清华大学-2024地球系统模式研发与应用国际暑期学校

海洋模式参数的智能估算和 海洋模式偏微分方程的智能求解

董昌明

韩国庆、谢华荣、高晓倩、周书逸、韩磊

南京信息工程大学

海洋科学学院、人工智能海洋研究院

2024年8月28日

南信大积极推动人工智能海洋学的发展



2018年底,国内首家"人工智能海洋学联合研究院"在南信大成立

南信大积极推动人工智能海洋学的发展

国家自然科学基金
海洋科学学科
研究方向与关键词
(试用版 2022)
DIRECTIONS AND KEY WORDS OF MARINE SCIENCE AND RELATED FIELDS OF THE NATIONAL NATURAL SCIENCE FOUNDATION OF CHINA
(Trial Edition 2022)
国家自然科学基金委员会地球科学部专项项目资助

	109		100 March 100	
区块链	洋数据智能同化与预	110		
(77)研究方向: 高	教值预报模式	数值预报	数位m.	
遥感大数据预报	智能預測	延伸期海洋预报产品	统计数量	应急响应
智能预报	人工智能	机器学习	四维海人	灾害风险计证
预测预报	耦合数据同化	数据问化	多尺度回应	突及于11
集合数据回忆	动态外推技术	动态内植技术	循环间体系	重感信息管理和
估值埋花运	海洋过程	1.1.0.1英全 安定预测	预报模式	
参数化化	气象预报	海洋親能建構	时间序列能加	
小文店加	灾害风险评估	内波预报	风暴潮智能来	
素平面变化智能预报	中尺度涡旋轨延顶掠	海洋突发灾害	神冰智能预算	
海洋要素智能预报	海雾智能预报	门控循环单元	行风路径预备	
海洋气象智能预报	智能化迭代顶床	循环神经网络	也积神经网络	
时间卷积网络	长短期记忆中年四日		179]建模	
轻量化	智能化		412 7	
(78)研究方向:人	工智能海洋字	and in Su	IT IN MAR	
and the second	a sea sea da	人工知能	北杨学习 带和神秘中	
深度学习	神经网络	「大二百郎」	10代件控制 4	
循环神经网络	对抗神经网络	平 此 权 受 习	在 里化 预报	
无监督学习	弱监督学习	十血哲子刁	少快念题合	
多源信息融合	数据驱动	3面到300以为1 3二次,105300	起了拼季重的	
特征自学习	物种鉴定	行来监测	小灰盆覆	
沉降模型	海岸带形态	生現建模	物程分布预测	
风场分析	海浪分析	流场分析	神序領資業部	
生态聚类	知识约束	物理约束	智能化提取	
智能化分割	海洋过程预测	海洋环境要素预测	风险评估	
监督分类	智能计算	并行处理	灾害预测按量	10000
数值分析方法	人工智能计算模型	方法库	模型库	
规则库			na a	
(79)研究方向:海	洋信息系统与海洋	数字孪生	11/1	
数字孪生	数据可视化	虚拟海洋	数字海洋	
智慧海洋	数字化场景	可视化表征	虚实文生	
虚拟场景预设	模拟仿真平台	动态仿真技术	模拟推动	
机交互系统	模糊推理系统	专家系统	多标准快来	
育息服务	今西去粉 今儿	十批报办理系统	信息系统	
工 培防测信自乏(4-	土安系双子化	人致始大星水水	数据共享	
T·鬼mi 砌信尼系统	立体监测系统	地埋信息系统	数据汇交	1000
A DO CHAR	A sets that all a	洲行 杜子 杂华 开助		
数据服务	奴 据安全	纵拍目生	冲撞支持服	A DECK DECK

南信大积极推动人工智能海洋学的发展

人工智能海洋学

一基础与应用

董昌明 主编 韩莹 徐广珺 张琪 谢文鸿 周书逸 副主编

中国海洋学会

中海学字〔2022〕26号

关于同意成立中国海洋学会人工智能海洋学 专业委员会的批复

南京信息工程大学:

根据民政部、中国科协相关规定,遵照《中国海洋学会章程》, 经中国海洋学会第九届第二次常务理事会研究审议,拟同意成立 中国海洋学会人工智能海洋学专业委员会,同意南京信息工程大 学作为该专业委员会的挂靠支撑单位。后续将提交学会理事会审 核确认。

请贵单位依照《中国海洋学会分支机构成立与换届选举程序》 召开成立大会。并在召开成立大会前 1 个月以书面形式请示报 告。确保专业委员会成立工作规范、平稳、有序进行。



一、海洋模式参数的智能估算

二、海洋模式偏微分方程的智能求解

一、海洋模式参数的智能估算

1.1 湍流过程参数化的必要性

1.2 湍流混合参数化的智能估算方法

1.3 外强迫场参数的智能估算方法

1.1 湍流过程参数化的必要性

N-S方程:

$$rac{\partial V}{\partial t} + \left(V ullet
abla
ight) V = f - rac{1}{
ho}
abla p + rac{\mu}{
ho}
abla^2 V$$

直角坐标中,N-S方程的分量形式:







▶目前参数化方案的挑战?

海洋模式参数化方案: 次网格过程



GM 参数化方案 (1990)

一、海洋模式参数的智能估算

- 1.1 湍流过程参数化的必要性
- 1.2 湍流混合参数化的智能估算
 - a) 基于观测数据的智能湍流混合参数估算
 - b) 基于模式数据的智能湍流混合参数估算
 - c) 基于湍流模式的智能湍流混合参数估算
- 1.3 外强迫场参数的智能估算

1.2 湍流混合参数化的智能估算

a 基于观测数据的智能湍流混合参数估算



基于观测数据驱动的海洋垂向混合参数化方案 (Zhu et al., 2022)

1.2 湍流混合参数化的智能估算方法

a 基于观测数据的智能湍流混合参数估算



三种参数化方案估算的混合系数与观测的对比 神经网络(NN)方案与观测的拟合效果最好

1.2 湍流混合参数化的智能估算方法 a 基于观测数据的智能湍流混合参数估算



不管是扩散率还是垂向热 通量,NN方案(红线) 比KPP方案(蓝线)更与 观测(黑线)接近

1.2 湍流混合参数化的智能估算方法 a 观测数据驱动的智能湍流参数化方案



NN方案比KPP方案在数值模式中 (MOM5)模拟效果更好

NN方案可以显著改善气候模式在赤 道海域的海温模拟偏差

(Zhu et al., 2022) **14**

一、海洋模式参数的智能估算

- 1.1 湍流过程参数化的必要性
- 1.2 湍流混合参数化的智能估算方法
 - a) 基于观测数据的智能湍流混合参数估算
 - b) 基于模式数据的智能湍流混合参数估算
 - c)基于湍流模式的智能湍流混合参数估算
- 1.3 外强迫场参数的智能估算方法

1.2 湍流混合参数化的智能估算方法

b. 基于模式数据的智能湍流混合参数估算



- 研究区域是黑潮和亲潮交汇区,存在强的经向温度梯度和明显的海洋 锋以及伴随的海洋涡旋、海洋失稳等动力过程。
- 这些动力现象对海洋的垂向混合具有重要影响。(D'Asaro et al., 2011)

1.2 湍流混合参数化的智能估算方法 b. 基于模式数据的智能湍流混合参数估算 KPP方案

湍流通量:
$$-w'X' = K\left(\frac{\partial \overline{X}}{\partial z} - \gamma\right)$$
 温度的NS控制方程:
垂向扩散系数:
 $K(\sigma) = hw(\sigma)G(\sigma)$ $\frac{\partial T_a}{\partial t} = \underbrace{-\left(u_a\frac{\partial T_a}{\partial x} + v_a\frac{\partial T_a}{\partial y}\right)}_{\text{Horizontal advection}} + \underbrace{\kappa_H\left(\frac{\partial^2 T_a}{\partial x^2} - v_a\right)}_{\text{Horizontal advection}}$

非局地项:

$$\gamma_{s} = C \frac{ws_{0}}{w_{s}(\sigma)h}$$
$$\gamma_{T} = C \frac{\overline{wT_{0}} + \overline{wT_{R}}}{w_{s}(\sigma)h}$$



计算复杂!

