练集实验结果对比
Fig. 11 Comparison of ablation experiment results on the training set

3 结 论

本文中提出一种 SWGU-ConvLSTM 模型用于偏差订正温度,该模型使用了 Swin transform 模块更好的提取全局特征信息,并且引入了 IAFF 模块利用双重全局注意力

机制和双重局部注意力机制实现将局部特征信息和全局信息进行特征融合。此外该模型使用了 U 形连接和跳跃连接,可以提取多尺度的信息,更好的融合浅层信息和深层信息。最后使用双向对抗网络,通过以该模型为基础的双向生成器和三向判别器进行互相对抗训练,有效的增强了模型的学习性和鲁棒性。实验结果表明,该模型在气象偏差订正领域具有极大的应用潜力,使得气象预测订正更加准确。

参考文献

- [1] ZHANG L, SIEMANN F, FRAEDDRICH K, et al. Variability of winter extreme precipitation in Southeast China: Contributions of SST anomalies[J]. *Climate Dynamics*, 2015, 45: 2557-2570.
- [2] SCREEN J A, DESER C, SUN L. Reduced risk of North American cold extremes due to continued Arctic sea ice loss [J]. *Bulletin of the American Meteorological Society*, 2015, 96(9): 1489-1503.
- [3] 段青云, 夏军, 缪驰远, 等. 全球气候模式中气候变化预测预估的不确定性[J]. *自然杂志*, 2016, 38(3): 182-188.
DUAN Q Y, XIA J, MIAO CH Y, et al. Uncertainty of climate change projections in global climate models[J]. *Chinese Journal of Nature*, 2016, 38(3): 182-188.
- [4] TIAN D, MARTINEZ C J, GRAHAM W D, et al. Statistical downscaling multimodel forecasts for seasonal precipitation and surface temperature over the southeastern United States[J]. *Journal of Climate*, 2014, 27(22): 8384-8411.
- [5] 孙全德, 焦瑞莉, 夏江江, 等. 基于机器学习的数值天气预报风速订正研究[J]. *气象*, 2019, 45(3): 426-436.
SUN Q D, JIAO R L, XIA J J, et al. Wind speed correction for numerical weather prediction based on machine learning[J]. *Meteorological Calendar*, 2019, 45(3): 426-436.
- [6] TAKANO N, ALAGHBAND G. Srgan: Training dataset matters [J]. *ArXiv preprint arXiv: 1903.09922*, 2019.
- [7] ÇİCEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016: 19th International Conference*, 2016: 424-432.
- [8] DOSOVITSKIY A. An image is worth 16x16 words: Transformers for image recognition at scale[J]. *ArXiv preprint arXiv:2010.11929*, 2020.
- [9] 郑祥明, 秦华旺, 陈浩然. 基于时空分离的雷达降水图像时空降尺度研究[J]. *电子测量技术*, 2024, 46(21): 159-167.
ZHENG X M, QIN H W, CHEN H R. Study on spatiotemporal descent scale of radar precipitation images based on spatiotemporal separation [J]. *Electronic Measurement Technology*, 2024, 46(21): 159-167.
- [10] WANG F, TIAN D. On deep learning-based bias correction and downscaling of multiple climate models simulations[J]. *Climate Dynamics*, 2022: 3451-3468.
- [11] 张延彪, 陈明轩, 韩雷, 等. 数值天气预报多要素深度学习融合订正方法[J]. *气象学报*, 2022, 80(1): 153-167.
ZHANG Y B, CHEN M X, HAN L, et al. Multi-element deep learning fusion correction method for numerical weather prediction [J]. *Acta Meteorica Sinica*, 2022, 80(1): 153-167.
- [12] HAO C, DU X, WANG J. A temperature correction method based on deep learning [C]. *Journal of Physics: Conference Series*. IOP Publishing, 2023, 2450(1): 012072.
- [13] WANG Y, HUANG G, PAN B, et al. Correcting climate model sea surface temperature simulations with generative adversarial networks: Climatology, interannual variability, and extremes[J]. *Advances in Atmospheric Sciences*, 2024, 41(7): 1299-1312.
- [14] 胡莹莹, 庞林, 王启光. 基于深度学习的 7~15 d 温度格点预报偏差订正[J]. *应用气象学报*, 2023, 34(4): 426-437.
HU Y Y, PANG L, WANG Q G. Correction of 7~15 d temperature grid prediction bias based on deep learning[J]. *Journal of Applied Meteorology*, 2023, 34(4): 426-437.
- [15] AMEMIYA A, SHLOK M, MIYOSHI T. Application of recurrent neural networks to model bias correction: Idealized experiments with the Lorenz-96 model[J]. *Journal of Advances in Modeling Earth Systems*, 2023, 15(2): e2022MS003164.
- [16] SUN D, HUANG W, LUO Y, et al. A deep learning-based bias correction method for predicting ocean surface waves in the northwest pacific ocean[J]. *Geophysical Research Letters*, 2022, 49(23): e2022GL100916.
- [17] HAN L, CHEN M, CHEN K, et al. A deep learning method for bias correction of ECMWF 24-240 h forecasts [J]. *Advances in Atmospheric Sciences*, 2021, 38(9): 1444-1459.
- [18] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [J]. *Advances in Neural Information Processing Systems*, 2015(1): 28.
- [19] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. *IEEE/CVF International Conference on Computer Vision*, 2021: 10012-10022.
- [20] YI Z, ZHANG H, TAN P, et al. Dualgan: Unsupervised dual learning for image-to-image translation [C]. *IEEE International Conference on Computer Vision*, 2017: 2849-2857.
- [21] GAO Z, TAN C, WU L, et al. Simvp: Simpler yet better video prediction[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 3170-3180.

作者简介

周旺亮, 硕士研究生, 主要研究方向为深度学习、偏差订正。

E-mail: 3149825698@qq.com

秦华旺(通信作者), 博士, 教授, 博士生导师, 主要研究方向为深度学习。

E-mail: qin_h_w@163.com