深度学习在印度洋偶极子预报中的应用研究

刘俊^{1,3};唐佑民^{2,3,4*};宋迅殊^{3,4};孙志林¹

1 浙江大学 海洋学院,浙江 杭州 310058

2 河海大学 海洋学院 自然资源部海洋灾害预报重点实验室, 江苏 南京, 210021

3 自然资源部第二海洋研究所 卫星海洋环境动力学国家重点实验室,浙江 杭州 310012

4 南方海洋科学与工程广东省实验室(珠海), 广东 珠海 519082

摘要:印度洋偶极子(IOD)是热带印度洋秋季最强的年际变率,它会通过大气遥相关来影响世界 许多地区的气候。目前耦合气候模式对 IOD 预报技巧仍非常有限,远低于热带太平洋的厄尔尼诺事 件的预报技巧。鉴于深度学习具备高效的数据处理能力,本文使用深度学习中的卷积神经网络 (CNN)与人工神经网络中的多层感知机(MLP)处理再分析观测资料,从而进行 IOD 预报。由于 当预报初始时刻为北半球冬春季时,对 IOD 事件的预报技巧较低。因此,为探索 CNN 的预报能力, 本文仅使用三种初始时刻,分别为1-2-3月(Jan-Feb-Mar, JFM)、2-3-4月(Feb-Mar-Apr, FMA)、 3-4-5月(Mar-Apr-May, MAM),来预报其后续七个月的印度洋偶极子指数(DMI)、东极子指数 (EIO)和西极子指数(WIO)。结果表明: CNN 对 DMI、EIO 和 WIO 指数的有效预测时效均超过 了 6 个月。与现在耦合动力模式相比,CNN 模型能够显著提升 DMI 指数和 EIO 指数的预报技巧, 但对 WIO 指数的预报技巧提升有限。当预报提前时间为 7 个月时,CNN 模型能够比较准确地预报 1994、1997 与 2019 年的 IOD 事件。由于 CNN 模型能够更好地抓住印度洋海温的空间结构特征,它 对 IOD 事件的预报技巧比传统神经网络 MLP 高。 关键词:印度洋偶极子;深度学习;卷积神经网络;气候预报

doi: 10.3878/j.issn.1006-9895.2105.21048

Prediction of the Indian Ocean Dipole using Deep Learning Method

Jun Liu^{1,3}, Youmin Tang^{2,3,4*}, Xunshu Song^{3,4}, Zhilin Sun¹ ¹Ocean College, Zhejiang University, Hangzhou, China;

² Key Laboratory of Marine Hazards Forecasting, Ministry of Natural Resources, Hohai University,

Nanjing, China;

³ State Key Laboratory of Satellite Ocean Environment Dynamics, Second Institute of Oceanography, Ministry of Natural Resources, Hangzhou, China;

⁴ Southern Laboratory of Ocean Science and Engineering (Zhuhai), Zhuhai, China;

Abstract: The Indian Ocean Dipole (IOD) is the strongest interannual variability in the tropical Indian Ocean in autumn. It will influence the climate in many parts of the world through atmospheric teleconnection. The current coupled climate model has very limited IOD forecasting skills, which are far lower than the forecasting skills of El Niño events in the tropical Pacific. Due to super capability of deep learning in processing data, we use the convolutional neural network (CNN) of the deep learning and the multi-layer perceptron (MLP) of the artificial neural network, respectively, to perform IOD prediction. In order to explore the forecasting capabilities of CNN, this article only uses three initial conditions in the boreal spring which has the low prediction skill, namely January- February-March (JFM) and February-March-April (FMA)), March-April-May (MAM), to forecast the Indian Ocean Dipole Index (DMI), East Pole Index (EIO), and West Pole Index

(WIO) for the next seven months. The results show that the CNN model can make useful prediction for the DMI, EIO and WIO at least 6-month ahead. Compared with the current state-of-the-art general coupled model, the CNN model can significantly improve the prediction skills of DMI index and EIO index, but has little improvement for WIO prediction skill. The CNN model is able to predict the strong IOD events in 1994, 1997 and 2019 well for the lead time longer than 7 months. In general, because of the CNN is better than the traditional neural network MLP for the IOD prediction due its strong capability in capturing the spatial structure characteristics of the Indian Ocean SST.

