

基于特征增强与时序感知的洪水预报模型

巫 义 锐¹ 郭 鸿 飞¹ 钱 程³ 王 文 鹏²

(1. 河海大学 计算机与信息学院 江苏 南京 210098; 2. 河海大学 水文水资源学院 江苏 南京 210098;
3. 江苏省水利科学研究院 江苏 南京 210017)

摘要: 面对洪水发生频率低且机制复杂的问题,提出了一类深度神经网络模型(ET-LSTM)。该模型通过构建特征增强模块提升了小样本情况下的洪水预报能力,通过结合时序感知模块的深度神经网络模型,构建洪水因子与径流量间的非线性关系,挖掘洪水因子间的隐含时序关联关系。首先利用一维卷积神经网络构建洪水深度特征表达;然后,结合瓶颈(BottleNeck)结构设计,通过特征通道间的信息交换,增强洪水深度特征的表达能力;最后,构建时序无关和时序相关模块,分别提取深度特征中的时序相关与时序无关部分,进一步提升深度特征的时变表达能力,并在流域数据集上进行对比分析。结果表明:该方法在模拟精度、相关性系数等指标上优于对比方法,能够更好地拟合真实径流量数据,提升洪水预报的准确性与预见期。

关键词: 洪水预报; 长短时记忆网络; 特征增强; 时序感知; 深度神经网络模型

中图分类号: P338

文献标志码: A

DOI: 10.16232/j.cnki.1001-4179.2021.S2.005

0 引言

随着流域的水雨情现代化观测手段日益完善,如何充分利用丰富的水雨情观测资料,快速有效地识别流域的产汇流特性,动态跟踪洪水形成模式,提高洪水预报精度已成为水文科学研究的新问题^[1]。机器学习方法在图像识别、自动控制等领域的成功应用,使得水文学家们重新审视水文数据的潜在价值,研究如何将新型的机器学习方法与洪水形成原理相结合,构建具有一定物理概念的数据驱动模型^[2],以充分发挥机器学习的模式识别和动态自适应能力,推进洪水预报精度的进一步提高。

利用实测序列建立数据驱动模型并预报洪水过程的研究大约起始于 20 世纪 80 年代。但当时的分析技术局限于随机过程、经典的多元回归分析和人工神经网络等方法^[3]。这些分析技术针对小样本的水雨情资料,难以展现出可靠的预报精度,预报结果也缺乏可

信的物理解释。机器学习与深度学习技术的进步,给洪水预报技术的改进带来了新的契机。在深度学习算法中,长短时记忆网络^[4](Long Short Term Memory Network, LSTM)因其能够兼顾传递和处理自然过程中的长期和短时记忆特征,引起了工程学界的广泛关注。Bouktif 等^[5]提出了一种基于增强型 LSTM 的电力负荷预测模型,该模型从多个输入时滞序列中寻找电力负荷存在的周期性特征并完成了提取,开发了自回归模型以及自相关函数(ACF),以回归消耗确定最相关的时滞,并馈入多序列 LSTM。Yang 等^[6]提出运用注意力机制捕获对当前状态具有显著影响的前期量测值,实现了对交通流量的准确预测。Ding 等^[7]使用 LSTM 和注意力机制从各种水文信息中动态提取关键特征向量,提出了一个可解释的时空注意力长短期记忆模型(STA-LSTM),在单个时间步中将空间权重动态分配给输入特征,利用 LSTM 的每个步骤的隐藏层状态来分配时间关注权重到每个时间步的隐藏层状态,以达

收稿日期: 2021 - 07 - 08

基金项目: 国家重点研发计划项目(2018YFC0407900); 中央高校基本科研业务费专项资金项目(B200202177)

作者简介: 巫义锐,男,副教授,博士,主要从事水利信息化相关工作。E-mail: wujirui@hhu.edu.cn

通讯作者: 王文鹏,男,副研究员,博士,主要从事水文不确定性分析研究。E-mail: wangwenpeng@hhu.edu.cn

到准确预测的目的。

然而,由于洪水发生频率较低,有效训练样本不足,将经典的 LSTM 模型用于洪水预报工作很容易出现过拟合现象。因此在少量的训练样本条件下,特别是在资料有限的中小河流,有针对性地建立网络结构,充分捕捉和利用洪水形成的关键信息,是提高洪水预报数据驱动模型精度的关键。

