

华北电力大学

学术硕士学位论文

风电系统次/超同步振荡 辨识与定位方法研究

**Research on Identification and Location Methods of
Sub-/Super-synchronous Oscillation
in Wind Power Systems**

郝 琪

2024 年 5 月

国内图书分类号：TM712

国际图书分类号：621.3

学校代码：10079

密 级：公开

学术硕士学位论文

风电系统次/超同步振荡 辨识与定位方法研究

硕 士 研 究 生：郝琪

导 师：刘崇茹教授

申 请 学 位：工学硕士

学 科 专 业：电气工程

所 在 学 院：电气与电子工程学院

答 辩 日 期：2024 年 5 月

授予学位单位：华北电力大学

Classified Index: TM712

U.D.C: 621.3

Thesis for the Academic Master's Degree

**Research on Identification and Location Methods of
Sub-/Super-synchronous Oscillation
in Wind Power Systems**

Candidate:	Hao Qi
Supervisor:	Prof. Liu Chongru
Academic Degree Applied for:	Master of Engineering
Speciality:	Electrical Engineering
School:	School of Electrical and Electronic Engineering
Date of Defence:	May, 2024
Degree-Conferring-Institution:	North China Electric Power University

摘 要

随着新能源并网技术的发展,电力系统电力电子化程度不断提高,风电机组与系统交互耦合引发的振荡频率范围更加宽广,次/超同步振荡频发,成为影响系统安全稳定运行的关键问题之一。为了预知系统的振荡风险并及时有效地抑制振荡,需要获悉振荡的特征及初始起振位置。相较于传统的机理建模方法,人工智能具有强大的拟合能力,可以逼近任何复杂的函数,其特征提取和信息处理能力十分强大,能够准确的识别振荡特征并进行振荡溯源。因此,本文围绕风电并网系统次/超同步振荡问题,提出了基于人工智能技术的振荡参数辨识及振荡源在线定位方法。主要研究工作以及所取得的研究成果如下:

(1) 考虑新能源振荡的时变特性,提出一种基于门控循环单元(Gate Recurrent Unit, GRU)与卷积神经网络(Convolutional Neural Network, CNN)的振荡参数在线辨识模型,能够快速有效地辨识振荡参数。所提方法利用卷积层与门控循环单元进行特征提取网络的构建,实现振荡数据深层隐藏非线性特征与时序波动特征的提取融合。基于人工智能技术,将振荡参数辨识问题转化为特征数据回归拟合问题,实现振荡参数精准辨识。通过离线训练,在线应用的实施过程,满足振荡参数辨识快速性要求。最后,通过算例对比,验证了所提振荡参数辨识方法的有效性和精确性。

(2) 考虑到电力系统实际振荡数据的匮乏,提出了一种基于深度子领域自适应网络(Deep Subdomain Adaption Network, DSAN)的振荡源定位方法。该方法将仿真系统中的强迫振荡泛化到实际次/超同步振荡领域,通过输入样本与迁移模型的构建,实现次/超同步振荡源在线定位,为振荡数据匮乏导致机器学习实施困难提供了一种解决方案。设计了直驱风机并网的仿真系统测试算例,并将所提方法与不同振荡源定位方法进行了对比,证明了所提方法能够在较短的时间内给出更为准确的定位信息。此外,本文验证了所提方法在不同样本构造(样本数量、数据窗口长度、振荡采样起始时间)、不同场景(系统规模、振荡频率)下的适应性,结果表明,所提定位模型性能表现稳定,能够适应于不同的工况和系统拓扑。

(3) 考虑新能源系统振荡数据的时序性,为进一步提高振荡源定位模型的定位精度,构建门控循环单元神经网络层对第三章所提振荡源定位模型特征提取网络进行改进,实现振荡数据深层时序波动特征的提取。同时,进行了模型各部分网络连接方式以及适配层结构的改进研究,提高模型特征传递效率以及模型离线训练时的收敛速度。算例结果表明,改进后的振荡源定位方法在模型

训练速度以及定位精度上都具有一定优越性，可实现振荡源在线精准定位，为后续振荡精准抑制提供了有效的位置信息参考。

关键词：风电并网系统；次/超同步振荡；振荡参数辨识；振荡源定位；人工智能

Abstract

With the development of new energy grid-connected technology and the increasing degree of power system power electronics, the frequency range of oscillations triggered by the interactive coupling between wind turbines and the system is wider, and the frequency of sub-/super-synchronous oscillations is frequent, which has become one of the key issues affecting the safe and stable operation of the system. In order to predict the oscillation risk of the system and suppress the oscillations in time, it is necessary to know the characteristics of the oscillations and the initial starting position. Compared with the traditional mechanism modelling methods, artificial intelligence has a powerful fitting ability to approximate any complex function, and its feature extraction and information processing ability is very powerful, which can accurately identify the oscillation characteristics and trace the oscillation. Therefore, this paper focuses on the problem of sub/supersynchronous oscillations of wind power grid-connected systems, and proposes a method of oscillation parameter identification and on-line location of oscillation source based on artificial intelligence technology. The main research work and the achieved research results are as follows:

(1) Considering the time-varying characteristics of new energy oscillations, an online oscillation parameter identification model based on gate recurrent unit (GRU) and convolutional neural network (CNN) is proposed, which is able to identify the oscillation parameters quickly and effectively. The proposed method makes use of convolutional layer and gated loop unit for the construction of feature extraction network, and realises the fusion of the deep hidden nonlinear features of the oscillation data and the extraction of the time series fluctuation features. Based on artificial intelligence technology, the oscillation parameter identification problem is transformed into a feature data regression fitting problem to achieve accurate identification of oscillation parameters. Through the implementation process of offline training and online application, the requirement of fast oscillation parameter identification is met. Finally, the effectiveness and accuracy of the proposed oscillation parameter identification method is verified by comparing the examples.

(2) Considering the scarcity of actual power system oscillation data, an oscillation source localisation method based on deep subdomain adaption network (DSAN) is proposed. The method generalises the forced oscillations in the simulation system to the real sub/supersynchronous oscillation domain, and realises the online localisation of the sub/supersynchronous oscillation source through the construction of input samples and transfer models, which provides a solution for the difficulty of

implementing machine learning due to the lack of oscillation data. A test case of the simulation system with direct-drive wind turbine grid-connected is designed, and the proposed method is compared with different oscillation source localisation methods, which proves that the proposed method can give more accurate localisation information in a shorter time. In addition, this paper verifies the adaptability of the proposed method under different sample configurations (number of samples, data window length, oscillation sampling onset time) and different scenarios (system size, oscillation frequency), and the results show that the proposed localisation model performs stably, and can be adapted to different working conditions and system topologies.

(3) Considering the temporal nature of the oscillation data of the new energy system, in order to further improve the positioning accuracy of the oscillation source localisation model, a gated recurrent unit neural network layer is constructed to improve the feature extraction network of the oscillation source localisation model proposed in Chapter 3, so as to realise the extraction of features of the deep temporal fluctuations of the oscillation data. At the same time, the improvement of the network connection and the structure of the adaptation layer is carried out to improve the feature transfer efficiency of the model and the convergence speed of the model when it is trained offline. The example results show that the improved oscillation source localisation method has certain superiority in model training speed and localisation accuracy, and can realise online accurate localisation of the oscillation source, which provides effective location information reference for the subsequent accurate suppression of oscillation.

Keywords: grid-connected wind power systems, sub-/super-synchronous oscillation, oscillation parameter identification, oscillation source location, artificial intelligence

目 录

第 1 章 绪论.....	1
1.1 课题背景及研究的目的和意义	1
1.2 国内外研究现状.....	2
1.2.1 振荡参数辨识技术研究现状.....	2
1.2.2 振荡源定位技术研究现状.....	4
1.3 本文主要工作.....	5
第 2 章 基于 CNN-GRU 的振荡参数辨识方法	8
2.1 引言.....	8
2.2 CNN 与 GRU 的工作原理.....	8
2.2.1 卷积神经网络.....	8
2.2.2 门控循环单元.....	11
2.3 基于 CNN-GRU 的次/超同步振荡参数辨识模型	12
2.3.1 次/超同步振荡参数辨识模型构建	12
2.3.2 次/超同步振荡参数辨识方法具体实施流程	14
2.4 算例分析.....	15
2.4.1 算例构建与验证.....	15
2.4.2 不同振荡参数辨识方法对比.....	16
2.5 小结.....	17
第 3 章 基于深度子领域自适应的振荡源定位方法	19
3.1 引言.....	19
3.2 深度子领域自适应原理.....	19
3.2.1 深度迁移学习原理.....	19
3.2.2 深度子领域自适应原理.....	21
3.3 基于 DSAN 的振荡源定位模型.....	23
3.3.1 源域与目标域样本空间构建.....	23
3.3.2 振荡源定位模型构建.....	26
3.3.3 振荡源定位方法具体实施流程.....	27
3.4 算例分析.....	29
3.4.1 算例构建与验证.....	29
3.4.2 不同振荡源定位方法对比.....	34
3.4.3 样本构造对模型精度影响研究.....	36
3.4.4 定位模型不同场景适应性研究.....	38
3.5 本章小结.....	41
第 4 章 基于 GRU-DSAN 的振荡源定位方法.....	42

4.1 引言.....	42
4.2 基于 GRU-DSAN 的振荡源定位.....	42
4.2.1 GRU-DSAN 振荡源定位模型建立.....	42
4.2.2 基于 GRU-DSAN 的振荡源定位方法实施架构.....	44
4.3 算例分析.....	46
4.3.1 算例构建与验证.....	46
4.3.2 基于不同迁移学习定位模型精度对比	50
4.4 本章小结.....	51
第 5 章 结论与展望	52
5.1 结论.....	52
5.2 展望.....	53
参考文献.....	54