Key words: the Indian Ocean Dipole; Deep Learning; Convolutional neural network; Climate prediction

1 引言

在热带印度洋存在两个明显的年际变率模态:印度洋海盆模态(Indian Ocean Basin-wide Mode, IOBM)和印 度洋偶极子模态(Indian Ocean Dipole Mode, IOD)。IOBM 表现为整个热带印度洋区域一致增暖的模态,该模态 一般被认为是热带印度洋对热带太平洋的厄尔尼诺-南方涛动(El Niño-Southern Oscillation, ENSO)的响应(Klevin et al. 1999; Venzke et al. 2000)。IOD 模态表现为东西部海表温度异常(Sea Surface Temperature anomaly, SSTA)符 号相反的印度洋偶极子模态(Saji et al. 1999)。印度洋偶极子的两极分别位于:热带西印度洋(10°S~10°N, 50°~70°E;简称西极子,WIO)与热带东南印度洋(10°S~0°,90°~110°E;简称东极子,EIO)。两极子之间 SST 距平的区域平均之差定义为印度洋偶极子指数(Indian Ocean Dipole Mode Index, DMI)。

IOD 是印度洋气候异常年际变率的主要模态(Saji et al. 1999; Ashok et al.2001),也是全球气候季节到年际变 化的主要影响因子之一(Saji et al. 2003)。IOD 一般起始于 5-7 月,在 9-11 月达到峰值,12 月到来年 1、2 月迅速 消亡,呈现出明显的季节锁相性(McKenna et al. 2020)。IOD 事件的整个过程与受到热带印度洋背景场的调控。 以正 IOD 事件为例,通常在 IOD 发展的初期,即 5-7 月,在热带印度洋夏季风的作用下,苏门答腊岛沿岸的东 南风加强,边界流引起的 Ekman 输运增强,离岸流造成上升流也增强,使得局地的温跃层变浅;当温跃层抬升 到一定的深度后,上升流的作用使得苏门答腊--爪哇岛沿岸的 SST 变冷;东印度洋的 SST 负异常将进一步加强热 带印度洋东西向的 SST 梯度,SST 的梯度反过来导致大气对流向西流动,从而进一步增强苏门答腊--爪哇岛沿 岸和赤道印度洋的东风异常,此东风异常有利于苏门答腊沿岸的 SST 变冷,这个过程也称为 Bjerknes 正反馈, 而在来年的冬季,由于季风转换,背景风场转向,热带东南印度洋的东南风转为西北风,不再利于上升流的产 生,从而关闭利于产生 IOD 事件的时间窗口,使得 IOD 事件迅速消亡(Saji et al. 1999; Saji et al. 2003)。

IOD 会直接或间接影响世界许多地区的气候,例如东非、印度尼西亚、澳大利亚、中国、欧洲和日本。 IOD 的正相位时期,印度洋东南部地区的冷 SST 异常会影响澳大利亚的气候,澳大利亚周围的异常冷水会导致 降雨的减少(Ashok et al. 2003); IOD 还可以通过调节太平洋遥相关对日本的气候产生影响,并且借由大气遥相 关影响欧洲的夏季(Behera et al. 2013); IOD 还能通过调节亚洲冬季风影响我国多个地区的气温和降雨(Li et al. 2001)。IOD 对许多国家产生了巨大的社会经济影响,因此,提前精准预测 IOD 尤为重要。目前,世界上各大 预报中心多使用大气海洋耦合气候模型来预测 IOD(Luo et al. 2007; Weller et al. 2013; Kritman et al. 2014)。这些 动力学模型对全球气候模拟与 IOD 预报起到了巨大的推动作用。目前气候动力学模型对 IOD 的实际预测时效 约为一个季度左右,而理论分析表明, IOD 的潜在预测时效在两个季度以上(Wang et al. 2017; Zhao et al. 2009; Shi et al. 2012; Becker et al. 2014; Liu et al. 2017; Wu et al. 2019)。因此, IOD 的实际预报技巧仍有较大的提升空间。