为此,本文提出了一种新的 ET-LSTM(Enhanced and Temporal-aware LSTM Network)洪水径流量预报网络,网络模型的结构是单一结构,在小数据集上有优异的表现。该网络结构不仅引入了新颖的特征增强模块以突出洪水因子集中的关键信息,而且还捕获并分析了历史洪水数据中时序相关和时序无关的信息。这两个模型都是构建洪水径流量预报任务的关键要素表示的一部分。主要内容如下:

(1) 本文提出了 1D-BottleNeck 模块来实现洪水特征增强。将数据传入特征增强模块中,通过改写多层次的卷积神经网络拉大输入输出数据维度差,从而成功地增加了特征维度,突出并得到洪水因子中的关键信息,进一步强调了洪水预测任务中最有价值的信息。

(2) 为了更好地描述时序数据中的信息,本文提出了具有时序无关单元 F 和时序相关单元 T 的 ET-LSTM,对洪水数据中的特征信息与对时间信息的感知分别捕获和分析,以信息性建模并分配不同的权重。这主要从两个不同的角度着眼于洪水信息的感知,从而产生并区分洪水特征,最后通过合并单元进行感知信息融合,完成训练。

1 洪水预报数据驱动模型发展

由于深度学习在其他领域的出色发挥,研究人员开始研究利用深度学习建模以预测洪水流量。受到深度学习算法启发,研究人员将洪水视为一种特殊的顺序数据,从而将深度学习准确地应用于预测洪水流量。准确的日径流量预报对水电站和电网的运行控制具有重要意义,然而包括降雨径流模型和统计技术在内的常规方法通常依赖于许多假设,从而导致与实际结果有所偏差。神经网络具有较高的容错性以及较强的非线性映射能力和学习能力,为日常径流预报提供了一种有效的方法。然而,它的训练具有某些缺点,例如耗时、学习速度慢以及容易陷入局部最优,这在现实世界的应用中是不能忽略的。为了克服人工神经网络模型的弊端,Cheng 等^[8]提出了一种基于量子行为粒子群优化^[9](QPSO)的人工神经网络模型,简称 ANN-QPSO,用于每日径流预报,其中采用 QPSO 进行人

工神经网络的突触权重和阈值的选择,而人工神经网络用于预测。所提出的模型可以结合 QPSO 和 ANN 的优势来增强预测模型的泛化性能。利用 2006~2014 年贵州省东南部洪家渡水库日径流量数据对该方法进行了评估。结果表明:该方法比基本的 ANN 模型具有更好的预测精度,而 QPSO 算法是一种优秀的替代方法。

此外,可靠的长期预报(提前 5~15 d)对极端洪水的预报至关重要。由于当前基于物理学的数值模拟模型可能非常复杂,无法解决测量和建模中的不确定性,因此一项重要的研究工作是开发使用机器学习技术进行长时洪水预报的方法。数值天气预报模型进行的准确降水预报仅限于提前几天,这是因为大气控制方程中的非线性会对初始条件产生敏感的依赖性^[10]。受时空信息启发,Zhuang 等^[11]设计了一种新颖的时空卷积神经网络(ST-CNN),用于基于聚类的极端洪水预测,并考虑空间和时间两种维度,发掘数据中的信息以用于极端洪水聚类预测。该网络成功地探索了输入水文因素的两个重要特征维之间的关系,即时空。

由于并非所有因素都有助于洪水预报,而无关因素通常会带来很大的噪音,因此本文更多地关注信息因素。在保留原始 LSTM 的序列建模能力的基础上,Wu 等^[12]提出了一种用于洪水预测的上下文感知注意力 LSTM(CA-LSTM)网络,该网络能够选择性地关注信息因素。在训练过程中,通过学习每个 LSTM 单元的流速和隐藏输出之间的概率分布来构造局部情境注意力模型。在测试过程中,学习到的本地注意力模型会分配权重,以调整 LSTM 网络各个步骤中输入因子与预测之间的关系。使用几种比较方法对洪水数据集进行了实验,以证明所提出方法的准确性以及所提出的上下文感知注意力模型的有效性。

由于洪水发生频率较低,在利用深度学习方法探究河流流量与特征因子间关系时会产生各种问题,比如出现数据不足的问题,导致过拟合等问题。同时洪水产生机理复杂,洪水序列中不仅包含着时序相关的信息,还包含着时序无关的信息,因此如何有效地提取这两者的信息在理解洪水序列信息方面起着关键作用,这也带来了如何进行精准建模的问题。