第1章 绪 论

1.1 课题背景及研究的目的和意义

随着“双碳”政策以及“十四五”能源规划的落实推进，以风能为代表的清洁能源逐渐代替传统化石能源，在能源供给侧逐步占据主导位置。我国是全球风电规模最大、发展最快的国家。图 1-1 为 2015 年到 2023 年间我国风电装机容量增长变化图，截至到 2023 年底，我国风机装机规模达 4.4 亿千瓦左右^[1]。预计到 2030 年底，风光发电总装机容量将达到 12 亿千瓦以上，基本完成清洁低碳、安全高效能源体系的构建^[2,3]。




图 1-1 2015-2023 年风电装机容量图

区别于传统电力系统，新能源电力系统电力电子化程度增强，改变了电力网络的基本形态、稳定特征和演化规律^[4]。新能源场站与电网之间的动态交互特性复杂多变，呈现出较强的非线性，快慢动态交互，导致互联系统产生的振荡形态更加多样化，从而诱发频段愈发宽广的次/超同步振荡，严重威胁电力系统的安全稳定运行^[5]。近年来，国内外多次发生风电系统次/超同步振荡引发系统稳定性问题的实际案例，如图 1-2 所示。2015 年中国新疆哈密地区出现直驱风电场与弱交流系统交互产生持续的次/超同步振荡，造成多台机组相继脱网^[6]。2022 年 01 月 30 日，康巴诺尔站监控室检测到系统电压发生频率为 44Hz/56Hz 的次/超同步振荡^[7]。风电并网系统所引发的次/超同步振荡问题已经成为当前电网维持安全与稳定所面临的重要挑战之一^[8-11]。




图 1-2 风电系统次/超同步振荡案例

综上所述，为了更好地实现新能源的推广与消纳，为新型电力系统的发展奠定基础，需要及时有效地抑制振荡。但随着电网规模的扩大和风电渗透率的提高，系统的复杂度不断攀升，振荡措施的精确实施依赖于次/超同步振荡具体振荡特征、振荡起始具体位置等必要的控制信息基础。因此，亟需提出适应于风电系统次/超同步振荡的振荡特征辨识与振荡源定位技术，实现系统振荡参数的快速识别和振荡源精准定位。这对有效实施振荡抑制策略，避免振荡进一步扩散，保证系统的安全稳定运行具有重要意义。

1.2 国内外研究现状

1.2.1 振荡参数辨识技术研究现状

风电系统次/超同步振荡的精准快速辨识，不仅能判断振荡类型，也能及时获得振荡频率、衰减系数等信息，为振荡抑制措施的有效实施提供了数据信息基础，保证系统的持续稳定运行。目前常用的振荡参数辨识方法主要为信号处理类方法，大致可以分为傅里叶变换法、小波变换法、经验模态分解法、谱估计方法四大类^[12]。

(1) 傅里叶变换法

傅里叶变换的方法是一种经典的信号分析方法，利用傅里叶变换将波动信号从时域映射到频域，获得其对应的振荡模态。主要包括快速傅里叶变换(Fast Fourier Transform, FFT)方法和离散傅里叶变换(Discrete Fourier Transform, DFT)方法两种。DFT 为传统处理离散数据的变换方法，但其计算量较大。FFT 为 DFT 的一种高效快速算法，极大的减少了 DFT 的计算量。国内外学者基于 FFT 进行了大量深入研究^[13-15]，已形成一套较为成熟的振荡频率辨识流程与方案。

FFT 在实际应用时会受到栅栏效应、频谱泄露与混叠等问题，将严重影响

到振荡辨识的精度。为此,目前基于 FFT 进行振荡辨识的相关研究大多立足于对其进行改进以减小辨识结果受上述问题的影响。文献[16,17]利用不同的插值进行辨识结果的修正,以减少栅栏效应对最终结果的影响。文献[18,19]通过加长窗口的方法来减少频谱泄露的影响,提高了辨识的精确性。但通过加长窗口的方法在另一方面增加了振荡辨识的计算时间,牺牲了辨识的快速性。文献[20]基于快速压缩感知在一定程度上加快了 FFT 的计算速度。文献[21]提出一种压缩感知的方法,以解决在多模态情况下频谱混叠的问题。

FFT 在振荡辨识的过程中,可以通过时域与频域之间的变换,有效获得振荡的频率,但对于衰减系数等振荡信息无法直接获得。同时,FFT 的辨识精度受限于窗口的长度,快速性方面具有局限。另一方面,FFT 只适应于线性平稳信号的分析,并不适用于非线性非平稳振荡信号。

(2) 小波变换法

小波变换是对傅里叶变换的进一步发展,不同于傅里叶变换,其采用有限长的具有衰减系数的小波(基函数)取代无限长的三角函数进行时域信号的逼近^[22]。目前,小波变换已经被研究用于包括低频、次同步振荡的参数辨识。文献[23]将 FFT 与小波变换相结合,实现次同步振荡的精准辨识。同时,小波变换方法对噪声干扰具有较高的敏感性,文献[24]利用希尔伯特变换与其相结合,提高了辨识方法的抗噪性。

小波变换可以适应于信号的时变性^[25],获得其频率、阻尼比等振荡参数。但小波变换法其辨识的效果需要依赖于合适的基函数与阈值设定,在不同的设定下辨识效果相差较大^[12]。但两者的设定并无确定的原则与规律^[26],因此在一定程度上限制了该类方法的使用。

(3) 谱估计法

谱估计法可以分为两类:参数谱估计、空间谱估计。

参数谱估计法利用指数项进行线性组合来拟合所辨识的信号,将参数辨识转化为求解方程组参数的问题^[25]。常用的有 Prony 算法、自回归滑动平均算法(Auto Regressive Moving Average, ARMA)。但该类方法稳定性较差,极易受到噪声的影响,影响辨识精度。基于此,大量研究对 Prony 算法以及 ARMA 进行了改进工作。文献[27]基于奇异值分解(Singular Value Decomposition, SVD)对 Prony 算法进行改进,提高了模型对于噪音的识别能力。文献[28]基于鲁棒协方差矩阵对 Prony 算法进行修正,提高 Prony 辨识的鲁棒性。文献[29]中通过解析振荡波的数学模型建立 ARMA 进行系统参数估计,具有较高的辨识精度。文献[30]通过结合 ARMA 与 Prony 算法,实现了振荡参数的辨识。

虽然目前对于参数谱估计算法已进行了大量改进工作,但仍无法稳定的解决噪声对辨识结果的影响以及模型的定阶问题,限制了其应用的场景。

空间谱估计类方法将需要辨识的信号分解为信号与噪声两个子空间,利用正交性进行信号子空间的分析^[31]。目前常用的方法有旋转不变子空间法、矩阵束法、随机子空间法等。旋转不变子空间法(Estimating Signal Parameter via Rotational Invariance Techniques, ESPRIT)通过状态空间矩阵可以准确的获得振荡的频率,但 ESPRIT 同大部分信号处理的方法一致,其识别精度受噪声影响较大^[32-34]。矩阵束法(Matrix Pencil, MP)不仅可以获得振荡的频率,也可以方便的获得衰减系数等参数信息,但其同样易受噪声干扰^[35]。随机子空间法(Stochastic Subspace Identification, SSI)相较于 ESPRIT 有不受系统规模影响的优势,但其精度同样受噪音影响,且计算量较大,无法用于在线监测^[36]。

上述可知,空间谱估计类方法普遍受噪声影响较大,需要与数据降噪预处理与滤波配合使用,同时其基于状态矩阵的辨识方式导致其计算量较大,无法进行振荡实时监测。

(4) 经验模态分解法

经验模态分解(Empirical Mode Decomposition, EMD)具有较低的辨识误差,其通过自适应信号分解,进行模态的分解。通常将 EMD 与希尔伯特-黄变换^[37](Hilbert-Huang Transform, HHT)结合使用以获得相关振荡参数。除 HHT 外,EMD 也可以和其他算法^[27](Prony 算法等)结合使用。

当前,EMD 与 HHT 结合使用的辨识方法广泛使用于低频识别领域,其对于高频段振荡辨识的效果较差,还需进一步的研究。

综上所述,当前振荡参数辨识方法大多都存在其局限性以及适应范围,无法适应于当前新能源系统次/超同步振荡参数辨识在精准性以及快速性上的要求,因此,亟需进行适应于风电并网系统次/超同步振荡参数辨识方法的研究,实现振荡参数的实时监测与辨识,为振荡快速抑制提供重要的信息基础。

1.2.2 振荡源定位技术研究现状

目前,振荡源定位常用的方法有行波检测法、能量法、混合动态仿真法等。行波检测法将振荡的传播看作是行波在电网中的移动^[38],以振荡机电波峰值总是最早出现在振荡源处的理论为基础^[39],通过比较各测量点记录到行波波头最大值对应的时刻,进而来定位振荡源^[40]。该方法响应速度非常快,但当振荡源距离电压测量单元较近时会失效。能量法通过构造能量函数,根据能量在系统中的传播路径即可判断出振荡源所在的位置,是一种基于机理分析的数值仿真方法,广泛应用于低频领域^[41-44]。但由于次/超同步振荡频带较宽,诱发机理复杂,系统能量函数构建工作较为复杂,采用能量法分析含新能源电力系统次/超同步振荡问题的普适性还有待考证。另外,能量法的应用需基于一定的假设条