随着大数据时代的来临,深度学习由于其高效的数据处理能力(Lecun et al. 2015),在气候科学中的应用逐 渐增多(Ham et al. 2019; Ratman et al. 2020; Rasp et al. 2018; Sahai et al. 2000; Lee et al. 2018)。深度学习一般由多 个处理层来组成计算模型,在经过若干处理层的转换之后,模型可以学到非常精细的组合模式和空间特征 (Lecun et al. 2015; Krizhevsky et al. 2012)。Ham 等 (2019)利用深度学习中的卷积神经网络 (CNN)模型对 ENSO 进行了预报。他们的结果显示利用深度学习获得的 ENSO 预报技巧要高于现有最先进的耦合气候动力模 式,证明了深度学习在预报气候事件中的潜力。由于 IOD 的预报存在冬春季和夏季预报障碍(Feng et al. 2014; Liu et al. 2019),当起始态为北半球冬春季时,预报后续的 IOD 发展最为困难(Wu et al. 2019; 雷蕾等 2020)。因 此,本文将使用深度学习中的卷积神经网络 (CNN)处理再分析资料中的 SSTA,以春季为起始来预报 IOD 事件 以及东、西极子的温度变化。同时,我们应用人工神经网络 (ANN)中的多层感知机 (MLP)进行相同的预 报试验,作为经典神经网络的预测结果。通过比较两种模型的预报结果,分析 CNN 模型的在预报印度洋海温 上的优势。

本文的主要内容如下:第二节为本文所用的数据和模型;第三节为利用 CNN 和 MLP 模型对 DMI 指数、 EIO 指数和 WIO 指数的预测结果;第四节为总结与讨论。

2数据与模型

2.1 数据

本文训练模型选取的观测资料为美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)的再分析资料 Extended Reconstructed Sea Surface Temperature Version 5(ERSSTv5)(Huang et al. 2017),其中,训练集时间范围为1854年到1989年;验证集时间范围为1990年到2019年,共30年。SSTA 所选范围为整个印度洋区域(25°E~130°E, 70°S~25°N)。我们将 ERSSTv5 中连续三个月(1-2-3月(Jan-Feb-Mar, JFM)、2-3-4月(Feb-Mar-Apr, FMA)、3-4-5月(Mar-Apr-May, MAM))的 SSTA 作为CNN 的输入数据。模型输出为提前时间(lead month)对应的 DMI 指数。输入和输出的数据均是相对于气候态的异常值,并且输入与输出的数据都进行了去趋势化处理。

2.2 CNN 模型与 MLP 模型

如图 1 所示,本文使用的 CNN 模型架构包含两个卷积池化层,一个全联接层和一个输出层。卷积层的作 用是提取输入 SSTA 的空间特征等关键信息,池化层对这些信息进行放大或平均。经过两次卷积池化处理后, 全联接层将特征图展开并映射到合理的解空间。每个卷积层中有 10-12 个过滤器,用于提取 SSTA 的空间信息。 过滤器在 3×3 网格中提取 SSTA 数据特征。平均池化层在 2×2 网格中提取特征。全连接层具有 8-10 个神经元。



