

考虑注意力机制的 CNN-LSTM 高渗透风电并网 暂态电压稳定性研究

张红颖¹, 贾一超¹, 汪江志², 张巍²

(1.中国电力科学研究院有限公司, 江苏 南京 210037; 2.上海理工大学 机械工程学院, 上海 200093)

摘要: 为了能够快速且精确地判断出风电场接入电网后系统暂态电压稳定性,文章基于注意力机制提出一种卷积-长短时记忆网络(Convolutional Neural Networks-Long Short-Term Memory, CNN-LSTM)暂态稳定评估指标。为了更好地捕捉输入数据中空间和时间的相关性,基于核主成分分析(Kernel Principal Component Analysis, KPCA)进行特征降维;针对高比例的新能源电网中,整个系统的短路容量下降、短路电流水平攀升问题,提出了安装超导故障限流器的主动支撑措施,限制故障过程短路电流水平,维持并网点电压稳定。最后,在PSD-BPA中搭建含风电的IEEE39节点系统进行仿真计算和数据采集。结果表明,KPCA方案能有效筛选电力系统暂态稳定评估中重要度高的特征,所提评估指标具有更高的辨识能力,所提改进措施对高比例风电并网系统暂态电压稳定具有积极作用。

关键词: 风电并网; 暂态电压稳定; 暂态评估指标; 故障限流器

中图分类号: TK81; TM712 **文献标志码:** A **文章编号:** 1671-5292(2024)03-0398-09

0 引言

在低碳绿色发展的背景下,风能作为一种清洁能源,其资源量和环境友好的特性具有化石能源无法比拟的优势。风能必将逐步成为化石能源的替代品,为实现“双碳”目标和促进国民经济绿色低碳发展提供坚实的保障^[1]。风电的装机容量在电力系统中的占比不断提高,风能的间断性和随机性,以及不同风电机组间的强耦合和非线性特性,使得风电并网系统的运行条件和特性较传统火电并网系统更加复杂,对电力系统暂态电压稳定性带来了严重挑战^[2]。

20世纪80年代末,机器学习方法逐步在电力系统暂态稳定评估问题中得到推广使用。随着广域测量技术的发展和人工智能技术的成熟,基于人工智能的方法为大电网数据的智能分析提供了新的途径。已有相关研究采用神经网络进行暂态稳定评估,导致大量信息浪费。研究人员针对如何最大限度地发挥单一神经网络的优势,提高人工智能暂态稳定评估方法的实用性展开了大量研究。文献[3]基于BP神经网络模型,利用故障前后采集的传统物理量和与风电场相关的物理量,作为输入特征量进行监督学习,该模型最终可应用于评估风电并网系统的暂态电压稳定

性。文献[4]提出了一种基于grcForest模型的方法,用于风电并网系统的暂态电压稳定性评估。尽管这种方法在提高评估准确性和速度方面有一定改进,但仍须要进一步优化。文献[5]提出了一种基于一维卷积神经网络的暂态电压稳定性评估方法,该方法利用卷积神经网络提取特征,通过输入特征和评估结果之间的映射关系来建立评估模型。文献[6]提出了一种基于时间卷积网络和图注意力网络的方法用于暂态稳定性评估,该方法利用图注意力网络处理图数据,并建立电网拓扑连接关系,以提取空间特征和时间特征,在不完全配置条件下,图注意力网络的泛化能力较弱。已有研究大多关注系统暂态功角稳定性评估,对于暂态电压稳定性评估研究还不够充分,涉及到高比例风电接入的暂态电压稳定性评估的研究更加匮乏,同时大多数研究都只停留于暂态稳定性评估,并未提出相应的改进措施^[7,8]。

电网电压发生骤降时,采用风电暂态电压主动支撑技术可以支撑电网电压^[9],确保风电机组及风电场在低电压穿越时不脱网。然而,改变系统结构参数以限制电压降落的成本高昂,而且会影响并网系统的稳定运行。此外,电抗器、高阻抗变压器等设备接入会增加系统网损,从而对系统的稳

收稿日期: 2023-07-03。

基金项目: 国家电网有限公司科技项目(5100-202255379A-2-0-ZN)。

作者简介: 张红颖(1992-),女,硕士,工程师,主要从事新能源并网控制及大电网仿真分析工作。E-mail: zhanghongying@epri.sgcc.com.cn

定性产生不利影响^[10]。使用故障电流限制器是解决风电系统故障电压越限问题的有效方案,该装置可以显著提高风电机组的低电压穿越能力,并为双馈风电暂态电压主动支撑技术的应用提供有力保障^[11]。