件，在电力系统实际运行时，这些假设条件可能无法满足，这会导致定位的偏差较大^[45]。混合动态仿真法基于系统仿真模型，仿真结果与实际测量数据之间差距较大的区域即为振荡源所在范围，通过多次迭代来获得精确振荡源位置^[46]。该方法原理简单易懂，但需要大量的迭代时间，因此，通常只用于振荡的事后分析。

伴随电力系统结构的多元化，动态特性的强非线性化，从物理机理角度出发进行次/超同步振荡源定位、识别的研究愈发困难。机器学习因其强大的处理非线性问题的能力被引入振荡源定位领域。文献[47]针对强迫振荡，考虑量测误差和系统变化的影响，提出了基于集成学习的振荡源定位方法。文献[48,49]同样针对强迫振荡，基于 K 最近邻(K-Nearest Neighbor, KNN)算法进行了振荡源定位的研究。文献[50]考虑广域电力系统数据传输的通信带宽限制，提出了基于自编码器的信号压缩与长短期记忆网络的振荡源定位方法。

然而，当前限制机器学习在振荡源定位领域应用的主要原因在于实际振荡数据的匮乏。机器学习是一种需要依赖大量高质量数据的数据驱动技术^[51]，但在实际电力系统中，相较于稳态数据，振荡数据极度匮乏。因此，实际系统振荡数据匮乏成为一个亟待解决的问题。随着迁移学习的发展，文献[52,53]基于两种场景，通过调节仿真系统中模型控制参数以获得大量源域振荡样本，尝试利用迁移学习将其迁移泛化至实际振荡领域。但上述研究并未考虑次同步振荡时的耦合特性。其次，上述迁移学习模型仅考虑了两域样本的全局边缘对齐，在两域差距较大时，迁移能力受限。同时，随着系统规模的扩大及控制环节的复杂化，通过调节仿真系统控制参数来激发大量振荡样本构成可迁移源域的方法也具有较大难度。

综上所述，为建立适应于风电系统次/超同步频段的振荡源在线定位方法，亟需突破在振荡源定位领域人工智能的数据瓶颈，进行数据集增强方法与次/超同步振荡源定位模型的研究，实现风电系统次/超同步频段振荡源在线定位，为系统振荡精准抑制提供关键位置信息。

1.3 本文主要工作

随着风电并网系统规模逐渐扩大，在风机与系统交互引发次/超同步振荡时，为及时精准地抑制振荡，本文系统地研究了风电并网系统次/超同步振荡的在线参数辨识方法与振荡源定位方法。基于人工智能技术，突破了振荡数据瓶颈，提出了适应于风电系统的次/超同步振荡特征与振荡源识别模型，实现了振荡特征与振荡源精准识别。其中，本文所提振荡源特指与交流系统耦合交互引发振荡的风电机组。论文研究的技术路线如图 1-3 所示。




图 1-3 论文研究技术路线图

第二章基于现代人工智能技术提出了一种次/超同步频段的振荡参数辨识方法，可在线获得较为精准的振荡频率与衰减系数。第三章构建了基于迁移学习的振荡源定位模型，解决了振荡源定位领域振荡数据匮乏的问题，实现振荡准确溯源。第四章通过考虑振荡时序特性对第三章所提模型进行改善，定位精度进一步提升。

各章节具体研究内容详述如下：

第一章，首先介绍了次/超同步振荡参数辨识、振荡源定位的研究背景以及其必要意义；然后，针对振荡参数辨识、振荡源定位两个内容详细介绍了当前的研究进展以及研究所面临的问题；最后给出了论文的整体研究架构与各章节具体安排。

第二章，基于现代人工智能技术，提出了一种次/超同步振荡参数(频率、衰减系数)在线辨识方法。首先研究了振荡参数辨识问题的数学本质，通过分析卷积神经网络与门控循环单元的作用原理，论证基于深度神经网络建立振荡参数辨识模型的可行性；其次，进行振荡参数辨识模型的详细设计，建立了次/超同步频段振荡参数辨识模型，并阐明了所提辨识方法的具体实施流程；最后，通过设计验证算例与对比算例证明了所提振荡参数辨识模型的有效性与优越性。

第三章，研究了一种基于迁移学习的振荡源定位方法，解决了在该领域人工智能技术应用所受到的数据瓶颈，实现振荡源的精确定位。首先，基于深度迁移学习与深度子领域自适应算法的作用原理，论证了利用迁移学习解决实际振荡数据缺失问题的适配性；其次，通过风电并网系统状态空间数值模型分析，

完成了可迁移源域与目标域样本空间构建；接着，通过网络设计完成了振荡源定位模型的建立并给出了具体实施流程；最后，通过算例验证了所提定位方法的有效性以及与其他定位方法相比的优越性，并通过实验证明了所提模型在不同场景、不同样本构造、宽频带振荡情况下都具有较强的适应性。

第四章，针对振荡数据的时序特性，基于第三章所提振荡源定位方法的研究基础进行改进，提出了一种考虑振荡时序波动特征的振荡源定位方法，进一步提高了振荡源定位精度。首先基于第二章的门控循环单元、瓶颈层网络等对振荡源定位网络相关环节进行改进，建立了优化后振荡源定位模型具体网络结构；其次，给出了基于改进后的振荡源定位模型进行振荡源定位的具体实施架构；最后，通过算例验证了所提振荡源定位方法的高精度以及较改进前定位模型的优越性。

第五章，总结了全文的工作，并在此基础上给出了后续的研究展望。

第2章 基于 CNN-GRU 的振荡参数辨识方法

2.1 引言

风电系统发生次/超同步振荡可能会造成电力电子器件损坏、大面积风电机组脱网等威胁电力系统安全稳定运行的问题。为了在振荡发生时精准快速采取抑制措施来抑制振荡，亟需进行振荡参数(振荡频率、衰减系数等)的快速辨识来为振荡抑制提供必需的振荡信息基础。目前常用的 Prony 等信号处理类振荡参数辨识方法属于线性分析方法而无法适应于“双高”系统的强非线性振荡信号。同时，这些方法的精确性依赖于在线计算的计算精细度，无法满足现如今振荡抑制快速性的要求。

针对当前研究所存在的问题，本章基于现代人工智能技术建立了次/超同步振荡频率辨识以及衰减系数辨识的数据驱动模型，有效实现了振荡参数的准确辨识。首先，通过分析卷积神经网络(Convolutional Neural Network, CNN)与门控循环单元(Gate Recurrent Unit, GRU)的原理与特征，论述利用 CNN 与 GRU 建立振荡参数辨识模型的可行性。其次，基于卷积神经网络与门控循环单元分别设计适应于次/超同步振荡频率与衰减系数辨识的 CNN-GRU 网络模型，并说明了所提振荡参数辨识方法具体实现流程。最后，通过算例验证，证明了本章所提振荡参数辨识模型的有效性。同时，通过与其他振荡参数辨识方法对比，证明了所提 CNN-GRU 振荡参数辨识模型在辨识精度上的优越性。

2.2 CNN 与 GRU 的工作原理

振荡参数辨识的任务即为将采样获得的离散振荡信号数据转化为具有物理意义的振荡特征数据(振荡频率、振荡衰减系数)，这一过程本质与回归拟合类似。因此，振荡参数辨识问题可以建模为回归问题。

风电系统次/超同步振荡具有强非线性化与时序性的数据特征。CNN 具有强大的非线性特征提取能力；GRU 通过门控形成记忆结构，可以深入挖掘数据前后之间隐含的时序关系。因此，可以联合 CNN 与 GRU 建立深度回归模型实现振荡特征的精准识别。本节对 CNN 与 GRU 的工作原理进行详细分析。

2.2.1 卷积神经网络

卷积神经网络是一种以卷积运算为基础的前馈人工神经网络^[54]。模型主要由卷积层、池化层、全连接层构成，如图 2-1 所示。CNN 可以通过自主学习从

样本数据中得到特征表达,具有较强的特征提取能力。同时,卷积层权值共享、局部感受野的特点以及池化层的池化作用,使得 CNN 参数数量大幅下降,较大程度上提高了 CNN 的训练效率。




图 2-1 CNN 结构图

(1) 卷积层

卷积层是 CNN 中进行特征提取的主要部分,通过使用卷积核实现特征提取的功能。卷积核在工作时,按照设定的要求在输入特征图上进行平移,每次平移都在感受野内将输入特征与权值矩阵相乘并叠加偏置值后输出。感受野是卷积层的一个重要的概念,用以表示输出的特征图上每一个元素所能映射的输入特征图上的区域。

同时,由于卷积核卷积运算为线性化运算,为了能使网络更好适应于非线性化模型,利用激活函数在卷积层的输出环节进行非线性化处理。故卷积层的作用公式整体可以表示为如式(2-1)所示^[55]。

$$H_i = \sigma(H_{i-1} \otimes W_i + b_i) \tag{2-1}$$

- 式中 H_i ——第 i 层卷积核的输出特征矩阵;
 σ ——激活函数,常用的有 ReLU、Tanh、Sigmoid 等;
 W_i ——卷积核进行卷积操作时权值所构成的矩阵;
 b_i ——第 i 层卷积核的偏置值向量。

在本章振荡辨识模型中,输入的数据样本为振荡波数据,是典型的时序数据。因此,本章所采用的卷积核为专门用于处理时序数据所设计的一维卷积。区别于常用的二维卷积核,一维卷积核仅在时间序列维度上进行卷积操作,得到一个特征向量,其作用过程可视化如图 2-2 所示。




