doi:10.6041/j.issn.1000-1298.2026.23.023

基于水翼振动信号特征的空化多状态分类与识别研究

聂　仑[1]　杨　魏[1,2]　陶　然[1,2]　刘竹青[2,3]　刘晓东[4]　董　亮[5]　江海松[6]

(1. 中国农业大学水利与土木工程学院, 北京 100083; 2. 北京市供水管网系统安全与节能工程技术研究中心, 北京 100083;
3. 东北农业大学水利与土木工程学院, 哈尔滨 150030; 4. 扬州大学电气与能源动力工程学院, 扬州 225009;
5. 江苏大学流体机械工程技术研究中心, 镇江 212013; 6. 承德北方水利水电工程有限公司, 承德 067032)

摘要: 空化是一种流体力学现象,液体内局部压力降低时,液体内部或液固交界面上蒸气或气体的空穴形成、发展和溃灭的过程。空化流动会诱发并加剧泵体振动,影响其安全稳定运行。因此实时监测和准确分类空化状态,对于设备的安全运行和性能优化具有重要作用。本研究提出了一种基于卷积神经网络和 Transformer 相结合的方法,利用水翼的振动信号频率特征来识别空化状态。水翼模型在高速空化隧道中进行了空化水翼流场观测试验,对无空化、空化发展、严重空化 3 种状态下的水翼振动信号进行了采集。首先,通过卷积神经网络(Convolutional neural network, CNN)与引入门控机制(Gated linear unit, GLU),选择性地保留输入信息,提取多尺度特征,并输入到 Transformer 模型中,使用这些特征进行具有自注意力机制的序列到序列的建模,有效地管理复杂的依赖关系。其次,引入稀疏的多头注意力机制,从而降低模型对大量数据分析计算的复杂度。最后,将两个网络集成,提出了混合模型 CNN-GLU-Transformer 算法。结果表明,该方法结合了 CNN 和 Transformer 模型的优点,提升了计算效率,并提高了准确率。本研究选取了 3 组(无空化、空化发展、严重空化)在不同攻角、不同强度的水翼空化进行了试验。此模型的空化分类准确率为 99.70%,本文在测试集上采用的精确率(Precision)、召回率(Recall)、调和分数(F1 分数)均超过了 LSTM、Bi-LSTM、Cov-LSTM、ResNet-CNN、CNN-Transformer 等其他传统方法。结果表明,本模型比 CNN 精确率上提高了 17%,比 ResNet 提高了 23%,比 LSTM 的方法提高了 30%,比 Bi-LSTM 提高了 22%,比 Cov-LSTM 提高了 29%。在这次数据集中,LSTM 表现出相对较低的诊断准确率,仅为 69.18%;相反,CNN-GLU-Transformer 方法展示了最佳的整体诊断性能;该模型显著提升了检测精度,可为离心泵运行中的空化信号诊断提供参考。

关键词: 水翼; 空化试验; 信号检测; 深度学习; 攻角

中图分类号: TG156　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)23-0245-09　　**OSID**:

Cavitation Multi-state Classification and Identification Based on Hydrofoil Vibration Signal Characteristics

Nie Lun[1]　Yang Wei[1,2]　Tao Ran[1,2]　Liu Zhuqing[2,3]　Liu Xiaodong[4]　Dong Liang[5]　Jiang Haisong[6]

(1. *School of Water Resources and Civil Engineering, China Agricultural University, Beijing* 100083, *China*
2. *Beijing Water Supply Network System Safety and Energy Saving Technology Engineering Research Center, Beijing* 100083, *China*
3. *School of Water Resources and Civil Engineering, Northeast Agricultural University, Harbin* 150030, *China*
4. *College of Electrical, Energy and Power Engineering, Yangzhou University, Yangzhou* 225009, *China*
5. *Fluid Machinery Engineering Technology Research Center, Jiangsu University, Zhenjiang* 212013, *China*
6. *Chengde Northern Water Conservancy and Hydropower Engineering Co., Ltd., Chengde* 067032, *China*)

Abstract: Cavitation is a fluid mechanics phenomenon characterized by the formation and collapse of bubbles. Cavitation flow can induce and exacerbate pump vibration, affecting its safe and stable operation. Therefore, real-time monitoring and accurate classification of cavitation states are crucial for the safe operation and performance optimization of equipment. To investigate the impact of deep learning algorithms on the cavitation flow characteristics of centrifugal pumps, a method was proposed based on the

收稿日期: 2025-09-05　修回日期: 2025-10-23

基金项目: 国家自然科学基金项目(U25A20363、52179093、52379085、52409121)

作者简介: 聂仑(1989—),女,博士生,主要从事计算机技术在水力机械领域的应用研究,E-mail: nielun137@163.com

通信作者: 刘竹青(1973—),男,教授,博士生导师,主要从事水力机械流动理论研究,E-mail: lzq@cau.edu.cn

combination of convolutional neural network (CNN) and Transformer, utilizing the frequency characteristics of hydrofoil vibration signals to identify cavitation states. The hydrofoil model was tested in a high-speed cavitation tunnel for observation of the flow field of cavitation hydrofoils, and signals were collected during the initial and developing stages of cavitation on the airfoil. Firstly, by introducing the gated liner unit (GLU), selective input information was retained, multi-scale features were extracted, and put into the Transformer model. These features were then used for sequence-to-sequence modeling with a self-attention mechanism, effectively managing complex dependencies. Secondly, a sparse multi-head attention mechanism was introduced to reduce the complexity of the model's analysis and computation for large datasets. Finally, the two networks were integrated, proposing the hybrid model CNN - GLU - Transformer algorithm. The results showed that this method combined the advantages of CNN and Transformer models, enhancing computational efficiency and improving accuracy. It selected three groups (no cavitation, developing cavitation, severe cavitation) of hydrofoil cavitation with different attack angles and intensities for testing. The accuracy of cavitation classification for this model was 99.70%. On the test set, the precision, recall, and F1-score surpassed that of other traditional methods such as LSTM, Bi - LSTM, Cov - LSTM, ResNet - CNN, and CNN - Transformer. This model significantly improved detection accuracy and provided a reference for cavitation signal diagnosis in centrifugal pump operation.

