





# 罗勇夏馨施文廖舟怡马子起黄建斌黄小猛





# 人工智能的发展

#### 1956 Dartmouth Conference The pioneers of AI



John McCarthy Marvin Minsky



Claude Shannon Ray Solomonoff Allen Newell



符号AI



1956达特茅斯会议

专家系统 规则系统



Herbert A. Simon





Oliver Selfridge Nathaniel Rochester Trenchard More







Yann LeCun



Geoffrey Hinton









Noam Chomsky Edward Feigenbaum

















Ilya Sutskever Yoshua Bengio

## Google DeepMind **NVIDIA** S OpenAl



## 认知智能

张钹院士2016年提出 第三代人工智能雏形, DARPA 2018年发布AI Next计划。核心要素 是数据、知识、算法 和算力。

第三代

通过对巨量数据的建模 和处理,实现对多模态 信息的理解、推理、规 划、执行,实现复杂的 高阶认知任务

第二代



大数据驱动的统 计学习方法初步 实现了针对文本、 图像、语音等感 知与识别





# 大数据与人工智能正在引发一场深刻的地球科学研究革命



大数据与人工智能应对全球变化研究呈爆发性增长,有力促进了地球系统的机理、模拟和预测研究, 人工智能与数值预报的融合成为热点和难点



# 人工智能如何创新研究范式?





## ☑增强预测能力



美国EarthRisk公司通过对传统区 域数值模式的预报结果进行深度 学习订正,将温度的有效预测时 间从原来的7天提升到40天





密西根大学在CFD模拟方面的最 新结果,利用深度学习代替LBM 方法,开展预报比数值方法要快 几个量级





应用人工智能的原理和方法,包括但不限于机器学习、深度学 习、数据挖掘和自然语言处理等,对气象数据进行高效处理、分析和 解释的技术。 这些技术在气象领域的应用越来越广泛,已经成为提升气象服务 水平的重要手段。





# AI气象大模型的发展







## 智能气候预测的理念与案例

## 基于机器学习方法的中国降水预测

## 基于中尺度气象同化预报和深度学习的风速预报

## 光伏电站太阳辐射超短期预报

## 基于深度学习的北极地区格点化地表气温重建

## 气象人工智能未来发展思考



## 基于机器学习方法的中国降水预测

## 基于中尺度气象同化预报和深度学习的风速预报

## 光伏电站太阳辐射超短期预报

## 基于深度学习的北极地区格点化地表气温重建

行智能评估、继而动态推荐预测结果。

应用,人工智能为气候预测提供了一种解决难题的新思路。

能力和准确率逐步提高。





- 将人工智能算法与气候预测相结合,构建智能气候预测技术体系,即以 大数据应用为前提,在通过机器学习和常规方法进行客观定量预测的基础上进
  - 随着大数据和人工智能的发展,海量数据深度学习、复杂神经网络等逐步
- 可以用人工智能算法把超级计算机的预报结果尽可能地、自动地、不用人 工干预地修正到与实际观测数据更接近,以促进延伸期-月-次季节-季气候预测















- ✓ 模型以数值模式回算资料的季节环流预测作为输 入,以对应的降水预测作为输出,训练模型学习 环流与同期降水之间的非线性关系;
- ✓ 利用观测资料对模型进行迁移学习,进一步调整 网络参数。
- ✓ 实际预测时,利用高质量的多模式集合季节环流 预测场输入模型, 预测季节降水。

巡航导弹通常采用惯导、地形匹配制导、GPS制导和景象匹配制导等组合制导方式。



图1 美国"战斧"BGM-109舰载巡航导弹结构图





## 探索思路:射击问题与巡航导弹

- ・传统的射击问题
- ·气候系统预测的相似性
  - ·大气:导弹;海陆冰:地形地貌









#### 巡航导弹通常采用惯导、地形匹配 制导、GPS制导和景象匹配制导等 组合制导方式。



#### 美国"战斧"BGM-109舰载巡航导弹结构图 图 1





## 1. 建立夏季降水的深度学习预测模型

水预测模型,对汛期降水距平百分率空间分布场进行预测,以期提高汛期降水预测准确率。

## 2. 前兆信号和影响机理的识别

响大小,分析汛期降水的影响机制。

## 3. 模式误差来源的分析和评估

估模式对不同物理过程的模拟能力;或通过深度学习模型分析模式汛期降水预测误差的主要来源。



- 通过监督学习/无监督学习的思路,将卷积神经网络等深度学习方法应用在夏季降水的季节预测中, 通过观测资料和动力模式数据(季节模式,CMIP6)建立基于模式季节预测结果和前期观测信息的汛期降
- 由于深度学习可以处理多维数据,具有自动提取特征的功能。可以利用可解释性深度学习的部分方 案,评估深度学习模型的预测机理。目的在发现新的影响因子和预报关系,评估不同因子对夏季降水的影

使用深度学习模型订正模式数据;通过分析模式回算数据与观测或再分析资料所构建模型的差异, 评



## 汛期全国气候趋势预测

## 1月 – 启动分析研判工作

2月-3月 - 召开汛期全国气候趋势预测 会商会; 3月23日起, 中国气象局首次 面向公众发布气候预测信息

4月 - 中国气象局举行新闻发布会,发 布全国汛期气候趋势预测结果

5月 - 召开汛期气候趋势预测滚动订正

6月 – 召开汛期气候趋势预测第二次滚 动订正

9月 - 汛期全国气候趋势预测检验评估



## 综合分析前期海洋、陆面、大气环 流、气候异常特征等影响因素

## 邀请水利部、高校及科研院所等专 家共同研判;结合国内外动力气候 模式预测结果

## 滚动订正预测结果

## 滚动订正预测结果



## 2021年汛期降水趋势预测

## 2021年汛期降水预测图汇总



邀请水利部、高校及科研院所等专家共同研判





## 中国汛期降水时空分布特征









受季风、地形等影响,我国汛期(6-8月)总 雨量占全年降水量比例大,且区域差异和年际 年代际变化明显。 汛期降水与国民经济和人民生活密切相关,是 我国短期气候预测的主要任务。

