

控制与决策

Control and Decision

基于残差U型卷积网络的海面风速多步时空预测

谢菡芑, 张华军, 黄双, 曹旭

引用本文:

谢菡, 张华军, 黄双, 曹旭. 基于残差U型卷积网络的海面风速多步时空预测[J]. *控制与决策*, 2023, 38(7): 1845–1853.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0035>

您可能感兴趣的其他文章

Articles you may be interested in

基于TVA-TCN的制造过程关键参数多步预测方法

Multi-step prediction method for key parameters of manufacturing process based on TVA-TCN

控制与决策. 2022, 37(12): 3321–3328 <https://doi.org/10.13195/j.kzyjc.2021.0922>

一种并行LSTM-FCN模型在船舶航迹预测中的应用

Parallel LSTM-FCN model applied to vessel trajectory prediction

控制与决策. 2022, 37(8): 1955–1961 <https://doi.org/10.13195/j.kzyjc.2020.1795>

基于自适应变量加权的汽油辛烷值预测方法

Prediction method of gasoline octane number based on adaptive variable weighting

控制与决策. 2022, 37(10): 2738–2744 <https://doi.org/10.13195/j.kzyjc.2021.0057>

基于时空图卷积循环神经网络的交通流预测

Traffic flow prediction based on STG-CRNN

控制与决策. 2022, 37(3): 645–653 <https://doi.org/10.13195/j.kzyjc.2020.1445>

基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

控制与决策. 2020, 35(12): 2835–2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

基于残差U型卷积网络的海面风速多步时空预测

谢苜苕¹, 张华军^{1†}, 黄双², 曹旭²

(1. 武汉理工大学 自动化学院, 武汉 430070; 2. 武汉第二船舶设计研究所 第五研究室, 武汉 430205)

摘要: 准确的海面风速预测是保证远洋船舶航行安全和节能减排的重要条件. 针对远洋航行领域的海面风速预测存在空间特征难以解析和多步预测精度偏低两个问题, 设计一种改进的多步时空预测方法. 在多步预测方面, 使用超前时刻策略使单个模型学习并区分不同的预测时刻, 并将海面风向作为外生变量, 将月份、日期和时刻作为协变量, 与历史风速数据结合以扩展样本空间. 在空间特征方面, 利用编码器-解码器结构的残差U型卷积神经网络, 对多层级空间信息进行提取和解析, 并将超前时刻特征同时输入编码器和解码器, 强化深层特征解析为对应预测时刻的效果. 在全球原油运输路线上进行的12小时预测实验表明, 所提出方法较其他6种预测方法具有更低的预测误差.

关键词: 深度学习; 时空预测; 多步预测; 风速; 卷积神经网络; 外生变量

中图分类号: TP399

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0035

引用格式: 谢苜苕, 张华军, 黄双, 等. 基于残差U型卷积网络的海面风速多步时空预测[J]. 控制与决策, 2023, 38(7): 1845-1853.

Multi-step sea surface wind speed spatio-temporal prediction based on residual Unet

XIE Ju-peng¹, ZHANG Hua-jun^{1†}, HUANG Shuang², CAO Xu²

(1. College of Automation, Wuhan University of Technology, Wuhan 430070, China; 2. Fifth Research Laboratory, Wuhan Second Institute of Ship Design, Wuhan 430205, China)

Abstract: Accurate sea surface wind speed prediction is an important condition to ensure the navigation safety and energy conservation of ocean ships. In terms of the two problems of difficult spatial feature decoding and low multi-step prediction accuracy of sea surface wind speed prediction in the field of ocean navigation, we design an improved multi-step spatio-temporal prediction method. For the problem of multi-step prediction, we use the lead time strategy to achieve that an individual model learns and distinguishes the data at multiple prediction time. We take the sea surface wind direction as an exogenous variable, take the month, date and time as covariant variables, and combine them with the historical wind speed data to expand sample space. For the problem of spatial features, the residual U-shaped convolutional network with encoder-decoder structure is used to extract and decode the multi-level spatial information, and the lead time features are input into the encoder and decoder at the same time, which strengthens the effect of decoding the deep features into the corresponding prediction time. The 12-hour prediction experiments on global major oil transportation routes show that the proposed method has lower prediction error than the other six prediction methods.

Keywords: deep learning; spatio-temporal prediction; multi-step prediction; wind speed; convolutional neural network; exogenous variables

0 引言

海面风速预测是远洋船舶气象水文保障的重要组成部分. 对于海上运输而言, 风速将影响航行速度和燃油消耗, 从而影响航运的安全性与经济性^[1]. 此外, 合理利用风速信息还可以减少船舶的碳排放.

研究表明, 各种风力技术带来的船舶减排潜力达 10%~60%^[2]. 因此, 实现高精度风速预测, 既是提高远洋船舶气象水文保障能力的前提, 又是实现船舶节能减排的关键.

海面风速预测为船舶气象水文保障提供服务, 与

收稿日期: 2022-01-05; 录用日期: 2022-02-25.

基金项目: 工信部高技术船舶专项课题项目(工信部装函(2019)331号).

责任编辑: 侯忠生.

[†]通讯作者. E-mail: zhanghj@whut.edu.cn.

陆上风电场的风速预测有较大区别. 第一, 船舶到达目标海域需要一定时间, 需提供数小时内的多步风速预测数据, 属于短期预测^[3]; 第二, 船舶在海上保持航行, 需求的风速预测数据是整片海域范围内的时空序列数据, 而非单个地点的时间序列数据. 因此, 海面风速预测问题是一种多步时空预测问题.

