



(12) 发明专利

(10) 授权公告号 CN 112200038 B

(45) 授权公告日 2023.12.05

(21) 申请号 202011050933.3

H02J 3/00 (2006.01)

(22) 申请日 2020.09.29

(56) 对比文件

(65) 同一申请的已公布的文献号
申请公布号 CN 112200038 A

CN 111160167 A, 2020.05.15

CN 105473065 A, 2016.04.06

CN 104578115 A, 2015.04.29

(43) 申请公布日 2021.01.08

CN 1981453 A, 2007.06.13

(73) 专利权人 国网四川省电力公司经济技术研究院

CN 109255394 A, 2019.01.22

CN 110261746 A, 2019.09.20

地址 610000 四川省成都市高新区蜀绣西路366号

CN 110236536 A, 2019.09.17

CA 3105412 A1, 2020.01.09

(72) 发明人 魏俊 叶圣永 张文涛 刘旭娜
刘立扬 韩宇奇 李达 赵达维
龙川 刘洁颖

CN 111046327 A, 2020.04.21

US 2003117652 A1, 2003.06.26

(74) 专利代理机构 成都行之专利代理有限公司
51220

刘晓芳等.基于小波变换和神经网络的暂态电能质量扰动自动识别.《继电器》.2005,(第23期),46-50.

专利代理师 张严芳

罗宁等.基于神经网络的电力负荷预测方法研究.《自动化与仪器仪表》.2020,(第01期),157-160. (续)

(51) Int. Cl.

审查员 周婷

G06F 18/24 (2023.01)

G06F 18/213 (2023.01)

G06N 3/0464 (2023.01)

G06N 3/08 (2023.01)

G06N 3/084 (2023.01)

权利要求书3页 说明书9页 附图4页

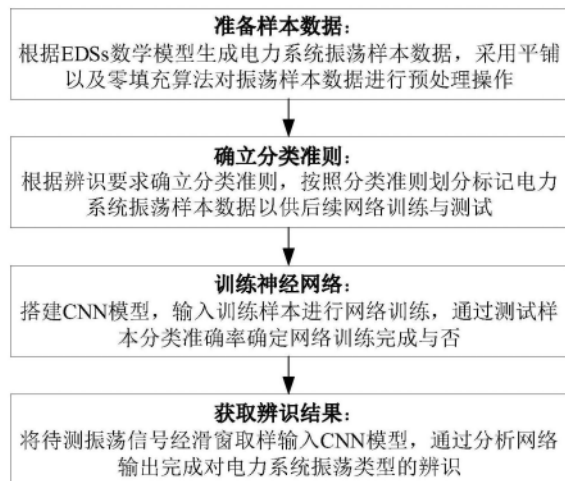
(54) 发明名称

一种基于CNN的电力系统振荡类型的快速辨识方法

的辨识。本发明具有对电力系统振荡类型快速辨识的有效性和可行性等优点。

(57) 摘要

本发明公开了一种基于CNN的电力系统振荡类型的快速辨识方法,本发明提供一种分析准确的电力系统振荡类型的快速辨识方法,包括:根据EDSs数学模型生成电力系统振荡样本数据,采用平铺以及零填充算法对振荡样本数据进行预处理操作;根据辨识要求确立分类准则,按照分类准则划分标记电力系统振荡样本数据以供后续网络训练与测试;搭建CNN模型,输入训练样本进行网络训练,通过测试样本分类准确率确定网络训练完成与否;将待测振荡信号经滑动窗口输入CNN,通过输出分析完成对电力系统振荡类型



CN 112200038 B

[接上页]

(56) 对比文件

Zhaobi Chu等.A Robust Direct Parameter Identification of Exponentially Damped Low-Frequency Oscillation in Power Systems.《Journal of Sensors》.2020,1-11.

Qianyu Li等.A Convolution Neural Network Method for Power System Oscillation Type Identification.《2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2)》.2021,499-504.

张文涛等.基于改进贝叶斯分类法的电能质

量扰动分类方法.《电网技术》.2007,(第07期), 22-25.

Zhongting Shen等.A Novel Neural Network Approach for Power System Low Frequency Oscillation Mode Identification.《2019 IEEE International Symposium on Circuits and Systems (ISCAS)》.2019,1-5.

邵冰冰等.多直驱风机经VSC-HVDC并网系统场内/场网次同步振荡特性分析.《中国电机工程学报》.2020,第40卷(第12期),3835-3847.

1. 一种基于CNN的电力系统振荡类型的快速辨识方法,其特征在于,方法包括以下步骤:

步骤1:根据电力系统振荡信号数学模型为CNN模型生成振荡样本数据,所述振荡样本数据包括训练样本数据和测试样本数据;

步骤2:采用预处理算法处理振荡样本数据以便后续训练过程中的特征提取;

步骤3:确定电力系统振荡类型的分类准则,根据分类准则为振荡样本数据添加类别标签;

步骤4:根据振荡样本数据特征以及分类需求构建CNN模型;

步骤5:将训练样本输入CNN模型,训练模型的分类能力;

步骤6:将测试样本输入CNN模型,测试各CNN模型的辨识准确率,并通过调节网络参数不断提升辨识准确率以完成网络训练;

步骤7:通过滑动时窗获取待测振荡信号实测数据;

步骤8:处理待测振荡信号并输入CNN模型,根据CNN模型输出分析振荡信号的所属类型;其中:

步骤2中所述预处理算法采用平铺的方式将序列数据处理为n阶方阵,其公式为:

$$X = (x(1), x(2), \dots, x(N)) \xrightarrow{\text{reshape}} \begin{pmatrix} x(1) & x(2) & \dots & x(n) \\ x(n+1) & x(n+2) & \dots & x(2n) \\ \vdots & \vdots & \ddots & \vdots \\ x((n-1)n+1) & x((n-1)n+2) & \dots & x(n^2) \end{pmatrix} \quad (2)$$

式(2)中,X为离散的时序序列,长度为N,由于目标矩阵为n阶方阵,因此 $N=n^2$;所述n阶方阵采用零填充操作,将原输入矩阵转换为m阶方阵, $m>n$;