Key words: hydrofoil; cavitation experiment; signal detection; deep learning; attack angle

0 引言

离心泵的空化类型复杂,空化的结构尺度差异很大,且极其不稳定;其诱导的水动力载荷会造成结构剧烈振动、噪声和空蚀等危害[1-5]。根据空化发生的位置和成因,通常可以将空化分为:翼型空化、旋涡空化、间隙空化和粗糙空化。通常,在泵的性能明显下降之前,不容易注意到气蚀的早期阶段。因此,已经进行了大量的研究,来提高气蚀检测的准确性和及时性,以确保泵的安全性并延长其生命周期。试验是研究离心泵空化现象的重要途径,但由于离心泵内部结构复杂,导致空化观测试验面临诸多挑战。例如,离心泵内部不规则的结构使得图像采集和照明设备的布置困难;此外,叶轮内流场的振动信息难以获取。

为了简化试验过程,研究者通常选择使用结构相对简单的模型,如单个水翼、叶栅或收缩-扩散管等[6-7]。例如,通过水翼在高速水洞中的试验,可以有效地控制影响空化的关键因素,如稳定的来流、规则的流道等,从而更专注于研究空化结构与压力、流速、攻角之间的关系[8-9]。这种方法,有助于揭示空化的机理并建立相应的规律,空化气泡的生成和消亡,对翼型的气动性能有着显著影响;另外,气泡的产生往往会降低局部压力,影响升力分布,而气泡的破裂则可能引起突发性的压力变化,产生振动和噪声;此外,空化现象的持续发展,可能导致翼型表面磨损,甚至引起结构的损伤。水翼发生空化时,伴随着压力脉动、噪声、振动等,这些物理现象在离心泵运行过程中依然存在[10]。因此,深入研究翼型的空化控制,可以为离心泵空化研究提供一些可行的方案。

根据现有的研究[11-13],各种统计和基本机器学习模型,已广泛应用于数据驱动分析和预测领域,以诊断空化信号。深度学习在各个领域都优于传统的机器学习技术,深度学习的端到端学习能力,简化了传统诊断方法固有的特征提取过程,可以直接从原始振动信号中提取特征。因此,越来越多的专业人员和研究人员,正在探索将深度学习用于识别和诊断。随着新的深度学习方法的兴起[14],利用这些先进的算法,对于空化信号监测模型的研究受到了广泛的关注。卷积神经网络(Convolutional neural network)[15-16]通过卷积和池化操作,从输入信号中自动提取空间特征。Siano 等[17]提出了一种将神经网络与非线性回归相结合的时域振动信号空化诊断方法;苏永生等[18]基于振动和噪声信号,利用 BP 神经网络和径向基神经网络对喷水推进泵的空化状态进行了识别研究;Nasiri 等[19]从离心泵的振动信号中提取特征,作为神经网络的输入来检测空化;Tiwari 等[20]从时域压力信号数据中提取了 6 个统计特征,然后将这些特征输入到神经网络中检测堵塞和空化。然而,CNN 对信号中时间特征的提取能力不足,而循环神经网络(Recurrent neural network)及其变体(如 GRU、LSTM),则擅长处理时间序列数据,能从信号中捕捉时间相关性。门控线性单元(Gated linear unit)[21-22]是卷积神经网络中的一种门控机制,与循环神经网络的门控循环单元(GRU)相比,门控线性单元更加容易进行梯度传播,不易造成梯度消失或者梯度爆炸;并且门控机制控制信息

在网络中流动的路径，这一机制已被证明对神经网络有很好的效果，并能带来优越的性能。GLU 可以更好地捕获全局信息，有效降低梯度弥散，同时还可以保留模型的非线性能力。由此可见，结合 CNN 和 GLU 的模型可以充分捕捉振动信号的时空信息，在对时间序列问题的处理上更具优势[23]。近年来，注意力机制被引入来解决传统深度学习模型的局限性[24]，Transformer 模型依赖于自注意力机制，擅长于并行探索信号段之间的全局关系[25-26]。但是，传统 ViT(Vision Transformer)模型的多头注意力机制中，每个注意力头都会同时考虑全部信息，这可能会加重计算负担并限制模型充分利用全局信息。因此引入稀疏的注意力机制，在每个注意力头以稀疏程度分析数据，从而降低模型在不同任务上的计算复杂度。

本文以一水翼为研究对象，通过构建包含高速摄影系统、激光测振仪(Laser Doppler vibrometer)和高频振动传感器的同步测试系统，采集由不同攻角引起的不同水翼振动信号。并提出一种基于稀疏矩阵注意力机制的卷积网络与 Transformer 相结合的神经网络架构，由一个多尺度卷积神经网络(CNN)和一个 Transformer 模块组成。使用 Transformer 模块，基于注意力机制进行分类，使神经网络专注于输入数据的关键方面，从而促进远程依赖关系的获取，并提高可解释性。

1　试验对象与系统

本课题组在瑞士洛桑水力机械实验室的高速空化隧道中，进行了空化水翼流场观测试验，对比观测了翼型的初生空化和空化的发展；该高速空化隧道主要由 3 部分组成：主循环管道系统、压力控制系统和动力系统，如图 1 所示。压力控制系统主要包括压力罐、真空泵和压力控制器，连接在储罐的顶部；试验中，雷诺数保持在 8.0×10^5 ~ 1.2×10^6 范围内，环境温度保持在(20 ± 2)℃ 范围内。该系统可在0 ~ 0.095 MPa 范围内调节环境压力，真空控制精度为 0.005 MPa。该装置可以无级变速运行，为管道提供稳定的流量，其不确定性小于 0.5%。试验时，可通过攻角调节装置调节至目标攻角；攻角调节后，需等待不少于 60 s 时间直至流动稳定；然后，从无空化开始逐渐降低环境压力、诱发空化的初生。采用对称水翼 NACA0009，其二维翼型在展向上具有一致性，如图 2 所示。这保证了水翼前缘空化条件的均匀性，降低了流场的复杂性，有利于空化机理的揭示和规律的构建。原 NACA0009 水翼试验段长 750 mm，翼展方向长度 150 mm(与试验段匹配)；试验时，将翼型安装至翼型试验段相应位置。采样频率为 1 000 Hz，来流平均速度为 10 m/s，并选取 0°、1°、5°、6°、13°、14°共 6 个不同角度作为试验条件。