风的高度波动使时空预测难度较大, 目前深度学习为时空预测提供了多种方法, 但仍存在一些问题. 首先, 许多风速预测研究进行的是单步时空预测, 这些方法需要单独对不同预测时刻的数据建模以实现多步预测. 由于临近的预测时刻与历史时段的风速具有很高的时间相关性, 这种多步预测策略可以在临近时刻预测中取得非常好的效果^[4]. 但随着预测步长的增大, 两个时段中数据的时间相关性减小, 使用该策略的模型并不能继续保持高精度预测. 而考虑到船舶航行时间, 相对于临近时刻的预测, 海面风速预测更加重视靠后时刻的预测精度. 文献[5-6]提出降水和分量风速的单步时空预测模型. 文献[7]对一段历史时刻与后续某一预测时刻的数据关系单独建模, 得到5步时空预测结果, 但这种方法在较近预测时刻具有很好的效果, 却不适合预测较长时刻^[4].

另外, 当前许多时空预测研究采用的模型难以实现高精度的像素级预测. 文献[8]使用编码器-解码器结构的LSTM, 将时空预测处理为序列到序列的预测, 降低了数据的空间相关性^[4,9]. 文献[10]使用自动编码器得到风速数据表示, 采用LSTM完成时空预测. 文献[11-12]使用CNN预测风速. 文献[7]进一步提出PSTN(predicted spatio-temporal network), 先后学习空间和时间相关性. 文献[13]采用CNN和LSTM预测分散地点的风速. 时空预测同时输出多地点风速值, 是一种像素级别预测任务^[14]. 深层神经网络是将提取的深层特征信息映射为输出值的过程^[15], 许多方法用简单的卷积或全连接层执行此映射, 由于时空预测输出数据量较大, 难以解析深层特征. 对于像素级预测, 不能从全局图像表示中直接预测, 而同样应当通过深层网络对特征解码^[14]. 如文献[16]使用两个UNet组合为多任务模型, 具有深层编码器-解码器结构, 适合重建预测图像^[17]. 文献[18]提出适用于像素级问题的残差U型卷积网络(ResUNet), 能够从一组图像中提取空间特征并解析映射为相同分辨率图像, 符合风速时空预测问题的数据形式, 且相对CNN和UNet具有更好处理空间数据的能力.

本文提出一个基于ResUNet并使用超前时刻多步预测策略的海面风速多步时刻预测模型. 该模型

依赖ResUNet的U型编码器-解码器架构, 构建高分辨率输入矩阵与同分辨率输出矩阵的映射, 从而得到精确的多地点预测结果. 模型使用超前时刻多步预测策略处理数据集, 并改进该策略的输入方式, 使单个模型学习到历史时段数据与多个不同预测时刻数据的关联. 此外, 该模型在输入数据中加入日期和风向外生变量, 在网络中使用Leaky ReLU激活函数进一步提高预测精度. 利用全球主要原油运输路线的数据进行12小时预测实验, 结果表明该模型相对PSTN等时空预测模型, 均方根误差在各预测时刻上的均值下降15.7%, 平均绝对百分误差的均值下降17.0%, 且在较远预测时刻上同样具有良好的效果.

1 风速多步时空预测问题

船舶远洋航行时需求多个地点在较长时段上的风速信息. 传统的单地点风速预测难以满足大范围的信息需求, 因此将多地点的风速多步预测问题定义为一种时空多步预测问题.

$M \times N$ 矩形网格表示预测区域, 其中每个海域地点的坐标为 (i, j) . 在第 t 时刻, $x_t(i, j)$ 表示 (i, j) 地点的变量观测值, $\mathbf{x}_t \in \mathbf{R}^{M \times N}$ 表示该预测区域的观测值, 有

$$\mathbf{x}_t = \begin{bmatrix} x_t(1, 1) & \dots & x_t(1, N) \\ \vdots & \ddots & \vdots \\ x_t(M, 1) & \dots & x_t(M, N) \end{bmatrix}. \quad (1)$$

$\mathbf{X}_{1:k} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k\} \in \mathbf{R}^{k \times M \times N}$ 表示 k 个时刻的变量矩阵按照时间顺序组成的时空序列. 在单变量的多步时刻预测问题中, 使用过去 k 个时刻的已知变量矩阵预测未来 τ 个时刻的变量矩阵, 有

$$\hat{\mathbf{X}}_{(t+1):(t+\tau)} = f(\mathbf{X}_{(t-k+1):t} | \boldsymbol{\theta}). \quad (2)$$

其中: f 为预测模型的函数, $\boldsymbol{\theta}$ 为模型参数组成的矩阵.

在实际的预测任务中, 外生变量和静态信息的引入会为目标变量的预测提供有效信息. 记目标变量为 o , 单个外生变量为 e , 最后一个已知时刻的单个静态协变量为 c , 则多步时空序列预测公式为

$$\hat{\mathbf{X}}_{(t+1):(t+\tau)}^{(o)} = f(\mathbf{X}_{(t-k+1):t}^{(o)}, \mathbf{X}_{(t-k+1):t}^{(e)}, \mathbf{X}_t^{(\text{date})} | \boldsymbol{\theta}). \quad (3)$$

2 基于ResUNet的风速多步预测模型

基于ResUNet的多步预测模型包含3个部分: 提取时空序列数据、根据超前时刻多步预测策略生成数据集和通过ResUNet对数据集建模.