步骤3中所述分类准则为按存在性分类,具体方法为:

电力系统振荡信号按不同频率可分为四类,分别为:低频振荡、次同步振荡、超同步振荡、中高频振荡;对于某一高阶振荡信号,其可能包含任一类型振荡模态或同时包含多种类型振荡模态,按存在性分类即分别判断该四种振荡模态于某一振荡信号中是否存在,再按存在与不存在分为两类进行辨识,因此需按照四种振荡类型训练四个不同的分类网络;所述低频振荡的频率f满足 $f \leq 2.5\text{Hz}$,所述次同步振荡的频率f满足 $2.5\text{Hz} < f \leq 45\text{Hz}$,所述超同步振荡的f满足 $50\text{Hz} < f < 100\text{Hz}$,所述中高频振荡f满足 $f \geq 100\text{Hz}$ 。

2. 根据权利要求1所述的一种基于CNN的电力系统振荡类型的快速辨识方法,其特征在于,步骤1中所述振荡信号数学模型为指数型衰减正弦量,其公式为:

$$x(t_j) = \sum_{i=1}^m A_i e^{\sigma_i(t_j - t_0^i)} \sin[2\pi f_i(t_j - t_0^i) + \varphi_i] \cdot \varepsilon(t_j - t_0^i) + \eta(t_j) \quad (1)$$

式(1)中, $x(t_j)$ 为 t_j 时刻的信号; A_i 为幅值; σ_i 为衰减因子; f_i 为频率; φ_i 为相位; $i=1, 2, \dots, m$; $j=0, 1, 2, \dots, n-1$; n 为采样点数; m 为模型实际阶数; t_0^i 为第i阶信号模态加入的时间节点; $\eta(t_j)$ 代表噪声信号。

3. 根据权利要求1所述的一种基于CNN的电力系统振荡类型的快速辨识方法,其特征在于,步骤4中所述CNN模型,具体结构包含输入层、卷积层、池化层、全连接层、Dropout层以及输出层;

所述输入层用以输入序列数据；卷积层用以将原始数据映射到隐层的特征空间；池化层用以缩小数据尺寸，减少全连接层的参数并加快训练速度；全连接层用以完成分布式特征表示到样本标记空间的映射；Dropout层通过令数据随机失活来预防过拟合现象的发生；输出层则输出最终的分类结果。

4. 根据权利要求1所述的一种基于CNN的电力系统振荡类型的快速辨识方法，其特征在于，步骤5中所述网络训练过程为一个循环迭代过程，通过前向传播算法和反向传播算法更新网络各层级状态与参数，具体包括以下步骤：

S51: 初始化各网络参数，包括各神经元的权重和偏置；

S52: 输入训练样本数据；

S53: 计算CNN网络内部各层级输出；

S54: 计算当前序列索引预测输出值及其损失函数；

S55: 计算所有参数基于损失函数的偏导数，通过梯度下降法更新网络所有的参数；

S56: 当损失函数不再下降或达到设定训练次数，完成训练。

5. 根据权利要求4所述的一种基于CNN的电力系统振荡类型的快速辨识方法，其特征在于，步骤S53中所述CNN网络各层级输出的计算公式为：

1) 卷积层输出：

$$Y_{i,j} = \sum_{m=1}^M \sum_{n=1}^N x_{i+m-1, j+n-1} k_{m,n} \quad (3)$$

式(3)中， $i=1, 2, \dots, I$ ； $j=1, 2, \dots, J$ ； $I=P-M+1$ ； $J=Q-N+1$ ； P, Q 为输入矩阵 X 的尺寸， $k_{m,n}$ 是 $M \times N$ 的卷积核的第 m 行，第 n 列的元素， $x_{i+m-1, j+n-1}$ 是输入矩阵 X 中的第 $i+m-1$ 行，第 $j+n-1$ 列的元素；每个卷积核都会产生一个 $I \times J$ 的输出矩阵 Y ；

2) 池化层输出(平均池化)：

$$u = \frac{1}{S_R} \sum_{i,j \in R} Y_{i,j} \quad (4)$$

式(4)中， S_R 为池化区域面积，即池化区域元素个数； $Y_{i,j}$ 为卷积层输出 Y 第 i 行第 j 列的元素；

3) 全连接层输出：

$$h_n = b_n + \sum_{m=1}^M v_m \times w_{mn} \quad (5)$$

式(5)中， h_n 为输出神经元的值； v_m 为输入神经元的值； w_{mn} 、 b_n 分别为链接权值与偏置， m 为输入神经元的数目； n 为输出神经元数目。

6. 根据权利要求5所述的一种基于CNN的电力系统振荡类型的快速辨识方法，其特征在于，步骤S54中所述预测输出的计算公式以及损失函数的选取分别为：

$$\hat{y}_n = \tanh(V \cdot h_n + c) \quad (6)$$

$$loss = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^K (y_{n,ij} \ln \hat{y}_{n,ij} + (1 - y_{n,ij}) \ln(1 - \hat{y}_{n,ij})) \quad (7)$$

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{2x}} \quad (8)$$

式(6)、(7)和(8)中, V 和 c 表示预测输出的权值和偏置; \tanh 表示双曲正切函数; N 为每次送入网络训练的批量大小; K 为类型数目; $y_{n,i,j}$ 表示第 i 批次及第 j 类型样本的实际标签, $\hat{y}_{n,i,j}$ 则表示第 i 批次及第 j 类型样本的预测输出值。

7.根据权利要求1所述的一种基于CNN的电力系统振荡类型的快速辨识方法,其特征在于,所述步骤6中,当辨识准确率达到90%以上时,停止网络参数的调节,完成网络训练获得训练完成的CNN模型。