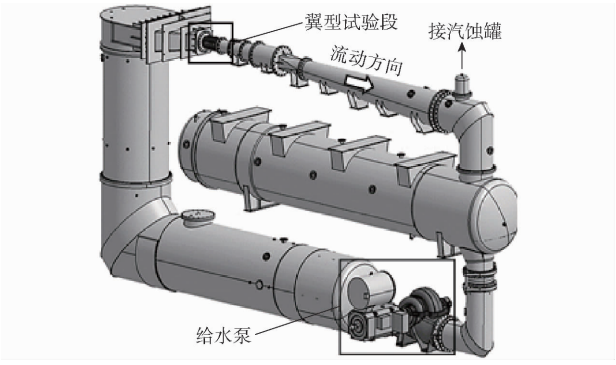

图 1　空化水洞装置示意图[27]

Fig. 1　Schematic of cavitating water tunnel[27]

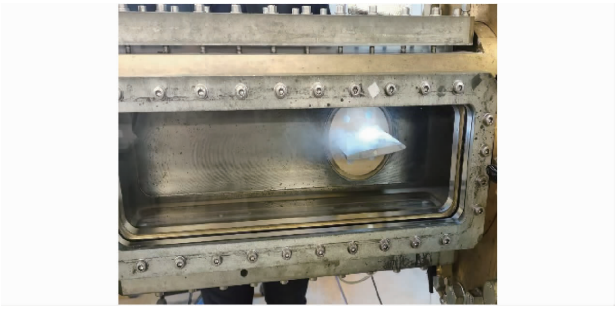

图 2　试验台

Fig. 2　Photograph of test rig

观察区正面和上方采用坚硬透明材料，便于观察和采光，背面用于支撑和固定水翼。空化水翼流场观测试验，包括典型空化图像的采集和空化作用下水翼振动。为了明确空化结构的整体特征，使用高速摄像机从水翼上部进行图像采集、观察和记录(图 3)，并在试验段上方进行照明以增强空化区域的对比度。试验水翼固定在通道的垂直中心，以减少上下壁面对水翼周围流动的影响。

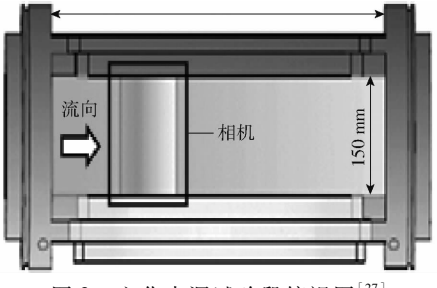

图 3　空化水洞试验段俯视图[27]

Fig. 3　Top view of test section of cavitating water tunnel[27]

空化水翼试验中，使用空化数 σ 表征空化剧烈程度，雷诺数 Re 表征流体流动时惯性力与粘性力的相对大小，定义为

$$\sigma=\frac{p_r-p_v}{0.5\rho v_r^2} \tag{1}$$

$$Re = \frac{U_r L_v}{\nu} \tag{2}$$

式中 p_r——局部静压 p_v——饱和蒸汽压

ρ——液体密度

v_r——转轮出口圆周速度

U_r——试验段入口速度

L_v——水翼弦长

ν——运动黏度

本次水翼试验中,取仪器测得的观测段进口压力作为参考压力。

2 空化机制和数据集

2.1 水翼攻角与空化发展

如图 4 所示,水翼攻角表示水翼弦线与入流方向之间的角度,直接影响水翼表面的压力分布、升力产生和流动分离;随着环境压力逐渐减小,空化剧烈程度逐渐增大; 振动信号也同时增大。通过改变攻角大小,分析了对应于不同空化状态的 3 种不同流态:零攻角、小攻角和大攻角。如图 4a、4b 所示,在攻角较小的情况下,特别是零攻角时,翼型前缘的流体速度较大,局部压力较低,低压区会较长且较宽;在这一阶段,由于流动方向与翼型表面较为平行,顺压梯度区较长,空化现象开始较为缓慢地发展;随着环境压力逐渐减小,流动发生了显著变化,流动状态变得更加复杂,空化发生的区域可能会进一步向翼型表面延伸,空化的强度也随之增加。如图 4c、4d 所示,在低压区域内,空化现象最初表现为从翼型的中部向外扩展的气泡;在空化数降低(即压力进一步减小)时,气泡的生成点可以位于低压区的任何位置;随着流动继续,气泡沿流动方向游移,最终在低压区的外缘溃灭,释放出一定的能量,形成冲击波[28]。较大的攻角通常会增强升力,但也会导致流动不稳定和气蚀发生。

在较小攻角下,翼型表面流动相对平稳,压力沿着翼型表面逐渐增大,低压区通常位于翼型后部;然而,当攻角稍微增大时,翼型表面的顺压梯度区位置向上游移动;这种变化意味着,翼型表面压力的递增区域变短,低压区开始向翼型前缘靠近,进而影响了空化的发生位置和性质;在攻角稍有增大之后,翼型表面尤其是吸力面的顺压梯度区,位置向上游移动;再随着攻角的增大,翼型表面的最低压力点也随之向上游移动,这导致低压区的范围变得更短且更薄。低压区是空化现象的关键区域,因为空化需要在液体的局部压力低于液体的蒸汽压时才能发生,在这一过程中,空化的初生位置发生了明显变化。较低的压力使得空化不再在翼型的中部产生,而是逐渐