Ding et al., 2008, Int. J. Climatol; Wu et al., 2018, Atmosphere



15

## 东亚季风影响因素示意图

## "东南西北中"这五大因素可以概括影响东亚季风的主要 热力、动力条件, 即大气环流和下垫面热状况。







## 汛期降水数值模式预测技巧

0.8 0.6

0.4

0.2 0.0







国际主流数值模式近四年汛期预测评分 (ACC, PS)



**APCC 14-model ensemble** 

上图来源:国家气候中心;吴捷等,2017,大气科学;Wang et al., 2009, CD



2019 JJA Prec. Percent.:CMME Forecast ACC/Ps/Pc/Pg Lead 1-4 months

季节气候模式的汛期预报PS评 分在70分左右;但ACC(距平 相关系数)仍在0.2以下,甚至 可能小于0。







500hPa高度场

模式对不同地区的降水预报能力 对中高纬度地区预报技巧 不同。 较低; 温度等变量预 模式对大气环流、 测能力远超对降水的预报能力。







# 动力-统计模型汛期降水预测



封国林等, 2013, 应用气象学报; 刘颖等, 2020, 气候与环境研究



#### 2. 统计降尺度 利用动力模式中具有较高预测技巧的大尺 度环流信息预测降水



动力-统计方法仍依赖对影响机制和模式误差的 理解, 且样本数量少, 效果不够稳定。





# 什么是Deep Learning?

能不能自动地学习一些特征呢?答案是能! "深度学习"就擅长做这个事情!

深度学习:学习数据表示的多级方法。 深度学习是机器学习的一个分支领域,是从数据中学习表示的一种新方法,强调从连续的 层 (layer) 中进行学习, 这些层对应于越来越有意义的表示。"深度学习"中的"深度" 指的并不是利用这种方法所获取的更深层次的理解,而是指一系列连续的表示层。



# 手工地选取特征是一件非常费力、启发式(需要专业知识)的方法,能不能选取好很 大程度上靠经验和运气,而且它的调节需要大量的时间。既然手工选取特征不太好,那么

## **Deep Learning =** Learning representations / features without being taught







## 深度学习方法的优势

#### 深度学习:通过多个处理层(神经网络)学习抽取合适的特征(预测因子), 而不再局 限于人工设计模型后的参数优化,称为表示学习(representation learning)。



Reichstein et al., 2019, Nature; Lecun et al., 2019, Nature







# 深度学习在气候预测中的应用前景

季节预测仍然是重大挑战,特别是中纬度降水预测 能力仍然较低,因此中国汛期降水预测仍然是 重大挑战,而深度学习可能带来新的提升:

- 目前的概念模型受限于对影响因子的理解。 深度学习的挖掘能力可能学习到新的预测信 号。
- 动力模式预测技巧较低。模式数据不断增 多,但对其误差的特征和原因的分析远远不 够;而深度学习擅于处理大数据。
- 目前应用的统计方法往往结构较为简单,对 非线性关系描述能力较弱。深度学习则可以 从数据中学习合理的非线性特征。
- 深度学习聚焦于空间学习和序列学习,其数 据形式与气候数据有很高的相似性。



#### Machine learning tasks

**Object classification and localization** 



Earth science tasks

# Pattern classification

#### Super-resolution and fusion

 $32 \times 32$ samples



## 降尺度

事件识别

#### Video prediction



Short-term forecasting

场预测





#### 序列预测





## 深度学习在气候领域的应用(1)

## 解决深度学习的两大问题: 1. 样本量不足: 一些研究结合模式数据训练模型。



Kadow, 2020, Nature; Ham, 2019, Nature



## 深度学习利用模式数据补充缺测值

HadCRUT4早期缺测值较多(图a),利用CMIP模式数 据,深度学习可以补充缺测值(图b),效果超过克里金 插值(图c)和PCA插值(图d)。

以1877年7月为例,深度学习方法可以复现厄尔尼诺现象 (图b)。

## 利用迁移学习提升ENSO预测准确率

使用21个CMIP5模式数据对深度学习模型进行预训 使用观测、再分析资料对模型参数进行订正 练, ,对结果有显著提升。 (迁移学习)





# 深度学习在气候领域的应用(2)

## 解决深度学习的两大问题: 2. 机理难以解释。一些研究探索了通过模型可视化探索机理的可能性。





Ham et al., 2019, Nature; Benjamin et al., 2019, arXiv



## 提前18个月预测1997/98 ENSO事件:

• 填色: Heatmap, 表示预测因子对结果影响的比重; •等值线:海表气温和热容量。 深度学习模型准确模拟了预测因子对1997/98年厄尔尼 诺的影响: 热带西太平洋热容量正异常, 印度洋偶极 子负位相,北大西洋冷海温。

## 利用深度学习识别ENSO事件:

模型可视化方法optimal input显示,神经网络准确识别 了ENSO指数的定义区域为赤道中东太平洋。













## 智能气候预测的理念与案例

## 基于机器学习方法的中国降水预测

## 基于中尺度气象同化预报和深度学习的风速预报

## 光伏电站太阳辐射超短期预报

## 基于深度学习的北极地区格点化地表气温重建

## 气象人工智能未来发展思考

## 基于卷积神经网络方法的季节降水预测



动力—统计结合 ٠

对多个动力模式进行后处理

统计降尺度

基于高技巧的环流变量预测降水



\*基于模式高技巧输出的预测







## 基于深度学习方法的中国季节降水预测系统 **SEasonal DEep-learning System**

- 深度学习
- CNN模型自动提取气象场中的预测因子

迁移学习

岭回归迁移学习方法克服小样本问题



25

# SEDES模型应用效果

#### 参加全国汛期预测会商



۲



全国降水距平百分率分布图 🍼

22年06月01日-08月31日





2020年

ACC=0.23 PS=81.2

**Mac** 





2022年

ACC=0.37 PS=74

ACC=0.13 PS=69.5









#### 2022年汛期降水预测误差的诊断复盘





# 基于卷积神经网络方法的次季节降水预测

#### 基本目标

- 对气候中心的区域次季节预测模式CWRF进行降尺度后处理
- 在三个时间尺度(5d、10d、30d)上分别建立环流和降水的关系 •
- 形成侯、旬、月三个时间尺度的预测产品