8.根据权利要求1所述的一种基于CNN的电力系统振荡类型的快速辨识方法,其特征在于,步骤7中所述通过滑动时窗获取待测振荡信号实测数据,如式(9)所示:

$$X = (x(1), x(2), \dots, x(N)) \xrightarrow{\text{滑动取样}} \begin{pmatrix} x(1) & x(2) & \dots & x(L) \\ x(1+f_s/2) & x(2+f_s/2) & \dots & x(L+f_s/2) \\ \vdots & \vdots & \ddots & \vdots \\ x(1+n \cdot f_s/2) & x(2+n \cdot f_s/2) & \dots & x(L+n \cdot f_s/2) \end{pmatrix} = \begin{pmatrix} L_1 \\ L_2 \\ \dots \\ L_{n+1} \end{pmatrix} \quad (9)$$

式(9)中, X 为离散的时序序列,长度为 N ; L 为滑窗长度; f_s 为信号采样频率,由于滑动间隔为 $0.5s$,则滑动步长等于 $f_s/2$; L_1, L_2, \dots, L_{n+1} 即为通过滑动时窗获取的不同时段振荡信号实测数据。

一种基于CNN的电力系统振荡类型的快速辨识方法

技术领域

[0001] 本发明涉及电力系统稳定与控制技术领域,具体涉及一种基于卷积神经网络(convolutional neural network,CNN)的电力系统振荡类型的快速辨识方法。

背景技术

[0002] 自电力系统诞生以来,振荡研究就成为了关乎电力系统动态性能与稳定性的重要研究之一。经过多年的研究,传统电力系统中低频振荡(low frequency oscillation,LFO)和次同步振荡(sub-synchronous oscillation,SSO)的特性已被充分揭示。它们的共同特性是由较大物理惯量的旋转单元所主导,尤其是大型同步发电机组。然而,由于可再生能源的快速发展,如太阳能、风能、地热能、生物质能等,大量的新能源并网发电装备通过电力电子逆变装置接入电网,这给电力系统的规划以及运行控制带来了巨大的挑战。传统控制策略的电力电子逆变器侧重于发电和电能质量的控制,具有响应速度快、低惯量等特性,大量的采用传统电力电子技术,会导致系统呈现出惯量减弱的趋势,严重危及电力系统的稳定运行。例如,2009年10月,美国德克萨斯州的双馈风力发电系统和串联补偿电网之间发生了频率约为20Hz的次同步谐振事故,造成消弧电路损坏和大规模断路故障。考虑到电力系统振荡对电力系统稳定运行的严重威胁,快速辨识出电力系统振荡类型对电网后续动态稳定性的评估及调整具有重要意义。

[0003] 目前,电力系统振荡类型的辨识主要是模态辨识,对应的方法分为基于模型的方法和基于实测信号的方法。由于无需系统精确的模型和参数,后者在电力系统中得到了广泛应用。常见算法有基于快速傅里叶变换(fast fourier transformation,FFT)的算法、小波分析、Prony、希尔伯特-黄变换(HHT)等以及近年来发展起来的借助旋转不变技术估计信号参数(ESPRIT:estimation of signal parameters via rotational invariance technique),矩阵束方法(MP:matrix pencil algorithm),随机子空间方法(SSI:stochastic subspace identification)等。经过多年的研究与改进,这些方法可以较为准确地获取系统的模态,在抗噪性上也有一定的效果,但在辨识的数学机理上,这些算法将被测信号视作平稳随机过程,并且往往需要采集数秒钟乃至数分钟的数据。随着可再生能源并网比例的提高以及大量的电力电子设备接入电网,所产生的振荡表现出不同于传统电力系统振荡的新特性。由于可再生能源的发电机单元和AC/DC电网之间的复杂动态交互,所产生的振荡一般具有从几赫兹到几千赫兹的宽频范围,同时还具有强时变性、非线性、非平稳性以及强噪声干扰等特性。在这种背景下,传统电力系统中振荡信号近似平稳的假设难以保证,亟需发展新的振荡类型辨识方法来适应电力系统的发展。

[0004] 近年来,深度学习(deep learning,DL)发展迅猛,在众多领域已经得到了成功的应用。在电力系统振荡类型辨识方面,也有学者开展了探索性的研究。有研究提出使用深度学习算法辨识电力系统振荡模式是区域振荡还是局部振荡。还有研究提出指数型衰减正弦神经网络(exponentially damped sinusoids neural network,EDSNN)的辨识方法。但这些研究,均存在对被测振荡信号非平稳性特性考虑不足的缺陷。目前,同步相量测量单元

(PMU)的广域测量系统(WAMS)在电力系统中获得了广泛应用,为电力系统振荡分析提供了数据来源,让深度学习在电力系统振荡类型辨识方面的应用成为可能。同时,由于事先通过大量的数据学习,深度学习的引入还使得电力系统振荡类型的辨识具有神经网络类算法的共同优点——辨识速度迅速。而这往往是系统状态强时变的高比例可再生能源并网电力系统中迫切需要的一个特点。因此,随着可再生能源渗透率的进一步提高,电力系统中的振荡模式愈发频繁且复杂,如何借鉴深度学习算法实现电力系统振荡类型的在线快速辨识,成为了一个亟待解决的技术问题。

发明内容

[0005] 本发明的目的在于针对高比例可再生能源并网的电力电子化系统中易出现的复杂振荡现象,提供一种分析准确,设计合理的基于CNN的电力系统振荡类型的快速辨识方法。

[0006] 本发明可通过下述技术方案实现:

[0007] 一种基于CNN的电力系统振荡类型的快速辨识方法,由以下步骤构成:

[0008] 步骤1:生成振荡样本数据,即根据电力系统振荡信号数学模型为CNN模型生成训练样本数据与测试样本数据。

[0009] 所选振荡信号数学模型为指数型衰减正弦量(exponentially damped sinusoids,EDSs),其公式为:

$$[0010] \quad x(t_j) = \sum_{i=1}^m A_i e^{\sigma_i(t_j - t_0^i)} \sin[2\pi f_i(t_j - t_0^i) + \varphi_i] \cdot \varepsilon(t_j - t_0^i) + \eta(t_j) \quad (1)$$

[0011] 式(1)中, $x(t_j)$ 为 t_j 时刻的信号; A_i 为幅值; σ_i 为衰减因子; f_i 为频率; φ_i 为相位; $j=0,1,2,\dots,n-1$;n为采样点数; $i=1,2,\dots,m$;m为模型实际阶数; t_0^i 为第i阶信号模态加入的时间节点; $\eta(t_j)$ 代表噪声信号。