因为需要回归来生成 DMI,最终输出层是一维的。根据卷积层中过滤器和全联接层中神经元数目的不同,共有 27 种 CNN 模型的架构,分别记做 C10C10D8,C10C10D9,C10C10D10,C10C11D8 ... C12C12D10 等(C 和 D 分别表示卷积层和全连接层,后面的数字代表过滤器或神经元数量)。数据批次为每次更新 CNN 模型读取的数据量大小。我们尝试了将数据批次设置为 12、24、48 和整个批次。结果表明,CNN 模型对数据批次并不

敏感,因此,我们将数据批次设置为24。



学习率(Learning Rate, LR)是 CNN 模型中相当重要的参数,它代表了模型寻优过程的优劣。不同 CNN 模型架构倾向于不同的 LR。因此,我们对于这 27 种 CNN 模型架构中的每一种,采用从 0.05 到 0.0001 的 LR 范围进行训练测试,选取使训练出的 DMI 与观测值相关系数最高的 LR 作为对应 CNN 模型架构的参数。随后, 在这个模型上,输入验证集数据来生成预测的 DMI。我们将 27 个不同架构的 CNN 模型输出的平均值用作最终 的预测 DMI。

我们针对每个输入时刻和对应的输出时刻建立各自的 CNN 模型组合(表 1)。由于使用了三种预报初始时刻, 且分别预报后续七个月的 DMI, 则一共有 21 个 CNN 模型组合。考虑到不同的 27 种 CNN 模型架构, 则总的 CNN 模型数量为 567 (21×27)。同理, 预测 EIO 和 WIO 的 CNN 模型的数量也均为 567 个。

输入	输出						
(SSTA)	(Lead=1)	(Lead=2)	(Lead=3)	(Lead=4)	(Lead=5)	(Lead=6)	(Lead=7)
JFM	Apr-DMI	May-DMI	Jun-DMI	Jul-DMI	Aug-DMI	Sep-DMI	Oct-DMI
FMA	May-DMI	Jun-DMI	Jul-DMI	Aug-DMI	Sep-DMI	Oct-DMI	Nov-DMI
MAM	Jun-DMI	Jul-DMI	Aug-DMI	Sep-DMI	Oct-DMI	Nov-DMI	Dec-DMI

表1 模型数量与输入输出

MLP 模型是一种前向结构的人工神经网络(ANN)模型,由输入层、隐藏层、输出层组成。MLP 模型所 有的神经层均为全联接结构,且可以包含多个隐藏层。本文使用的多层感知机 MLP 只包含一个隐藏的全联接 层。与本文所用的 CNN 模型相比, MLP 模型缺少了卷积层和池化层,因此提取空间特征的能力相对较弱。为了与 CNN 模型的预测结果进行对比, MLP 模型输入输出的资料和设置与 CNN 一致。

3 结果

3.1 IOD 预报技巧

图 2 显示了分别使用 CNN 与 MLP 模型预报出的 DMI 指数与观测值间的相关系数和均方根误差(RMSE) 随目标月份的变化。如果以相关系数超过 0.5 作为有效预报的阈值(Liu et al. 2017; Wu et al. 2019),利用 CNN 模 型从 JFM、FMA、MAM 三个初始状态预报出的 DMI 有效预报时效均达到 7 个月,而利用 MLP 模型所获得的 DMI 指数有效预报时效则不超过 3 个月。同时,利用 CNN 模型从三个初始时刻预报出 DMI 指数的 RMSE 技巧 均优于 MLP 模型。从相关系数和 RMSE 这两种实际预报技巧评价标准来看,CNN 模型对 DMI 指数的实际预 报技巧远胜于 MLP 模型。这可能是由于 CNN 能对海表温度异常的空间结构进行解析,其卷积与池化能提取 SSTA 中的空间特征,并充分考虑 SSTA 中的非线性因素,从而能够将输入的 SSTA 映射到合理的解空间,实现 对数据的高效处理。MLP 模型由于不擅长处理结构型数据,对 SSTA 空间结构特征的提取能力较弱,因此, MLP 预报的结果较差。现有最先进的动力耦合模式以春季为初始状态对 DMI 指数的有效预报时效不到一个季 度 (Shi et al. 2012),这远低于 CNN 模型的预报技巧,说明 CNN 模型在预报 DMI 指数上较现有的动力耦合模 式有明显的优势。RMSE 在预报目标月 11 月以后迅速减少,主要是因为 IOD 在秋季成熟后迅速衰退所致。 RMSE 的大小跟预报量的振幅有直接的关系。