图 2-2 一维卷积作用图

(2) 池化层

池化层是卷积神经网络区别于传统全连接神经网络的重要特征之一，也是提高卷积神经网络训练效率的设计之一^[56]。池化层通过缩小特征图大小，来减少网络参数以提高模型训练的速度。通常，常用的池化方式有两种：最大池化、平均池化。

最大池化：对输入的特征矩阵进行划分形成若干个矩阵子区域，仅保留每个子特征区域的最大值，其作用公式如式(2-2)所示。

$$u = \max_{(i,j) \in R_{ij}} y_{ij} \quad (2-2)$$

式中 y_{ij} —— 矩阵 R_{ij} 区域内的数据元素；

u —— 该区域的最大池化输出。

平均池化：对输入的特征矩阵进行划分形成若干个矩阵子区域，输出每个子特征区域的均值，其作用公式如式(2-3)所示。

$$u = \frac{1}{S_{R_{ij}}} \sum_{(i,j) \in R_{ij}} y_{ij} \quad (2-3)$$

式中 $S_{R_{ij}}$ —— 区域 R_{ij} 中的数据元素个数。

在本章辨识模型设计过程中，为使得模型计算量更少，采用了最大池化的方法。最大池化本质上提取特征图中占比最大的数据进入下一层，减少了网络的冗余信息参数，加快模型的收敛。

(3) 全连接层

CNN 在经过卷积与池化层操作后，需要经过一层或多层全连接层对前级网络所提取的局部特征进行整合。全连接层的结构如图 2-3 所示。




图 2-3 全连接层结构图

其每个神经元都与上一层网络的所有神经元进行全连接^[57]。通过加权参数与偏置参数，对上一层特征矩阵进行加权和并叠加偏置后输出，其输出可以表示为公式(2-4)所示。

$$h_n = b_n + \sum_{m=1}^M v_m \times w_{mn} \quad (2-4)$$

式中 h_n —— 第 n 个输出神经元的输出值；

v_m ——第 m 个输入神经元的输入值；

w_{mn} ——第 m 个输入神经元与第 n 个输出神经元之间的权值；

b_n ——第 n 个输出神经元的偏置值。

全连接层由于其每个神经元都与上层所有神经元相连，因此其有很强的特征表示能力，可以很好的拟合特征数据。但是全连接层参数量较大，所以一般情况下，全连接层层数不宜过高。

本质上讲，全连接层仍然为线性化运算，因此，为提高模型的表达能力，一般会在全连接层的输出环节加入激活函数(ReLU、Tanh、Sigmoid 等)对输出数据进行非线性化。

2.2.2 门控循环单元

GRU 采用门控机制控制信息流动来捕捉时间序列中特征的时序依赖关系^[58]，相较于传统循环神经网络(Recurrent Neural Network, RNN)^[59]，可以更好地解决训练过程中的梯度爆炸与梯度消失问题。同时相较于经典的长短期记忆神经网络(Long Short-Term Memory, LSTM)^[60]，GRU 网络结构更简单，仅有两个门控单元，训练参数量更小，在收敛速度与训练难度上都要优于长短期记忆神经网络。GRU 的网络单元结构如图 2-4 所示。




图 2-4 门控循环单元结构图

r_t 和 z_t 分别是门控循环单元控制重置与控制更新的门控。直观上， r_t 决定了如何结合新的输入信息与前面的记忆信息， z_t 决定了前面记忆信息传递到当前的数量。本质上， r_t 用以控制先前状态信息的遗忘程度，计算公式如式(2-5)所示； z_t 用以控制需要记忆先前状态信息的程度，计算公式如式(2-6)所示。

$$r_t = \sigma(W^r x_t + U^r h_{t-1}) \quad (2-5)$$

$$z_t = \sigma(W^z x_t + U^z h_{t-1}) \quad (2-6)$$

式中 σ ——sigmoid 激活函数，将数据映射至 0 到 1 之间充当门控信号；

x_t ——当前时刻输入的特征信息，即所输入时间序列的第 t 个数据；

U 、 W ——网络中需要学习的的权重参数;

h_{t-1} ——前一时刻的隐藏层状态信息。

相对应, h_t 表示当前时刻的隐藏层信息, 具体计算表达式如式(2-7)所示。

$$h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1} \quad (2-7)$$

式中 $\tilde{h}_t$ ——当前时刻的记忆信息。

当前时刻记忆信息的具体计算公式如(2-8)所示。

$$\tilde{h}_t = \tanh(Wx_t + r_t U h_{t-1}) \quad (2-8)$$

门控循环单元通过重置门与更新门两个门控之间的配合, 保留或者遗忘前一时间段的信息, 传递与模型目标相关信息, 完成数据之间隐含的深层时序特征的提取。

2.3 基于 CNN-GRU 的次/超同步振荡参数辨识模型

2.3.1 次/超同步振荡参数辨识模型构建

本节基于 CNN 与 GRU 建立深度回归神经网络, 提取振荡特征, 辨识振荡参数。在利用 CNN 强非线性特征提取能力进行振荡特征提取的同时, 基于 GRU 进行 CNN 特征提取部分的改进以提高辨识模型对于振荡时序特征的深度提取能力, 以适应振荡的强时序性特性, 从而提高模型的辨识精度。

同时, 由于振荡衰减系数与振荡频率两者相关性不高, 同时数值差距较大, 为降低模型离线训练成本, 提高模型在工程应用中的实用价值, 将振荡的衰减系数辨识与振荡的频率识别各自构建为两个单独的辨识模型, 进行分别训练。

2.3.1.1 频率辨识模型构建

频率辨识模型的输入为振荡波通过采样后的离散时序序列, 其数据长度为 L 。因此, 输入层通过设置 L 个神经元进行输入信号的激活。模型的特征提取器部分由卷积层以及门控循环单元构成, 首先通过卷积层进行振荡数据内部隐藏非线性特征提取, 同时利用门控循环单元进行振荡波动时序特征学习, 最终两级网络特征融合获得包含振荡数据前后深层隐藏时序关系的数据特征。最后将特征提取器部分所提取的与振荡频率相关的隐藏数据特征通过全连接层进行回归拟合, 通过输出层获得振荡频率。

进一步, 为加快模型的收敛速度, 提高模型训练的稳定性, 在卷积层以及全连接层中随机加入了归一化层(Batch Normalization, BN)进行特征的归一化处理。同时, 为减轻模型层数过高以及全连接层参数量大所带来的过拟合问题, 在全连接层之间利用随机失活(Dropout)正则化手段将模型内部隐藏层的输出

或部分权重随机置零，使部分神经元随机不参与训练过程，降低神经元之间过度依赖故有关系的程度，提高模型的鲁棒性，减少过拟合现象。

模型的详细结构与网络参数如下表 2-1 所示。

表 2-1 基于 CNN-GRU 振荡频率辨识模型结构与网络参数

网络类型	名称	参数
输入网络	输入层	L
卷积网络层	一维卷积层+ReLU	1,32,7
	BN 层	32
	最大池化层	2
	一维卷积层+ReLU	32,16,7
	BN 层	16
	最大池化层	2
	一维卷积层+ReLU	16,8,5
	BN 层	8
门控循环单元层	GRU 层	8,50
	GRU 层	50,100
	GRU 层	100,50
	GRU 层	50,8
全连接回归层	全连接层+ReLU	1000
	BN 层	1000
	Dropout 层	0.2
	全连接层+ReLU	256
	全连接层+ReLU	100
输出层	全连接层+Sigmoid	1

2.3.1.2 衰减系数辨识模型构建

振荡衰减系数辨识模型与频率辨识模型设计思路一致，但由于衰减系数本身数值较小，导致其精准辨识相较于频率难度较大。故在建立衰减系数辨识模型时，通过加深模型的层数来提高模型的特征拟合与非线性表达的能力。本章通过增加 GRU 层的层数来加深网络深度。同时，为减轻模型深度加深所带来的模型收敛速度降低的问题，将输出层的激活函数改用 Tanh 函数。Tanh 函数以原点中心对称，其输出均值为 0，故其收敛性能较好。

综上，将衰减系数辨识模型相较于频率辨识模型改进部分的具体结构与网络参数给出，如表 2-2 所示。模型剩余部分的详细结构与网络参数见表 2-1，此

处不再赘述。

表 2-2 基于 CNN-GRU 振荡衰减系数辨识模型部分结构与网络参数

网络类型	名称	参数
门控循环单元层	GRU 层	8,50
	GRU 层	50,100
	GRU 层	100,50
	GRU 层	50,50
	GRU 层	50, 8
输出层	全连接层+Tanh	1

2.3.2 次/超同步振荡参数辨识方法具体实施流程

本章所提的基于 CNN-GRU 的次/超同步振荡参数辨识方法本质为基于人工智能技术的数据驱动方法，因此，如图 2-5 所示，模型在具体实施时可以概括为模型离线训练、在线实际应用两个大部分。各部分的具体使用步骤与流程说明如下。




图 2-5 次/超同步振荡参数辨识方法实施流程

离线训练部分：

1) 样本准备：单个模态的振荡可以以一个频率、振荡初始幅值、衰减系数、初始相位已知的正弦信号表示，其数学表达如下所示：

$$\begin{cases} x(t) = Ae^{\alpha t} \cos(\omega t + \varphi) \\ \omega = 2\pi f \end{cases} \quad (2-9)$$