2.1 提取时空序列数据

部分传统的风速预测模型仅对历史风速观测值与未来预测值的关联进行建模. 在实际的预测任务中, 除待预测变量自身的历史观测值外, 外生变量和静态协变量有助于预测效果的提升^[18-19].

在远洋船舶气象水文保障系统中, 各类气象数据以时间序列表格形式存储在关系型数据库中. 以海面风速变量为例, 在数据库中选择 $M \times N$ 个地点在单个时刻的风速值, 组合为风速变量矩阵 $\mathbf{X}_t^{(s)}$. 将 k 个时刻的风速变量矩阵组合为该片矩形海域的风速时空序列 $\mathbf{X}_{(t-k+1):t}^{(s)}$. 同理可得该海域在该时段的风向时空序列 $\mathbf{X}_{(t-k+1):t}^{(d)}$, 作为风速预测的外生变量.

静态协变量的作用是扩展原数据样本空间, 辅助模型学习数据特征. 模型使用月、日和小时3个协变量, 假设两个样本具有近似的历史风速, 且由于所处时间段或季节不同, 其未来风速的差异较大, 那么模型的预测将介于两者之间, 导致两者都得不到准确的预测. 日期变量的引入扩大了样本空间, 让样本产生合理的差异, 使模型更好地区分和学习这些样本. 使用3个矩阵分别代表样本最后一个已知时刻的月、日和小时, 每个矩阵中的元素相同. 各样本的输入部分中, 风速和风向数据都是大小为 (M, N, k) 的三维矩阵, 日期数据是大小为 $(M, N, 3)$ 的三维矩阵, 在最后一个维度上进行连接.

2.2 超前时刻多步预测策略

多步预测问题中输入数据可以分为4类: 目标变量的历史观测值、外生变量的历史观测值、静态协变量和其他已知信息^[19]. 在多步时空预测中, 通过输入与观测值无关的已知未来信息, 可以让模型区分不同的预测时刻, 选择性输出特定预测时刻的结果, 从而实现高性能的多步预测.

为实现不同预测时刻的区分, 模型额外输入代表预测时刻的特征, 即超前时刻^[18]. 超前时刻特征采用 one-hot 编码, 记录所期望的预测时刻距最后一个观测时刻的时间差. 使用同一个模型训练具有不同预测时刻的样本. 超前时刻特征的引入, 使模型既从所有预测时刻的样本中捕获特征, 又能清晰地区分不同预测时刻的样本, 在较长步长上实现了精确预测. 通过输入超前时刻特征, 可以超前模型输出特定预测时刻的结果. 使用超前时刻策略的风速多步预测公式为

$$\mathbf{X}_{(t+1):(t+\tau)}^{(o)} = f(\mathbf{X}_{(t-k+1):t}^{(o)}, \mathbf{X}_{(t-k+1):t}^{(e)}, \mathbf{X}_t^{(\text{date})}, \mathbf{L}|\theta). \quad (4)$$

其中: date 为日期特征; $\mathbf{L} = \{\mathbf{l}_1, \dots, \mathbf{l}_c, \dots, \mathbf{l}_\tau\} \in \mathbf{R}^{\tau \times M \times N}$ 为超前时刻特征矩阵, $c \in [1, \tau]$ 为待预测时刻, \mathbf{l}_c 是元素均为1的 $M \times N$ 矩阵, 其他为零矩阵.

对于 τ 步时空预测, 由于超前时刻特征的加入, 需要 τ 个样本完成一次完整的预测, 得到 $\hat{\mathbf{X}}_{(t+1):(t+\tau)}^{(s)}$. 一组 τ 步预测样本的历史时空序列数据与日期特征相同, 超前时刻不同. 通过输入一组样本的历史数据, 可以实现同时预测 τ 个时刻. 相对传统多步预测策略, 超前时刻策略建立单个预测模型, 且不同预测时刻的数据能被模型更好地区分.

2.3 ResUNet 模型

ResUNet 是基于 UNet 改进而来的一种图像模型, 由编码器、解码器和连接桥3部分组成, 三者均为深层卷积神经网络. 编码器实现对输入图像下采样, 将图像数据转为具有低分辨率和高维度的深度特征图. 解码器通过反复上采样增大深度特征图的分辨率, 得到原始分辨率大小的输出图像. 连接桥负责连接两者.

编码器在不同深度上输出的特征图携带不同尺度的图像信息, 这些多尺度信息的融合有助于提升整体预测效果^[17]. ResUNet 采用 U 型网络结构, 复制编码器不同深度上的特征图, 与解码器对应深度的特征图进行通道连接, 从而实现多尺度信息的融合. 同时, 这种融合使全局特征为局部特征提供了定位作用, 使局部特征更好地映射到最终输出图像的对应位置^[17].

ResUNet 的编码器和解码器均由如图1所示的残差模块 (ResBlock) 堆叠而成. 其中第1个2D卷积层的步长为 $n = 1$ 或 $n = 2$, 记作 ResUNet(n). 当 $n = 2$ 时 ResBlock 将输入图像分辨率减小一倍, $n = 1$ 时维持不变. ResUNet 的编码器和连接桥均使用 ResUNet(2) 进行下采样, 且每层 ResBlock(2) 的卷积核数目比上层增大一倍. 编码器第1个 ResBlock(1) 取消了第1个批归一化层和激活层. ResUNet 的解码器使用上采样层将特征图分辨率增大一倍, 使用 ResUNet(1) 学习融合后的特征, 且每层 ResBlock(1) 的卷积核数目比上层减小一倍.