为进一步评估系统受扰后的暂态稳定性,本文基于注意力机制提出一种 CNN-LSTM 暂态稳定性评估模型,针对暂态电流越限问题提出安装超导短路限流器的主动支撑措施,改善风电场系统无功环境,维持并网点电压稳定。最后,在 PSD-BPA 中搭建含风电的 IEEE39 节点系统进行仿真模拟和数据收集用于模型训练。结果表明,本文所提评估指标具有更高的识别率,所提改进措施对提高系统暂态稳定性具有积极作用。

1 CNN-LSTM-Attention 暂态稳定性评估模型

在实际工程中,通过判断持续时间是否超过给定值来评估暂态电压的稳定性,该持续时间是指暂态电压偏移某一阈值的时间。随着人工智能技术的迅速发展,在电力系统暂态稳定性评估中广泛采用了机器学习和模糊逻辑技术等方法。

1.1 特征选取降维

在电力系统暂态稳定性评估中,样本数据即为学习模型的输入,样本数据 x 可表示为 $x=[x_1^D, x_2^D, \dots, x_n^D]$, D 为样本个数, n 为特征数。

本文从时间、空间、系统规模的角度选取了 28 组原始特征,如表 1 所示。

表 1 原始特征集
Table 1 Original feature set

名称	特征属性
特征 1	故障前后,系统的总能量调整 x_1
特征 2	故障的瞬间,双馈风机受到的最大有功功率冲击 x_2
特征 3	故障的瞬间,双馈风机受到的最小有功功率冲击 x_3
特征 4	故障的瞬间,双馈风机加速功率的平均值 x_4
特征 5	故障的瞬间,最大加速度的发电机的相对初始角度 x_5
特征 6	故障的瞬间,双馈风机转子加速度的最大值 x_6
特征 7	故障的瞬间,双馈风机转子加速度的方差 x_7
特征 8	故障切除时,最大转子角度的双馈风机转子动能 x_8
特征 9	故障切除时,对系统的有功冲击 x_9
特征 10	故障切除时,双馈风机转子加速功率的平均值 x_{10}
特征 11	故障切除时,最大转子动能的发电机转子角度 x_{11}
特征 12	故障切除时,转角与惯性中心角相差的最大值 x_{12}
特征 13	故障切除时,双馈风机与惯性中心最大转速差值 x_{13}
特征 14	故障切除时,双馈风机角速度最大值与最小值之差 x_{14}
特征 15	故障切除时,双馈风机的转子动能最大值 x_{15}

续表 1

名称	特征属性
特征 16	故障切除时,双馈风机转子动能的平均值 x_{16}
特征 17	故障切除时,双馈风机转子的最大加速度之差 x_{17}
特征 18	故障切除时,双馈风机转子动能的最大差值 x_{18}
特征 19	故障后,各节点电压幅值之和的平均值 x_{19}
特征 20	故障后,各节点电压相角之和的平均值 x_{20}
特征 21	故障后,各双馈风机有功功率之和的平均值 x_{21}
特征 22	故障后,各双馈风机无功功率之和的平均值 x_{22}
特征 23	故障后,各双馈风机功角之和的平均值 x_{23}
特征 24	故障切除时,风电场并网点电压 x_{24}
特征 25	故障切除时,风电场增发的无功 x_{25}
特征 26	故障切除时,风电场减少的出力 x_{26}
特征 27	故障切除时,双馈风机的 q 轴转子电流的变化量 x_{27}
特征 28	故障切除时,双馈风机的 d 轴转子电流变化量 x_{28}

电力系统是一个复杂的非线性系统,高比例风电接入电网进一步增加了系统的复杂度,采用传统线性方法进行数据处理计算效率低下。因此,本文考虑采用非线性降维方法对输入特征进行降维。核主成分分析(KPCA)是一种非线性数据处理方法,其核心思想是通过非线性映射将原始空间中的数据投影到高维特征空间,然后在该特征空间中采用主成分分析(PCA)进行数据处理^[12]。