清著大学地球系统科学系

1D

2D





随机样本对比























#### 空间细节模糊



## 降水异常典型模态的环流配置



#### 以降水的第1和第3模态为例:





#### 降水异常典型模态的环流配置

通过"optimal input"方法求解深度学习模型中有利于 特定降水异常模态的环流配置。

#### 降水异常**典型年**的环流成因

# 通过"Grad-CAM"方法求解典型年同期环流中导致降水异常分布的主要影响信号。

SEDES可以对某特定环流配置下季节降水各 EOF模态对应的PC系数值进行预测。

通过**输入优化 (optimal input)** 方法,寻 找SEDES模型预测冬季降水EOF1和EOF3模 态正位相时的判据,即生成EOF1和EOF3模 态正位相对应的典型环流场,从而讨论该 模型的物理可解释性。



## **降水异常典型模态的环流配置** – 方法介绍



- 输出接近期待值。





## 降水异常典型模态的环流配置 – 以EOF1为例



北方降水偏多对应500hPa位势高度异常场为西北低东南高分布,乌山至贝湖地区为大面积负异常,中高纬冷空气活 跃; 西太副高偏强偏北, 大量水汽在低层沿偏南风向北输送。 该结果表明深度学习模型具有物理可解释性。揭示了不同季节典型降水异常的环流成因。





环流对应降水标准化异常空间分布







## 降水异常典型模态的环流配置 – 以EOF3为例



基于EOF3正位相生成的环流场









冬季南方降水偏多对应的深度 学习输入优化环流与厄尔尼诺 成熟期的环流类似。表明模型 对大范围遥相关的非线性拟合 能力。





## 季节降水的环流影响机制



对于典型降水异常年,通过**类激活图 (Class** Activation Mapping) 方法,标出对模型预测 结果产生显著影响的环流区域,从而找到该 年降水异常的环流成因。



#### 降水异常典型模态的环流配置

#### 通过"optimal input"方法求解深度学习模型中有利于 特定降水异常模态的环流配置。

#### 降水异常典型年的环流成因

通过"Grad-CAM"方法求解典型年同期环流中导致降 水异常分布的主要影响信号。

#### Grad-CAM:

对于模型第c个输出值 $y^c$ , 第k个特征图对应的权重 $w_k^c$ 为:

$$w_k^c = \sum_i \sum_j \alpha_{ij}^{kc} \frac{\partial y^c}{\partial A_{ij}^k}, \ \alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k}$$

其中A为特征图集合, i、j为特征图上的格点坐标, Z为格点总数。 最终输出的激活图L<sup>c</sup>为:

$$\mathbf{L}^{c} = ReLU(\sum_{k} w_{k}^{c} A^{k})$$



## **降水异常典型年的环流成因**-以2013年夏季为例



再分析大气环流标准化异常空间分布





# 深度学习可解释性方法-遮挡敏感性

#### (Zeiler et al., 2014)



boostcamp A

现有应用

衡量不同空间区域的输入贡献, 定位 潜在的预报信号(Shin et al., 2022) 寻找高频降水变率中人类活动的信号 (Ham et al., 2022)





零值遮挡:输入本身的重要性







- 将输入动力模式环流的部分环流区域替换为再分析资 料,计算降水ACC变化,评估优化不同区域环流预测效 果对降水预测技巧的提升,可以**揭示出对降水预测产生** 负面效果的环流预测误差关键区;
- 对历史同期平均而言, SEDES模型预测技巧对近地面热 力条件和低层水汽异常的误差最为敏感。

## 真值遮挡: 输入误差的重要性







.\_\_\_\_35

# 深度学习可解释性方法-输入优化

#### (Olah, 2017)



### 固定模型参数,从 输出反推输入

#### 现有应用

反推极端天气事件的输入环 流配置 (Gagne et al., 2019)

特定分类

0.1 -7.0 -5.0 -3.0 -1.5 -0.5 -0.5 -0.5 -6.0 -40 --20 -20 -40 -1.00 0.75 0.25 0.25 0.25 0.25 0.25 0.00

利用气候模式做为训练集的模型,反 推气候模式对气候变暖模拟的关键偏 差 (Barnes et al., 2020)











根据降水主要模态反推最优输入环流,指示与 特定降水分布对应的典型环流场

给定单一模态输出





## 最优环流

配置?



# 局部误差及其影响-中高纬系统







- 在东北地区, 200hPa纬向风和700hPa纬向风的预测误差 • 对降水预测影响较大。
- 动力模式对急流的波动特征、强度和出口位置预测不准 确,700hPa风场在东北地区的预测与实际相反
- 可能是东北、内蒙东部一带降水预测偏差的主要原因。
- 这种实况配置与最优环流一致






## 1. 机器学习, 特别是深度学习方法在季节-次季节气候预测中有广泛的应用前 景。

- 数据, 提供更准确的全国汛期降水距平百分率分布预报。



2. 当前汛期预报业务主要依赖于数值模式和预报员的主观订正。本研究提供了 针对全国汛期降水距平百分率的深度学习客观预报模型,利用模式环流预报

3. 利用模型的可解释性,可进一步分解深度学习模型的误差来源,为分析同期 环流与汛期降水的非线性关系,及分析数值模式的关键误差提供帮助。





## 智能气候预测的理念与案例

## 基于机器学习方法的中国降水预测

## 光伏电站太阳辐射超短期预报

## 基于深度学习的北极地区格点化地表气温重建

## 气象人工智能未来发展思考

## 风电场风速和风电功率预报现状













## WINDES设计思路







全国或省电网范围内所有风电场风速和风功率预报产品







# 采用的模式运行设置在实际应用中可以满足电网对于时间的需求。

### 预报时间: 2009年6月-2010年5月

### 模拟区域划分依据: 省级电网区域范围

### WRF模式模拟区域和嵌套网格设置



# 基于中尺度气象同化预报和深度学习方法的风速预报系统 (WINDES, WIND speed dEep-learning System)







#### WRF模式的网格以及参数设置

网格	01	02-16
水平分辨率	25 km	5 km
垂直层数	51	51
云微物理方案	Morrison	Morrison
长波辐射方案	RRTMG	RRTMG
短波辐射方案	RRTMG	RRTMG
陆面过程方案	Noah	Noah
积云对流方案	Kain–Fritsch	无
边界层方案	YSU	YSU