[0012] 步骤2:采用预处理算法处理电力系统振荡样本数据以便后续训练过程中的特征提取;

[0013] 预处理算法采用平铺的方式将序列数据处理为n阶方阵,其公式为:

$$[0014] \quad X = (x(1), x(2), \dots, x(N)) \xrightarrow{\text{reshape}} \begin{pmatrix} x(1) & x(2) & \cdots & x(n) \\ x(n+1) & x(n+2) & \cdots & x(2n) \\ \vdots & \vdots & \ddots & \vdots \\ x((n-1)n+1) & x((n-1)n+2) & \cdots & x(n^2) \end{pmatrix} \quad (2)$$

[0015] 式(2)中,X为离散的时序序列,长度为N,由于目标矩阵为n阶方阵,因此 $N=n^2$;

[0016] 此外,为了实现对特征矩阵的边缘滤波,对上述n阶方阵实施零填充操作,即在输入矩阵的边缘使用零值进行填充,使原输入矩阵转换为 $m(m>n)$ 阶方阵。

[0017] 步骤3:确定电力系统振荡类型的分类准则,根据分类准则为样本数据添加类别标签。

[0018] 分类准则为按存在性分类。一般而言,电力系统振荡信号按不同频率可大致分为四类,分别为:低频振荡($f \leq 2.5\text{Hz}$)、次同步振荡($2.5\text{Hz} < f \leq 45\text{Hz}$)、超同步振荡($50\text{Hz} < f < 100\text{Hz}$)、中高频振荡($f \geq 100\text{Hz}$);对于某一高阶振荡信号,其可能包含任一类型振荡模态或

同时包含多种类型振荡模态,按存在性分类即分别判断该四种振荡模态于某一振荡信号中是否存在,再按存在与不存在分为两类进行辨识,因此本发明需按照四种振荡类型训练四个不同的分类网络。

[0019] 步骤4:根据振荡样本数据特征以及分类需求构建CNN模型。

[0020] 本发明所搭建的CNN模型,具体结构包含输入层、卷积层、池化层、全连接层、Dropout层以及输出层;

[0021] 其中,输入层用以输入序列数据;卷积层为网络核心部分,负责将原始数据映射到隐层的特征空间;池化层用以缩小数据尺寸,减少全连接层的参数并加快训练速度;全连接层用以完成分布式特征表示到样本标记空间的映射;Dropout层通过令数据随机失活来预防过拟合现象的发生;输出层则输出最终的分类结果。

[0022] 步骤5:将训练样本输入CNN模型,训练模型分类能力。

[0023] CNN模型训练过程为一个循环迭代过程,主要通过前向传播算法和反向传播算法更新网络各层级状态与参数,具体包括以下步骤:

[0024] S51:初始化各网络参数,包括各神经元的权重和偏置等;

[0025] S52:输入训练样本数据;

[0026] S53:计算CNN网络内部各层级输出;

[0027] S54:计算当前序列索引预测输出及其损失函数;

[0028] S55:计算所有参数基于损失函数的偏导数,通过梯度下降法更新网络所有的参数;

[0029] S56:当损失函数不再下降或达到设定训练次数,完成训练。

[0030] 进一步的,在CNN模型训练过程中,所述CNN网络各层级输出的计算公式为:

[0031] 1) 卷积层输出:

$$[0032] \quad Y_{i,j} = \sum_{m=1}^M \sum_{n=1}^N x_{i+m-1,j+n-1} k_{m,n} \quad (3)$$

[0033] 式(3)中, $i=1,2,\dots,I$; $j=1,2,\dots,J$; $I=P-M+1$; $J=Q-N+1$; P,Q 为输入矩阵 X 的尺寸, $k_{m,n}$ 是 $M \times N$ 的卷积核的第 m 行,第 n 列的元素, $x_{i+m-1,j+n-1}$ 是输入矩阵 X 中的第 $i+m-1$ 行,第 $j+n-1$ 列的元素。每个卷积核都会产生一个 $I \times J$ 的输出矩阵 Y ;

[0034] 2) 池化层输出(平均池化):

$$[0035] \quad u = \frac{1}{S_R} \sum_{i,j \in R} Y_{i,j} \quad (4)$$

[0036] 式(4)中, S_R 为池化区域面积,即池化区域元素个数; $Y_{i,j}$ 为卷积层输出 Y 第 i 行第 j 列的元素;

[0037] 3) 全连接层输出:

$$[0038] \quad h_n = b_n + \sum_{m=1}^M v_m \times w_{mn} \quad (5)$$

[0039] 式(5)中, h_n 为输出神经元的值; v_m 为输入神经元的值; w_{mn} 、 b_n 分别为链接权值与偏置, m 为输入神经元的数目; n 为输出神经元数目。

[0040] 进一步的,在CNN模型训练过程中,所述预测输出值的计算公式及其损失函数的选

取分别为:

$$[0041] \quad \hat{y}_n = \tanh(V \cdot h_n + c) \quad (6)$$

$$[0042] \quad loss = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^K (y_{n,ij} \ln \hat{y}_{n,ij} + (1 - y_{n,ij}) \ln(1 - \hat{y}_{n,ij})) \quad (7)$$

$$[0043] \quad \tanh(x) = \frac{1 - e^{-2x}}{1 + e^{2x}} \quad (8)$$

[0044] 式中, V 和 c 表示预测输出的权值和偏置; \tanh 表示双曲正切函数; N 为每次送入网络训练的批量大小; K 为类型数目; $y_{n,ij}$ 表示第 i 批次及第 j 类型样本的实际标签, $\hat{y}_{n,ij}$ 则表示第 i 批次及第 j 类型样本的预测输出值。

[0045] 步骤6:将测试样本输入CNN模型,测试各网络模型的辨识准确率,并通过调节网络参数不断提升辨识准确率以完成网络训练,当辨识准确率达到90%以上时,停止网络参数的调节,完成网络训练获得训练完成的CNN模型。