2 ET-LSTM 网络

2.1 设计思路

洪水的机制很复杂,其同时包含着与时序相关和时序无关的信息。如何有效地识别提取特征在理解洪水序列数据模式中起着关键作用。为了获得更准确的洪水预测结果,本文通过专门设计时序无关的模块 F

和与时序相关的模块 T 来重写 LSTM 网络。本质上, LSTM 网络应该包含两种信息:一个可以把它看作是时间序列上具有相关性的时变信息,即与时间有关的信息,由前一个神经元传递给下一个神经元的消息,即细胞状态值;另一个是与时间无关的信息,即单个神经元感知到的信息。两种信息从不同方面对洪水特征进行了描述,对实行可靠的洪水预测都很重要。与其在原始 LSTM 网络中将涉及的信息合并,不如先捕获和分析它们,以为信息模型分配不同的权重,最后由所提出的合并单元执行特征融合,以区分洪水特征。

本文将对所提出的 ET - LSTM (Enhanced and Temporal - aware LSTM Network) 进行介绍,同时,与 CA - LSTM (Context - Aware Attention LSTM)、Series-Net^[13]、FCN^[14]、LSTM 等进行对比试验。其中,CA - LSTM 网络能够选择性地关注信息因素。在训练过程中,通过学习每个 LSTM 单元的流速和隐藏输出之间的概率分布来构造局部情境注意模型。SeriesNet 可以充分学习不同间隔长度的时间序列数据的特征,并从时间序列数据中学习多范围和多层次的特征。与使用固定时间间隔的那些模型相比,该模型具有更高的预测精度。

2.2 整体网络架构

ET - LSTM 的整体网络结构如图 1 所示。具体来说,本文首先收集各种水文因素,包括前期降雨、蒸发、径流量值和预报降雨,这些都作为 ET - LSTM 的输入。ET - LSTM 的目标是对未来 k 小时内的径流量做出预测,其中 k 的范围为 1 ~ 6。值得注意的是,由于试验流域的时变水文因子难以捕获,ET - LSTM 仅采用了 4 个水文特征,而较少的输入因子将导致低维要素空间,

这也是解决洪水径流量预测复杂性面临的主要困难。此外,因为数据不足不能保证执行可靠的推理,特征之间的内在关系很难描述。因此,用小数据集预测洪水的一项基本任务是执行特征增强以解决不同特征之间的关系。

本文在一维卷积神经网络的基础上重写完成了瓶颈 (BottleNeck) 的形式,以实现通道之间的信息交互,并增强了洪水中特征因子的特征,从而产生了与当前任务相关的改进特征。处理后的特征描述将与原始特征数据融合在一起,并且该信息将用于探索河流流量与特征因子之间的关系模型。特征增强功能描述如下:

$$E(f) = C_B(B(f)) \tag{1}$$

式中: f 为洪水特征因子, $B()$ 为对该特征的多层卷积运算, $C_B()$ 为特征增强函数。

将时间无关模块 F 和时间相关模块 T 引入循环神经网络以从不同角度进行建模,并将增强后的数据引入已建立的神经网络中进行训练,平衡权重并调整比例。最后,感知信息被合并单元合并以完成训练。加权信息描述如下:

$$l_i = C_\xi(E(f), F(h_i), T(c_i)) \tag{2}$$

式中: h_i 为输出状态向量, c_i 为 LSTM 神经元的状态, C_ξ 为根据单元 F 和 T 的信息融合而调整的学习权重。前一个 LSTM 神经元的输出和学习到的加权方案将被传输到下一个神经元,以完成学习并用作神经元的输出结果,公式如下。