式中 A —— 振荡的初始幅值；
 f —— 该模态的振荡频率；
 α —— 振荡的衰减系数；
 φ —— 振荡发生时的初始相位。

基于公式(2-9)，通过设定振荡数值模型中相关参数(衰减系数、初相位、振荡幅值与频率)的取值范围，按照一定采样规则，采样生成大量振荡数据，构建样本集。

2) 数据预处理：为减少网络训练过程中的计算量，提高模型的收敛速度，需要按照公式(2-10)对第 1) 步所生成的振荡样本进行归一化处理。同时，由于次/超同步振荡频率标签数据尺度跨越较宽(10Hz~150Hz)，同样需对频率标签进行归一化操作。

$$a' = \frac{a - \min(a)}{\max(a) - \min(a)} \quad (2-10)$$

式中 a —— 振荡波数据的特征向量；

a' —— 向量 a 经归一化后的特征向量。

3) 模型网络搭建：根据 2.3.1 节分别进行次/超同步振荡频率辨识与衰减系数辨识的 CNN-GRU 回归网络构建，网络具体结构与参数设置分别如表 2-1 与表 2-2 所示。

4) 模型训练：对频率辨识、衰减系数辨识的两个模型进行分别训练。两个模型的优化器选择均为 Adam，损失函数为 MSEloss 函数。使用平均相对误差 E 作为衡量模型性能的指标^[61]，计算公式如公式(2-11)所示。

$$E = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i^* - y_i}{y_i} \right| \times 100\% \quad (2-11)$$

式中 N —— 测试样本总数；

y_i^* ——测试样本 i 经过模型后输出的辨识值；

y_i —— 样本真实标签值。

在线应用部分：

1) 待辨识振荡数据获取：基于电力系统的量测设备获取待辨识振荡实时录波数据。

2) 数据预处理：将录波信号初步降噪后利用公式(2-10)进行数据归一化处理，得到可以直接输入至模型的待测信号。

3) 参数辨识：将预处理后的振荡信号分别输入训练好的频率、衰减系数网络进行辨识，得到振荡的频率与衰减系数。

2.4 算例分析

2.4.1 算例构建与验证

根据 2.3.2 节中的样本准备部分所述进行样本集构建工作，基于 MATLAB 仿真平台建立公式(2-9)的数学模型进行振荡波的生成。频率 f 范围设置为

[10:0.5:150]; 衰减系数取值范围设置为[-0.5:0.1:0.5]; 振荡幅值与初始相位角随机生成。对生成振荡波进行数值采样获得大量振荡数据, 采样频率设置为 2kHz, 采样时长为 1s。保存采样后的振荡数据以及其对应的频率与衰减系数, 通过数据预处理后获得模型的样本集 X 与标签集 Y , 并将其随机划分为模型训练集样本与测试集样本。

利用 Python 语言在 Pytorch1.8.0 架构上分别进行基于 CNN-GRU 次/超同步频段振荡频率、衰减系数辨识模型的搭建, 两模型的具体网络结构与网络参数如表 2-1 与表 2-2 所述。

利用上述生成的样本进行模型的训练, 两模型的主要训练超参数设置如表 2-3 所示。

表 2-3 基于 CNN-GRU 振荡辨识模型的训练参数

模型	参数名称	参数值
振荡辨识模型	学习率	0.0003
	批次大小	38
衰减系数辨识模型	学习率	0.0005
	批次大小	48

以公式(2-11)所定义的平均相对误差 E 衡量模型性能, 保留训练过程中误差最小时的网络为最终的参数辨识模型, 此时模型具有最高的参数辨识精度。表 2-4 展示了最优模型下振荡频率、衰减系数辨识误差结果。

表 2-4 次/超同步频段振荡参数辨识误差结果

参数名称	平均相对误差(%)
频率	1.53
衰减系数	3.74

由上表所述结果可知, 频率辨识的相对误差为 1.53%, 衰减系数辨识误差为 3.74%。衰减系数由于其本身数值较小, 因此其辨识的相对误差要略大。总体分析, 两个模型辨识的相对误差均小于 4%, 其中频率辨识模型的辨识误差可以达到小于 2%的较低水平。本章所提基于 CNN-GRU 的振荡频率辨识与衰减系数辨识模型都具有较高的精准度。

2.4.2 不同振荡参数辨识方法对比

为体现本章所提模型的优越性, 本节通过设计基于 CNN-LSTM 的振荡参数辨识模型, 与所提 CNN-GRU 模型进行对比实验。CNN-LSTM 的网络结构图如图 2-6 所示。




图 2-6 基于 CNN-LSTM 的振荡参数辨识网络

图中：ConV 代表卷积层；BN 即归一化层；Dropout 为随机失活层；Max-pooling 为最大池化层；Linear 为全连接层；LSTM 为长短期记忆神经网络层。

以式(2-11)所定义的平均相对误差 E 衡量模型性能，通过调整模型训练超参数，分别保存频率、衰减系数辨识精度最高的两个模型为最终的基于 CNN-LSTM 次/超同步振荡参数辨识模型，与本章所提 CNN-GRU 次/超同步振荡参数辨识模型的辨识结果对比如下表 2-5 所示。

表 2-5 CNN-LSTM 与 CNN-GRU 辨识误差对比

参数名称	频率辨识相对误差(%)	衰减系数辨识相对误差(%)
CNN-LSTM	2.49	4.52
CNN-GRU	1.53	3.74

由表 2-5 可知，CNN-LSTM 模型频率与衰减系数辨识的相对误差均高于本章所提的 CNN-GRU 模型。虽然长短期记忆神经网络与门控循环单元都可以通过门控配合进行振荡深层隐藏时序特征的提取，但在次/超同步振荡参数辨识问题上，GRU 性能表现要优于 LSTM，即本章所提的基于 CNN-GRU 次/超同步振荡参数辨识模型在精度上相较于 CNN-LSTM 具有一定的优越性。

2.5 小结

本章针对风电系统次/超同步频段振荡识别的问题，提出了一种基于 CNN-GRU 的振荡参数辨识模型。通过探究振荡参数辨识问题的本质，将次/超同步频段振荡参数辨识问题建模为特定数值范围内的回归问题。考虑振荡波的时序

特性，利用门控循环单元对卷积神经网络的特征提取层进行改进，实现振荡深层非线性时序波动特征提取，建立了基于 CNN-GRU 的回归模型。通过算例验证了所提模型辨识的精准性，并通过对比实验证明了本章所提模型与其他振荡参数辨识模型相比在精度上的优越性。本章研究内容的结论为：

（1）所提振荡参数辨识方法基于人工智能强大的非线性数据处理能力，相较于传统线性信号类处理方法，可有效适应于非线性振荡信号的特征提取。实现了振荡参数的精准辨识，为振荡后续抑制措施的开展提供了必要的振荡特征信息基础。

（2）本章提出利用改进的 CNN-GRU 进行振荡时序波动特征的提取与融合，建立回归辨识模型，有效提高了模型的特征提取与表达能力。相较于其他具有时序特征提取能力的神经网络模型相比，具有更高的辨识精准度，更适用于风电系统次/超同步频段的振荡参数辨识问题。

（3）相较于传统数值建模辨识方法，所提基于 CNN-GRU 辨识方法实现了模型的离线训练，在线应用。不存在实际应用辨识过程中的建模重计算环节，提高了参数辨识本身的辨识速度，可实现较短时间内振荡参数的精准辨识，为振荡能在起始发展阶段即能有效监测与抑制奠定了基础。

第3章 基于深度子领域自适应的振荡源定位方法

3.1 引言

直驱风机接入弱交流系统会引发形态较复杂的次/超同步振荡,随着并网风机规模扩大化,为了更加精准有效地抑制振荡,亟需及时定位引发振荡的风电机组。目前,传统振荡源定位方法多数基于电网复杂化数值模型建立以及长时间数值求解过程。随着电力系统动态特性的强非线性化,基于物理机理建立数值模型愈发复杂化,同时模型在求解过程中也会受到大矩阵“维度灾难”,无法保证定位的精准性与时效性。

鉴于此,人工智能技术因其强大的处理非线性问题以及在线应用能力被引入振荡源定位领域。然而,传统深度学习是一种需要依赖大量高质量数据样本的数据驱动技术,但在实际电力系统中,相较于稳态数据,振荡数据极度匮乏。因此,实际系统振荡数据匮乏成为一个亟待解决的问题。

本章的主要贡献是针对直驱风电场接入弱交流系统引发次/超同步振荡的场景,提出一种基于深度子领域自适应网络(Deep Subdomain Adaption Network, DSAN)的振荡源定位方法,突破振荡样本匮乏所带来的数据瓶颈,实现振荡源快速精准定位。首先,在深度子领域自适应作用原理研究基础上,论证了迁移学习对解决振荡数据匮乏的可行性。其次,基于风电机组与系统交互机理分析基础完成可迁移泛化样本域特征空间选择,建立了基于 DSAN 的次/超同步振荡源定位模型。最后,采用多场景的算例验证了本章所提的振荡源定位方法的有效性与优越性。

3.2 深度子领域自适应原理

3.2.1 深度迁移学习原理

迁移学习是一种将在具有较多数据样本的相似领域内学到的知识应用到另一相关领域,以解决该领域标签数据少、难以进行训练等方法^[62]。迁移学习原理示意图如图 3-1 所示。