17

所需变量:温度、盐度、经纬向流、海表热通量、海表淡水通量等

1.2 湍流混合参数化的智能估算方法 b. 基于模式数据的智能湍流混合参数估算

BPNN



1.2 湍流混合参数化的智能估算方法 b. 基于模式数据的智能湍流混合参数估算



(Han et al., 2022)

1.2 湍流混合参数化的智能估算方法 b. 基于模式数据的智能湍流混合参数估算



a-c: 剖面极值 **d-f:** 剖面最大深度

(a, d) BPNN-exp1(b, e) BPNN-exp2(c, f) BPNN-exp3

BNPP对于K剖面参数的计算是可靠的

1.2 湍流混合参数化的智能估算方法

b. 基于模式数据的智能湍流混合参数估算

● NCEP CFSv2数据集

变量: 海表2m温度、绝对湿度、降雨率、海表10m风速以及长短波通量等; 时间范围: 2020-01-01至2020-01-31日;

●HYCOM数据集

变量: 海表高度、温度、盐度以及流场; 时间范围: 2020-01-01;

● ETOPO数据集 地形文件: ETOPO2:

前16天基于KPP方案生成训练集 分别用BPNN和KPP运行15天 比较2020年1月31日结果

●近岸与区域海洋共同模式(CROCO)

模式配置:水平分辨率为1/12°,垂向分层为64层,垂直S坐标表面拉伸参数为3,底 部拉伸参数为1。模拟时间段从2020年1月1日-31日,时间分辨率为4分钟。设定最大和最 小的截断水深分别为6000m及5m。

1.2 湍流混合参数化的智能估算方法 b.基于模式数据的智能湍流混合参数估算



1.2 湍流混合参数化的智能估算方法 b. 基于模式数据的智能湍流混合参数估算

结果对比



33.8

40°N

36°N

34°N

32°N

38°N

36°N

34°N

32°N

34.2

145°E

33.8

次表层

底层

1459 149°F 151 153°F 34

147°E 149°E 151°E 153°E

34 1

149°E 151°E 153°E

34.3

34.25

34.2

34.1

34.2

34.3

145°E

145°E

34.35

34.3

147°E

34.4

149°E

149°E

147°E

34.4

151°E

34.45

153°E

34.5

151°E

34.6

153°F

34.7

34.8

34 5



34.6

34.7

34.8

-0.1

145°E

-0.1

145°E

-0.04

145°E 149°E 34.5



145°E 147°E 151°E

0

147°E 149°E 151°E 153°E

147°E 149°E 151°E 153°E

0.05

0.05

0.02

0.04

n

-0.05

-0.05

-0.02

1月31日盐度模拟结果

整体分布模态比较一致

最大误差出现在亚北极 锋附近

在海洋表层和次表层, 高温(低温)和高盐 (低盐)误差总是同时 出现的

```
(Han et al., 2024)
                       23
```

1.2 湍流混合参数化的智能估算方法 b.基于模式数据的智能湍流混合参数估算



1月30日海流模拟结果

两种参数化方案都可以 刻画出锋面强流区以及 涡旋场,而速度差异的 高值基本出现在这些海 洋动力过程丰富的海域

● BPNN参数化方案高估 了涡旋边缘的流速,低 估了涡旋中心的流速

(Han et al., 2024) 24

1.2 湍流混合参数化的智能估算方法 b.基于模式数据的智能湍流混合参数估算 动力过程模拟比较

表层海洋的平均动能(m²/s²) 混合层(m)与锋面强度(℃/km)的比较



一、海洋模式参数的智能估算

- 1.1 湍流过程参数化的必要性
- 1.2 湍流混合参数化的智能估算方法
 - a) 基于观测数据的智能湍流混合参数估算
 - b) 基于模式数据的智能湍流混合参数估算
 - c) 基于湍流模式的智能湍流混合参数估算
- 1.3 外强迫场参数的智能估算

1.2 湍流混合参数化的智能估算方法 c. 湍流模式 (LES) 驱动的混合参数化方案—PALM



1.2 湍流混合参数化的智能估算方法 c. 湍流模式(LES)驱动的混合参数化方案—PALM

PALM (Parallized Large Eddy Simulation) :