$$G_i = H(l_{i-1}, G_{i-1}) \tag{3}$$

式中: $H()$ 为 LSTM 神经元的长期依赖信息的学习和记忆过程。最后,获得的结果由 LSTM 输出,用于逻辑回归计算,以完成洪水预测过程。

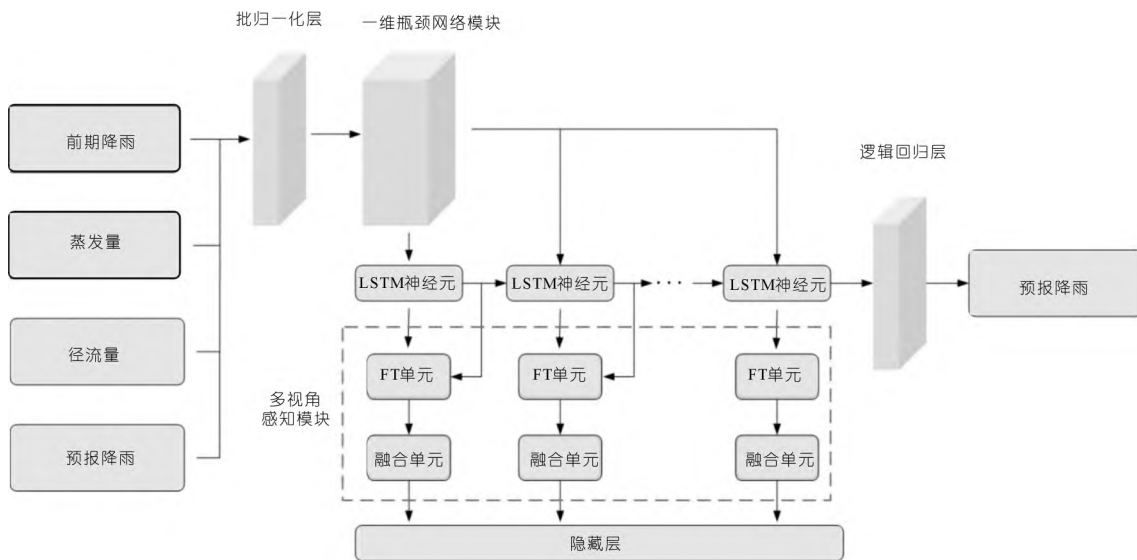


图 1 ET - LSTM 网络结构

2.3 1D - BottleNeck 模块

本文在具有一维卷积神经网络的瓶颈结构的形式基础上设计用于特征增强的 1D - BottleNeck 模块(见图 2)。




图 2 1D - BottleNeck 结构

以往 瓶颈结构被广泛用于提取高维图像中的特征,多用于感受野的扩大,以提取图像中整体的或者覆盖范围较大的部分体现出来的特征信息。一般来说,由于两个相关像素之间的位置可能相距较远,因此需要拉大网络的感知,因此瓶颈结构通过卷积层设计了高度非线性的功能系统,该系统执行特征压缩和提取的任务,从而大大提高了图像分类期间的特征识别能力和处理速度。瓶颈的一般体系结构是在块的两端定位更多的通道,在中间定位更少的通道,这类似于瓶子的形状。

受瓶颈结构在提取特征方面的显著性能的启发,本文重新设计了瓶颈结构以执行水文特征增强任务。采用的一维瓶颈结构,可以表示为

$$F = F_{C_3}(F_{C_2}(F_{C_1}(D))) + I \quad (4)$$

其中 β 个卷积层 C_1 、 C_2 和 C_3 设计为内核大小分别为 1×1 、 1×3 、 1×1 和特征通道分别为 64、64、32 的形式。相较于采用完全连接层,采用卷积层构造一维瓶颈可以大大减少参数数量,从而加快传播计算。

如图 2 所示,由于输入水文因素稀少、尺寸值偏低,本文设计了第一层卷积层 C_1 来将尺寸值提高两倍,而不是缩小原始瓶颈结构的尺寸。在增加输入水文特征的维数之后,网络中可以获得更大的特征空间,以保持原始信息和特征之间的关系信息。然后,将另一个卷积层 C_2 应用于传递一维序列数据信息而无需进行维值的修改,该卷积层作用是解决不同水文特征之间的非线性功能系统。换句话说,本文设计 C_2 来模拟水文特征之间的关系,这是用于增强特征的主要信息来源。最后,通过 C_3 将生成的高维特征缩减为输入原始数据的大小,从而方便以后进行顺序处理。

洪水预报问题中的一个重要问题是找到与每个样本最相关的要素维度,这需要充分利用原始数据集中提供的所有可用信息。在这种思想的指导下,本文着眼于涉及原始样本的信息,以沿着每个样本的特征维定位关键通道,这表示为等式的最终总和部分。

2.4 ET - LSTM 设计

原始 LSTM 网络主要用于解决长时间序列中的依

赖性问题,它适用于一个链接到另一个链接的完整时间序列数据。但是,在洪水径流量预测的研究中,网络的输入数据不单单是一条同类型数据的严格时间序列形式,而是包含着径流量、降雨量、面雨量等相关洪水因子,因而在对洪水因子的把控中需要更加精准地提取时间相关信息;另一方面,所设计水文因子中蕴含着随时间变化之外的特征信息,这一部分的感知与权重的分配也带来了一定的困难。因此在原始 LSTM 中,数据中的洪水因子信息无法很好地感知记录,以至于原始 LSTM 不能很好地执行洪水预报功能。