## WINDES技术路线

















### 不同省WRF风速预报结果与LSTM、Attention+LSTM、BP神经网络的结果在测试集上 的RMSE对比。

省 (区、市)	预报时间	WRF	ATTN	LSTM	MLP	省 (区、市)	预报时间	WRF	ATTN	LSTM	MLP
	0-24h	<mark>4.60</mark>	<mark>1.94</mark>	2.17	2.71		0-24h	<mark>2.64</mark>	<mark>1.68</mark>	1.88	2.11
北京	24-48h	<mark>4.80</mark>	<mark>2.13</mark>	2.34	2.87	辽宁	24-48h	<mark>2.96</mark>	1.84	2.10	2.29
	48-72h	<mark>4.90</mark>	<mark>2.16</mark>	2.43	3.33		48-72h	<mark>3.20</mark>	2.01	2.27	2.55
	0-24h	<mark>3.08</mark>	<mark>1.68</mark>	1.92	2.77		0-24h	<mark>3.03</mark>	2.07	2.34	2.70
广东	24-48h	<mark>3.31</mark>	<mark>1.84</mark>	2.06	2.85	内蒙古	24-48h	<mark>3.40</mark>	2.30	2.62	2.81
	48-72h	<mark>3.51</mark>	<mark>1.94</mark>	2.13	2.97		48-72h	<mark>3.63</mark>	2.43	2.74	2.91
	0-24h	<mark>3.03</mark>	<mark>1.66</mark>	1.86	2.48		0-24h	<mark>3.30</mark>	1.91	2.18	2.94
海南	24-48h	<mark>3.22</mark>	<mark>1.76</mark>	1.95	2.57	宁夏	24-48h	<mark>3.66</mark>	2.01	2.27	3.14
	48-72h	<mark>3.45</mark>	<mark>1.84</mark>	2.05	2.72		48-72h	<mark>3.85</mark>	2.10	2.39	3.21
	0-24h	<mark>3.37</mark>	<mark>1.72</mark>	1.96	3.04		0-24h	<mark>4.28</mark>	<mark>2.36</mark>	2.60	3.77
河北	24-48h	<mark>3.67</mark>	<mark>1.86</mark>	2.10	3.15	青海	24-48h	<mark>4.48</mark>	<mark>2.43</mark>	2.74	3.94
	48-72h	<mark>3.85</mark>	<mark>2.02</mark>	2.23	3.32		48-72h	<mark>4.58</mark>	<mark>2.46</mark>	2.80	4.04
	0-24h	<mark>2.78</mark>	<mark>1.65</mark>	1.79	2.42		0-24h	<mark>3.47</mark>	1.81	2.07	2.39
河南	24-48h	<mark>3.26</mark>	<mark>1.84</mark>	2.03	2.62	山西	24-48h	<mark>3.94</mark>	1.93	2.20	2.49
	48-72h	<mark>3.39</mark>	<mark>1.91</mark>	2.18	2.83		48-72h	<mark>4.08</mark>	2.03	2.29	2.59
	0-24h	<mark>2.48</mark>	<mark>1.57</mark>	1.78	2.05		0-24h	<mark>2.81</mark>	1.76	1.99	2.34
黑龙江	24-48h	<mark>2.76</mark>	<mark>1.70</mark>	1.92	2.15	陕西	24-48h	<mark>3.22</mark>	<mark>1.92</mark>	2.22	2.43
	48-72h	<mark>2.95</mark>	<mark>1.79</mark>	2.05	2.26		48-72h	<mark>3.41</mark>	1.99	2.30	2.50
	0-24h	<mark>2.70</mark>	<mark>1.53</mark>	1.69	2.05		0-24h	<mark>2.42</mark>	1.33	1.44	1.91
湖北	24-48h	<mark>2.99</mark>	<mark>1.66</mark>	1.91	2.21	上海	24-48h	<mark>2.83</mark>	<mark>1.45</mark>	1.49	1.99
	48-72h	<mark>3.13</mark>	<mark>1.68</mark>	1.87	2.30		48-72h	<mark>3.17</mark>	<mark>1.51</mark>	1.77	2.22
	0-24h	<mark>2.76</mark>	<mark>1.57</mark>	1.78	2.30		0-24h	<mark>4.12</mark>	<mark>1.58</mark>	1.72	3.49
湖南	24-48h	<mark>3.13</mark>	<mark>1.79</mark>	1.90	2.49	四川	24-48h	<mark>4.41</mark>	<u>1.55</u>	1.82	3.59
	48-72h	<mark>3.11</mark>	<mark>1.82</mark>	2.05	2.61		48-72h	<mark>4.51</mark>	<mark>1.66</mark>	1.87	3.67
	0-24h	<mark>2.51</mark>	<mark>1.46</mark>	1.62	1.96		0-24h	<mark>4.12</mark>	<mark>2.70</mark>	3.00	3.46
江苏	24-48h	<mark>3.01</mark>	<mark>1.65</mark>	1.86	2.16	新疆	24-48h	<mark>4.52</mark>	<mark>2.85</mark>	3.15	3.69
	48-72h	<mark>3.27</mark>	<u>1.77</u>	1.97	2.29		48-72h	<mark>4.64</mark>	<mark>2.89</mark>	3.29	3.74
	0-24h	<mark>2.68</mark>	<mark>1.60</mark>	1.77	2.19		0-24h	<mark>4.02</mark>	<mark>1.91</mark>	2.08	3.22
江西	24-48h	<mark>2.99</mark>	<mark>1.74</mark>	1.99	2.40	云南	24-48h	<mark>4.05</mark>	2.00	2.19	3.31
	48-72h	<mark>3.06</mark>	<mark>1.81</mark>	1.99	2.52		48-72h	<mark>4.07</mark>	<mark>2.09</mark>	2.32	3.39