CNN 模型对 DMI 指数的预报技巧也存在着季节性变化,其相关系数技巧在目标月份为北半球夏季时有明显的下降,并且 RMSE 在这一季节增长迅速。这一现象在以 FMA 为初始时刻的预报中最为明显。这说明 CNN 模型的 DMI 指数预报技巧可能受到了 IOD 夏季预报障碍现象的影响(Liu et al. 2019)。



图 2. 以 JFM、FMA、MAM 为起始态,分别使用 CNN 模型(实线)与 MLP 模型(虚线)预报出的 DMI 指数与观测值的相关 系数(a)和均方根误差(RMSE)(b)随目标月份的变化。

Fig. 2 With JFM, FMA, and MAM as the initial conditions, the correlation coefficient and root mean square error between the forecasted and observed DMI by the CNN models (a) and the MLP models (b), respectively.

图 3 为利用 CNN 模式预报出的北半球秋季(9 月和 10 月) 平均的 DMI 指数和对应观测值随时间的变化。

所有指数均做了标准化处理。我们以一个标准差作为判定 IOD 事件的阈值。当秋季平均的 DMI 指数减去多年 均值后超过一个标准差时,则认为发生了正 IOD 事件;反之,当小于一个负标准差时,则认为发生了负 IOD 事件。根据此标准,1990-2019 年间共发生五次正 IOD 事件(1994,1997,2006,2015,2019)和七次负 IOD 事件(1990,1992,1996,1998,2005,2010,2016)。如果标准化的预报 DMI 指数超过 1,则认为预报出了 IOD 事件。由于 MLP 预报北半球秋季(9 月和 10 月)平均 DMI 指数的效果较差,其相关系数不超过 0.5(图 2)。因此我们仅重点分析 CNN 的结果。





Fig. 3 Normalized observation and forecast of the averaged DMI in boreal autumn (September and October).

以 MAM 为起始态,即提前预报时间为 4 个月时, CNN 预报秋季平均 DMI 指数与对应观测值之间的相关 系数为 0.72。CNN 模型正确预报出了 1997 年和 2019 年的强 IOD 事件,但低估了 1994 年强 IOD 事件的强度。 对于强负 IOD 事件,例如 1990、1996 和 2016 年,CNN 模型预报的强度与观测较为符合,但 CNN 模型低估了 2010 年强负 IOD 时间的强度。

随着提前时间的增加,预报出的 DMI 指数与观测的相关系数逐渐减小。以 FMA 和 JFM 为初始时刻的相关 系数预报技巧分别降低至 0.67 和 0.61。预报出的 DMI 指数在 21 世纪初出现较多的误报。但对于 1994 年和 1997 年的强正 IOD 事件,CNN 模型能够提前 5 个月(以 FMA 为初始态)和 6 个月(以 JFM 为初始态)正确预报出 IOD 的强度。而目前动力耦合模式以春季为初始态对这两个强事件进行的预报均低估了 IOD 事件的强度(Luo et al. 2005; Zhao and Hendon 2010)。这说明 CNN 在预报 IOD 事件的强度上比现有的动力耦合模式存在优势。