因此,本文将时序相关单元和时序无关单元引入循环神经网络,从不同的角度进行建模,如图 3 所示。随后将增强的数据引入已建立的神经网络中进行训练,平衡两个视角的权重并调整其比例,并通过合并单元融合感知信息以完成训练。

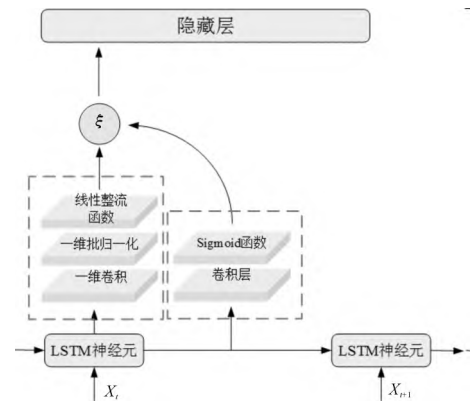


图 3 ET - LSTM 结构

在该网络中,设计了一个与时序无关的单元 F 和一个与时序相关的单元 T,它们分别用作单个输入样本上的特征提取模块和顺序输入上的时间信息编码器。

时间戳 t 的时序无关单元 F 的输出定义为

$$p_{i,t} = F(p_{i-1,t}; \mu_i) \quad (5)$$

式中:时间无关的单元 F 代表卷积神经网络层,包括 ReLU 层, $p_{i,t}$ 为时间戳 t 在第 i 层中 F 的输入, μ_i 为第 i 层中 F 的参数。

时间戳 t 的时间相关单元 T 的输出定义为

$$v_{i,t} = T(v_{i,t-1}, p_{i-1,t}; \varphi_i) \quad (6)$$

式中: $v_{i,t}$ 为第 i 层中时间戳 t 的存储状态, $v_{i,t-1}$ 为前一个时间点的时间信息的存储状态, $p_{i-1,t}$ 为时间戳 t 时,在第 i 层中时序相关单位 T 的输入, φ_i 为第 i 层 T 的参数。时序相关单元 T 是通过 LSTM 或 Sigmoid(Conv) 实现的,表示为一个传统的递归神经网络。

将来自两个单元的信息流输入到合并单元中,合并后的数据结果表示为

$$G_i^d = \xi(p_{i,t}, v_{i,t}) \quad (7)$$

式中: ξ 表示合并功能, 该功能是通过将相同位置的相应元素逐位相乘而生成的。

3 应用效果分析

3.1 流域概况

本文选取了浙江省昌化流域进行验证, 如图 4 所示。昌化流域地势东南高西北低, 流域面积约 3 444 km², 地表落差 965 m。昌化属热带季节性气候, 因而夏季降雨密集, 冬季较少。特别是每年的梅雨季节, 降雨持久且量大, 洪涝灾害频发^[15]。在昌化流域中, 包含岛石坞站、桃花村站、龙门寺站、双石站等 6 个雨量站, 其中昌化站既提供降雨数据, 又提供流量数据。在昌化流域, 大量的降雨给周边水库带来了很大的影响, 因此该流域的数据对防洪工作有着重要的意义。



图 4 昌化流域地势

3.2 预报结果

将本文建立的方法 ET-LSTM 与 CA-LSTM、SeriesNet、FCN、LSTM 等进行了比较。如表 1~3 所列, 比较了各方法的均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 以及相关系数 (DC 系数)。

表 1 昌化流域预测结果 RMSE 损失对比

方法	T+1	T+2	T+3	T+4	T+5	T+6	平均值
FCN	28.70	42.88	57.87	84.32	110.80	125.30	74.98
LSTM	41.08	50.93	56.02	68.32	82.27	97.81	66.07
SeriesNet	26.94	52.01	63.21	71.45	81.90	92.98	64.74
CA-LSTM	30.79	45.23	54.51	67.35	79.27	90.36	61.25
ET-LSTM	39.14	47.05	53.80	62.67	74.14	86.76	60.59

从表 1 可以看出: ET-LSTM 方法在预测前 2 个点时的损失仅次于 FCN 和 CA-LSTM, RMSE 损失分别为 39.14 和 47.05, 而 FCN 预测的 RMSE 损失分别为 28.70 和 42.88, CA-LSTM 为 30.79 与 45.23。在前 2 个点的预测中, FCN 有着不错的优势。而随着时间的推移, ET-LSTM 方法在预测精度上逐渐提高, 特