残差连接已被证明能缓解深层卷积网络的退化现象^[20]. ResBlock 设置了如图1下方所示的残差连接, 并使用步长为 n 的卷积层令残差连接路径输出与主路径相同分辨率的图像. 批归一化层将每批输入的样本归一化为标准正态分布, 缓解了模型训练中的梯度爆炸和消失现象, 同时加速了收敛^[21].

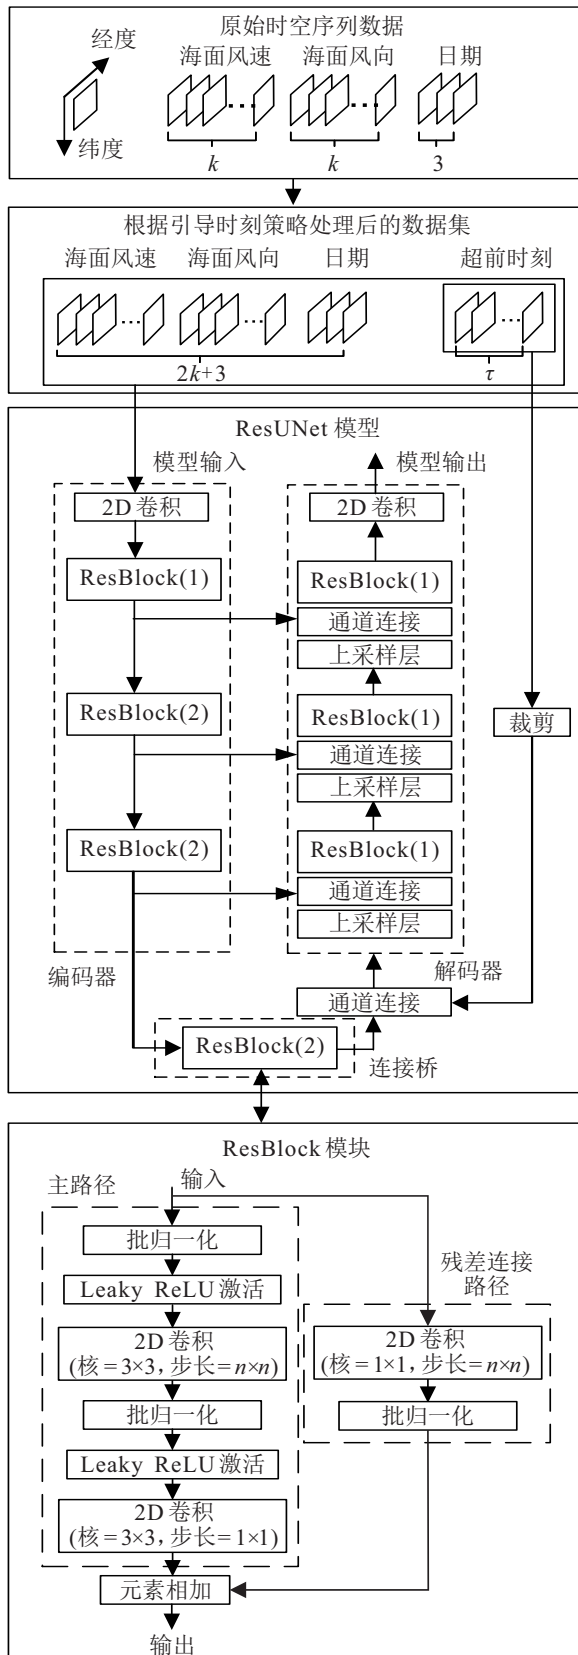


图1 预测模型的整体流程

模型使用Leaky ReLU激活函数取代了ResUNet中的ReLU激活函数. Leaky ReLU激活函数在负区间内仍存在数值,减少了深度神经网络训练中的神经元静默问题. 另外,超前时刻特征携带控制预测时刻的关键信息,当其输入编码器时,编码器直接获得预测

时刻特征,而解码器通过连接桥间接获得该信息. 这种方式不利于解码器将来自连接桥的深层特征解析为对应预测时刻的结果,因此模型不仅将超前时刻特征输入编码器,也经裁剪到合适大小后输入解码器. 输入层为2D卷积层,卷积核大小为 3×3 ,数目与第1个ResBlock(1)相同. 输出层为卷积核大小为 1×1 的2D卷积层,使用线性激活. 预测模型的整体流程见图1.

2.4 损失函数与模型设置

多步时空预测属于像素级回归问题,使用Frobenius范数作为损失函数. 模型采用批训练方式,总样本按照批大小(batch size)划分为小样本进行训练,所有批次的损失的均值作为总损失. 模型对单个批次样本的损失函数定义如下:

$$J = \frac{1}{M \times N \times C} \sum_{c=1}^C \|\mathbf{x}_{t+c}^{(s)} - \hat{\mathbf{x}}_{t+c}^{(s)}\|_F^2, \quad (5)$$

其中 C 为该批次样本总数,大小等于batch size,是 τ 的整数倍,以保证一组 τ 步预测样本出现在同一个批次中.

模型的超参数为 batch size = 36, 学习率 = 0.0001. 网络结构初始卷积核数(编码器第1个卷积层中卷积核的个数) = 32, 网络深度(编码器和解码器中ResBlock个数) = 3. 表1按照编码器、连接桥、解码器的顺序展示网络结构,其中ResBlock的步长代表主路径第1个卷积层和残差连接路径的卷积层步长.