0-24h: 0-24小时预报 24-48h: 24-48小时预报 48-72h: 48-72小时预报

"WRF": WRF预报结果; "ATTN": Attention+LSTM结果; "LSTM": LSTM结果; "MLP": 对照试验结果

三种方法相对于WRF结果都能减小RMSE。

ATTN和LSTM的RMSE减小幅度较大。

ATTN的效果最佳,在不同省的结果中, 相对于WRF原始结果,RMSE减小幅度为 30%-65%







## 面向某省电网的风电场风速预报



WRF模式预报流程(丢掉16小时)





# 某省四个风电场的72小时风速预报均方根误差

	rmse	wrf	24h	48h	72h	reference	n_train	n_test
	1	2.93	<mark>1.81</mark>	1.97	1.88	<u>2.16</u>	27592	8146
凤山	2	3.17	<mark>1.73</mark>	1.83	1.85	<u>2.40</u>	22267	6648
巴 场	3	3.20	<mark>1.73</mark>	2.02	2.20	nan	28591	8570
	4	3.14	<mark>1.59</mark>	1.80	2.13	<u>2.40</u>	14688	4416



风速: m/s







## 智能气候预测的理念与案例

## 基于机器学习方法的中国降水预测

## 基于中尺度气象同化预报和深度学习的风速预报

## 光伏电站太阳辐射超短期预报

## 基于深度学习的北极地区格点化地表气温重建

## 气象人工智能未来发展思考

# 基于深度学习方法的太阳辐射预报系统 (SOLARES, SOLAR irradiance dEep-learning System)

数据预处理











## 太阳辐射短期预报





#### WRF模式模拟区域和嵌套网格设置 地点:新疆五家渠光伏电站

初始场数据:美国GFS全球预报数据

### 预报时间: 2020年1月-2022年12月

采用的模式运行设置在实际应用中可以满足电网对于时间的需求。



#### WRF模式的网格以及参数设置

网格	d01	d02	d03
水平分辨率	27 km	9 km	3 km
垂直层数	41	41	41
云微物理方案	Thompson	Thompson	Thompson
长波辐射方案	RRTMG	RRTMG	RRTMG
短波辐射方案	RRTMG	RRTMG	RRTMG
陆面过程方案	Noah	Noah	Noah
积云对流方案	Grell 3D	Grell 3D	无
边界层方案	Eta TKE scheme	Eta TKE scheme	Eta TKE scheme





## 太阳辐射短期预报

区域输入数据









## 太阳辐射短期预报结果





### 2020-2022 未来24小时预报均方根误差



## 太阳辐射超短期预报

- 致趋势。
- ✓ 但在超短期预报中,这些方法容易忽视爬坡事件以及辐射的短暂波动
- ✓ 准确的现场观测数据包括全天空成像仪图像序列有助于改进超短期预报效果。

2021-07-18 未来一小时预报





## ✓ WRF预报和WRF+人工智能订正的方法擅长未来24小时至未来数天的预报,能预测未来天气的大



数据获取

- 实验地点:新疆五家渠
- 44° 24' 23'' N, 87° 39' 22 " Ε
- 全球水平辐照度 (GHI) 观测: 光伏电站内观测站 每10分钟一次
- 天空图像采集 EKO ASI-16 每5分钟一次



## 数据预处理

- 质量控制和异常值过滤
- 图像大小调整与畸变调整
- 数据分割:训练集、验证集、测试集

A. Observation Tower in a Photovoltaic Power Station









B. ASI Installation Near the **Observation Tower** 

C. EKO ASI-16 All Sky Imager







## 关键算法: AARes – ConvLSTM

### 注意力增强下的残差网络 (Attention-augmented ResNet)

•卷积神经网络从天空图像中提取云层空间特征。

•采用ResNet-18作为卷积神经网络结构,因为采用残差计算可以平衡计算效率和 梯度消失问题。

•通过注意力增强卷积网络(AACN)增强ResNet-18,通过关注输入中更重要的 部分, 克服传统卷积神经网络的局限。

## 卷积长短期记忆网络 (ConvLSTM)

- LSTM在保留长期依赖关系和解决传统递归神经网络(RNN)中常见的梯度消 失问题方面有优势,确保了序列图像的高效处理。
- 卷积LSTM是LSTM的演变,将卷积操作纳入LSTM结构中,有效捕获二维图像 数据的时空依赖性。









## 太阳辐射超短期预报

## 模型比较

- 1. Persistence Model
- 3. Stacked CNN (Feng et al. 2022) 4. 3DCNN (Feng et al. 2022)
- 5. 3DResNet (ResNet without LSTM & attention)
- 6. ResNet-ConvLSTM (ResNet-ConvLSTM without attention)
- 7. AARes-ConvLSTM

### 均方根误差





2. Basic ANN

### 预报技巧





## 智能气候预测的理念与案例

## 基于机器学习方法的中国降水预测

## 基于中尺度气象同化预报和深度学习的风速预报

## 光伏电站太阳辐射超短期预报

# 研究目的







## 北极缺测情况以及其所带来的影响

### 北极地区相对于中纬度观测十分有限

数据最少的地方出现在格陵兰岛和北冰洋部分区域

### 已有研究表明:极地缺测对研究全球温度变化存 在明显的影响

重建一套覆盖30°N以北的地表空气温度数据集



序号	资料	起止时间	时间分辨率	陆地气温资料	海表面温度	
1	HadCRUT5	1850-2020	月	CRUTEM5	HadSST4	
2	GISTEMP v4	1880-2020	月	GHCN v4	ERSST v5	L
3	NOAAGlobalTemp- Interim	1850-2020	月	GHCN v4	ERSST v5	
4	Berkeley Earth	1850-2020	月	Berkeley	HadSST4	Roh
5	Kadow et al.	1850-2020	月	CRUTEM5	HadSST4	
6	China-MST	1856-2020	月	CLSAT	ERSSTv5	
7	Cowtan and Way	1850-2020	月	CRUTEM4	HadSST3	С
8	Vaccaro et al.	1850-2020	月	CRUTEM4	HadSST3	