3.2 EIO 预报技巧

印度洋东极子(EIO)在 IOD 的发生发展中起到重要作用,是 IOD 预报的重要区域(Luo et al. 2005)。图 4显示了利用 CNN 模型和 MLP 模型预报出的 DMI 指数与观测值的相关系数和 RMSE 随目标月份的变化。MLP 模型以北半球春季为起始态对 EIO 的有效预报能够提前约 3-4 个月做出,而 CNN 模型则能够提前 7 个月做出 有效预报。同时,CNN 模型预报出 EIO 指数的 RMSE 也明显低于 MLP 模式,说明 CNN 模型对 EIO 指数的预 报技巧优于 MLP 模型。目前耦合动力模式以北半球春季为起始态对 EIO 的预报的有效预报时效约为 4-5 个月

(Luo et al. 2007; Zhao and Hendon 2010)。这一预报技巧优于 MLP 模型但低于 CNN 模型,说明 CNN 模型能够

显著改进目前对 EIO 的预报技巧。



Fig. 4 With JFM, FMA, and MAM as the initial conditions, the correlation coefficient and root mean square error between the forecasted and observed EIO by the CNN models (a) and the MLP models (b), respectively.

图 5 是以北半球春季为初始态, CNN 模型预报出的北半球秋季(9 月和 10 月)平均的标准化 EIO 指数随时间的变化。可以看出,无论哪个初始态, CNN 模型能够较好地预报出过去 30 年主要的 EIO 冷暖事件,例如: 1994、1997 的冷事件和 1998、2010 的暖事件。但对于 2019 年的强冷事件,无论以哪个初始状态, CNN 模型均低估了其强度。





Fig. 5 Normalized observation and forecast of the averaged EIO in boreal autumn (September and October).

3.3 WIO 预报技巧

印度洋西极子(WIO)受到太平洋 ENSO 事件的影响,其预报技巧通常比 EIO 和 DMI 高(Luo et al. 2005; Luo et al. 2007; Zhao and Hendon 2010; Shi et al. 2012)。图 6显示了以北半球春季为初始态,利用 CNN 模型和 MPL 模型预报出的 WIO 指数与观测的相关系数和 RMSE 随目标月份的变化。MPL 模型对 WIO 指数的有效预 报时效仅为一个季度不到,这远低于目前耦合动力模式的有效预报时效(约为 6-7 个月, Luo et al. 2007; Zhao and Hendon 2010)。而 CNN 模型对 WIO 的有效预报也仅能提前 6-7 个月做出,与目前耦合动力模式的预报技巧相近。与 EIO 的预报技巧相比, CNN 模型对 WIO 的预报技巧更低,这与耦合动力模式的预报技巧不一致。 这可能是由于我们在构造 CNN 模型时仅利用印度洋作为输入数据,缺少太平洋的 ENSO 信号作为先兆因子,





Fig.6 With JFM, FMA, and MAM as the initial conditions, the correlation coefficient and root mean square error between the forecasted and observed WIO by the CNN models (a) and the MLP models (b), respectively.

图 7 给出了以北半球春季为初始态, CNN 模型预报出的北半球秋季(9 月和 10 月)平均的标准化 WIO 指数随时间的变化。当提前时间较短时,以 MAM 作为初始状态, CNN 模型基本预报出了主要的 WIO 事件,例如 1996 年的冷事件以及 2015 年和 2019 年的暖事件。随着提前时间的增长, CNN 模型对 WIO 的预报技巧逐渐降低,并且在 21 世纪初出现了较多的误报。对于强 WIO 事件(如 1996, 2015 和 2019 年), CNN 模型均能提前 5 个月以上(以 FMA 为初始条件)预报出。





Fig. 7 Normalized observation and forecast of the averaged WIO in boreal autumn (September and October).