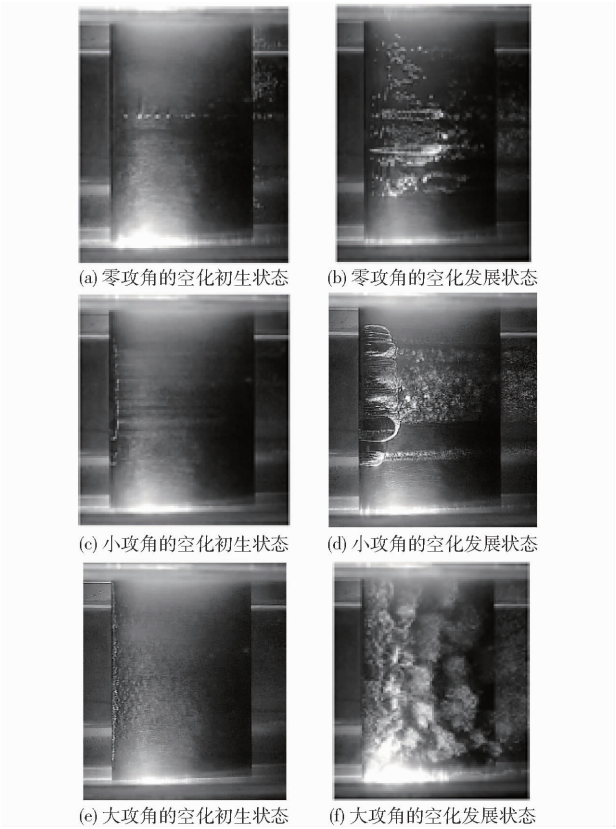

图 4 翼型的典型空化初生与发展形态[29]

Fig. 4 Typical inception and development patterns of cavitation in airfoils[29]

向翼型的前部移动,这表明空化现象与翼型的压力分布有着密切关系,特别是在低压区域的形成和演变过程中。进一步随着攻角的增大,低压区的面积减小且离翼型表面较近,空化现象变得更加局部化,空化开始表现为较薄弱的气泡层覆盖在翼型前缘及其后方的一部分区域[29-30];再进一步随着攻角的增大之后,顺压梯度区的长度逐渐缩短,意味着翼型表面的压力梯度变化变得更为剧烈,低压区的范围变小;特别是在较大攻角下,低压区开始向翼型前缘集中,并且低压区域的高度变得极为薄弱,几乎仅限于翼型前缘的极小范围内;当攻角进一步增大时,流动分离现象愈发明显。流动分离是指水流在翼型表面不再平滑贴合,而是脱离表面形成涡流区,局部压力显著下降。

随着分离区的扩大,空化现象开始由翼型前缘初生,由于低压区域的范围变小空化气泡迅速在前缘处产生,并迅速溃灭;在这一过程中,空化现象的持续时间变得非常短,气泡在形成后几乎立即消失;这是因为低压区的范围较小,空化气泡一旦生成就迅速离开低压区域,导致其在极短的时间内发生溃灭。如图 4f 所示,随着空化数即压力进一步降低,空化的形态也发生了显著变化,空化不再表现为单一的气泡,而是呈现出云状空化特征;这种云状空化

是指空泡团以准周期的方式不断脱落，形成类似云朵的形态；流动分离加剧后，气流的不规则波动和压力波动会导致空泡团不断脱落，产生不规则的空化现象；并在局部区域产生激烈的冲击波。许多学者在试验中观察到了这种空化现象，翼型会经历从传统气泡空化到云状空化的过渡，尤其是在大攻角条件下，翼型表面的流动分离和压力波动成为云状空化形成的关键因素[31-33]。

2.2　空化信号的获取与分析

如图 5 所示，随着环境压力的降低，空化现象会逐渐加剧。攻角的变化会影响翼型表面流动的压力分布，从而改变空化的初生和发展过程；当攻角逐渐增大到 14°时，信号幅值增大为 0°时的 5 倍左右，空化气泡的生成与破裂对水动力性能和结构稳定性具有重要影响。除了受到来流方向、翼型几何等因素影响之外，翼型表面的压力分布还受到粘滞力的影响。

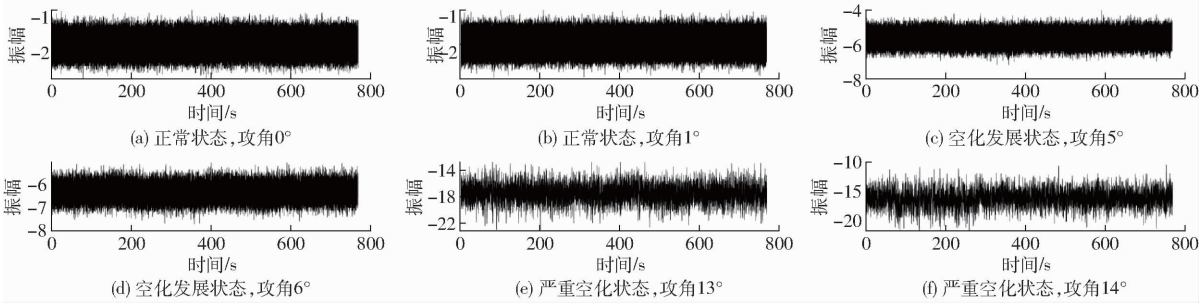

图 5　不同工况下空化信号时域图

Fig. 5　Time domain diagrams of cavitation signal

2.3　信号预处理

此次数据集包含不同空化状态下的振动数据，正常状态、空化发展状态和严重空化状态，每种状态包括两种不同的攻角。将正常状态的样本标记为 0，空化发展状态的样本标记为 1，严重空化状态的样本标记为 2。本次试验采用归一化处理，以消除数据中的量纲和单位差异，公式为

$$X_{new}=\frac{X-X_{min}}{X_{max}-X_{min}} \tag{3}$$

式中　X_{new}——归一化数据

X——原始数据

X_{min}——整个预测期间数据的最小值

X_{max}——整个预测期间数据的最大值

设定步长为 50，重叠长度为 974，按每次步长进行数据切片，得到 50 000 个数据集样本、40 000 个训练数据集样本和 10 000 个测试数据集样本。