别是从 T+6 时间点上能明显看出, ET-LSTM 方法的 RMSE 损失在 T+6 时达到 86.76, 比第二低的 CA-LSTM 的 RMSE 损失 (90.36) 低了 3.60, 表明随着时间的推移本文的模型保持着高精度的预测效果。ET-LSTM 方法的平均 RMSE 损失为 60.59, 优于其他方法, 而 CA-LSTM 为 61.25, 略高于 ET-LSTM 方法。在表 1 中可以看出, ET-LSTM 方法相比于其他方法的预测具有更高的准确性。

从表 2 可以看出: 在 MAPE 损失下, FCN 模型在短期预测中具有较高的性能, 在 T+1 时间点上 MAPE 损失达到了 9.89%, 优于 ET-LSTM 方法的 11.15%。而在中期预测中, ET-LSTM 模型开始体现出一定的优势, T+3 与 T+4 两个时间上的 MAPE 损失分别为 14.49% 和 16.54%, 略低于 CA-LSTM 的 15.42% 和 16.87%。在长期预测中, ET-LSTM 模型的 MAPE 损失最低, 约为 20.01%, 略低于第二低的 CA-LSTM 的 21.80%。除此之外, ET-LSTM 模型的平均 MAPE 损失为 15.75%, 比 CA-LSTM 低 0.47%, 相比于其他模型有着不错的性能优势, 这意味着 ET-LSTM 模型具有较高的准确性, 并且平均模型性能优于其他模型。

表 2 昌化流域预测结果 MAPE 损失对比 %

方法	T+1	T+2	T+3	T+4	T+5	T+6	平均值
FCN	9.89	14.03	18.47	21.33	23.32	24.29	18.56
LSTM	13.19	15.04	17.29	19.14	22.79	24.73	18.70
SeriesNet	10.19	16.28	18.12	21.86	23.74	24.94	19.19
CA-LSTM	10.04	14.16	15.42	16.87	19.03	21.80	16.22
ET-LSTM	11.15	13.01	14.49	16.54	19.21	20.01	15.75

从表 3 可以看出, 在对前几个点的预测中, 各个方法结果 DC 系数较为接近。T+1 时刻中 ET-LSTM 方法 DC 系数为 0.9813, 比 SeriesNet、CA-LSTM 分别低了 0.05、0.68。而在后几个点的预测中, ET-LSTM 方法的 DC 系数下降缓慢, 在对 T+6 时间点的预测中, ET-LSTM 方法的 DC 系数保持在 0.8771, 而除了 CA-LSTM 的 0.8679, 其他对比方法的 DC 系数纷纷降低至 0.86 以下, 体现出 ET-LSTM 方法在长时间预测结果上的有效性。

表 3 昌化流域 DC 系数对比

方法	T+1	T+2	T+3	T+4	T+5	T+6
FCN	0.9811	0.9523	0.9267	0.8976	0.8628	0.8297
LSTM	0.9522	0.9463	0.9380	0.9169	0.8850	0.8434
SeriesNet	0.9863	0.9566	0.9360	0.9174	0.8891	0.8540
CA-LSTM	0.9881	0.9620	0.9466	0.9214	0.9001	0.8679
ET-LSTM	0.9813	0.9745	0.9679	0.9454	0.9140	0.8771

本文将未来 6 h 的洪水流量预测与 CA-LSTM 进行了比较。预测结果的折线图如图 5 所示, 左侧是 CA-LSTM 的预测结果, 右侧是 ET-LSTM 方法的预测结果。