4 结论与讨论

本文使用CNN模型和MLP模型处理再分析资料ERSSTv5,并以北半球春季的三个初始态为起始,对IOD模态以及印度洋东西极子的海温变化进行了预报。结果表明:

(1) CNN对DMI、EIO和WIO指数的有效预测时效均超过了6个月。与现在耦合动力模式相比,CNN模型能够显著提升DMI指数和EIO指数的预报技巧,但对WIO指数的预报技巧提升有限。

(2) 当预报提前时间为7个月时, CNN模型能够比较准确地预报1994、1997与2019年的IOD事件。

(3)相比于传统的神经网络模型MLP, CNN模型对DMI、EIO和WIO指数的预报均有更高的预报技巧。

IOD事件在空间结构上的主要特征是东西印度洋的温度梯度。由于CNN模型拥有卷积层和池化层,能够更 好地解析图像数据的空间结构(Zeiler et al. 2014),抓住IOD事件东西温度梯度的特征,从而能高效地求解SSTA 与DMI之间映射关系,因此,CNN模型对IOD事件的预报技巧较优于传统的神经网络MLP模型。

CNN模型对WIO指数的预报不够理想表明了在训练模型时,不仅要考虑局地印度洋的信号,而且还要考虑太平洋信号的遥相关作用。今后我们将就这一点进行进一步研究。

同时,深度学习中超参数的最优解会随具体数据集变化而不同,需根据具体的数据状况进行逐步调试,应 避免过拟合与欠拟合现象发生。神经元数量、学习率、优化器、网络层数等是模型自身超参数,其调节一般都 是试错的过程。在算力充足的条件下,可对每个超参数设定一个数值或类型范围,对它们的组合全部进行训练。 若时间有限,在固定其他超参数为默认值的条件下,可优先调节神经元数量与学习率,同样能够取得较为理想 的结果。

总而言之,我们的研究结果表明,CNN模型在印度洋海温预报中有着较好的表现,深度学习方法在气候预报中存在较大的潜力和应用价值。

参考文献

- Klein S A, Soden B J, Lau N C. 1999. Remote sea surface temperature variations during ENSO: evidence for a tropical atmospheric bridge[J]. J. Clim., 12(4): 917–932
- [2] Venzke S, Latif M, Villwock A. 2000. The coupled GCM ECHO-2. Part II: Indian Ocean response to ENSO[J]. J. Clim., 13(8): 1371-1383
- [3] Saji, N H, Goswami B N, Vinayachandran P N, Yamagata T. 1999. A Dipole mode in the tropical Indian Ocean. Nature 401, 360–363
- [4] Ashok K, Guan Z, Yamagata T. 2001.Impact of the Indian Ocean Dipole on the relationship between the Indian monsoon rainfall and ENSO. Geophys. Res. Lett. 27, 3977–3980
- [5] Saji N H, Yamagata T. 2003. Possible impacts of Indian Ocean Dipole mode events on global climate. Clim. Res. 25, 151–169
- [6] McKenna S, Santoso A, Gupta A S, et al. 2020.Indian Ocean Dipole in CMIP5 and CMIP6: characteristics, biases, and links to ENSO. Sci Rep. 10, 11500
- [7] Ashok K, Guan Z, Yamagata T. 2003. Influence of the Indian Ocean Dipole on the Australian winter rainfall. Geophys. Res. Lett. 30, 1821–1823
- [8] Behera S K, Ratnam J V, Masumoto Y, Yamagata T. 2013.Origin of extreme summers in Europe: the Indo-Pacific connection. Clim. Dyn., 41, 663–676
- [9] Li Chongyin, Mu Mingquan. 2001. The influence of the Indian Ocean dipole on atmospheric circulation and climate[J]. Advances in Atmospheric Sciences, 18(5): 831–843