[0046] 步骤7:通过滑动时窗获取电力系统振荡信号实测数据。对某段振荡信号采用滑动时窗取样,其过程如式(9)所示:

$$[0047] \quad X = (x(1), x(2), \dots, x(N)) \xrightarrow{\text{滑动取样}} \begin{pmatrix} x(1) & x(2) & \dots & x(L) \\ x(1+f_s/2) & x(2+f_s/2) & \dots & x(L+f_s/2) \\ \vdots & \vdots & \ddots & \vdots \\ x(1+n \cdot f_s/2) & x(2+n \cdot f_s/2) & \dots & x(L+n \cdot f_s/2) \end{pmatrix} = \begin{pmatrix} L_1 \\ L_2 \\ \dots \\ L_{n+1} \end{pmatrix} \quad (9)$$

[0048] 式(9)中, X 为离散的时序序列,长度为 N ; L 为滑窗长度; f_s 为信号采样频率,由于滑动间隔为0.5s,则滑动步长等于 $f_s/2$; L_1 、 L_2 、 \dots 、 L_{n+1} 即为通过滑动时窗获取的不同时段振荡信号实测数据。

[0049] 依此法获取的待测信号按时序排列,通过对这些待测信号顺序逐一辨识,可以有效分析出待测振荡样本数据各模态的时变特征,以适应电力系统中振荡频繁且复杂的环境。

[0050] 步骤8:处理待测振荡信号并输入CNN模型,根据网络输出分析振荡信号的所属类型。根据存在性分类准则,所有网络输出结果均为包含对应模态分段或不包含对应模态分段这两种情况。对于某段待测振荡信号,将其输入各网络模型并综合分析输出结果,即可获得其所包含的振荡类型。

[0051] 本发明所述振荡类型辨识方法采用深度学习算法,选取CNN作为振荡样本训练模型,能够从较短时的振荡信号中迅速分析出其所属的类型,实现对电力系统振荡类型的在线快速辨识。

[0052] 本发明与现有技术相比,具有如下的优点和有益效果:

[0053] (1) 本发明引入了人工智能领域的深度学习算法,利用深度神经网络的分类能力实现电力系统振荡类型的辨识,相较于传统的信号模型分析法,辨识更快更准确,更加适用于电力系统中振荡类型的实时辨识。

[0054] (2) 本发明充分考虑到真实电网中常见的不稳定与时变振荡信号,采用深度学习算法并且选择定性辨识解决这一问题,使其更加适用于高比例可再生能源并网电力电子化系统中相对复杂的运行工况与振荡环境,相较于传统的信号模型分析法会将其视作稳定与

时不变信号处理,得到的辨识结果既不是模态的真实数值也无法体现时变特征更有优势。

附图说明

[0055] 此处所说明的附图用来提供对本发明实施例的进一步理解,构成本申请的一部分,并不构成对本发明实施例的限定。在附图中:

[0056] 图1为本发明的工作流程图。

[0057] 图2为本发明的CNN模型结构图。

[0058] 图3为本发明的CNN训练流程图。

[0059] 图4为含噪声情况下理想振荡信号图像。

[0060] 图5为电力系统实测振荡信号图像。

具体实施方式

[0061] 为使本发明的目的、技术方案和优点更加清楚明白,下面结合实施例和附图,对本发明作进一步的详细说明,本发明的示意性实施方式及其说明仅用于解释本发明,并不作为对本发明的限定。

[0062] 本发明中,S51-S56表示步骤5的详细子步骤。

[0063] 如图1所示,一种基于CNN的电力系统振荡类型的快速辨识方法,包括如下步骤:步骤1:生成样本数据,即根据电力系统振荡信号数学模型为CNN模型生成训练样本数据与测试样本数据。

[0064] 所选振荡信号数学模型为EDSs,其公式为:

$$[0065] \quad x(t_j) = \sum_{i=1}^m A_i e^{\sigma_i(t_j - t_0^i)} \sin[2\pi f_i(t_j - t_0^i) + \varphi_i] \cdot \varepsilon(t_j - t_0^i) + \eta(t_j) \quad (1)$$

[0066] 式(1)中, $x(t_j)$ 为 t_j 时刻的信号; A_i 为幅值; σ_i 为衰减因子; f_i 为频率; φ_i 为相位; $i=1,2,\dots,m$; $j=0,1,2,\dots,n-1$; n 为采样点数; m 为模型实际阶数; t_0^i 为第 i 阶信号模态加入的时间节点; $\eta(t_j)$ 代表噪声信号。

[0067] 本实施例中,振荡信号采样时间取1s,采样频率取400Hz,其中采样时间即振荡信号模态辨识所需最短时间。生成信号过程中,振荡信号各模态参数在合理范围内随机取值,最高阶数取到4。此外,为验证本发明抗噪性能,噪声信号 $\eta(t)$ 信噪比(signal-noise ratio,SNR)取10dB。

[0068] 步骤2:采用预处理算法处理电力系统振荡样本数据以便后续训练过程中的特征提取。

[0069] 预处理算法采用平铺的方式将序列数据处理为 n 阶方阵,其公式为:

$$[0070] \quad X = (x(1), x(2), \dots, x(N)) \xrightarrow{\text{reshape}} \begin{pmatrix} x(1) & x(2) & \dots & x(n) \\ x(n+1) & x(n+2) & \dots & x(2n) \\ \vdots & \vdots & \ddots & \vdots \\ x((n-1)n+1) & x((n-1)n+2) & \dots & x(n^2) \end{pmatrix} \quad (2)$$

[0071] 式(2)中, X 为离散的时序序列,长度为 $N=400$,由于目标矩阵为 n 阶方阵,因此 $n=20$;