给定样本矩阵 x , x 为 D 维列向量,共 n 个样本, $D \times n$ 维矩阵所在的空间称为输入空间,引入非线性变换 φ 将输入空间映射到高维特征空间,这个高维空间称为特征空间 Γ ,对 Γ 进行 KPCA 降维,定义协方差矩阵 C_T 如下:

$$C_T = \frac{1}{n} \sum_{i=1}^n \varphi(x_i) \varphi(x_i)^T \quad (1)$$

求解协方差矩阵的特征值 λ 和特征向量 V :

$$C_T V = \lambda V \quad (2)$$

将式(2)乘以 $\varphi(x)$,利用主成分应用系数 $\alpha_i = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ 将 V 线性表示为

$$\lambda \sum_{i=1}^n \alpha_i [\varphi(x_k) \varphi(x_i)] = \frac{1}{n} \sum_{i=1}^n \alpha_i [\varphi(x_k) \sum_{i=1}^n \varphi(x_i)] \times [\varphi(x_j) \varphi(x_i)] \quad (3)$$

引入 K 为 $n \times n$ 维正半定核矩阵,高斯径向基核函数计算方法简单,分类效果好,因此本文采用高斯径向基核函数作为核主成分分析的核函数^[13]。

$$K_{ij} = \exp\left(-\frac{\|x_j - x_i\|}{2\sigma^2}\right) \quad (4)$$

式中: $i=1, 2, \dots, n; j=1, 2, \dots, n; \sigma$ 为函数跌落到零

的速度,取值 0.5。

将 $K=\varphi(x)^T \varphi(x)$ 代入式(3)得:

$$n\lambda K\alpha=K^2\alpha\Rightarrow n\lambda\alpha=K\alpha \quad (5)$$

通过对式(5)进行求解,得到特征值问题的非零特征值和矩阵 K 的第 k 个特征向量 α_i^k ,利用式(6)求解特征空间主元方向,即特征向量。

$$V_k=\sum_{i=1}^n \alpha_i^k \varphi(x_i) \quad (6)$$

将式(6)代入式(3)可求解出对应的特征值 λ_k ,对特征值进行降序排序,确定主成分个数后根据排列顺序选取对应主成分特征,形成降维特征集。采用累计方差贡献率确定主成分个数:

$$R_{CVC}=\frac{\sum_{i=1}^K \lambda_i}{\sum_{i=1}^n \lambda_i} \quad (7)$$

1.2 通道注意力机制

CNN 具有参数共享、局部感知的特点,能够快速且精准地提取样本特征,获取更多隐藏特征信息,但在处理较长时间序列时效果不佳。LSTM 作为 CNN 的变种模型,通过遗传门、输入门、输出门的结构,能够有效记忆长时间序列信息,通过联系前后信息的特征得到更多数据。两个神经网络对于时序数据的非线性问题均有较好的处理能力,处理方式与结果各有优势。为了提升模型的性能,本文将 CNN 与 LSTM 串联结合,形成 CNN-LSTM 模型,该模型能够精准提取暂态特征并且可以有效解决学习时序数据中长期依赖信息的问题。但是在训练该模型时,会忽略各通道信息的重要程度,造成资源分布不均,分辨效果下降^[14]。因此,本文将注意力机制引入模型,通过注意力机制并根据重要程度对 CNN 中各输出特征通道赋予不同的权重系数,对 LSTM 下各时序特征赋予不同的权重系数,保证序列长度增加时,重要特征不会丢失,以此实现分辨准确率的提升。本文在训练模型时选用了通道注意力机制(Channel Attention Module, CAM)^[15],该机制主要是通过网络训练得到的损失值(Loss)来不断学习更新特征权重,通过了解到的每个特征面的重要程度,根据重要性依次给每个特征通道赋予权重值,重要性强的特征面权重重大,重要性弱的特征面权重小,从

而使得有限的神经网络用于计算有效特征面,减少参数与计算量。通道注意力机制的具体结构如图 1 所示。




图 1 通道注意力机制具体结构

Fig.1 The specific structure of the channel attention mechanism

由图 1 可知,一个 $H' \times W' \times C'$ 的特征图 X 在经过卷积操作后变为一个 $H \times W \times C$ 的特征图 U ,特征图 U 经过 Squeeze 操作后变为一个 $1 \times 1 \times C$ 的矩阵,然后再经过 Excitation 操作,根据重要度给每一个特征通道赋予相应的权重值,最后被赋予权重的 $1 \times 1 \times C$ 矩阵与特征图 U 经过 Sigmoid 函数将权重变量进行归一化变换,如式(8)所示。对原始输入特征图赋予权重后可得到新的特征图。

$$g(p)=\frac{1}{1+e^{-p}} \quad (8)$$

式中: p 为归一化前的权重变量。

1.3 模型评估标准

制定模型评估标准时,须要考虑实际电力系统中“漏判”和“误判”对电力系统的影响。因此,模型评估方法指标除了整体的分辨准确率 P_{AC} 外,还须要引入漏判率 P_{MD} 和误判率 P_{FA} , P_{MD} 和 P_{FA} , 分别用于评估模型对稳定样本和失稳样本的分辨能力。