次网格模型的参数化方案(Deardorff, 1980)

 $\tau_{ki} = -\kappa_{m} \left(\frac{\partial \overline{u_{l}}}{\partial \overline{u_{k}}} + \frac{\partial \overline{u_{k}}}{\partial \overline{u_{k}}} \right)$

次网格 通量

$$\frac{\overline{u_k'\theta'}}{\overline{u_k'\theta'}} = -\kappa_h \frac{\partial \overline{\theta}}{\partial x_k}$$

$$\overline{u_k's'} = -\kappa_s \frac{\partial \overline{s}}{\partial x_k}$$

$$l = \begin{cases} \min_{l=1}^{\min} l = l \\ min \\ l = l \end{cases}$$
治能 e
计算量大

利用Prandtl-Kolmogorov 假设,动量的的次网格涡系数或湍流 扩散系数为:

$$\kappa_{\rm m} = c_m l \sqrt{e}$$

$$l = \begin{cases} \min(\Delta, 0.7d), & \text{unstable stratification } \frac{\partial \overline{\Theta}}{\partial z} \leq 0 \\ \min\left(\Delta, 0.7d, 0.76\sqrt{e} \left[\frac{g}{\Theta_0} \frac{\partial \overline{\Theta}}{\partial z}\right]^{-\frac{1}{2}}\right), \text{stable stratification } \frac{\partial \overline{\Theta}}{\partial z} > 0 \end{cases}$$

湍动能 e (SGS-TKE) 可通过预报方程计算得到: $\partial e \quad \partial \bar{u}_k e = \partial \bar{u}_i + g = \partial \bar{u}_i - \partial \left[\frac{\partial \bar{u}_i}{\partial \bar{u}_i} - \partial \bar{u}_i + \partial \bar{u}_i + \frac{\partial \bar{u}_i}{\partial \bar{u}_i} - \partial \bar{u}_i + \partial \bar{u$

$$\frac{\partial e}{\partial t} = -\frac{\partial u_k e}{\partial x_k} - \tau_{ki} \frac{\partial u_i}{\partial x_k} + \frac{g}{\theta_0} \overline{u_3' \theta'} - \frac{\partial}{\partial x_k} \left[u_k' \left(e + \frac{p}{\rho_0} \right) \right] - \epsilon$$

28

1.2 湍流混合参数化的智能估算方法 c. 湍流模式 (LES) 驱动的混合参数化方案—PALM



BPNN对LES的混合参数典型剖面可以较好地刻画出趋势 29

一、海洋模式参数的智能估算

- 1.1 湍流过程参数化的必要性
- 1.2 湍流混合参数化的智能估算方法
 - a) 观测数据驱动的智能湍流参数化方案
 - b) 模式驱动的细网格湍流参数化方案
 - c) 湍流模式 (LES) 驱动的混合参数化方案
- 1.3 外强迫场参数的智能估算方法

1.3 外强迫场参数的智能估算方法 ——海气热通量参数



- 观测数据少
- 缺少极端海况下的观测
- 难以快速迭代

Bulk formula $LHF = \rho_a L_v C_E(q_s - q_a)$ $SHF = \rho_a c_P C_H(\theta_s - \theta_a)$

(WHOI)

1.3 外强迫场参数的智能估算方法





一海气热通量参数

 提出了一个基于弱物 理约束的神经网络来 构建海气热通量参数 化方案

• 使用了12个海气热通 量观测数据集

(Zhou et al., 2024)

1.3 外强迫场参数的智能估算方法



(Zhou et al., 2024)

 基于神经网络的参数 化方案要优于传统的 参数化方案

气热通量参数

高风速下基于神经网
 络的热通量值要小于
 传统的参数化方案

1.3 外强迫场参数的智能估算方法

—海气热通量参数



基于神经网络的参数化方案在次季节预报模型中表现良好 34



Dong, C., Xu, G., Han, G., Bethel, B. J., Xie, W., & Zhou, S. (2022). Recent developments in artificial intelligence in oceanography. Ocean-Land-Atmosphere Research.