3　分类模型选取与优化

3.1　基于稀疏注意力的 CNN－GLU－Transformer 空化信号分类方法

Transformer 模型已被证明在解决许多任务的远程依赖问题方面非常出色；然而，要实现高性能，需要大量的计算；此外，该模型在提取局部信息的能力上也有一定的局限性。为了解决这些问题，本文提出了一种局部信息增强和稀疏注意机制 Transformer（CNN－GLU－Transformer）模型。首先，卷积神经网络具有局部连接和权值共享的特点，因此本文通过引入 GLU 等注意力机制对卷积神经网络进行优化。从深度和多尺度捕获数据之间的局部信息，实现局部信息的特征融合和增强；其次，通过稀疏注意机制，保留了数据之间的远程依赖关系；最后，改进模型的计算复杂度从二次型降低到线性型，同时保留了捕获远程依赖关系的能力。该网络的具体结构参数如表 1 所示。

表 1　CNN－GLU－Transformer 网络的结构参数

Tab. 1　Structural parameters of CNN－GLU－Transformer network

类型	层	步	输入大小	输出大小
Block1	Convolution	7/1/16	1 512	16 506
	BN	/	/	/
	ReLU	/	/	/
	Pooling	4/4/16	16 506	16 126
Block2	Convolution	3/1/32	16 126	32 124
	BN	/	/	/
	ReLU	/	/	/
	Pooling	4/4/32	32,124	32,31
Block3	Convolution	3/1/64	32,31	64,29
	BN	/	/	/
	ReLU	/	/	/
	Pooling	4/4/16	64,29	64,7
Block4	Convolution	3/1/16	32,31	64,29
	BN	/	/	/
	ReLU	/	/	/
	Pooling	4/4/16	64,5	64,1
Encoder	Convolution	4/4/16	64,1	64,1
Decoder	Linear	10/16	64,1	10,1

3.1.1　CNN 模型

CNN 即卷积神经网络。这是一种深度神经网

络,适合涉及图像的任务,如图像识别、分类、分割和对象检测。CNN 的架构包括多层,如卷积层、池化层、激活函数、全连接层等。卷积层使用可学习的过滤器或核执行卷积操作,从输入图像中提取特征。在图像上滑动卷积核时,只关注卷积核的局部像素区域,这种操作的优势在于权重共享,即使用相同卷积核可以在图像中不同位置感知相似特征。此外,非线性激活函数可以增强模型对特征的表达能力,池化操作有助于降低模型输出的维度。卷积层和池化层的计算过程可分别表示为

$$y_{conv}^{m+1} = F\left(\sum_{i=1}^{N}\sum_{j=1}^{K} W_{i,j}^{m} X_i^m + b_{i,j}^m\right) \tag{4}$$

$$y_{pool}^{m+1} = \text{pooling}(y_{conv}^{m+1}) \tag{5}$$

式中 $W_{i,j}^m$、$b_{i,j}^m$——第 m 层卷积层中第 j 个卷积核的权重、偏置

X_i^m——第 m 层卷积层的第 i 个输入

y_{conv}^{m+1}——卷积操作后的输出特征图

F、pooling( )——激活函数、池化函数

3.1.2 GLU 模型

GLU 模型(门控线性单元)是一种在深度学习中用于增强模型表现的激活函数。GLU 通过引入门控机制,使得模型能够选择性地通过信息,从而提高模型的表达能力和性能。这种机制允许模型动态地选择哪些特征应该被保留或抑制,从而增强特征的表达能力。GLU 激活函数的定义为

$$GLU = \boldsymbol{x} \otimes (\boldsymbol{g}(\boldsymbol{x})) \tag{6}$$

式中 $\boldsymbol{x}$——输入向量,表示逐元素相乘

$\boldsymbol{g}(\boldsymbol{x})$——通过全连接层或卷积层得到的中间向量

门控机制使得 GLU 能够选择性地过滤输入向量的某些部分,并根据输入的上下文来调整输出。这种机制可以有效地减少噪声和不相关信息的影响,提高网络的表达能力和泛化能力。

3.1.3 1D-CNN 模型和 CNN-GLU 模型

1D-CNN 卷积层主要通过卷积核在输入数据上滑动,依靠权重共享和局部连接,提取局部特征。卷积操作能够捕捉到输入数据中的局部模式和结构,例如图像中的边缘、纹理等。卷积层的输出是特征图,每一层的特征图会逐渐抽象化,从低层的简单边缘到高层的复杂语义。GLU 是一种门控机制,它将输入数据分为两部分:一部分经过线性变换;另一部分经过非线性激活(如 Sigmoid)后作为门控信号,控制线性变换部分的输出。这种机制允许模型动态地选择哪些特征应该被保留或抑制,从而增强特征的表达能力。本文使用 GLU 门控机制替代 CNN 卷积提取的部分。GLU 由于引入了门控机制,能够更灵活地选择特征,适用高维数据处理。因此允许部分信息直接流入下一层,减少信息丢失,同时过滤掉无关特征,可以更高效地提取出对任务更有意义的特征。在语言模型中,GLU 能够更好地捕捉文本中的长距离依赖关系;在并行计算能力上卷积操作本身是并行的,每个卷积核和每个滑动窗口位置之间没有依赖关系,因此可以高效地利用 GPU 等硬件资源。此外,GLU 的门控机制可以进一步优化特征提取的效率。传统的 CNN 卷积层在某些任务上可能会遇到收敛速度较慢的问题,尤其是在处理复杂的长距离依赖关系时。而 GLU 在模型收敛速度上表现更好。