①准确率 P_{AC} :正确评估的样本数占总样本的百分比。

$$P_{AC}=\frac{T_P+T_N}{T_P+F_P+F_N+T_N} \times 100\% \quad (9)$$

②漏判率 P_{MD} :真实失稳样本被错误判定为稳定样本的数量占真实失稳样本总数的百分比。

$$P_{MD}=\frac{F_P}{F_P+T_N} \times 100\% \quad (10)$$

③误判率 P_{FA} :真实稳定样本被错误判定为失稳样本的数量占真实稳定样本总数的百分比。

$$P_{FA}=\frac{F_N}{T_P+F_N} \times 100\% \quad (11)$$

式中: T_P 表示正确预测为稳定的真实稳定样本数量; F_N 表示错误预测为失稳的真实稳定样本数量; F_P 表示错误预测为稳定的真实失稳样本数

量; T_N 表示正确判断为失稳的真实失稳样本数量。

1.4 暂态稳定评估算法流程

CNN-LSTM-Attention 暂态稳定评估模型对电力系统暂态稳定性进行评估的算法流程如图 2 所示。通过 PSD-BPA 软件进行时域仿真收集数据集, 这些数据经 KPCA 降维后的优选特征集将作为神经网络的输入特征。通过 CNN 层进行特征提取与深度挖掘后, 利用 Dropout 层丢弃部分无用参数, 再利用池化层对输入特征进一步压缩提取。将输出特征传入 LSTM 层, 进一步提炼数据与时间之间的相关性, 不断调整参数, 解决时序数据中长期依赖信息的问题。在完成 CNN-LSTM 串联连接后接入自注意力机制层, 根据重要程度对不同的特征赋值, 最终通过全连接层输出分解结果。由于本文为二分类研究, 因此采取 Sigmoid 作为激活函数, 可将输出结果映射为 (0, 1) 的概率分布, 用于表示暂态稳定性评估结果。




图 2 暂态电压稳定评估流程
Fig.2 Transient voltage stability evaluation process

2 暂态电压稳定性机理及控制措施

2.1 风电并网影响系统暂态电压稳定性的机理

当高比例风电接入的送端电网系统发生故障时, 暂态电压的变化程度与系统的短路容量密切相关。目前的研究普遍认为, 高比例的新能源电网呈现出“弱电网”现象, 因为大量的新能源电源取代了同步发电机, 从而导致整个系统的短路容量降低。高比例风电接入的送端电网的抗扰动能力较差, 电网的强度也较弱。双馈风机作为目前采用的主要风机类型, 其主体是异步电机, 双馈风机的短路容量计算式为

$$S_{oc,am} = \frac{\sqrt{3} U_N I_N}{x_k} = \frac{S_{am}}{x_k} \quad (12)$$

式中: U_N 为发电机平均额定电压; I_N 为额定电流; S_{am} 为电机等效容量; x_k 为短路电抗。

在工程设计中, 异步电机的短路电抗越大, 其

提供的短路容量就越小。因此, 在高比例的新能源电网中, 整个系统的短路容量会下降, 在相同程度的无功波动条件下, 高比例风电接入的系统母线暂态电压波动幅度也会更大。

2.2 故障限流器模型

电力系统的迅猛发展导致其规模不断扩大, 互联程度越来越高, 这使得短路电流水平不断攀升, 极大地影响了系统的安全运行。已有研究表明, 在出现故障时, 使用超导故障限流器可以有效维护机组无功功率输出能力。因此, 在解决风电系统过载问题方面, 应用超导故障限流器是一个有效的解决方案。图 3 显示了理想条件下单机无穷大系统超导故障限流器接入模型示意图^[6]。




图 3 超导故障限流器布置示意图
Fig.3 Superconducting fault current limiter layout diagram

当系统正常运行时, 发电机通过变压器和双回路将电力输送至无限大系统。当系统发生短路故障时, 超导故障限流器中的超导体进行“自动变阻”。为了简化分析, 忽略超导故障限流器的电阻, 只考虑其电抗的作用。假设发生短路故障时, 投入系统的超导故障限流器的电抗标么值为 X 。考虑到故障发生时, 非故障线路上的故障限流器也会被触发, 因此, 超导故障限流器可表示为如图 4 所示的等效电路。