Han, G., Cen, H., Jiang, J., Gao, X., Jiang, X., Zhou, S., ... & Dong, C. (2022). Applying machine learning in devising a parsimonious ocean mixing parameterization scheme. Deep Sea Research Part II: Topical Studies in Oceanography, 203, 105163.

Gao, X., Han, G., Sun, W., Zhou, S., Xie, W., Cen, H., ... & Dong, C. (2024). Application of deep learning in estimating the convective mixing induced by brine rejection. Ocean Modelling, 102314.

Feng, Q., Han, G., Liu, Y., Lin, X., Li, B., Gao, X., ... & Wang, H. (2024). Application of data-driven mixing parameterization scheme in a regional ocean model. Ocean Modelling, 102325.

Gao, X., Dong, C., Liang, J., Yang, J., Li, G., Wang, D., & McWilliams, J. C. (2019). Convective instability-induced mixing and its parameterization using large eddy simulation. Ocean Modelling, 137, 40-51.

Gao, X., Dong, C., & Liang, J. (2022). Convective mixing induced by brine rejection and its parameterization using large eddy simulation. Deep Sea Research Part II: Topical Studies in Oceanography, 205, 105179.

Liang, J.-H., J. Yuan, X. Wan, J. Liu, B. Liu, H. Jang, and M. Tyagi. (2022). Exploring the use of machine learning to parameterize vertical mixing in the ocean surface boundary layer. Ocean Modelling, 176, 102059.

Zhou S., Shi R., Yu H., Zhang X., Dai J., Huang X., and Xu F., (2024). A Physical-informed Neural Network for Improving Air-Sea Turbulent Heat Flux Parameterization. Journal of Geophysical Research-Atmospheres.

Zhu, Y., Zhang, R.H., Moum, J.N., et al. (2022). Physics-informed deep learning parameterization of ocean vertical mixing improves climate simulations. Natl. Sci. Rev. 9, nwac044.

一、海洋模式参数的智能估算

二、海洋模式偏微分方程的智能求解

二、海洋模式偏微分方程的智能求解

- 1、绪论
- 2、PINN求解海水温度扩散方程
- 3、PINN求解KdV方程
- 4、PINN在风暴潮智能预报的应用



偏微分方程(Partial Differential Equation , PDE)是在数学上通过 多个未知变量及其偏导数来描述系统的行为。

PDE被频繁应用于多个学科中,以模拟物理过程的时空演变。 例如,使用 Navier-Stokes 方程模拟机翼周围的气流,使用<mark>浅水方</mark> 程模拟全球天气模式,使用 Maxwell 方程进行光学设计等。

在许多实际应用中,可能<mark>难以获得 PDE 解析解</mark>的函数形式, 因此,必须数值求解 PDE。

1、绪论 Physical-Informed Neural Network (PINN)



通过把物理方 程的迭代前后 的差值加到神 经网络的损失 函数, 使训练 的结果满足物 理规律。

(Raissi et al., 2019)

1、绪论 Physical-Informed Neural Network (PINN)



(Raissi et al., 2020)

二、智能求解偏分方程

1、绪论

2、PINN求解海水温度扩散方程

3、PINN求解KdV方程

4、PINN在风暴潮智能预报的应用





正问题: 方程完全已知, 求解方程在确定边界和初始条件下的解 反问题: 方程参数未知, 求解方程参数和方程在确定边界和初始条件下的解 42

Dirichlet边界条件

<u>ງ</u>2 ຫ

(am

若已知k_z=0.05,初始条件为:

$$\begin{cases} \frac{\partial T}{\partial t} = k_z \frac{\partial^2 T}{\partial z^2} & 0 < z < L, t > 0 \\ T(z, 0) = f(z) & 0 \le z \le L \\ T(0, t) = 0, T(L, t) = 0 & t > 0 \end{cases} f(z) = \sin \frac{\pi z}{2} + \sin \pi z$$

则原方程的一般解为:

此初始条件对应于一般解的傅里叶正弦级数 的前两项,则原方程的一般解为:

$$T(z,t) = \sum_{n=1}^{\infty} C_n e^{-k_z \left(\frac{n\pi}{L}\right)^2 t} \sin \frac{n\pi z}{L}$$

$$T(z,t) = e^{-0.05\frac{\pi^2}{4}t} \sin\frac{\pi z}{2} + e^{-0.05\pi^2 t} \sin\pi z$$