表1 ResUNet模型的网络结构

网络层	输出	核大小	核个数	步长
卷积层	8×8	3×3	32	1
ResBlock(1)	8×8	均为 3×3	均为32	2
ResBlock(2)	4×4	均为 3×3	均为64	2
ResBlock(2)	2×2	均为 3×3	均为128	2
ResBlock(2)	1×1	均为 3×3	均为256	2
上采样层	2×2			
ResBlock(1)	2×2	均为 3×3	均为128	1
上采样层	4×4			
ResBlock(1)	4×4	均为 3×3	均为64	1
上采样层	8×8			
ResBlock(1)	8×8	均为 3×3	均为32	1
卷积层	8×8	1×1	1	1

3 实验研究

3.1 数据集

实验使用数据来源于欧洲中期气象预报中心(ECMWF)发布的第5版欧洲再分析数据集(ERA5). 该数据集在ECMWF网站(<https://www.ecmwf.int/en/forecasts/datasets>)上免费开放. ERA5提供了自1950

年以来的小时级全球大气再分析数据,其中风速数据为海面U、V分量风速,转换为风速、风向数据. ERA5将全球地图划分为 1440×721 的网格,空间分辨率约30 km. 为证实对远洋航运的保障效果,在世界原油贸易主要运输航线上选定一片矩形海域,其网格大小为 8×8 ,左上角坐标为(0 N, 45 E). 从ERA5中提取该海域在2019~2020年间的时空序列,包含17 544小时的数据. 该海域风速的最大值为13.7095 m/s,均值为6.2020 m/s,方差为5.2018 (m/s)².

3.2 实验设置与评价指标

实验硬件平台搭载 Intel i7-9700K CPU 和 NVIDIA GeForce GTX 1060 GPU, GPU配置CUDA 10.1 并行框架和 cuDNN 7.6 加速库,模型基于Tensorflow 2.3.0和Numpy 1.18.5搭建,代码基于Python 3.8.5.

实验中使用前24小时数据预测后12小时,数据集样本按照4:1:1的比例划分为训练集、验证集和测试集. 风速、风向和日期数据进行[-1, 1]最大最小归一化,并在评估预测结果前进行反归一化. 模型使用训练集进行训练,使用验证集进行超参数调节,使用测试集得出预测结果. 所有深度学习模型的权重矩阵和偏置向量均使用正态分布初始化. 所有深度学习模型均使用批训练,所有深度学习模型的最长的训练周期(epochs)为100,优化器使用Adam^[22].

实验中使用均方根误差、平均绝对误差和平均绝对误差百分比指标评价单个预测时刻 t 的效果,分别记为:RMSE _{t} 、MAE _{t} 和MAPE _{t} . 取 τ 个预测时间步上的均值评价多步预测效果,记为MRMSE、MMAE和MMAPE.

3.3 基准方法

为验证模型的先进性,选择以下基准方法进行对比:无参数模型、时间序列模型和时空序列模型,所有有参数模型均确定了最佳网络结构和最佳超参数. 无参数模型代表简单手段能实现的预测,选择历史平均(HA)模型,该模型仅需统计平均值即可达到一定的准确度. 时间序列模型是风速预测采用最多的类别之一,选择门控循环单元(GRU),该模型在经典时间序列模型LSTM上改进而来,在各类时间序列预测问题上具有较高的准确率. 实验设置了GRU的传统时序预测方式和使用多地点数据的方式. 时空序列模型选择PSTN和CPNet,两者均为近期提出的深层神经网络模型,使用CNN和UNet提取空间特征带来较好的预测能力. 使用上述先进模型作为对比,能够证实所提模型的优越性.

1) HA. HA为无参数模型,将历史时刻风速的平均值作为预测时刻的结果,实验中取12个历史时刻,其效果优于使用24个历史时刻.

2) GRU. GRU通过沿时间轴的循环连接结构,实现时间步之间信息记忆的传递. GRU不仅能高效捕获多维时间序列之间的时间相关性,而且具有比LSTM快的训练速度^[23]. 针对时空序列数据,实验中设计了GRU的两种不同预测方式:GRU-v1与GRU-v2.

GRU-v1为时间序列预测模型,预测单个地点的时间序列. 建立64个风速-风向预测模型,将所有预测结果汇总为时间序列. 采用的网络结构为单个GRU层-Dropout层-全连接输出层. GRU层大小为400,使用tanh激活函数. Dropout层丢弃率为0.2. 全连接层大小为12,使用linear激活. 模型在batch size = 32、学习率 = 0.0001下训练.

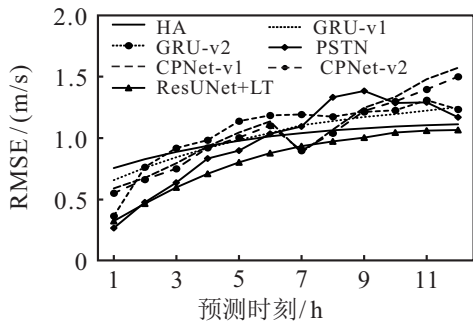
GRU-v2为时空预测模型,将GRU的输出序列映射为多地点在单个时刻的风速预测值. 通过建立12个时刻的预测模型,得到风速多步预测结果. GRU-v2的最佳GRU层大小为500,输出层大小为64,其他设置与GRU-v1相同.

3) PSTN. PSTN使用CNN和LSTM两种深度学习模型先后提取风速时空序列的空间特征和时间特征. 实验中,输入时间长度为24的时空序列,输出64个预测地点的1D序列. 分别建立每个预测时刻与历史时刻的模型,得到12个时刻的预测值.