图 4 系统正常运行时超导故障限流器等效电路
Fig.4 Equivalent circuit of superconducting fault current limiter in normal operation

经过星-角变换后得到化简电路, 如图 5 所示。




图 5 化简等值电路
Fig.5 Simplified equivalent circuit

图 5 中: $X_a = \frac{X X_L}{X + X_L} + X'_d + X_{T1}$; $X_b = \frac{X^2}{X + 2X_L} + X_{T2}$;

$X_c = \frac{X X_L}{X + 2X_L} + X_{\Delta c}$ 。此时发电机与无穷大系统间的转移电抗和发电机发出的电磁功率分别为

$$X_{II} = X_{ab} = X_a + X_b + \frac{X_a + X_b}{X_c} \quad (13)$$

$$P_{II} = \frac{E' U + X_b}{X_{II}} \sin \delta \quad (14)$$

当系统发生三相短路时, $X_{\Delta} \approx 0$, 系统的转移阻抗可以表示为 SFCL 投入电抗值的函数 $f(X)$ 。随着 SFCL 投入系统电抗值的增加, 系统的总转移阻抗会减小, 并最终趋于一个稳定值。当 X 趋近于零时, 转移阻抗将趋近于无穷大。因此, 当系统发生短路时, 超导限流器投入阻抗以减小系统的总转移阻抗, 从而提高 P_{II} 幅值, 有助于提升系统的暂态稳定性。

3 算例分析

本文采用中国电科院暂态仿真软件 PSD-BPA 作为仿真平台, 构建了如图 6 所示的英格兰 10 机 39 节点电力系统的仿真模型。仿真参数见表 2。基准功率设定为 100 MW, 基准电压为 345

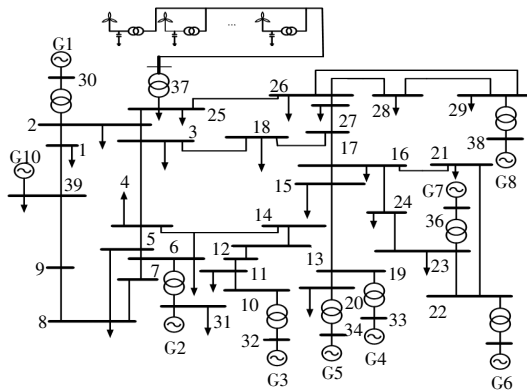


图 6 风机接入 IEEE39 节点系统拓扑图

Fig.6 Topology of the fan connected to the IEEE39 nodes

表 2 新英格兰 39 节点系统仿真算例的样本数据构造方法
Table 2 Sample data construction method of New England 39-bus system simulation example

参数	数值
发电机模型	二阶经典模型
风电渗透率	0.20%, 30%, 40%
故障类型	三相短路故障
故障位置	各线路首末端设置故障点
故障持续时间	0.2, 0.4, 0.6, 0.8 s
采样频率	30 Hz
故障前采样	从第 30 周波起连续采样 10 周波
故障期间采样	从第 40 周波起视故障持续时间设置采样时长
故障后采样	故障结束后连续采样 100 周波

kV。为进一步研究风电并网对系统暂态电压稳定性的影响, 将 25 台 1.5 MW 的风电机组等效成一个群体, 接入到电网中。该风电机组的额定电压为 0.69 kV, 经升压变压器升高后连接到 37 号节点。通过潮流计算和时域仿真, 共获得 1 986 个样本, 其中包括 1 330 个稳定样本和 656 个失稳样本。

3.1 KPCA 特征降维

利用 KPCA 算法对采集得到的 28 维特征数据共计 1 986 个样本进行特征降维分析, 当累积方差贡献率 $\geq 99\%$ 时, 优选特征向量即可代表所有特征向量。表 3 为 13 个主成分的特征值、累积方差贡献率。

表 3 主成分分析

Table 3 Principal component analysis table

主成分	特征值	累积方差贡献率/%
1	4.356 2	29.85
2	2.854 6	45.62
3	2.165 7	59.23
4	1.682 4	67.25
5	1.497 0	76.52
6	0.962 1	86.35
7	0.862 5	90.45
8	0.648 0	92.12
9	0.546 0	94.55
10	0.482 3	95.21
11	0.325 4	97.32
12	0.195 3	98.12
13	0.112 0	99.10