- [10] Luo J J, Masson S, Behera S, Yamagata T. 2007. Experimental forecasts of the Indian Ocean Dipole using a coupled OAGCM. J. Clim., 20, 2178–2190
- [11] Weller E, Cai W. 2013.Realism of the Indian Ocean Dipole in CMIP5 models: The implications for climate projections. J. Clim., 26, 6649-6659
- [12] Kirtman B P, et al. 2014. The North American Multimodel Ensemble: Phase-1 seasonal-to-interannual prediction; Phase-2 towards developing intraseasonal prediction. Bull. Amer. Meteor. Soc. 95, 585–601
- [13] Wang G, Cai W, Santoso A. 2017. Assessing the impact of model biases on the projected increase in frequency of extreme positive Indian Ocean Dipole Events. J. Clim. 30, 2757–2767
- [14] Zhao Mei, Hendon H H. 2009.Representation and prediction of the Indian Ocean dipole in the POAMA seasonal forecast model[J].
 Quarterly Journal of the Royal Meteorological Society, 135(639): 337–352
- [15] Shi Li, Hendon H H, Alves O, et al. 2012. How predictable is the Indian Ocean dipole? [J]. Monthly Weather Review, 140(12): 3867–3884
- [16] Becker E, van den Dool H, Zhang Qin. 2014. Predictability and forecast skill in NMME[J]. J. Clim., 27(15): 5891–5906
- [17] Liu Huafeng, Tang Youmin, Chen Dake, et al. 2017. Predictability of the Indian Ocean Dipole in the coupled models[J]. Clim. Dyn., 48(5/6): 2005–2024
- [18] Wu Yanling, Tang Youmin. 2019 Seasonal predictability of the tropical Indian Ocean SST in the North American multimodel ensemble[J]. Clim. Dyn., 53(5/6): 3361–3372
- [19] LeCun Y, Bengio Y, Hinton G. 2015. Deep learning. Nature 521, 436-444
- [20] Krizhevsky A, Sutskever I, Hinton G E. 2012. Imagenet classification with deep convolutional neural networks. Adv. Neural Inf. Process. Syst. 25, 1097–1105
- [21] Ham YG, Kim JH, Luo JJ. 2019.Deep learning for multi-year ENSO forecasts. Nature 573, 568–572
- [22] Ratnam J V, Dijkstra H A, Behera S K. 2020. A machine learning based prediction system for the Indian Ocean Dipole. Sci Rep, 10, 284
- [23] Rasp S, Pritchard M S, Gentine P. 2018. Deep learning to represent subgrid processes in climate models. PNAS
- [24] Sahai A K, Soman M K, Satyan V. 2000. All India summer monsoon rainfall prediction using an artificial neural network. Clim. Dyn,. 16, 291–302
- [25] Lee J, Kim C G, Lee J E, Kin N W, Kim H. 2018. Application of artificial neural networks to rainfall forecasting in the Geum river basin, Korea. Water, 10, 1448
- [26] Zeiler M D, Fergus R. 2014. Visualizing and understanding convolutional networks. In Eur. Conf. On Computer Vision 818-833
- [27] Huang B, Peter W, Thorne, et al. 2017 Extended Reconstructed Sea Surface Temperature version 5 (ERSSTv5), Upgrades, validations, and intercomparisons. J. Clim., 30(20),8179-8205
- [28] Feng R, Duan W, Mu M. 2014. The "winter predictability barrier" for IOD events and its error growth dynamics: Results from a fully coupled GCM. J. Geophys. Res. Ocean. 119, 8688–8708
- [29] Liu D, Duan W, Feng R, Tang Y. 2018.Summer Predictability Barrier of Indian Ocean Dipole Events and Corresponding Error Growth Dynamics. Journal of Geophysical Research: Oceans, 123(5), 3635-3650.
- [30] 雷蕾,伍艳玲,唐佑民. 2020.印度洋偶极子预报技巧在多模式中的对比研究[J].海洋学报,42(7):51-63
 Lei Lei, Wu Yanling, Tang Youmin. 2020.A comparison of Indian Ocean dipole prediction skill in a multi-model ensemble[J].
 Haiyang Xuebao, 42(7):51-63
- [31] Luo J J, Masson S, Behera S, Shingu S, Yamagata T. 2005.Seasonal Climate Predictability in a Coupled OAGCM Using a Different Approach for Ensemble Forecasts. J. Clim., 18(18), 4474-4497