4) CPNet. CPNet将两个UNet模型的编码器输出进行通道融合,同时传递给两个模型各自的解码器,实现了风速U、V分量风速的联合单步时空预测. 实验中设计CPNet-v1、CPNet-v2两个变体模型,两者的最佳设置与文献[8]相同,均单独对历史时段数据和每个预测时刻数据建模. CPNet-v1输入U、V分量风速,并将预测结果转换为风速、风向数据. CPNet-v2输入风速、风向数据,同时预测两者,但实验中只评价风速预测结果.

3.4 对比实验结果与分析

对比实验在12个时刻的评价指标如图2所示. 由于MAE的走势与RMSE基本一致,曲线中仅展示RMSE和MAPE. 由2图可见,基于ResUNet和超前时刻多步预测策略的模型(ResUNet+LT)整体上具有最低的RMSE和MAPE,且显著低于PSTN和CPNet. 由于船舶驶向目标海域需要时间,海面风速预测任务更加重视较远时刻的预测精度. 使用超前时刻策略的ResUNet模型从第3h开始具有最高预测精度,因此最适合用于船舶气象水文保障的模型.



(a) 对比实验的RMSE曲线



(b) 对比实验的MAPE曲线

图2 对比实验的误差曲线

各模型各预测时刻指标均值如表2所示. 由表2可知, ResUNet+LT的3个平均指标均为最低,是最佳模型. GRU-v1和PSTN各自在至少1个指标上位列第2,因此并列为次佳模型. 使用ResUNet和超前时刻策略,模型的MRMSE、MMAE和MMAPE相对GRU-v1分别降低了19.7%、13.1%和8.0%,相对PSTN分别降低了15.7%、15.9%和17.0%.


表2 对比实验的平均评价结果

模型	MRMSE	MMAE	MMAPE
HA	0.9905	0.7912	18.0553
GRU-v1	1.0234	0.7493	16.0883
GRU-v2	1.0576	0.8390	19.0800
PSTN	0.9748	0.7742	17.8433
CPNet-v1	1.06244	0.8344	22.1074
CPNet-v2	1.02822	0.7802	18.6041
ResUNet+LT	0.8208	0.6505	14.7986


3.5 预测结果

为直观表现所提出模型的性能,从空间和时间两个角度展示预测结果. 在测试集中随机选取2个样本,图3展示了样本在第2,4,...,12h上的对比图像,图中高风速表现为白色,低风速表现为黑色. 图3(a)表明,模型在第2~6h上的预测图与真实图非常相似. 在第8~12h上,预测图中存在白色区域,且随时间推移而缩小,这与真实图的趋势一致,验证了ResUNet模型处理空间数据的性能. 预测不完美的地方在于第10h和12h的白色区域有少量偏移,第

8~12h的上边缘部分有偏差. 样本b的风速情况相对简单,图像相对平滑. 对于简单的风速情况,模型的预测图与真实图像非常相似. 同时可以看出,预测图的黑色部分随时间推移而略微缩小,与真实趋势一致,验证了ResUNet模型能够预测时间上的较小变化.



(a) 样本a的空间结果



(b) 样本b的空间结果

图3 预测结果的空间图像对比

在测试集中随机选取2个样本,图4显示了样本3个地点上的时间序列. 图像表明,模型对于包括整体上升、整体下降和先升后降等各种风速变化趋势,均能产生较准确的预测结果,也验证了超前时刻多步预测策略的性能.

3.6 消融实验

为证实模型的各个改进的提升效果和输入步长的影响,进行如下消融实验.

3.6.1 不同卷积神经网络的效果

为验证ResUNet带来的提升效果,进行如图5(a)所示的对比实验. 由于RMSE、MAE与MAPE走势基本一致,图5(a)仅展示RMSE曲线. 所有实验均使用超前时刻多步预测策略并加入日期特征,分别记作CNN+LT、UNet+LT和ResUNet+LT. 各网络使用相同的卷积核设置以保证具有相近的参数数量,且使用相同的训练设置. 结果表明,ResUNet模型在每一预测时刻都具有最低的RMSE. 因此,ResUNet模型通过改善空间特征的利用可以提升各个时刻的预测表现.

为验证使用Leaky ReLU替代ResUNet的ReLU激活函数带来的提升效果,在相同配置下使用tanh、ReLU、Leaky ReLU、指数线性单元(ELU)和高斯误差线性单元(GELU)5种激活函数进行实验,结果如表3