从图 5 可以看出: 在之前的几个时间点, 与 CA-

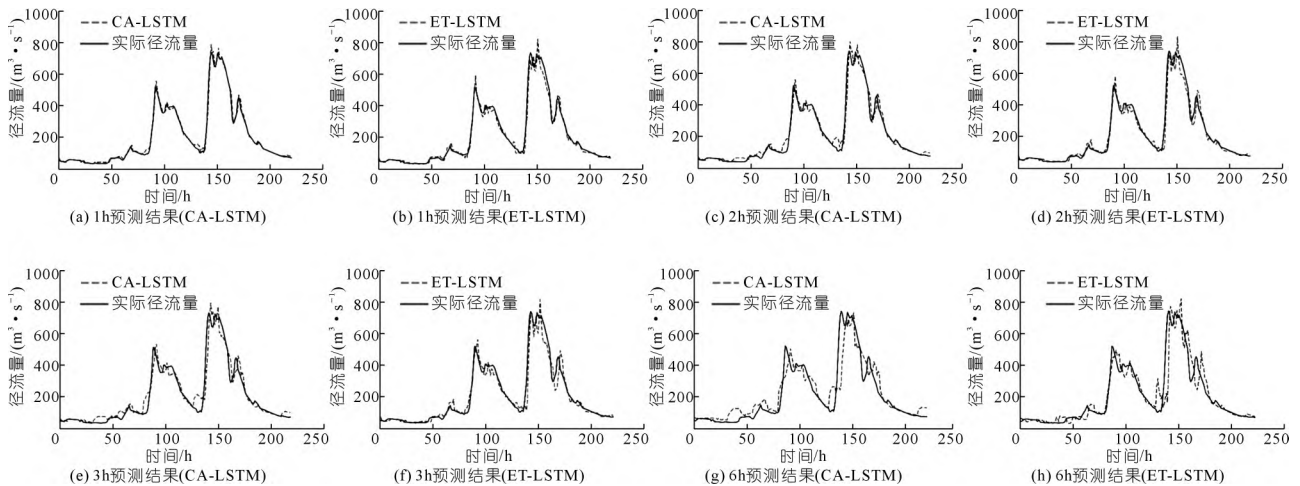


图5 昌化流域上 CA-LSTM 与 ET-LSTM 预测结果

LSTM 相比,ET-LSTM 方法的预测曲线有着一定劣势,CA-LSTM 的预测结果较为拟合,然而在峰谷的拐点上,CA-LSTM 已经表现出了一定的错位。特别是从 2 h 预测径流量折线图上可以看出,ET-LSTM 方法依旧保留着一定的拟合性。随着时间的增加,在 2 h 后的时间点洪水预报中,两者的预测效果均有不同程度的下降,这在洪水数据拐点和洪峰预报中更为明显。当洪水数据出现拐点时,CA-LSTM 的预测精度会大大降低,并且无法预测径流的变化,折线图出现了明显的预测错位。在预测转折点和峰值时,ET-LSTM 方法更实际地拟合了数据,洪水径流量趋势可以被较好的描述。在预报的前 2 h,当洪水径流量预报稳定且没有波动时,两者的方法会有一定偏差。但是随着时间的流逝,在进一步的预测点上,CA-LSTM 显然难以满足洪水的变化,并且 ET-LSTM 方法更适合于实际径流,这意味着 ET-LSTM 方法对于长时间洪水径流量预报具有更好的效果。

4 结论

本文针对深度学习在中小河流域洪水径流量上的预测进行了研究学习,通过特征增强,构建了深度神经网络模型(ET-LSTM),模拟洪水因子与径流量间的非线性关系。引入时序单元等方法解决了洪水发生频率低且机制复杂、关键特征难以提取等问题,在 LSTM 等时序预测模型的基础上进行了有效地改进。与其他方法相比新模型在一定程度上提高了预测精度,对于长时间洪水径流量预报具有更好的效果。研究结论如下:

(1) 研究了以特征增强解决洪水样本量少的问题,将数据传入特征增强模块中,通过改写多层次的卷积神经网络拉大输入输出数据维度差,突出并得到洪

水因子中的关键信息,实现特征增强的功能。

(2) 对洪水特征信息与时间信息进行精准感知建模,加入时序无关模块 F 与时序相关模块 T,分别捕获洪水中时序相关与无关的信息,分别感知这两方面的内容,在训练的过程中进行权重平衡并调节两者比重,最后通过合并单元进行感知信息融合,完成训练。

本文提到的增强和信息分别感知的特征构造过程可以被认为是适合于时序数据问题本质的正确解决方案,从而达到精确径流量预测的效果。在昌化流域上进行了试验,预测效果有一定程度的改善。今后将着手于其他水文因子的采集,以获得更好的预测效果,并在一维时间序列预测的基础上进行多元序列的探索,以在其他领域上进行应用拓展。

参考文献:

- [1] 刘志雨,刘玉环,孔祥意.中小河流洪水预报预警问题与对策及关键技术应用[J].河海大学学报(自然科学版),2021,49(1):1-6.
- [2] CAMPOLO M,ANDREUSSI P,SOLDATI A. River flood forecasting with a neural network model[J]. Water Resources Research,1999,35(4):1191-1197.
- [3] GOVINDARAJU R S. Artificial neural networks in hydrology. II: hydrologic applications[J]. Journal of Hydrologic Engineering,2000,5(2):124-137.
- [4] HOCHREITER S,SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation,1997,9(8):1735-1780.
- [5] BOUKTIF S,FIAZ A,OUNI A,et al. Single and multi-sequence deep learning models for short and medium term electric load forecasting[J]. Energies,2019,12(1):149.
- [6] YANG B,SUN S,LI J,et al. Traffic flow prediction using LSTM with feature enhancement[J]. Neurocomputing,2019,332:320-327.
- [7] DING Y,ZHU Y,FENG J,et al. Interpretable spatio-temporal attention LSTM model for flood forecasting[J]. Neurocomputing,2020,403:348-359.

(下转第 44 页)

胞密度有很大正相关性,刚好与滇池藻类的季节性变化一致,滇池冬春季节气温相对较低,藻类生长、繁殖较慢,藻细胞密度相对最低;随着4~9月夏秋季节气温逐渐升高,藻类开始暴发式地生长繁殖,藻细胞密度处于全年最高,故藻类暴发时,不过滤与过滤的测定值有很大差异。

(3) 由于水样组成复杂及形态各异,水体的浑浊度、悬浮物和固体成分直接影响化学需氧量测定结果,化学需氧量样品前处理方法的选择很重要,具体的处理方式因样品而异。下一步可对样品中固体的成分与化学需氧量关系进行分析研究,以为化学需氧量监测前处理的选择提供更完善的参考。

参考文献:

- [1] 孙海林,左航,贺鹏,等. 污染源水质 COD 在线仪器比对监测[J]. 中国环境监测 2014, 30(4): 179-182.
- [2] 陈瑞娟,李明. 三种方法测定不同水质化学需氧量的比对分析[J]. 环境科学导刊 2016, 35(3): 101-104.
- [3] 黄硕俊,舒艺,彭虹. 地表水化学需氧量两种实验室分析方法的比较[J]. 广东化工 2021, 48(3): 101-102.
- [4] 杨先锋,但德忠. 化学需氧量(COD)测定法的现状及最新进展[J]. 重庆环境科学 1997(4): 57-61.
- [5] 韦利杭. 化学需氧量快速测定法的研究[J]. 环境污染与防治, 1995(3): 38-41.
- [6] 郑小宏. 闽江口海域化学需氧量与溶解氧周年变化特征分析[J]. 四川环境 2009, 6(28): 65-67.

(编辑:刘媛)

引用本文:李春永,杨中兰. 前处理方式对化学需氧量测定的影响[J]. 人民长江 2021, 52(增2): 41-44.

(上接第26页)

- [8] CHENG C T, NIU W J, FENG Z K, et al. Daily reservoir runoff forecasting method using artificial neural network based on quantum-behaved particle swarm optimization [J]. Water, 2015, 7(8): 4232-4246.
- [9] SHI Y H, EBERHART R C. Empirical study of particle swarm optimization [C] // Congress on Evolutionary Computation, IEEE 2002.
- [10] FOURNIER, AIMÉ. Atmospheric energetics in the wavelet domain. part I: governing equations and interpretation for idealized flows [J]. Journal of the Atmospheric Sciences, 1999, 59(7): 1182-1197.
- [11] ZHUANG W Y, DING W. Long-lead prediction of extreme precipitation cluster via a spatiotemporal convolutional neural network [C] // Proceedings of the 6th International Workshop on Climate Informatics 2016.
- [12] WU Y, LIU Z, XU W, et al. Context aware attention LSTM network for flood prediction [C] // Proceedings of International Conference on Pattern Recognition 2018.
- [13] SHEN Z, ZHANG Y, LU J, et al. SeriesNet: a generative time series forecasting model [C] // 2018 International Joint Conference on Neural Networks (IJCNN) 2018.
- [14] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence 2015, 39(4): 640-651.
- [15] 王玉明, 陈雪芹, 卢益贡, 等. 昌化附近特小流域特大暴雨调查 [J]. 水文 2009, 29(3): 90-92.

(编辑:谢玲娴)

引用本文:巫义锐,郭鸿飞,钱程,等. 基于特征增强与时序感知的洪水预报模型[J]. 人民长江 2021, 52(增2): 21-26, 44.