[0072] 此外,为了实现对特征矩阵的边缘滤波,对上述 20×20 矩阵实施零填充操作,即在输入矩阵的边缘使用零值进行填充,使原输入矩阵转换为 28 阶方阵。

[0073] 步骤3:确定电力系统振荡类型的分类准则,根据分类准则为样本数据添加类别标签。

[0074] 分类准则为按存在性分类。一般而言,电力系统振荡信号按不同频率可大致分为四类,分别为:低频振荡($f \leq 2.5\text{Hz}$)、次同步振荡($2.5\text{Hz} < f \leq 45\text{Hz}$)、超同步振荡($50\text{Hz} < f < 100\text{Hz}$)、中高频振荡($f \geq 100\text{Hz}$);对于某一高阶振荡信号,其可能包含任一类型振荡模态或同时包含多种类型振荡模态,按存在性分类即分别判断该四种振荡模态于某一振荡信号中是否存在,再按存在与不存在分为两类进行辨识,因此本发明需按照四种振荡类型训练四个不同的分类网络。

[0075] 该分类方法可以实现不同阶数振荡信号的同时辨识,无需依赖传统辨识方法中难以实现的精确定阶过程,因此辨识结果更加可信。

[0076] 步骤4:根据振荡样本数据特征以及分类需求构建CNN模型。

[0077] 如图2所示,本发明所搭建的CNN模型具体结构为:输入层-卷积层1-池化层1-卷积层2-池化层2-全局平均池化层-Dropout层1-全连接层1-Dropout层2-全连接层2-Dropout层3-全连接层3-Softmax层-输出层。

[0078] 其中,输入层用以输入序列数据,根据输入数据格式,将输入层型号设定为 $28 \times 28 \times 1$;卷积层为网络核心部分,负责将原始数据映射到隐层的特征空间,其中卷积层1与卷积层2的卷积核大小均设定为 4×4 ;池化层用以缩小数据尺寸,减少全连接层的参数并加快训练速度,其中池化层1与池化层2均采用最大池化,其大小均设定为 2×2 ;全局平均池化层用以替代全连接层,可以有效减少参数数量并防止过拟合现象发生;全连接层与Softmax层用以完成分布式特征表示到样本标记空间的映射以及结果归一化;Dropout层置于全连接层之后,同样为了防止过拟合现象发生,其随机失活概率为 50% ;输出层则输出最终的分类结果。

[0079] 步骤5:将训练样本输入CNN模型,训练模型的分类能力。

[0080] CNN模型训练过程为一个循环迭代过程,如图3所示,主要通过前向传播算法和反向传播算法更新网络各层级状态与参数,具体包括以下步骤:

[0081] S51:初始化各网络参数,包括各神经元的权重和偏置等;

[0082] S52:输入训练样本数据;

[0083] S53:计算CNN网络内部各层级输出;

[0084] 其中,CNN网络内部各层级输出的计算公式为:

[0085] 1) 卷积层输出:

$$[0086] \quad Y_{i,j} = \sum_{m=1}^M \sum_{n=1}^N x_{i+m-1,j+n-1} k_{m,n} \quad (3)$$

[0087] 式(3)中, $i=1,2,\dots,I$; $j=1,2,\dots,J$; $I=P-M+1$; $J=Q-N+1$; P 、 Q 为输入矩阵 X 的尺寸, $k_{m,n}$ 是 $M \times N$ 的卷积核的第 m 行,第 n 列的元素, $x_{i+m-1,j+n-1}$ 是输入矩阵 X 中的第 $i+m-1$ 行,第 $j+n-1$ 列的元素。每个卷积核都会产生一个 $I \times J$ 的输出矩阵 Y ;

[0088] 2) 池化层输出(平均池化):

$$[0089] \quad u = \frac{1}{S_R} \sum_{i,j \in R} Y_{i,j} \quad (4)$$

[0090] 式(4)中, S_R 为池化区域面积,即池化区域元素个数; $Y_{i,j}$ 为卷积层输出 Y 第 i 行第 j 列的元素;

[0091] 3)全连接层输出:

$$[0092] \quad h_n = b_n + \sum_{m=1}^M v_m \times w_{mn} \quad (5)$$

[0093] 式(5)中, h_n 为输出神经元的值; v_m 为输入神经元的值; w_{mn} 、 b_n 分别为链接权值与偏置, m 为输入神经元的数目; n 为输出神经元数目。

[0094] S54:计算当前序列索引预测输出及其损失函数;

[0095] 其中,预测输出值的计算公式及其损失函数的选取分别为:

$$[0096] \quad \hat{y}_n = \tanh(V \cdot h_n + c) \quad (6)$$

$$loss = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^K (y_{n,ij} \ln \hat{y}_{n,ij} + (1 - y_{n,ij}) \ln(1 - \hat{y}_{n,ij})) \quad (7)$$

[0097]

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{2x}} \quad (8)$$

[0098] 式中, V 和 c 表示预测输出的权值和偏置; \tanh 表示双曲正切函数; N 为每次送入网络训练的批量大小; K 为类型数目; $y_{n,ij}$ 表示第 i 批次及第 j 类型样本的实际标签, $\hat{y}_{n,ij}$ 则表示第 i 批次及第 j 类型样本的预测输出值。

[0099] S55:计算所有参数基于损失函数的偏导数,通过梯度下降法更新网络所有的参数;

[0100] S56:当损失函数不再下降或达到设定训练次数,完成训练。

[0101] 步骤6将测试样本输入CNN模型,测试各网络模型的辨识准确率,并通过调节网络参数使得辨识准确率能够达到95%左右,得到训练完成的神经网络模型。

[0102] 根据上述步骤获得训练完成的神经网络模型,步骤7与步骤8将由两个具体的实施例进行阐释。

[0103] 实施例1:

[0104] 为验证该算法是否能够辨识出系统在振荡过程中叠加新的振荡模态,构造如下理想振荡测试信号:

$$[0105] \quad s(t) = 0.6 e^{0.12t} \sin(2\pi \times 0.84t + \pi) + 0.7 e^{-0.15t} \sin(2\pi \times 1.21t + \frac{\pi}{3}) + 0.8 e^{0.3(t-1)} \sin(2\pi \times 8.8(t-1) + \frac{\pi}{4}) \varepsilon(t-1) + \eta(t), 0 \leq t \leq 2 \quad (10)$$