3.2 Transformer 模型

3.2.1 位置编码

Transformer 模型由一个编码器和一个解码器组成,将序列到序列的架构连接在一起。为了对输入序列的顺序进行说明,因此将位置编码 $\boldsymbol{P}$ 添加到输入序列中,这个向量能决定当前数据的位置。这里使用不同频率的正弦与余弦进行位置编码,计算公式分别为

$$p_{2S+1}^{(2S)} = \sin\left(\frac{i}{10\,000^{2S/d_{mod}}}\right) \tag{7}$$

$$p_{2S+1}^{(2S)} = \cos\left(\frac{i}{10\,000^{2S/d_{mod}}}\right) \tag{8}$$

式中 i——序列数据的位置索引

S——向量维数

d_{mod}——全连通映射得到的顺序数据的维数

3.2.2 稀疏注意机制

MHA(Multi-head attention mechanism)即多头自注意机制,由多个平行的自注意机制组成。自注意力机制在捕获序列数据中的远程关系和全局依赖方面展示了强大的功能,这是 Transformer 网络中的核心算法。自注意层将输入序列线性变换为 3 个新的矩阵:查询向量 $\boldsymbol{Q}$、键向量 $\boldsymbol{K}$ 和值向量 $\boldsymbol{V}$,然后计算 $\boldsymbol{Q}$ 与转置矩阵的点积,并除以一个比例因子 $\sqrt{d_K}$,以分散注意力聚集,提高模型的泛化性能。随后,通过 Softmax 归一化函数获得权重,最后将 $\boldsymbol{V}$ 向量乘以 Softmax 函数的结果,以减少对不相关序列的关注。具体计算过程可表示为

$$\text{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \text{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_K}}\right)\boldsymbol{V} \tag{9}$$

式中 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$——查询向量、键向量、值向量

Attention——自注意力机制的输出函数

softmax——归一化指数函数

d_K——键向量维度

由于 $\boldsymbol{K}$ 和 $\boldsymbol{V}$ 的高维数,原始的自注意机制存在计算效率低下的问题;与原有的自我注意机制相比,

稀疏注意机制(Multi-head sparse attention mechanism, MSA)是为处理大规模序列数据而设计的一种模型。它采用稀疏注意机制,在保持模型性能的同时降低计算复杂度。此模型特别适合处理由于序列长度过大而难以用传统 Transformer 模型处理的任务。稀疏转换器的关键在于其分解注意机制,稀疏注意机制的原理是引入一种稀疏的方法来选择与每个查询相关的键。通常是通过引入掩码矩阵,掩码矩阵可以按照一定的规则选择与每个查询相关的键,例如只选择最接近查询的 k 个键进行计算,这样可以大大减少计算量,提高模型的效率,计算公式为

$$C_i^t = \mathrm{Concat}[h_{i-1}^{t-1}; h_i^{t-1}; h_{i+1}^{t-1}; h_i^0; \boldsymbol{S}^{t-1}] \quad (10)$$

$$\mathrm{MSAttention}(q, H) = \mathrm{Concat}(head_1, \cdots, head_a, \cdots, head_h)\boldsymbol{W}^O \quad (11)$$

$$head_a = \mathrm{MSAttention}(qW_Q, KW_K, VW_V) \quad (12)$$

式中　h——多头注意力中头的数量

$head_a$——多头稀疏注意机制中第 a 个的计算结果

C——第 i 个样本数据的上下文信息

Concat——矩阵拼接函数

$\boldsymbol{S}^{t-1}$——第 $t-1$ 层中继节点的状态向量

$\boldsymbol{W}^O$——输出投影矩阵

q——每个样本数据的高维嵌入

多头稀疏注意力机制中,W_Q、KW_K、VW_V 是可学习的参数,表示两个相同尺寸的矩阵按照对应位置作乘法运算。

4　结果与分析

4.1　试验环境

所有试验都在一台配备 Intel(R) Xeon(R) Gold 6330 CPU @ 2.00 GHz 和 NVIDIA RTX 3090 的计算机上进行。Python 3.8 和 PyTorch 2.1.0 用于构建和训练模型。

4.2　基准模型对比试验

表 2 的结果表明,本模型比 CNN 提高了 17%,比 ResNet 提高了 23%,比 LSTM 的方法提高了 30%,比 Bi-LSTM 提高了 22%,比 Cov-LSTM 提高了 29%。本研究将与 CNN、LSTM、Bi-LSTM、Cov-LSTM、ResNet 等 5 种算法进行了全面比较。在这个数据集中,LSTM 表现出相对较低的诊断准确率,仅为 69.18%;相反,CNN-GLU-Transformer 方法展示了最佳的整体诊断性能,为 99.70%。

表 2　不同模型的试验结果对比

Tab.2　Comparison of experimental results of different models　%

模型	准确率	召回率	精度	F1 分数
LSTM	69.18	70.17	69.00	68.94
Cov-LSTM	72.30	70.20	70.60	72.30
Bi-LSTM	76.50	70.70	77.30	76.50
ResNet	76.25	76.17	76.55	76.25
CNN[15-16]	81.37	81.36	81.78	81.25
CNN-Transformr	97.53	97.56	97.53	97.53
CNN-GLU-Transformer	99.70	99.70	99.70	99.70

4.3　消融试验

对 CNN-GLU-Transformer 模型的有效性进行了全面研究,结果如表 3、图 6 所示。可以看出,通过对各个模块的消融试验,准确率、召回率等试验

表 3　CNN-GLU-Transformer 的消融试验结果

Tab.3　Ablation experimental results of CNN-GLU-Transformer　%

模型	精度	召回率	准确率	F1 分数
CNN-GLU-Transformer	99.70	99.70	99.70	99.70
-CNN 卷积网络	93.51	93.51	93.51	93.23
-稀疏矩阵	99.51	99.52	99.52	99.52
-GLU 门控	99.01	99.01	99.01	99.01