由表 3 可知, 主成分累计方差贡献率已经达到 99%, 说明前 13 个主成分完全可以替代所有主成分作为暂态电压稳定评估的输入特征集。通过对各个主成分与其对应的特征值进行排序选取前 13 个特征, 可以得到表 4 中所示的优选特征。

表 4 优选降维特征集

Table 4 Preferred downwitter solicitation

主成分	优选特征
1	故障前后, 系统的总能量调整 x_1
2	故障瞬间, 所有双馈风机承受的最大有功功率冲击 x_2
3	故障瞬间, 所有双馈风机承受的最小有功功率冲击 x_3
4	故障瞬间, 最大加速角度的双馈风机的相对初始角度 x_4
5	故障切除时, 具有最大转子角度的双馈风机转子动能 x_5
6	故障切除时, 对系统的有功冲击 x_6
7	故障切除时, 具有最大转子动能的双馈风机转子角度 x_7
8	故障切除时, 转角与惯性中心 (COI) 角相差的最大值 x_8
9	故障切除时, 所有双馈风机的转子动能最大值 x_9
10	故障切除时, 所有双馈风机转子动能的平均值 x_{10}

续表 4

主成分	优选特征
11	故障后,各节点电压幅值之和的平均值 x_{19}
12	故障切除时,双馈风机的 q 轴转子电流的变化量 x_{27}
13	故障切除时,双馈风机的 d 轴转子电流变化量 x_{28}

3.2 失稳判据

每一个样本数据 $X_i(i=1,2,\dots,n)$ 都有一个对应的标记 $Y_i=[Y_1, Y_2, \dots, Y_n]$, 当 Y_i 取 1 时标记为稳定, 当 Y_i 取 0 时标记为失稳。

仿真过程中,采用符合《风电场接入电网技术规定(GB/T19963-2011)》的风电并网系统暂态电压稳定性评判准则。该准则规定,在发生大幅度扰动情况下,系统侧母线电压低于 0.75 p.u.的时间不得超过 1.0 s, 且双馈风机的功角必须保持稳定,否则将被判定为暂态不稳定。

图 7 所示为系统在 0.1 s 发生三相短路故障时系统母线电压幅值。从图 7 中可以看出,在发生故障期间,系统母线电压发生了剧烈的变化。当故障清除时间较短时,系统可以通过自我调节保持暂态电压稳定。但是,当故障清除时间较长时,系统无法维持暂态电压的稳定,如图 8 所示。




图 7 大扰动情况下暂态电压稳定性
Fig.7 Transient voltage stability under large disturbance




图 8 大扰动情况下暂态电压不稳定性
Fig.8 Transient voltage instability under large disturbance

3.3 结果分析

为了能更加直观地体现模型对电力系统暂态稳定性的评估性能,本文将同样的优选特征训练

样本分别输入到 CNN,LSTM 模型中,进行训练并测试模型的评估性能。其中,LSTM 和 CNN 的结构参数和本节提出的 CNN-LSTM-Attention 一致,其他模型结构参数均通过网格搜索法找出最优的超参数。各评估模型的测试结果如图 9 所示。




图 9 各评估模型分辨准确率测试结果
Fig.9 Test results of the estimated model

由图 9 可知:当训练到 30 轮以后,CNN-LSTM-Attention 准确率更高且趋于收敛,其余模型在训练 40 轮以后才趋于收敛并且后续准确率波动较大;CNN-LSTM-Attention 模型的分辨准确率 P_{AC} 最高,漏判率 P_{MD} 最低,这与该模型能够精准提取暂态特征并且可以有效解决学习时序数据中长期依赖信息的问题密不可分。同时利用注意力机制并根据重要程度对 CNN 中各输出特征通道赋予不同的权重系数,对 LSTM 下各时序特征赋予不同的权重系数,保证序列长度增加时,重要特征不会丢失。预测结果表明,引入注意力机制能更好地保留重要特征用于模型训练,更精准地提取使用关键的特征,CNN-LSTM-Attention 比 CNN-LSTM 的分辨准确率高 0.98%,漏判率降低了 2%。

为了验证本文双馈风机对电力系统暂态电压稳定性的影响以及构建的附加超导故障限流器对电力系统暂态稳定性的积极作用,设置如表 5 所示的不同渗透率及发生不同程度的负荷扰动共 10 个场景进行仿真分析。

表 5 不同渗透率仿真场景

Table 5 Simulation scenarios of different permeability rates			
场景	故障持续时间/s	风电渗透率/%	有无超导故障限流器
1	0.6	0	无
2	0.6	20	无
3	0.6	30	无
4	0.6	40	无
5	0.6	40	有