(IPCC AR6, 2021)





- Morice et al. (J. Geophys. Res.: Atmos., 2021)
- enssen et al. (J. Geophys. Res.: Atmos., 2019)
- Vose et al. (Geophys. Res. Lett., 2021)
- nde and Hausfather (Earth Syst. Sci. Data, 2020)
  - Kadow et al. (Nat. Geosci., 2020)
- Sun et al. (Adv. Atmos. Sci., 2021)
- Cowtan and Way (Q. J. R. Meteorol. Soc., 2014)
  - Vaccaro et al. (J. Clim., 2021)

## 在北极地区仍存在不足:

- 以上资料时间分辨率较低(月资料)
- 未使用极地观测或对观测使用不充分







# 北极格点温度资料

## 基于器测观测的北极温度资料

序号	资料	起止时间	时间分辨率	空间分辨率	插值方法	基础资料
1	Martin and Munoz (J. Clim., 1997)	oz 1979-1993 6小时 100km 最优		最优插值	北冰洋沿岸陆地台站观测, 浮标观测,船舶观测,NP	
2	Rigor et al. (J. Clim., 2000)	1979-1997	12小时 100km 最优插值		NCAR陆地观测、浮标观测、 NP、NCEP	
3	Huang et al. (Nat. Clim. Change, 2017)	1900-2014	年平均	5°latx5°lon	DINEOF	NOAATemp、Rigor et al.2000
4	Dodd et al. (2019)	1995-2012	逐日	1km	基于卫星观测	ATSR-2卫星观测、AATSR 卫星观测等
5	Englyst et al. (2021)	2000-2009	逐日	0.25°×0.25°	基于卫星观测	DMIEUSTACE、PROMICE 站点观测、浮标观测、 AASTI卫星数据

## 北极区域再分析资料

资料	起止时间	空间范围	
Mesinger et al. (Bull. Amer. Meteorol. Soc., 2006)	1979-2020	Mainly in North America	
Zhang et al. (J. Clim., 2016)	1979-2009	Arctic marginal ice zone	
Bromwich et al. (Q. J. R. Meteorol. Soc., 2016)	2000-2012	Most of the Arctic	
Dahlgren et al. (Q. J. R. Meteorol. Soc., 2016)	1989-2010	Mainly in Europe	





### 当前北极温度资料仍存在不足:

- 主要覆盖海洋, 而陆地较少
- 覆盖时间短,不能持续稳定更新
- 重建基础资料误差较大或时间分辨率较低
- 重建结果在云覆盖区域为缺测



- 再分析数据非观测资料  $\bullet$
- 卫星数据非直接观测2m温度







# 北极温度重建方法

资料	所用方法	不足		
HadCRUT5	Gaussian process			
GISTEMP v4	Distance Weighted Interpolation			
Cowtan and Way (Q. J. R. Meteorol. Soc., 2014)	Kriging	假设高纬地区的温度变化与中温度变化一致		
Berkeley Earth	Kinging			
Martin and Munoz (J. Clim., 1997)	optimal interpolation			
Rigor et al. (J. Clim., 2000)	optimal interpolation			
NOAAGlobalTemp-Interim	Empirical Orthogonal	重建高时间分辨率温度如日资		
China-MST	Teleconnections			
Huang et al. (Nat. Clim. Change, 2017)	DINEOF			
Vaccaro et al. (J. Clim., 2021)	Gaussian Markov random fields	在极地地区独立观测		
Kadow et al. (Nat. Geosci., 2020)	Deep Learning			
Huang et al. (Nat. Clim. Change, 2017) Vaccaro et al. (J. Clim., 2021) Kadow et al. (Nat. Geosci., 2020)	DINEOF Gaussian Markov random fields Deep Learning	在极地地区缺乏观测		











# 北极观测数据





#### 1.GHCN (Global Historical Climatology Network)-Daily (1979-2021)

- ・ NOAA全球陆地站点数据集
- 最早的温度记录在1833年比利时,数据随时间更新
- ・经过质量控制和订正
- 2. Russian North Pole drift stations (1979-1991 & 2003-2012)
- ・ 来自AARI (Arctic and Antarctic Research Institute) 的冰上的站点数据
- · 从1937年开始, 一直到1991年结束; 2003年后仍有数据。
- 较为准确的观测数据
- 3. Buoy data (1979-2021)
- 由IABP (International Arctic Buoy Programme)进行数据汇集
- ・ 浮标首次部署于1979年,但温度主要为了校准气压计
- 既有地表温度观测,也有2m温度观测 (2011后)
- 4. ICOADS R3.0 (1979-2021)
- ·提供1662年至今海洋观测数据
- ・包括<mark>气温</mark>、海表面温度、海表面气压等
- 观测数据经过质量控制,随时间更新





# 深度学习模型及重建流程





Liu et al. (Comput Vis ECCV, 2018)

$$\mathbf{x}' = \begin{cases} \mathbf{W}^{\mathrm{T}}(\mathbf{X} \odot \mathbf{M}) \frac{\mathrm{sum}(1)}{\mathrm{sum}(\mathbf{M})} + \mathbf{b}, & \text{if sum}(\mathbf{M}) > 0\\ 0, & \text{otherwise} \end{cases}$$

$$m' = \begin{cases} 1, & \text{if sum}(M) > 0 \\ 0, & \text{otherwise} \end{cases}$$





Graham et al. (Geophys. Res. Lett., 2019) 对比了ERA5、 ERA-Interim、JRA-55、 CFSv2、 MERRA-2再分析数 据在北极地区的表现。

结果表明: ERA5、ERA-I效 果最好。

Jakobson et al. (Geophys. Res. Lett., 2012) 对比了ERA-Interim、 JCDAS, NCEP-CFSR, NCEP-DOE, NASA-MERRA 再分析数据在北极地区的表 现。

结果表明: ERA-I效果最好。



北极探空观测数据







Lindsay et al. (J. Clim., 2014)对比了NCEP-R1、NCEP-R2、CFSR、 20CR, MERRA, ERA-Interim、JRA-25再分析数据 在北极地区的表现。