[0106] 式(10)中, $\varepsilon(t)$ 表示阶跃函数, $\eta(t)$ 表示噪声信号。

[0107] 该振荡信号图像如图4所示,信号长度2s,信噪比 $SNR=10$ dB。1s前,信号包含两个模态,其中频率 $f_1=0.84$ Hz, $f_2=1.21$ Hz,属于低频振荡。 $t=1$ s时,引入一个新的振荡模态,其频率 $f_3=8.8$ Hz,属于次同步振荡,因此1s后的振荡信号中同时包含低频振荡与次同步振荡两种振荡类型。

[0108] 步骤7通过滑动时窗获取待测振荡信号样本。滑窗长度为1s,滑动间隔为0.5s,采样频率为400Hz。为了辨识振荡信号中发生的模态改变,需在1s前后分别使用滑窗取样。本实施例中,选取四段信号作为辨识对象,分别为0~1s、0.5~1.5s与1~2s。其中0.5~1.5s包含了模态发生变化的时间节点,用以验证本发明针对复杂振荡模态辨识的能力。

[0109] 步骤8处理待测振荡信号并输入CNN模型,根据网络输出分析振荡类型的辨识结果,如下表1所示:

[0110] 表1.基于实施例1的振荡类型的辨识结果表

分段	存在与否	可能性				辨识结果
		低频振荡	次同步振荡	超同步振荡	中高频振荡	
0~1s	存在	0.9999	0.0476	0.0125	0.0023	低频振荡
	不存在	0.0001	0.9524	0.9875	0.9977	
0.5~1.5s	存在	0.9622	0.9523	0.0187	0.0035	低频振荡 次同步振荡
	不存在	0.0378	0.0477	0.9813	0.9965	
1~2s	存在	0.9470	0.9538	0.0208	0.0037	低频振荡 次同步振荡
	不存在	0.0530	0.0462	0.9792	0.9963	

[0112] 参考上表1,可以发现该方法的辨识结果与理想振荡信号的真实类型完全吻合。当所辨识的振荡信号涉及新振荡类型的加入,该方法依旧适用。此外,该方法所需辨识时间仅1s,远快于传统振荡信号辨识方法,因此从各方面考虑,该方法都更具优势。

[0113] 实施例2:

[0114] 为了验证本发明的实际辨识效果,从电力系统中获取一段振荡信号实测数据。如图5所示,该段振荡信号由一处小扰动所激发,时间位于4s处。为了辨识该扰动所激发的振荡类型,因此截取扰动结束后的数据作为本实施例中的待测振荡信号。

[0115] 步骤7:通过滑动时窗获取待测振荡信号样本。滑窗长度为1s,滑动间隔为0.5s,采样频率为400Hz。本实施例中,于扰动结束后滑取两段信号作为辨识对象,分别为4~5s与6~7s,以验证振荡类型是否会发生改变。

[0116] 步骤8:处理待测振荡信号并输入CNN模型,根据网络输出分析振荡类型的辨识结果,如下表2所示:

[0117] 表2.基于实施例2的振荡类型的辨识结果表

分段	存在与否	可能性				辨识结果
		低频振荡	次同步振荡	超同步振荡	中高频振荡	
4~5s	存在	0.9999	0.0530	0.0180	0.0044	低频振荡
	不存在	0.0001	0.9470	0.9820	0.9956	
6~7s	存在	0.9999	0.0482	0.0230	0.0036	低频振荡
	不存在	0.0001	0.9518	0.9770	0.9964	

[0119] 参考上表2,可以判断该系统中由扰动所激发的振荡类型为低频振荡。由于采用滑窗采样,该方法可以伴随振荡信号的产生不断实时返回所产生的振荡类型,判断是否存在

新型振荡的加入。此外,1s的识别时间使得该方法能迅速获取辨识结果,因此相较于传统振荡信号辨识方法,本发明更具实用价值。

[0120] 以上所述的具体实施方式,对本发明的目的、技术方案和有益效果进行了进一步详细说明,所应理解的是,以上所述仅为本发明的具体实施方式而已,并不用于限定本发明的保护范围,凡在本发明的精神和原则之内,所做的任何修改、等同替换、改进等,均应包含在本发明的保护范围之内。