Neumann边界条件

 $\left(a T a 2 T \right)$

若已知k_z=0.05,初始条件为:

$$\begin{cases} \frac{\partial T}{\partial t} = k_z \frac{\partial T}{\partial z^2} & 0 < z < L, t > 0 \\ T(z, 0) = f(z) & 0 \le z \le L \\ T_z(0, t) = 0, T_z(L, t) = 0 & t > 0 \end{cases} f(z) = \cos \frac{\pi z}{2} + \cos \pi z$$

则原方程的一般解为:

此初始条件对应于一般解的傅里叶余弦级数的前三项,则原方程的一般解为:

$$T(z,t) = D_0 + \sum_{n=1}^{\infty} D_n e^{-k_z \left(\frac{n\pi}{L}\right)^2 t} \cos \frac{n\pi z}{L} \qquad T(z,t) = e^{-0.05 \frac{\pi^2}{4} t} \cos \frac{\pi z}{2} + e^{-0.05 \pi^2 t} \cos \pi z$$

44

45

2、PINN求解海水温度扩散方程

Robin边界条件

 $\begin{cases} \frac{\partial T}{\partial t} = k_z \frac{\partial^2 T}{\partial z^2} & 0 < z < L \\ T(z,0) = f(z) & 0 \le z \le L \\ T(0,t) + hT_z(0,t) = 0 & t > 0 \\ T(L,t) + hT_z(L,t) = 0 & h > 0 \end{cases}$

L,t > 0

$$E(z) = e^{-z} + \frac{\pi}{2} \cos \frac{\pi z}{2} - \sin \frac{\pi z}{2} + \pi \cos \pi z - \sin \pi z$$

此初始条件对应于一般解的傅里叶级 数的前三项,则原方程的一般解为:

则原方程的一般解为:

$$T(z,t) = E_0 e^{k_z t} e^{-z} + \sum_{n=1}^{\infty} E_n e^{-k_z \left(\frac{n\pi}{L}\right)^2 t} \left(\frac{n\pi}{L} \cos\frac{n\pi z}{L} - \sin\frac{n\pi z}{L}\right)$$

$$T(z,t) = e^{0.05t-z} + e^{-0.05\frac{\pi^2}{4}t} \left(\frac{\pi}{2}\cos\frac{\pi z}{2} - \sin\frac{\pi z}{2}\right) + e^{-0.05\pi^2t} (\pi\cos\pi z - \sin\pi z)$$

PINN求解海水温度扩散方程 2、

4.0

3.0

2.0

1.0 -

0-

2.0

1.0

0

-1.0

−2.0[↓]____

0.5

1.0 1.5 2.0

7

t

正问题



Neumann边界条件



Bias

 1.5×10^{-4}

Robin边界条件



Dirichlet边界条件





5.0

4.0

3.0

2.0

1.0

6.0_T

4.0

0

-2.0

-4.0[⊥]₀

(1, 2, 0)

1



Neumann边界条件

损失函数在不同实例下的变化



Loss 函数的大小: Dirichlet 边界<Neumann 边界<Robin 边界 Loss下降的速度: Dirichlet 边界>Neumann 边界>Robin 边界



二、智能求解偏分方程

- 1、绪论
- 2、PINN求解海水温度扩散方程
- 3、PINN求解KdV方程
- 4、PINN在风暴潮智能预报的应用

3、PINN求解KdV方程

KdV方程用来描述在引力作用下浅水在自由表面上波的单向传播, 具有不变形状的脉冲状孤立波解

$$\begin{cases} u_t + 6uu_x + u_{xxx} = 0, x \in [-20, 20], t \in [-6, 6] \\ u(t_0, x) = u_0(x), \\ u(t, -20) = u(t, 20), \end{cases}$$