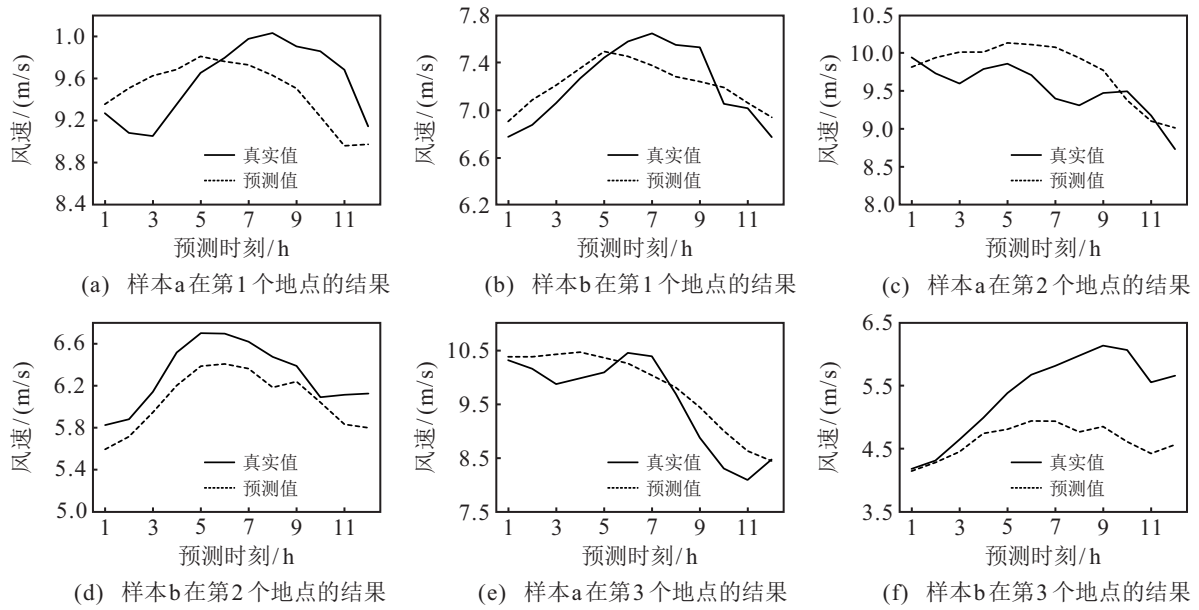


图4 预测结果的时间序列对比

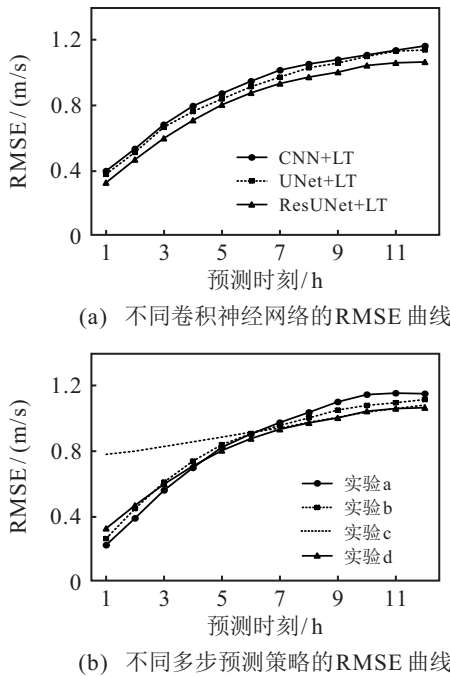


图5 消融实验的RMSE结果

表3 不同激活函数的平均评价结果

激活函数	MRMSE	MMAE	MMAPE
tanh	0.8979	0.7159	16.0929
ReLU	0.8506	0.6715	15.4490
ELU	0.8215	0.6480	15.0488
GELU	0.8364	0.6603	15.1284
Leaky ReLU	0.8208	0.6505	14.7986

所示. 实验结果表明,使用Leaky ReLU的模型具有最低的MRMSE和MMAPE,相对使用ReLU分别降低了3.5%和4.2%.

3.6.2 超前时刻多步预测策略的效果

为验证模型使用的超前时刻多步预测策略带来的提升效果,进行如图5(b)所示的实验. 由于RMSE、MAE和MAPE走势基本一致,图5(b)仅展示RMSE曲线. 其中:a代表对多个时刻单独建模;b代表将输出层通道设置为12,使用每个通道输出不同时刻的结果;c代表使用超前时刻策略处理数据集,但不输入超前时刻特征;d代表使用超前时刻策略处理数据集,同时将超前时刻特征输入编码器和解码器. 其中实验a和实验b的最佳初始卷积核数为24,学习率为0.001. 实验c和实验d的最佳设置与第3.4节相同.

相对实验a和实验b,实验d在靠后时刻的RMSE值最低,表明超前时刻多步预测策略能够提升靠后时刻的预测性能,模型从第4h开始具有最低的误差. 实验c与实验d的对比表明,超前时刻特征起到控制模型预测时刻的重要作用,该作用在靠前的预测时刻更为显著.

为验证超前时刻特征同时输入编码器和解码器带来的提升效果,进行不同输入方式下的实验,结果如表4所示. 实验结果表明,同时输入方式下的模型具有最低的3种指标,相对使用仅输入编码器分别降低了2.3%、2.2%和0.1%.

表4 超前时刻不同输入方式的平均评价结果

输入方式	MRMSE	MMAE	MMAPE
输入编码器	0.8406	0.6652	14.8172
输入解码器	0.8662	0.6880	16.5962
同时输入两者	0.8208	0.6505	14.7986

3.6.3 外生变量的效果

太阳辐射造成不同地点的海面大气温度差,从而导致两个地点存在气压差,在该方向上产生大气流动.因此,风速和风向均属于描述海面风现象的参数.为证实外生变量对预测效果的提升,选择海面风向作为外生变量进行实验,结果如表5所示.由表5可知,风向变量的采用使模型的MRMSE、MMAE和MMAPE分别降低了2.1%、1.2%和6.3%.

表5 不同外生变量的平均评价结果

外生变量	MRMSE	MMAE	MMAPE
无	0.8386	0.6629	15.7940
风向	0.8208	0.6505	14.7986

3.6.4 日期特征的效果

为验证日期特征的提升效果,进行如表6所示的实验,其中日期特征从对照组的输入数据中去除,其他设置相同.实验结果表明,采用日期特征使模型的MRMSE、MMAE和MMAPE分别降低了2.3%、2.3%和1.8%.