续表 5

场景	故障持续时间/s	风电渗透率/%	有无超导故障限流器
6	0.2	40	无
7	0.4	40	无
8	0.6	40	无
9	0.8	40	无
10	0.8	40	有

为了验证不同风电渗透率对系统暂态电压稳定性的影响,在相同故障持续时间下,在 25 节点处引入短路故障进行仿真分析。短路类型从金属性故障转化为三相非金属性短路故障,并在故障发生后的 0.6 s 被完全切除。通过仿真获得了风电渗透率为 0%, 20%, 30%, 40% 时风电并网系统的运行情况,分析了不同风电渗透率下的系统暂态电压稳定性。分别提取不同风电渗透率下的优选特征参数,代入训练好的 CNN-LSTM-Attention 模型进行暂态评估,结果如表 6 所示。

表 6 不同风电渗透率评估结果

Table 6 Evaluation results of different wind power permeability

场景	风电渗透率/%	有无超导故障限流器	评估结果
1	0	无	稳定
2	20	无	稳定
3	30	无	稳定
4	40	无	不稳定
5	40	有	稳定

由表 6 可以看出,在场景 1~4 中,在没有超导故障限流器的情况下,随着风电渗透率不断增大,电网的无功需求随之增多,电网静态电压稳定裕度不足的问题凸显。当风电渗透率达到 40% 时,系统并网母线电压发生严重跌落且不具备回稳能力,系统发生暂态电压失稳现象。对比场景 4 和场景 5,在故障发生瞬间超导故障限流器介入工作,故障限流器会立刻投入高阻抗来抑制系统短路电流,提高短路容量,进一步提高系统暂态稳定能力。当故障切除时,故障限流器不呈现阻抗,不会对线路的传输容量造成任何影响。

本文还验证了不同故障持续时间下系统的暂态电压稳定性。故障扰动过程:0 s 时在 25 节点处发生三相金属性短路,0.1 s 时故障发展为三相非金属性短路故障。在不同故障持续时间下,分别提取不同风电渗透率下的优选特征参数,代入训练好的 CNN-LSTM-Attention 模型进行暂态评估,结果如表 7 所示。

表 7 有无超导故障限流器评估结果

Table 7 Evaluation results of current limiter with or without superconducting fault

场景	故障持续时间/s	有无超导故障限流器	评估结果
6	0.2	无	稳定
7	0.4	无	稳定
8	0.6	无	不稳定
9	0.8	无	不稳定
10	0.8	有	稳定

对比场景 6,7 可以看出,当系统故障切除时间小于 0.6 s 时,系统中枢母线电压及风电并网母线电压波动相对较小,系统仍处于稳定状态。当故障切除时间延长至 0.6 s 时,系统中枢母线电压将发生严重跌落,系统由暂态稳定状态过渡到暂态电压失稳状态。随着故障持续时间的延长,系统中枢母线及风电并网母线的电压跌落程度越发严重。对比场景 9,10 可以看出,超导故障限流器在一定限度内能支撑严重故障。

4 结论

本文基于自注意力机制提出了一种 CNN-LSTM 暂态稳定评估指标,为更好地捕捉输入数据中的空间和时间相关性,基于核主成分分析(KPCA)进行特征降维;针对暂态电压突出问题提出安装超导故障限流器的主动支撑措施,改善风电场系统无功环境,维持并网点电压稳定。在 PSD-BPA 中搭建含风电的 IEEE39 节点系统进行仿真计算和数据采集,得到如下结论。

①核主成分分析(KPCA)方法能够有效地筛选电力系统暂态稳定性评估中重要度高的特征,前 13 个主成分完全可以替代所有主成分,作为风电并网暂态电压稳定性评估的输入特征集,明显地缩短了风电并网系统暂态电压稳定性评估的计算时间。

②与目前一些浅层的神经网络和深度学习网络相比,本文所提出的 CNN-LSTM-Attention 网络能有效提高电力系统暂态稳定性评估性能。CNN-LSTM 可以充分利用时间序列变量的信息,注意力机制也能够有效地挖掘数据信息。

③随着故障持续时间的不断延长,系统中枢母线及风电并网母线的电压跌落程度越发严重,超导故障限流器在一定限度内能支撑严重故障,对系统暂态电压的稳定具有积极作用。

参考文献:

- [1] 郭琦, 卢远宏. 新型电力系统的建模仿真关键技术及展望[J]. 电力系统自动化, 2022, 46(10): 18-32.
- [2] 陈国平, 李明节, 许涛, 等. 我国电网支撑可再生能源发展的实践与挑战[J]. 电网技术, 2017, 41(10): 3095-3103.
- [3] 张晓英, 史冬雪, 张璘, 等. 基于 CPSO-BP 神经网络的风电并网暂态电压稳定评估 [J]. 智慧电力, 2021, 49(10): 38-44.
- [4] 陈康, 王泽, 郭永吉. 基于 grcForest 模型的风电并网系统暂态电压稳定评估[J]. 智慧电力, 2023, 51(1): 31-37.
- [5] 孙黎霞, 白景涛, 周照宇, 等. 基于双向长短期记忆网络的电力系统暂态稳定评估 [J]. 电力系统自动化, 2020, 44(13): 64-72.
- [6] 张亮, 安军, 周毅博. 基于时间卷积和图注意力网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2023, 47(7): 114-122.
- [7] Yu J J Q, Hill D J, Lam A Y S, et al. Intelligent time adaptive transient stability assessment system [J]. IEEE Transactions on Power Systems, 2018, 33 (1): 1049 - 1058.
- [8] 陈光宇, 孙叶舟, 江海洋, 等. 基于 DIndRNN-RVM 深度融合模型的 AGC 指令执行效果精准辨识及置信评估研究 [J]. 中国电机工程学报, 2022, 42 (5): 1852-1867.
- [9] 杨东升, 吉明佳, 周博文, 等. 基于双生成器生成对抗网络的电力系统暂态稳定评估方法 [J]. 电网技术, 2021, 45(8): 2934-2945.
- [10] Chen C Y, Cui M J, Li F X, et al. Model free emergency frequency control based on reinforcement learning [J]. IEEE Transactions on Industrial Informatics, 2021, 17(4): 2336-2346.
- [11] Yang H, Zhang W, Chen J, et al. PMU-based voltage stability prediction using least square support vector machine with online learning [J]. Electric Power System Research, 2018, 160: 234-242.
- [12] Zhang Y C, Xu Y, Dong Z Y, et al. A hierarchical self-adaptive data analytics method for real time power system short-term voltage stability assessment [J]. IEEE Transactions on Industrial Informatics, 2019, 15 (1): 74-84.
- [13] 黎晓, 刘崇茹, 辛蜀骏, 等. 暂态功角稳定与暂态电压稳定的耦合机理分析与耦合强度评估指标[J]. 中国电机工程学报, 2021, 41(15): 5091-5107.
- [14] Suo M L, Cheng Y J, Zhuang C Q, et al. Extension of labeled multiple attribute decision making based on fuzzy neighborhood three-way decision [J]. Neural Computing and Applications, 2020, 32(23): 17731-17758.
- [15] Purwins H, Li B, Virtanen T, et al. Deep learning for audio signal processing [J]. IEEE Journal of Selected Topics in Signal Processing, 2019, 13(2): 206-219.
- [16] Han K, Wang G Y, Tian Q, et al. Ghostnet: more features from cheap operations [A]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Ithaca: IEEE, 2020.

Study on high penetration wind power integration and transient voltage stability in power grid using CNN-LSTM with attention mechanism

Zhang Hongying¹, Jia Yichao¹, Wang Jiangzhi², Zhang Wei²

(1.China Electric Power Research Institute Co.,Ltd., Nanjing 210037, China; 2.School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In order to achieve rapid and accurate assessment of transient voltage stability in the power system following the integration of wind farms into the grid, a transient stability assessment metric is proposed based on Convolutional Neural Networks-Long Short-Term Memory (CNN-LSTM) and attention mechanisms. To better capture spatial and temporal correlations in the input data, feature dimensionality reduction is carried out using Kernel Principal Component Analysis (KPCA). Addressing challenges related to decreased short-circuit capacity and increased short-circuit current levels in high-proportion renewable energy grids, an active support measure is introduced by installing superconducting fault current limiters to restrict short-circuit current levels during fault processes and maintain voltage stability at grid connection points. Finally, simulations and data collection are performed on an IEEE39-node system with wind power integration using PSD-BPA. The results indicate that the KPCA approach effectively screens features of significant importance in the transient stability assessment of power systems. The proposed evaluation metric demonstrates higher discriminative capability, and the suggested improvement measures are observed to play a positive role in enhancing transient voltage stability in high-proportion wind power integration systems.

Keywords: wind power integration; transient voltage stability; transient assessment metrics; fault current limiters