单孤子解:
$$u(t,x) = \frac{c}{2}\operatorname{sech}^2\left(\frac{\sqrt{c}}{2}(x-x_0-ct)\right)$$

u为高于水平地面的波的高度 t是与过去时间成正比例的变量

x是与传播方向距离成正比例的变量 x₀为孤子的初始位置

3、PINN求解KdV方程



```
def net_f(self, x,t):
    u = self.net_u(x,t)
    u_t = tf.gradients(u, t)[0]
    u_x = tf.gradients(u, x)[0]
    u_xx = tf.gradients(u_x, x)[0]
    u_xxx = tf.gradients(u_xx, x)[0]
    f = u_t + u * u_x + u_xxx-0.5*tf.cos(t)
    # f = u_t + 6*u * u_x + u_xxx-0.1*tf.cos(t)
    return f
```

3、PINN求解KdV方程

首先设 $c = 2, x_0 = 0$





KdV方程的精确解和预测解的对比

(a) Exact Solution (b) Predicted Solution 0.8 0.8 0.6 0.6 ⊃ С 0.4 0.4 0.2 0.2 0.0 0.0 5 5 ⁻²⁰-10 0 ⁻²⁰-10 0 0 t t 0 -5 -5 10 10 20 20 х х

KdV方程的精确解和预测解的时空行为对比

模型在18秒内经过481次迭代将相对L²误差降到了4.6×10⁻²

二、智能求解偏分方程

- 1、绪论
- 2、PINN求解海水温度扩散方程
- 3、PINN求解KdV方程
- 4、PINN在风暴潮智能预报的应用

4、PINN在风暴潮智能预报的应用

使用ADCIRC-SWAN模式风暴潮水位数据搭建模型



4、PINN在风暴潮智能预报的应用

SSNN模型和ADCIRC-SWAN模式结果的比较



4、PINN在风暴潮智能预报的应用

总结:

1、PINN是一种无网格方法,可以在训练阶段后按需 计算解,并且它们允许使用分析梯度使解可微。

2、除了求解微分方程(正问题), PINN还可用于求解 逆问题。事实上,用同样的代码来解决正问题,可以 用最小的修改来解决逆问题。

3、PINN可以在具有非常复杂的几何形状或非常高维的领域中解决偏微分方程。

参考文献

Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. Journal of Computational Physics, 378, 686–707.

Raissi, M., Yazdani, A., & Karniadakis, G. E. (2020). Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations. Science, 367, 6481, 1026–1030.

Li, Z., Kovachki, N., Azizzadenesheli, K., Liu, B., Bhattacharya, K., Stuart, A., & Anandkumar, A. (2021) Fourier neural operator for parametric partial differential equations. In International Conference on Learning Representations.

Pathak, J., Subramanian, S., Harrington, P., Raja, S., Chattopadhyay, A., Mardani, M., Kurth, T., Hall, D., Li, Z., Azizzadenesheli, K., & et al. (2022). Fourcastnet: A global data-driven high-resolution weather model using adaptive fourier neural operators. arXiv preprint arXiv:2202.11214.

Tran, A., Mathews, A., Xie, L., & Cheng, S. (2021). Factorized fourier neural operators. arXiv preprint arXiv:2111.13802.

Pfaff, T., Fortunato, M., Sanchez-Gonzalez, A., & Battaglia, P. (2021). Learning mesh-based simulation with graph networks. In International Conference on Learning Representations.

Lu, L., Jin, P., Pang, G., Zhang, Z., & Karniadakis, G. E. (2021). Learning nonlinear operators via DeepONet based on the universal approximation theorem of operators. Nature machine intelligence, 3, 3, 218-229.

训练的程序和数据

基于湍流模型的海洋模式参数的智能估算 链接: https://pan.baidu.com/s/117gQsDNm1AclYaJPB1FdNg 提取码: yjrg

海水温度扩散方程的智能求解: 链接: https://pan.baidu.com/s/1DYYZheQJB5b8EOogsHctOg 提取码: 8xxr

清华大学-2024地球系统模式研发与应用国际暑期学校

感谢聆听!

董昌明

南京信息工程大学 海洋科学学院、人工智能海洋研究院

南信大正在建成大型海洋物理模拟器 ----世界最大的旋转水池



旋转实验平台(海洋学科楼)透视图



建设参数:

四大组成系统



旋转水池系统组成



四大组成系统

水池主体平台侧壁及水交换系统





三个研究团队