Wang et al. (Cryosphere, 2019)对比了 ERA-Interim、ERA-5再分析 数据在北极地区的表现。

结果表明, 在较冷时期, ERA-I效果较好,而在较暖时 期ERA5效果更好。





CRU陆地站点观测





# 数据集划分及模型训练

Module Name	Filter Size	Channels	Stride	Padding	Nonlineari ty
PConv1	7×7	18	2	3	ReLU
PConv2	$5 \times 5$	36	2	2	ReLU
PConv3	5×5	72	2	2	ReLU
UpSample1	-	72	-	-	-
Concat1	-	72+36	-	-	-
PConv4	3×3	36	1	1	LeakyReL U
UpSample2	-	36	-	-	-
Concat2	-	36+18	-	-	-
PConv5	3×3	18	1	1	LeakyReL U
UpSample3	-	18	-	-	-
Concat3	-	18+3	-	-	-
PConv6	3×3	3	1	1	LeakyReL U





- batch size : 50; iterations : 6000
- 损失函数: MSE •
- 为了增加泛化能力,温度场和二进制掩码随机匹 • 配
- 为了防止模型过拟合,每100次迭代保存模型参 ۲ 数并基于训练集和验证集计算误差,当模型在训 练集上的误差不再下降或是在训练集上误差下降 但在验证集上误差上升则停止

两套再分析数据(ERA5、ERA-Interim) 1979-2005年 (训练集) 用于模型训练, 2006-2012年 (<u>验证集</u>)用于调试模型参数以及初步评估模型 的表现,2012年之后(<u>测试集</u>)的数据用于结果 验证。

将所有数据放入等面积网格,利用ERA5再分析数 据对所有数据进行标准化。





# 方法验证







### 与陆地观测数据对比

Datasets	Red	con	ER	A-5	ERA-	Interim	
Observation	r	RMSE	r	RMSE	r	RMSE	
Land-1 (id RSM00020891, 2011-01~2018-12)	<u>0.996</u>	<u>1.55</u>	0.994	1.79	0.994	1.88	
Land-2 (id CA002100402, 2011-01~2018-12)	0.981	3.91	<u>0.986</u>	3.90	0.983	<u>3.68</u>	
Land-3 (id USR0000ASNI, 2011-01~2018-12)	<u>0.962</u>	<u>2.66</u>	0.946	3.44	0.935	3.50	<ul> <li>2011-2018年,重建结果与6个预留的观测站的相关系数分别 0.996、0.981、0.962、0.985、0.995和0.973,重建效果与函 析数据相当。</li> </ul>
Land-4 (id USW00027401, 2011-01~2018-12)	0.985	<u>2.10</u>	0.985	2.43	<u>0.986</u>	<u>2.10</u>	• 均很接近观测的原因可能是再分析数据已经同化地面观测。
Land-5 (id RSM00023975, 2011-01~2018-12)	0.995	1.58	<u>0.997</u>	<u>1.35</u>	0.996	1.49	
Land-6 (id NOE00134886, 2011-01~2018-12)	0.973	1.68	0.969	1.73	<u>0.990</u>	<u>0.894</u>	









### 与海洋观测数据对比

Datasets	Ree	con	ER	ERA-I	
Observation	r RMSE		r	RMSE	r
NP-32 (2003-06~2004-03)	<u>0.994</u>	<u>2.51</u>	0.985	5.80	0.989
NP-33 (2004-09~2005-08)	<u>0.986</u>	<u>2.46</u>	0.977	5.03	0.979
NP-34 (2005-09~2006-05)	<u>0.986</u>	<u>2.39</u>	0.963	3.83	0.959









### <u>1979-2021北极年平均温度变化趋势</u>





#### 研究组 search Group



### 1979-2021北极年平均温度变化趋势的空间分布





- 1979-2021年期间,四个数据集几乎在整个北极 (≥60°N) 都明 显变暖。
- 重建结果、ERA5和Berkeley Earth的结果均显示北极变暖最强地 区出现在巴伦支海-喀拉海附近,而NASA GISTEMP虽然有相似 的变暖特征,但变暖强度大大减弱
- 重建结果在北冰洋中部到东西伯利亚海附近显示出较强的变暖趋 势,但其他三套全球温度产品在该地区没有显著变暖



71

### 不同时间段北极温升速率的对比

<u> </u>			1									
时间尺度时间段	年	春季	夏季	秋季	冬季		•	北极正处于加速变暖中,其年平均温度变化速率从0.402℃/1 增加到0.792℃/10a,近20年北极的变暖速率是1979-2000年				
1979-2000	0.402±0.011	0.784±0.017	0.307±0.009	0.422±0.016	-0.044±0.017		·	<u>1.9/</u> 倍 北极季节平均温度变化除夏季外,其变暖强度均有大幅度提升				
2001-2021	0.792±0.011	1.061±0.018	0.211±0.007	0.93±0.013	1.019±0.017			其中最明显的为冬季,从早期的略微变冷(-0.044±0.017 ℃/10a)转为较强的变暖(1.019±0.017 ℃/10a)				

单位: °C/10a









# 北极放大效应的估计

#### 对于北极放大效应的估计, 重建结果高于其他全球温度数据 (3.78±0.14)

		Linear trends		Ratios of the A	Arctic to NH	Ratios of the Arctic to GL (AA)	
	Arctic	NH	GL	Original	Recon	Original	Recon
Recon	0.715±0.011						
Berkeley Earth	$0.689{\pm}0.01$	$0.285 \pm 0.003$	0.190±0.002	2.42	2.51	3.52	3.65
GISTEMP	0.626±0.01	0.281±0.003	0.190±0.002	2.23	2.54	3.26	3.72
HadCRUT5	0.637±0.01	0.282±0.003	0.190±0.002	2.26	2.54	3.28	3.69
NOAA-Interim	0.628±0.011	0.278±0.003	0.180±0.002	2.26	2.57	3.41	3.89
CMST2.0	0.662±0.01	0.282±0.003	0.180±0.002	2.34	2.54	3.68	3.97
EM	0.649±0.01	0.281±0.003	0.189±0.002	2.30±0.08	2.54±0.02	3.43±0.17	<u>3.78±0.14</u>