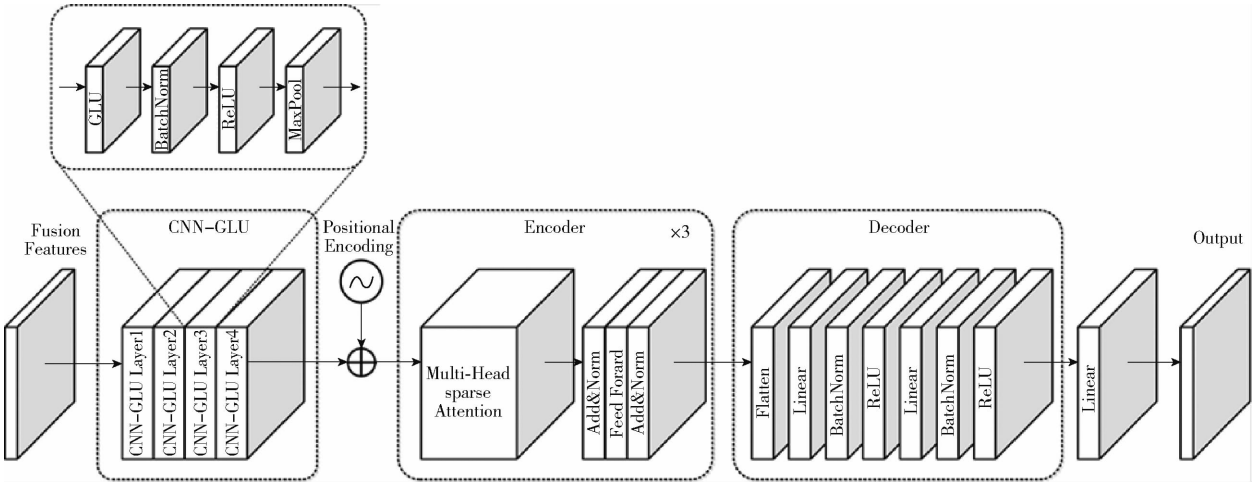

图 6　CNN-GLU-Transformer 原理图

Fig.6　Schematic of CNN-GLU-Transformer

结果反映了各个模块在改进分类网络方面的有效性,可以得出以下结论:去掉 CNN 卷积网络的 Transformer 编码器的模型(-CNN 卷积网络),相比于 CNN-GLU-Transformer 在数据集上 F1 分数下降了 6.47 个百分点,准确率、精确率也下降了 6.19 个百分点。去掉稀疏矩阵的 Transformer 编码器的模型(-稀疏矩阵),相比于 CNN-GLU-Transformer 在数据集上 F1 分数、召回率下降了 0.18 个百分点,整体准确率也下降了 0.19 个百分点。去掉 GLU 门控卷积的 Transformer 编码器的模型(-GLU 门控),相比于 CNN-GLU-Transformer 在数据集上 F1 分数下降了 0.69 个百分点,整体准确率、精度也下降了 0.69 个百分点。

5 结论

(1)本研究提出了一种基于稀疏矩阵注意力机制的卷积网络与 Transformer 相结合的神经网络架构。它由一个多尺度卷积神经网络(CNN)和一个 Transformer 模块组成。这种方法结合了 CNN 和 Transformer 模型的优点,从而提高识别和分类性能。通过 CNN-GLU 网络引入门控机制选择性地保留输入信息,提取多尺度特征并输入到 Transformer 模型,使用这些特征进行具有自注意力机制的序列到序列建模,有效地管理复杂的依赖关系。

(2)模型引入了稀疏的多头注意力机制,从而降低模型在大量数据分析的计算复杂度。为了验证所提出的 CNN-GLU-Transformer 模型的性能,通过消融试验验证了基于 CNN 的局部信息提取模块和基于稀疏注意力机制的全局信息捕获模块的有效性;并通过与其他算法进行水翼空化信号强度的对比试验,与 CNN、LSTM、Bi-LSTM、Cov-LSTM、ResNet 等 5 种算法进行了全面比较,该预测模型在测试集上的预测准确率为 99.70%,远高于其他方法。

参 考 文 献

[1] 王福军. 水泵与水泵站[M]. 北京: 中国农业出版社, 2021.

[2] Kan K, Zheng Y, Chen Y, et al. Numerical study on the internal flow characteristics of an axial-flow pump under stall conditions[J]. Journal of Mechanical Science and Technology, 2018, 32(10): 4683-4695.

[3] Liu H, Liu D, Wang Y, et al. Experimental investigation and numerical analysis of unsteady attached sheet cavitating flows in a centrifugal pump[J]. Journal of Hydrodynamics, 2013, 25(3): 370-378.

[4] Lei T, Shan Z B, Liang C S, et al. Numerical simulation of unsteady cavitation flow in a centrifugal pump at off-design conditions[J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2013, 228(11): 1994-2006.

[5] Cao W, Jia Z, Zhao Z, et al. Validation and simulation of cavitation flow in a centrifugal pump by filter-based turbulence model [J]. Engineering Applications of Computational Fluid Mechanics, 2022, 16(1): 1724-1738.

[6] Ge M, Petkovšek M, Zhang G,et al. Cavitation dynamics and thermodynamic effects at elevated temperatures in a small Venturi channel[J]. International Journal of Heat and Mass Transfer, 2021, 170: 120970.

[7] Ye W, Yi Y, Luo X. Numerical modeling of unsteady cavitating flow over a hydrofoil with consideration of surface curvature [J]. Ocean Engineering, 2020, 205: 107305.

[8] Che B, Cao L, Chu N, et al. Dynamic behaviors of re-entrant jet and cavity shedding during transitional cavity oscillation on NACA0015 hydrofoil[J]. Journal of Fluids Engineering, 2019, 141(6): 061101.

[9] Foeth E. The structure of three-dimensional sheet cavitation[D]. Delft: Delft University of Technology, 2008.

[10] 张伟,杨朴,朱兵. 云空化结构的溃灭与空蚀风险预估研究进展[J]. 空气动力学学报,2020,38(4):761-770.
Zhang Wei, Yang Pu, Zhu Bing. Review of cloud cavitation structure collapse and its prediction of erosion risk[J]. Acta Aerodynamica Sinica, 2020, 38(4): 761-770. (in Chinese)

[11] 李志杰,兰媛,黄家海,等. 基于 CBLRE 模型的轴向柱塞泵空化状态检测研究[J]. 机电工程,2022,39(5):634-640.
Li Zhijie, Lan Yuan, Huang Jiahai, et al. Research on cavitation state detection of axial piston pump based on CBLRE model [J]. Mechanical and Electrical Engineering, 2022, 39(5): 634-640. (in Chinese)

[12] 刘忠,潘宜桦,邹淑云,等. 基于优化 VMD 组合降噪和 LMD 的水轮机空化声发射信号特征提取[J]. 排灌机械工程学报,2022,40(10):1007-1013.
Liu Zhong, Pan Yihua, Zou Shuyun, et al. Feature extraction of acoustic emission signals from turbine cavitation based on optimized VMD combined noise reduction and LMD[J]. Journal of Drainage and Irrigation Machinery Engineering, 2022, 40(10): 1007-1013. (in Chinese)

[13] Zhao G, Cao L, Wu R, et al. Wavelet-based multiresolution analysis of cavitation-induced loading instabilities under phase effect in a waterjet pump[J]. Ocean Engineering, 2021, 240:109918.