图 3-1 迁移学习原理示意图

与第二章的深度学习不同，迁移学习具有两个数据域，分别为源域 D_s 和目标域 D_t ，其中，下标 s 代表源域， t 代表目标域。源域具有大量标签样本，是需要迁移的对象。目标域即为缺乏标注样本，需要被给予迁移知识的对象。每个域都由样本空间 X 以及概率分布 $P(X)$ 构成，即 $D_s = \{X_s, P(X_s)\}$ ， $D_t = \{X_t, P(X_t)\}$ 。源域与目标域内的学习任务由标签空间与其对应的预测函数组成，记作 $T = \{Y, f\}$ 。其中，预测函数 f 本质为数据分布的条件概率 $Q_s(Y_s|X_s)$ 、 $Q_t(Y_t|X_t)$ 。当 f 为深度表征函数时即为深度迁移学习。在源域与目标域的数据特征完全相同的情况下，源域所学到的预测函数 f_s 也可以完全泛化到目标域中，完成目标域的任务。但是源域与目标域的初始数据特征是不同的，反映到数据上即两域的边缘分布和条件分布是不同的。因此，迁移学习的目标本质上就是解决两域的数据分布问题。为使所提出的振荡源定位方法具有适用性，不因样本权重的改变而导致适用性降低，本章采用基于特征的迁移学习方法。即通过模型的设计使得两域特征被映射到另一个潜在特征空间上，在该空间中，两域的特征分布完全一致，源域所学到的知识便可以完全泛化适应于目标域任务。

由上述迁移学习的作用原理分析可知，可以通过寻找一个与实际次/超同步振荡相似的可迁移数据域构成源域 D_s ，少量实际次/超同步振荡数据构成目标域 D_t ，以引发次/超同步振荡的风机编号作为样本标签 Y ，利用迁移学习建立振荡源定位模型，完成源域向目标域的泛化，解决实际电力系统振荡数据匮乏的问题，实现目标域实际系统次/超同步振荡源精准定位。

在振荡研究领域，通常以高精度仿真系统模拟实际系统来进行实际系统振荡的研究与分析，但随着系统规模的扩大及控制环节的复杂化，调节系统控制参数来形成大量的可迁移有效振荡样本也具有较大难度。因此，本章提出通过在仿真系统风机侧直接加入扰动源激发系统次/超同步频段强迫振荡的方法来获取大量振荡样本构成源域，将少量实际次/超同步振荡样本构成目标域，建立两者迁移模型，极大地降低了源域数据空间的准备成本。

3.2.2 深度子领域自适应原理

加入扰动源所激发的强迫振荡与实际风机产生的次/超同步振荡在产生机理上就有着较大差异，导致源域与目标域两域数据特征差异较大。若仅考虑数据域的全局领域自适应——两域边缘分布 $P(\mathbf{X})$ 具有一致性，而忽略不同类别之间分布的差异性时，在源域与目标域相差较大的情况下，迁移效果具有局限性。鉴于此，本章提出采用深度子领域自适应的方法建立次/超同步振荡源定位模型。深度子领域自适应^[63]的方法进一步考虑颗粒度的对齐(本章的颗粒度指不同的振荡源风机机组)，通过利用颗粒度关系进行相关子领域对齐，使不同域的全局分布和局部分布同时被拉近。子领域自适应与全局领域自适应的区别如图 3-2 所示。




图 3-2 全局领域自适应与子领域自适应对比图

在本章中，将仿真系统产生的强迫振荡所形成的源域记作 $D_s = \{(\mathbf{x}_{s,1}, y_{s,1}), (\mathbf{x}_{s,2}, y_{s,2}), \dots, (\mathbf{x}_{s,l}, y_{s,l})\}$ ，源域为有标签数域，其中， l 为源域的样本数， $\mathbf{x}_s \in \mathbf{X}_s$ 、 $y_s \in \mathbf{Y}_s$ 分别表示源域样本与对应的标签。实际次/超同步振荡所形成的目标域记作 $D_t = \{\mathbf{x}_{t,1}, \mathbf{x}_{t,2}, \dots, \mathbf{x}_{t,k}\}$ 或 $D_t = \{(\mathbf{x}_{t,1}, y_{t,1}), (\mathbf{x}_{t,2}, y_{t,2}), \dots, (\mathbf{x}_{t,m}, y_{t,m}), \mathbf{x}_{t,m+1}, \mathbf{x}_{t,m+2}, \dots, \mathbf{x}_{t,k}\}$ ，其为无标签或少量标签数域，其中， m 为目标域有标签的少量样本个数， k 为目标域的样本数量， $\mathbf{x}_t \in \mathbf{X}_t$ 、 $y_t \in \mathbf{Y}_t$ 分别表示目标域中的样本和其对应标签。

深度子领域自适应的基本思想是通过在神经网络中设计不同适配层，进行两域相关子领域分布差异的测量，通过减小分布差异进而实现子领域的对齐。由此可知，子领域自适应的核心是设计适配层：通过选择合适的迁移正则项来量度两域之间分布的差异。在迁移学习中，最大均值差异(Maximum Mean Discrepancy, MMD)是应用最为广泛的量度方式，但 MMD 无法测量局部分布之间的欧氏距离，故在此基础上，进一步定义局部最大均值差异(Local Maximum Mean Discrepancy, LMMD)，具体形式如下：

$$d_H(p, q) = E_c \left(\left\| E_{p,c}(\phi(\mathbf{x}_s)) - E_{q,c}(\phi(\mathbf{x}_t)) \right\|_H^2 \right) \quad (3-1)$$

式中 p 、 q ——源域和目标域的数据分布；

$E_c(\cdot)$ ——类别 c 的数学期望；

$E_{p,c}(\cdot)$ —— 类别 c 下源域的数学期望

$E_{q,c}(\cdot)$ —— 类别 c 下目标域数据的数学期望；

H —— 再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS);

$\phi(\cdot)$ —— 数据由原数据空间到 RKHS 的映射。

设样本属于类别 c 的概率为 $\omega_{i,c}$ ，本章中即表示振荡样本溯源后振荡源为编号 c 风机的概率权重。定义 $\omega_{i,c}$ 如下：

$$\omega_{i,c} = \frac{y_{i,c}}{\sum_{(x_j, y_j) \in D} y_{j,c}} \quad (3-2)$$

式中 x_j 、 y_j —— 域 D 中的样本以及其对应标签，当公式用于计算源域样本权重时， D 为 D_s ，当用于目标域时， D 即为 D_t ；

$y_{j,c}$ —— 属于类别 c 的标签。

则式(3-1)的无偏差估计值为：

$$\hat{d}(p, q) = \frac{1}{b} \sum_{c=1}^b \left\| \sum_{x_{s,i} \in D_s} \omega_{s,i,c} \phi(x_{s,i}) - \sum_{x_{t,j} \in D_t} \omega_{t,j,c} \phi(x_{t,j}) \right\|_H^2 \quad (3-3)$$

式中 b —— 标签类别总数，本章即为风机台数；

$\omega_{s,i,c}$ —— 仿真强迫振荡所形成的源域样本 $x_{s,i}$ 溯源后为风机 c 的概率；

$\omega_{t,j,c}$ —— 实际振荡形成的目标域样本 $x_{t,j}$ 溯源后振荡源为风机 c 的概率。

在实际应用中，源域样本采用真实的标签 $y_{s,i}$ 来计算 $\omega_{s,i,c}$ ，目标域样本采用模型预测的伪标签 $y_{t,j}^*$ 来进行 $\omega_{t,j,c}$ 的计算，如果目标域中有少部分真实标签，有标签部分以真实标签来进行参数的计算在理论上会提升迁移的效率。

通过加入概率权重，使用概率预测进行类别权重赋值，较于直接使用模型预测伪标签^[52]，会减轻标签错误时对模型性能的影响。

将式(3-3)展开后用于不同适配层来计算两域之间的距离，其函数表示如式(3-4)所示。

$$\begin{aligned} \hat{d}_o(p, q) = \frac{1}{b} \sum_{c=1}^b \left[\sum_{i=1}^{n_s} \sum_{j=1}^{n_t} \omega_{s,i,c} \omega_{t,j,c} k(z_{s,i,o}, z_{t,j,o}) + \sum_{i=1}^{n_t} \sum_{j=1}^{n_t} \omega_{t,i,c} \omega_{t,j,c} k(z_{t,i,o}, z_{t,j,o}) \right. \\ \left. - 2 \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} \omega_{s,i,c} \omega_{t,j,c} k(z_{s,i,o}, z_{t,j,o}) \right] \end{aligned} \quad (3-4)$$

式中 o —— 适配层的层数；

$z_{s,i,o}$ 、 $z_{s,j,o}$ —— 源域样本 $x_{s,i}$ 、 $x_{s,j}$ 在适配层 o 的高维激活向量；

$z_{t,i,o}$ 、 $z_{t,j,o}$ —— 目标域样本 $x_{t,i}$ 、 $x_{t,j}$ 在适配层 o 的高维激活向量；

n_s 与 n_t —— 源域、目标域的样本数量；

$k(\cdot)$ —— 映射的内积。

内积 $k(\cdot)$ 的定义式如式(3-5)所示。

$$k(\mathbf{x}_s, \mathbf{x}_t) = \langle \phi(\mathbf{x}_s), \phi(\mathbf{x}_t) \rangle \quad (3-5)$$

综上所述,基于 LMMD 的深度子领域自适应网络的数学架构可以表示为:

$$f^* = \min_f \left(\frac{1}{n_s} \sum_{i=1}^{n_s} J(f(\mathbf{x}_{s,i}), \mathbf{y}_{s,i}) + \lambda \sum_{o \in \Omega} \hat{d}_o(p, q) \right) \quad (3-6)$$

式中 Ω —— 适配层的集合;

λ —— 迁移损失权重;