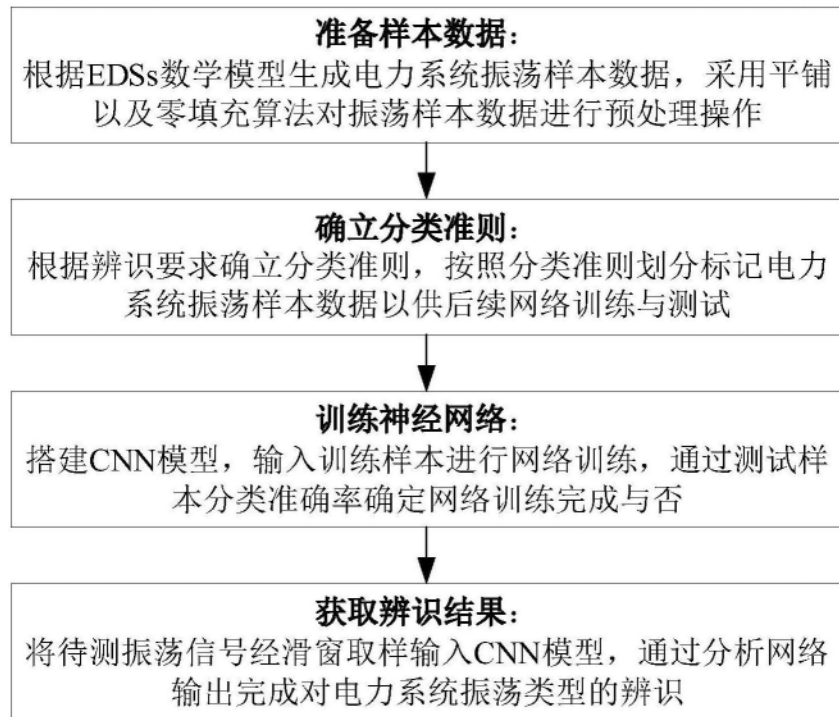


图1

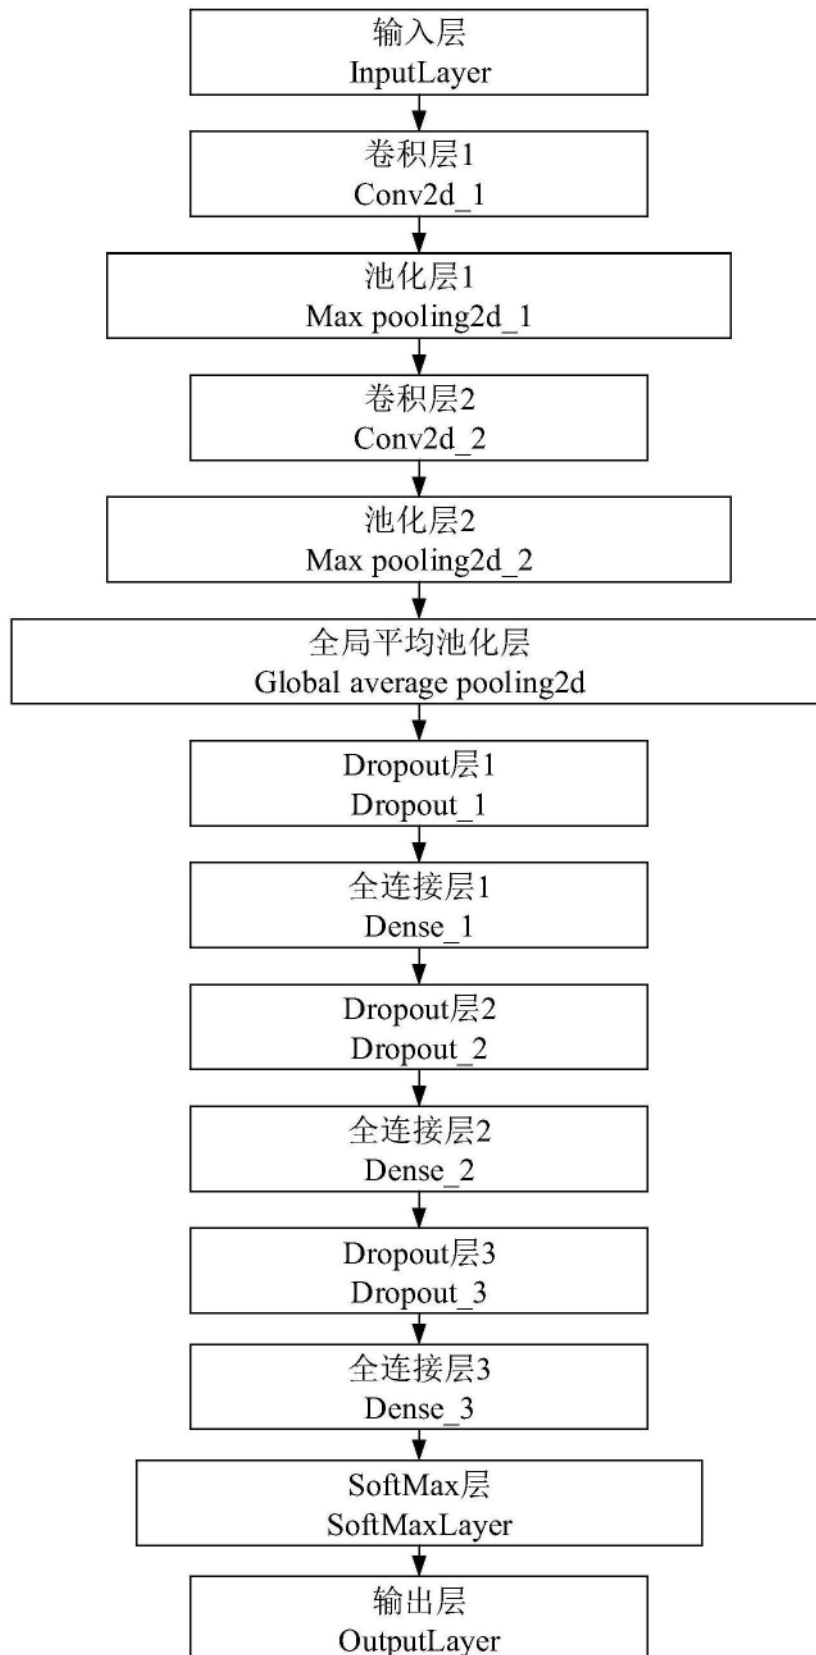


图2

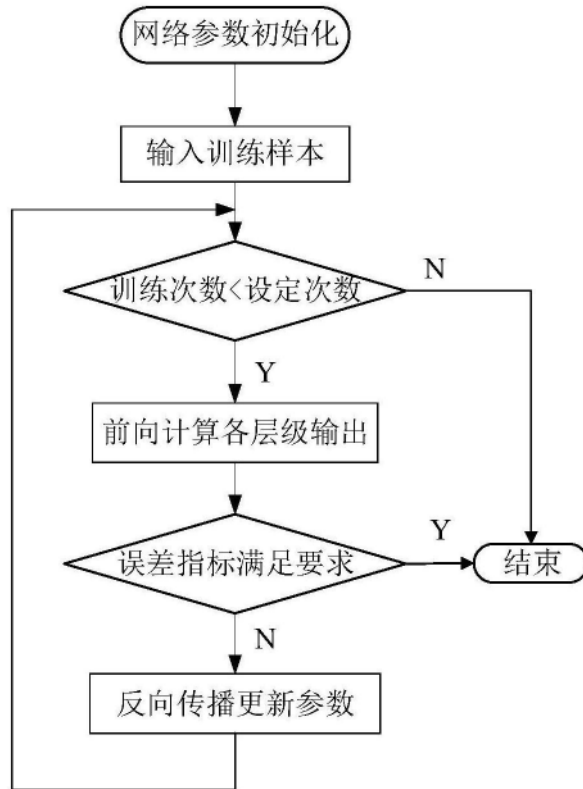


图3




图4




图5