[14] 魏晓良,潮群,陶建峰,等. 基于频谱分析和卷积神经网络的高速轴向柱塞泵空化故障诊断[J]. 液压与气动,2021,45(7):7-13.

[15] Dong L, Wu K, Zhu J, et al. Cavitation detection in centrifugal pump based on interior flow-borne noise using WPD-PCA-

RBF[J]. Shock and Vibration, 2019,2019:8768043.

[16] 梁兴,罗远兴,邓飞,等. 多传感器数据下基于 MFDFA－BP 的离心泵空化致振故障分析[J]. 振动与冲击,2022,41(17):238－243.
Liang Xing, Luo Yuanxing, Deng Fei, et al. Cavitation induced vibration fault analysis of centrifugal pump based on MFDFA－BP with multi-sensor data[J]. Journal of Vibration and Shock, 2022, 41(17): 238－243. (in Chinese)

[17] Siano D, Panza M A. Diagnostic method by using vibration analysis for pump fault detection[J]. Energy Procedia, 2018, 148: 10－17.

[18] 苏永生,王永生,段向阳. 基于多传感器数据融合的喷水推进泵空化分类识别[J]. 振动与冲击,2012,31(18):93－96.

[19] Nasiri M R, Mahjoob M J, Vahid-Alizadeh H. Vibration signature analysis for detecting cavitation in centrifugal pumps using neural networks[C]//2011 IEEE International Conference on Mechatronics. IEEE, 2011: 632－635.

[20] Tiwari R, Bordoloi D J, Dewangan A. Blockage and cavitation detection in centrifugal pumps from dynamic pressure signal using deep learning algorithm[J]. Measurement, 2021, 173: 108676.

[21] 孙承爱,丁宇,田刚. 基于 GLU－CNN 和 Attention－BiLSTM 的神经网络情感倾向性分析[J]. 软件,2019,40(7):62－66.
Sun Cheng'ai, Ding Yu, Tian Gang. Neural network affective tendency analysis based on GLU－CNN and Attention－BiLSTM [J]. Software, 2019, 40(7):62－66. (in Chinese)

[22] 彭飞鸿,刘万平,黄东. 基于 CBAM－GLU－ISF 的多模态融合恶意软件检测方法[J]. 计算机工程与应用,2024,61(20):306－314.

[23] Guo Q, Qiu X, Liu P, et al. Multi-scale self-attention for text classification[J]. AAAI,2020,34(5):7847－7854.

[24] Li J, Tu Z, Yang B, et al. Multi-head attention with disagreement regularization[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018:2897－2903.

[25] 谢再秘, 王骥, 莫春梅. IFWA 优化的 BLSTM 与 transformer 融合构建海水三维预测模型[J]. 农业工程学报, 2023, 39(4): 162－170.
Xie Zaimi, Wang Ji, Mo Chunmei. IFWA's optimized BLSTM and transformer are integrated to build a 3D seawater prediction model[J]. Transactions of the CSAE, 2023, 39(4): 162－170. (in Chinese)

[26] 刘茜, 易诗, 李立, 等. 基于轻量级 CNN－Transformer 混合网络的梯田图像语义分割[J]. 农业工程学报, 2023, 39(13): 171－181.
Liu Xi, Yi Shi, Li Li, et al. Semantic segmentation of terrace image regions based on lightweight CNN－Transformer hybrid networks[J]. Transactions of the CSAE, 2023, 39(13): 171－181. (in Chinese)

[27] Holl J W, Carroll J A. A new high-speed cavitation tunnel for cavitation studies in hydraulic machinery[J]. Comment on AJR Am J Roentgenol, 2008, 190(5): 1149－1151.

[28] Beltagy I, Peters M E, Cohan A. Longformer: the long-document transformer[PP/OL]. V2. arXiv (2020－12－02)[2025－10－23]. https://doi.org/10.48550/arXiv.2004.05150.

[29] Guennoun M F. Etude physique de l'apparition et du développement de la cavitation sur une aube isolée[D]. Lausanne: École Polytechnique Fédérale de Lausanne, 2006.

[30] 曹彦涛,彭晓星,张国平,等. 绕三维扭曲水翼云空化形成及演化的试验研究[J]. 船舶力学,2014,18(5):485－491.
Cao Yantao, Peng Xiaoxing, Zhang Guoping, et al. Experimental study on the generation and development of cloud cavitation around a three dimensional twisted hydrofoil[J]. Journal of Ship Mechanics, 2014, 18(5): 485－491. (in Chinese)

[31] 时素果,王国玉,王复峰,等. 绕三维水翼云状空化现象的实验研究[J]. 应用力学学报,2011,28(2):105－110.
Shi Suguo, Wang Guoyu, Wang Fufeng, et al. Experimental study of cloud cavitation around three-dimensional hydrofoil[J]. Chinese Journal of Applied Mechanics, 2011, 28(2): 105－110. (in Chinese)

[32] Zhang Q, Lin Y, El Moctar O, et al. Data-driven identification of cavitation regimes using acoustic signatures of hydrofoil[J]. Physics of Fluids, 2025, 37:047147.

[33] 陶然. 叶片前缘几何特征对水泵水轮机初生空化的影响研究[D]. 北京:中国农业大学,2018.
Tao Ran. Study of the influence of blade leading-edge geometry on the inception cavitation of reversible pump-turbine[D]. Beijing: China Agricultural University, 2018. (in Chinese)