$J(\cdot)$ —— 分类损失,本章使用交叉熵函数计算分类损失;

$\hat{d}_o(p, q)$ —— 用 LMMD 计算的自适应损失。

本章基于该方法的迁移思想并通过进一步设计将其适配于振荡源定位的场景,应用到实际风电并网系统次/超同步振荡源的在线定位。

3.3 基于 DSAN 的振荡源定位模型

3.3.1 源域与目标域样本空间构建

由 3.2 节分析可知,深度迁移学习的本质是对数据的特征进行泛化学习。同传统深度学习一致,样本特征的选择对于模型的准确率具有较大的影响。本章通过对源域与目标域样本特征的选择、样本数据处理等,完成源域与目标域样本空间的构建。

3.3.1.1 样本特征选择

本章研究所针对的直驱风机经弱交流电网并网的场景结构示意图如图 3-3 所示。直驱风电场用 n 台并联的直驱风机模型表示,汇集到集中母线上。经过弱交流系统连接并入交流主网(等效为无穷大系统)。风电场风机台数众多,当系统发生次/超同步振荡时,快速准确定位到振荡源风机对于振荡的平息至关重要。图 3-3 中: $V_1, V_2, \dots, V_n$ 表示各台风机出口母线电压; V_t 表示风电场并网母线电压; V_s 表示交流侧出口母线电压; $P_1, P_2, \dots, P_n$ 与 $Q_1, Q_2, \dots, Q_n$ 分别表示各台风机输出有功、无功功率; $X_{j1}, X_{j2}, \dots, X_{jn}$ 表示各风机侧电抗; R_1, X_1 分别表示输电线路等效电阻和电抗; R_2, X_2 分别表示交流侧等效电阻和电抗。




图 3-3 风机经弱交流系统并网场景示意图

为选取有效的数据特征，需研究电气量与振荡源之间的关系，选取与振荡源有关的电气特征。首先，根据闭环互联模型理论^[64]，建立系统状态空间方程。

不考虑所研究风机外剩余子系统动态方程，风机子系统的系统状态空间方程为：

$$\begin{cases} \frac{d}{dt} \Delta X_1 = A_1 \Delta X_1 + B_1 \Delta F_1 \\ \Delta Y_1 = C_1 \Delta X_1 + D_1 \Delta F_1 \end{cases} \quad (3-7)$$

式中 $\Delta F_1 = [\Delta V_1, \Delta I_1]^T$ ——该风机子系统的输入变量，由风机子系统与剩余子系统并网处的电压和电流构成；

$\Delta Y_1 = [\Delta P_1, \Delta Q_1]^T$ ——所研究风机子系统的输出变量，即风机送出的功率；

ΔX_1 ——风机所有状态变量组成的列向量；

A_1 、 B_1 、 C_1 、 D_1 ——风机子系统的系数矩阵。

不考虑风机子系统的动态方程，剩余子系统的系统状态空间方程为：

$$\begin{cases} \frac{d}{dt} \Delta X_2 = A_2 \Delta X_2 + B_2 \Delta Y_1 \\ \Delta F_1 = C_2 \Delta X_2 + D_2 \Delta Y_1 \end{cases} \quad (3-8)$$

式中 ΔX_2 ——剩余子系统的状态变量；

A_2 、 B_2 、 C_2 、 D_2 ——剩余子系统的系数矩阵。

由式(3-7)、式(3-8)联立可知，风机经弱交流电网并网的互联系统状态方程如下：

$$\begin{bmatrix} \frac{d}{dt} \Delta X_1 \\ \frac{d}{dt} \Delta X_2 \end{bmatrix} = A \begin{bmatrix} \Delta X_1 \\ \Delta X_2 \end{bmatrix} \quad (3-9)$$

式中 A ——闭环系统的特征矩阵。

由传统的模式分析法可知^[65]，当系统的线性化状态空间方程建立完成后，可以通过特征矩阵 A 计算系统的参与因子进而判断振荡源。参与因子的定义如

式(3-10)所示。参与因子 $C_{\mu\beta}$ 衡量了受第 μ 个状态变量激励的情况下，第 β 个模式在该状态变量时域响应中的参与程度。

$$C_{\mu\beta} = \frac{|v_{\mu\beta} w_{\mu\beta}|}{\sum_{\beta=1}^n |v_{\mu\beta} w_{\mu\beta}|} \quad (3-10)$$

式中 $v_{\mu\beta}$ ——右特征向量矩阵的第 μ 行第 β 列元素；

$w_{\mu\beta}$ ——左特征向量的第 μ 行第 β 列元素；

n ——系统特征向量数。

由式(3-10)可知，当已知闭环系统的特征矩阵 A ，便可以求出其参与因子 C ：

$$C = \partial(A) \quad (3-11)$$

式中 $\partial(\cdot)$ ——参与因子与系统特征矩阵之间的映射关系函数。

联合式(3-7)—式(3-9)可知，在互联闭环系统中，闭环系统的特征矩阵 A 与系统的运行点 M 有关。因此，振荡源与系统电气量之间的关系可以表示为：

$$S = g(C) = g(\partial(A)) = g(\partial(h(M))) = s(M) \quad (3-12)$$

式中 S ——振荡源标签，即风机标号；

M ——输入变量与输出变量构成， $M=[Y, F]=[P, Q, U, I]$ ；

P, Q, U, I ——有功功率、无功功率、电压、电流；

$g(\cdot)$ ——振荡源标签与系统参与因子之间的映射关系函数；

$h(\cdot)$ ——系统特征矩阵与系统运行点之间的映射关系函数；

$s(\cdot)$ ——振荡源标签与系统运行点之间的映射关系函数。

综上所述，实际系统振荡源与风机系统的有功功率、无功功率、电压、电流有关。同时，上述变量在实际系统中均能通过测量获得。显然，当利用数据驱动进行实际系统振荡溯源时，可选取风机出口母线处的有功功率、无功功率、电压、电流作为数据样本的特征。为形成同构迁移学习^[62]，由强迫振荡所形成的源域亦采用风机出口母线处的有功功率、无功功率、电压、电流这4个电气量作为源域样本特征。即本章所提振荡源定位方法两域样本特征均由各风机出口母线处的有功功率、无功功率、电压、电流构成。

3.3.1.2 样本生成与数据预处理

由3.2节分析可知，本章所提出的振荡源定位方法中，目标域样本集由少量的实际次/超同步振荡数据构成，源域样本集由仿真系统中加入扰动源生成的大量次/超同步强迫振荡数据构成。

(1) 目标域样本集构建

由3.3.1.1节所述，取实际系统次/超同步振荡时各风机出口母线电气量测的历史数据。选取样本所需的电气特征量：有功功率、无功功率以及A相电压、电流，构建目标域样本，形成样本集 X_t 。通过振荡历史记录或系统离线仿真分

析的方法获取少量历史振荡数据的真实溯源结果，形成目标域部分真实标签集 Y_t 。进一步对所获样本集进行训练集和测试集的划分。

(2) 源域样本集构建

在根据实际电网场景案例搭建的时域仿真系统中，分别在不同的风机出口侧母线处注入谐波扰动，引发强迫振荡。所注入谐波频率为所对应的实际系统真实可以激发产生的次/超同步振荡频率。通过较大范围改变系统运行工况，在较宽频段内改变扰动源注入的谐波扰动分量，获取大量振荡数据。根据 3.3.1.1 节可知，采集振荡时各个风机出口母线处的有功功率、无功功率以及 A 相电压、电流波形数据构建源域样本，形成源域样本集 X_s 。并根据实际注入谐波扰动的风机母线所对应的风机编号形成源域标签集 Y_s 。同理，对源域样本进行训练集与测试集的划分。

(3) 数据预处理

为加速后续神经网络梯度下降的速度，消除样本中特征量级不同对优化精度的影响^[66]，利用 min-max 归一化的方法，对所采集的样本数据进行数据预处理，将不同量级的 P 、 Q 、 U 、 I 特征都映射到 $[0,1]$ 区间中。min-max 归一化的具体原理见式(2-10)，此处不再赘述。

3.3.2 振荡源定位模型构建

由于实际电力系统次/超同步振荡数据匮乏，本章提出通过在仿真系统中激发强迫振荡，与实际系统次/超同步振荡构成迁移学习以解决振荡数据匮乏的问题。同时，由 3.2.2 节可知，鉴于本章源域与目标域两域之间差异较大，选择采用考虑颗粒度对齐的迁移学习方法，即深度子领域自适应进行振荡源定位与识别研究^[63]。

DSAN 的网络结构图如图 3-4 所示。由图可知，基于 DSAN 的定位模型主要由特征提取网络与适配网络两部分组成。




图 3-4 DSAN 结构图

基于次/超同步频段振荡样本的强非线性化数据特征，特征提取器采用具有强复杂特征提取能力的卷积神经网络，如 2.2.1 节所述，包括卷积层、激活层、

池化层、全连接层等。由于电气振荡样本具有长条形特点，特征矩阵维数较高，在训练过程中容易发生拟合现象。因此，除去采用最大池化的方法减少训练参数这一措施外，同时在模型中加入了 Dropout 层来进一步防止过拟合。由 3.3.1 节可知，归一化可以加快模型的收敛，提高模型的实用特性。因此，本章在对输入样本进行预处理的基础上，BN 层的加入也在训练过程中对中间层的输入进行再次归一化处理，提高模型的收敛性能。

通过 3.3.1 节的分析可知，数据样本为次/超同步频段的有功功率、无功功率、电压、电流振荡曲线，相较于自然语言处理与计算机视觉领域，特征处理任务并不复杂。因此，本章在适配网络部分仅采用单层适配网络而非多层适配，提高了模型训练的速度。