NH:北半球;GL:全球;









## 智能气候预测的理念与案例

## 基于机器学习方法的中国降水预测

## 基于中尺度气象同化预报和深度学习的风速预报

## 光伏电站太阳辐射超短期预报

## 基于深度学习的北极地区格点化地表气温重建

# 人工智能给地球系统科学研究带来新的机遇与挑战



1. 更准的目标识别
 2. 更高的预测能力
 3. 更快的预测效率

# 挑战

- 1. 可解释性
- 2. 物理一致性
- 3. 求解PDE方程
- 4. 有限的样本
- 5. 巨大的计算需求


# 【物理背景的"最后倔强"

✓AI的应用发展很快,目前仍有发展空间,但可能有上限。

✓AI原则上基于经验,基于大数据,就跟依据老寒腿预报天气、跟看云识天气是 一样的,缺乏物理机制,虽然AI比人的智能分析和记忆力、数据量强得多。

✓如果AI计算能力跟物理模型无限接近,估计AI可能就到头了,接近上限。把基 于经验和大数据能做的"吃干用尽",榨干"油水",AI的应用就到头了。

✓在计算技术和AI的强大"攻势"下,我们退守到"物理机制"这一最后的小岛 F,







# 地球系统模式中的模拟难点





- 模式模拟不确定性的 重要来源:
  - 大气中的云和辐射
  - 海洋中的涡
  - 陆地中的碳



# 大气模式中的智能参数化方案

### 智能湿物理过程参数化方案



# 数据驱动的模式替代 FourCastNet by NVIDIA



- 使用40年ERA5数据, 10TB
- 分辨率0.25度 (720×1440 pixels)
- •比IFS模式快45,000倍
- 在Typhoon和Atmospheric River预报上
  表现良好
- 值得重点关注的模型



### **Pangu-Weather**



- 使用43年ERA5数据, hourly, ~30TB
- 分辨率0.25度 (720×1440 pixels)
- AI预报能力首次超过IFS
- 迭代预报误差累计、依赖于NWP、降水预报













Track Forecast for Typhoon Yutu from 2018-10-23 12UTC



30°N 20°N

10°N

# 以物理学为基础的机器学习

### **Principles of physics-informed learning**

#### 究竟如何在机器学习模型嵌入物理约束?



将物理约束融入神经网络中,不仅能减少对训练数据量的需 求,还能大大提高模型的合理性和泛化能力。



# 未来的智能模式





#### 智能模式1.0版本

### 智能模块替代

#### 智能模式2.0版本

### 智能模式替代

#### 智能模式3.0版本

数据驱动和物理驱动混合



## 几点总结与思考

- 人工智能和大数据给地球系统模式发展带 来新的机遇, AI for Earth已经逐步成为研 究热点
- 应用深度学习的一些弊端:
  - 黑盒难于解释
  - 依赖于大量的样本和标定
  - 单个网络单个任务, 泛化能力差



### • 未来方向

- 利用海量的模式数据发现规律,利用在 线迁移学习来补充观测数据的不足
- 运用异常检测来处理不平衡的样本数据
- 运用时空数据聚类和因果网络寻求机理 解释
- 设计物理约束的神经网络

## 清华AI for Earth案例







# 未来工作计划 (十四五规划)

### 实现更高效、更精细化的智能网格预报,生产更准确的全要素预报数据产品



发展通用的地球系统模式AI框架





- 在计算框架OpenArray中加入自动求导计算能力,实现参数训练及自调优
- 实现自定义算子, 支持更多计算方法和网格
- 分布式图计算优化, 打破传统时间步迭代
- <sup>L</sup> 多物理量守恒约束条件和神经网络结构和损失函数的映射关系





### ✓ "AI+气象"的可解释性研究

有较大的探索空间。

### √气象大模型的低成本泛化与迁移研究

大规模气象模型的训练过程需要庞大的计算资源,其业务化应用必须考虑泛化能力和迁移成本,这必然将朝着泛 化能力更强的算子学习领域发展。

### ✓物理-数据融合驱动的建模研究

AI气象模型在长时序的预报中可能输出不符合基本物理约束的结果。在数据驱动的基础上引入物理约束,不仅 可以增强AI模型的可解释性,还有助于提高预报能力。

### ✓ 数值模式和人工智能相互结合和促进

人工智能的快速发展给数值模式的发展提供了新的机会,例如人工智能已经在模式参数化研发、过程理解、参 数估计、模式优化、模式模拟后处理和误差订正、空气质量预测、可预报性研究等方面得到广泛应用。

### ✓更多圈层变量和过程的引入及AI地球系统模式发展

目前,大多数AI模型只建模单个圈层变量(例如仅大气或海洋),引入多圈层相互作用对较长时间尺度的天气 和气候研究至关重要,多圈层的AI模型有望解决当前次季节到季节的预报难题。



#### 现阶段,深度学习模型缺乏足够的数学理论分析,针对可解释性的神经网络架构和相应的数学分析工具仍然具



### 推进气象人工智能发展建议

# 方法的发展,促进对气象领域基础学科的探索;

- ✓ 参与制定和推广人工智能气象应用的技术标准和规范,确保技术的可靠性, 推动相关数据和技术的标准化与规范化;
- ✓ 促进相关科研机构、高校和企业合作,推动产学研一体化发展,推广成功的 应用经验和技术成果,促进科技成果转化;
- ✔ 开展国内外人才培养、合作与交流活动,推动人工智能技术在气象领域的理 论和实践创新,提升从业人员的专业水平和技术能力。

### 中国气象局雄安气象人工智能创新研究院 中国气象学会第29届理事会成立气象人工智能专业委员会



✓ 开展人工智能与气象行业相关的科研项目攻关和课题研究,推动关键技术和







# 办公室: 清华大学蒙民伟科技大楼南楼S-807 固定电话: 010-62788891 手机号码: 13911316530 电子邮箱: yongluo@tsinghua.edu.cn 微信号: JakeYLuo