表6 使用日期特征的平均评价结果

使用日期特征	MRMSE	MMAE	MMAPE
✓	0.8208	0.6505	14.7986
×	0.8406	0.6660	15.0745

3.6.5 不同输入步长的影响

为验证不同输入步长对模型的影响,进行如表7所示的实验,对比输入12~48h之间的效果.实验结果表明,在12~24h之间预测误差保持下降,在24~48h之间预测误差非常接近.因此考虑到准确性和计算效率,24h的输入步长是最好的选择.

表7 不同输入步长的平均评价结果

输入步长/h	MRMSE	MMAE	MMAPE
12	0.8422	0.6680	15.5765
18	0.8332	0.6597	15.9501
24	0.8208	0.6505	14.7986
36	0.8247	0.6512	14.9325
48	0.8190	0.6495	14.8743

4 结论

本文针对海面风速多步时空预测问题,提出了一种以ResUNet为主体并配合超前时刻多步预测策略的模型.该模型能更好地捕获全局空间信息并映射

到期望的多地点输出,且能够同时学习不同预测时刻样本,实现精确的时空预测.另外,使用Leaky ReLU激活函数改进ResUNet模型,使用同时输入的方式改进超前时刻策略,并在输入中加入日期特征和风向外生变量,这些改进均被证明有效.实验证明,所提出模型不仅能够实现海域内多地点和多步预测,而且在较远的预测时刻仍然保持较低的误差,在远洋船舶气象水文保障中具有应用前景.

参考文献(References)

- [1] 张增海,刘涛,曹越男,等.船舶海洋气象导航的业务概况与发展现状[J].海洋气象学报,2020,40(3):11-16.
(Zhang Z H, Liu T, Cao Y N, et al. Overview and development situation of marine weather routing service for ships[J]. Journal of Marine Meteorology, 2020, 40(3): 11-16.)
- [2] Rehmatulla N, Parker S, Smith T, et al. Wind technologies: Opportunities and barriers to a low carbon shipping industry[J]. Marine Policy, 2017, 75: 217-226.
- [3] Soman S S, Zareipour H, Malik O, et al. A review of wind power and wind speed forecasting methods with different time horizons[C]. North American Power Symposium. Arlington, 2010: 1-8.
- [4] Shi X J, Yeung D. Machine learning for spatiotemporal sequence forecasting: A survey[J/OL]. 2018, arXiv: 1808.06865.
- [5] Agrawal S, Barrington L, Bromberg C, et al. Machine learning for precipitation nowcasting from radar images[J/OL]. 2019, arXiv: 1912.12132.
- [6] Sønderby C K, Espeholt L, Heek J, et al. Metnet: A neural weather model for precipitation forecasting[J/OL]. 2020, arXiv: 2003.12140.
- [7] Chen Y R, Wang Y, Dong Z K, et al. 2-D regional short-term wind speed forecast based on CNN-LSTM deep learning model[J]. Energy Conversion and Management, 2021, 244: 114451.
- [8] Srivastava N, Mansimov E, Salakhudinov R. Unsupervised learning of video representations using lstms: International conference on machine learning[Z]. 2015.
- [9] Shi X, Chen Z, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[Z]. 2015.
- [10] Zhu Q, Chen J F, Zhu L, et al. Wind speed prediction with spatio-temporal correlation: A deep learning approach[J]. Energies, 2018, 11(4): 705.
- [11] Trebing K, Mehrkanoon S. Wind speed prediction using

- multidimensional convolutional neural networks[C]. IEEE Symposium Series on Computational Intelligence. Canberra, 2020: 713-720.
- [12] Zhu Q M, Chen J F, Zhu L, et al. Wind speed prediction with spatio-temporal correlation: A deep learning approach[J]. *Energies*, 2018, 11(4): 705.
- [13] Chen Y, Zhang S, Zhang W Y, et al. Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting[J]. *Energy Conversion and Management*, 2019, 185: 783-799.
- [14] Vandenhende S, Georgoulis S, van Gansbeke W, et al. Multi-task learning for dense prediction tasks: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3614-3633.
- [15] Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798-1828.
- [16] Bastos B Q, Cyrino Oliveira F L, Milidiú R L. Componentnet: Processing U- and V-components for spatio-temporal wind speed forecasting[J]. *Electric Power Systems Research*, 2021, 192: 106922.
- [17] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[J/OL]. 2015, arXiv: 1505.04597.
- [18] Zhang Z X, Liu Q J, Wang Y H. Road extraction by deep residual U-net[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(5): 749-753.
- [19] Lim B, Ark S Ö, Loeff N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting[J]. *International Journal of Forecasting*, 2021, 37(4): 1748-1764.
- [20] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, 2016: 770-778.
- [21] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[Z]. 2015.
- [22] Kingma D P, Ba J. Adam: A method for stochastic optimization[J/OL]. 2014, arXiv: 1412.6980.
- [23] Chung J, Gulcehre C, Cho K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J/OL]. 2014, arXiv: 1412.3555.

作者简介

谢莒芃(1997—), 男, 硕士生, 从事深度学习、时空序列的研究, E-mail: xie2020world@whut.edu.cn;

张华军(1980—), 男, 副教授, 博士, 从事船舶控制、应急疏散、模糊评估等研究, E-mail: zhanghj@whut.edu.cn;

黄双(1986—), 男, 高级工程师, 博士, 从事舰船自动化等研究, E-mail: huangshuang0709@126.com;

曹旭(1991—), 男, 工程师, 博士, 从事舰船自动化等研究, E-mail: caoxu1020@163.com.