模型的网络结构与参数设置如表 3-1 所示。

表 3-1 模型网络结构与网络参数设置

网络类型	名称	参数
输入网络	输入层	$4b \times L$
	卷积层+ReLU	1,64,5
特征提取网络	BN 层	64
	Dropout	0.5
	池化层+ReLU	2
	全连接层+ReLU	1000
	BN 层	1000
	Dropout	0.5
	全连接层+ReLU	256
适配网络	全连接层+Softmax	b

注： b 即为风机数量； L 为特征向量长度

3.3.3 振荡源定位方法具体实施流程

本章所提的次/超同步振荡源定位方法可以分为样本获取、离线训练和在线应用三部分。具体实施流程如图 3-5 所示。




图 3-5 基于 DSAN 振荡源定位方法的具体实施流程

样本获取部分的具体步骤如下：

1) 获取实际系统中次/超同步振荡的历史录波数据，形成目标域初始数据集。对目标域初始数据进行预处理，划分形成目标域训练样本集与目标域测试样本集。

2) 根据实际系统构建时域仿真系统，按照 3.3.1 节所述方式在仿真系统中激发强迫振荡生成源域样本，对源域数据进行预处理，划分形成源域训练样本集和源域测试样本集。

离线训练部分的具体步骤如下：

1) 按照 3.3.2 节所建立的深度子领域自适应模型结构进行次/超同步振荡源定位模型搭建。

2) 利用两域训练集样本数据，通过多次尝试获取最优学习率等超参数，进行模型的训练。使用 I_{acc} 指标来衡量模型的准确率是否满足定位要求，设置 I_{acc} 初始设定阈值。 I_{acc} 定义如式(3-13)所示。

$$I_{acc} = \frac{T_1 + T_2 + T_3 + \cdots + T_b}{N} \times 100\% \quad (3-13)$$

式中 N ——目标域测试集样本总数；

T_c ——预测与实际均是风机 c 为振荡源的测试样本数量，其中 $c \in [1, b]$ ；

b ——系统风机台数。

3) 目标域测试样本的 I_{acc} 未达到初始设定阈值时，根据系统损失函数按照梯度下降方式进行迭代，模型进行参数更新。

4) 模型 I_{acc} 达到初始设定阈值, 停止训练并保存网络。此时所获得的网络便是最终的次/超同步振荡源定位模型。

在线应用部分具体步骤如下:

1) 根据电力系统量测设备获取系统待定位振荡源的在线次/超同步振荡量测数据。

2) 利用本文 3.3.1 节所提方式进行现场量测数据的数据处理, 获得模型可用特征数据。

3) 输入振荡源定位模型, 获取振荡源位置标签, 实现次/超同步振荡源在线定位。

3.4 算例分析

3.4.1 算例构建与验证

3.4.1.1 算例模型搭建

本文在 PSCAD/EMTDC 仿真软件中搭建 4 台直驱风机经弱交流电网并网的模型作为实验算例, 进行所提方法有效性的验证, 模型结构如图 3-6 所示。模型搭建详细参数见表 3-2。




图 3-6 四直驱风机经弱交流电网并网结构图

图中: V_1 、 V_2 、 V_3 、 V_4 表示 4 台风机出口母线电压; V_t 表示风电场并网母线电压; V_s 表示交流系统并网母线电压; P_1 、 P_2 、 P_3 、 P_4 与 Q_1 、 Q_2 、 Q_3 、 Q_4 分别表示各台风机输出有功、无功功率; X_{f1} 、 X_{f2} 、 X_{f3} 、 X_{f4} 表示各风机侧电抗, 以不同的电抗值表示风机接入距离的远近; R_1 、 X_1 分别表示输电线路等效电阻和电抗; R_2 、 X_2 分别表示交流侧等效电阻和电抗。

表 3-2 算例系统参数设置

参数名称	直驱风机 1	直驱风机 2	直驱风机 3	直驱风机 4
额定功率(MW)	2	2	2	2
额定风速(m/s)	11	11	11	11
风场侧电抗(H)	0.0025	0.001	0.002	0.0015
d 轴外环比例系数	0.5	0.5	0.5	0.5
d 轴外环积分系数	20	20	20	20
q 轴外环比例系数	0.5	0.5	0.5	0.5
q 轴外环积分系数	20	20	20	20

3.4.1.2 两域样本获取

目标域样本获取：因无法获取实际工程系统振荡历史录波数据，本章采用搭建的仿真系统模拟实际系统振荡发生过程产生少量次/超同步振荡形成目标域训练样本以及测试样本，进行所提振荡源定位方法有效性的验证。按照 3.3.1 节样本空间构建的方法，设置 4 个风电机组分别与交流系统耦合产生次/超同步振荡^[67]，调节各机组的额定出力变化范围为 0.5~1.0 p.u.，得到若干不同运行点以模拟实际系统运行情况。随着运行点改变，系统次/超同步振荡频率随之改变，变化范围为 16~18 Hz/82~84 Hz。采集 4 台风机出口母线处的有功功率、无功功率以及 A 相电压、电流信号(采样频率为 2 kHz，采样时长为 0.5 s)，形成目标域的振荡样本 $x_t=[P_1, Q_1, U_1, I_1, P_2, Q_2, U_2, I_2, P_3, Q_3, U_3, I_3, P_4, Q_4, U_4, I_4]$ 。剔除系统潮流不收敛的无效样本，经数据预处理后获取目标域有效训练样本 400 个。同样，按照上述方法，获得有效测试样本 364 个，并形成测试样本与少量训练样本的标签数据集 Y_t 。

源域样本获取：在上述 3.4.1.1 节所搭建的算例仿真模型中，分别在 4 台风机出口侧母线处加入强迫振荡源，通过向系统注入周期性扰动(本算例中扰动频率为 15~19 Hz、81~85 Hz)，引发系统强迫振荡。改变风机出力情况(0.5~1)，注入扰动幅值(0.01~0.06)来模拟实际运行中的若干运行点。根据 3.3.1 节所述，记录振荡时各个风机出口母线处的有功功率、无功功率以及 A 相电压、电流(采样频率为 2 kHz，时长为 0.5 s)形成源域样本 $x_s=[P_1, Q_1, U_1, I_1, P_2, Q_2, U_2, I_2, P_3, Q_3, U_3, I_3, P_4, Q_4, U_4, I_4]$ ，并按照 3.3.1 节所述方法形成对应标签数据集 Y_s 。剔除稳定、潮流不收敛等无效样本，经数据预处理后获得源域有效训练样本 2568 个，源域测试样本 500 个。

经过上述样本生成过程，最终两域形成的样本数量如表 3-3 所示。

表 3-3 两域样本数量分布

数据域	样本集名称	样本数量
源域	训练集	2568
	测试集	500
目标域	训练集	400
	测试集	364

并以一个样本生成为例，给出了样本中 4 台风机各个特征的时域仿真结果波形图如图 3-7 所示。




图 3-7 风机出口特征仿真波形图

3.4.1.3 模型训练结果

利用 Python 语言在 Facebook 公司发布的 Pytorch1.7.0 架构搭建迁移学习网络，构建 3.3.2 节所设计的振荡源定位模型。

在利用本节产生的训练样本进行模型离线训练的过程中，样本分批次进行

训练,批次大小设置为 25,网络学习率与迁移损失权重分别设置为 10^{-4} 与 0.5。同时,采用 Adam 加速算法进行模型训练的优化。

利用 3.3.3 所提出的评价指标 I_{acc} 来对模型的准确度进行评估,模型准确率随训练迭代次数变化的曲线图如图 3-8 所示。




图 3-8 模型准确率随训练次数变化曲线

观察曲线可知,随着训练的不断深入,模型的精准度虽有波动,但是整体呈现出逐渐升高的趋势。当训练次数达到 300 次,模型精确度已经达到较高水平,指标准确率到达 90% 以上,模型最终测试准确率为 96.43%,基本可以满足实际应用中振荡源定位的精度要求。

为更加全面评估所提方法的性能,除准确率指标 I_{acc} 外,另定义每个类别的精准率 K 和召回率 ζ 对模型性能再次评估,定义如下:

$$K_c = \frac{T_c}{T_c + \sum_{e=1, e \neq c} F_{ec}} \quad (3-14)$$

$$\zeta_c = \frac{T_c}{T_c + \sum_{e=1, e \neq c} F_{ce}} \quad (3-15)$$

式中 T_c —— 预测与实际均是风机 c 为振荡源的测试样本数量;

F_{ec} —— 实际振荡源为风机 e , 但预测振荡源为风机 c 的样本数量;

F_{ce} —— 实际振荡源为风机 c , 但预测振荡源为风机 e 的样本数量。

模型混淆矩阵与指标评价结果如图 3-9 所示,图中每个单元格中的整数为样本数量,百分数为指标评价结果。模型对于每个类别的精准率以及召回率都能达到 90% 以上,模型定位在各个标签中表现都较为稳定。基本可以实现实际应用中振荡源的定位。




图 3-9 定位模型的混淆矩阵

进一步分析所提迁移学习方法的域适应效果，利用 t-分布随机邻域嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)算法^[68]，给出两域样本通过 DSAN 前后的特征空间分布，如图 3-10 所示。




图 3-10 DSAN 前后两域数据特征分布图对比

由图 3-10 可以看出，在经过迁移学习网络之前，两域样本空间重合较少，分布差距较大；经过迁移学习网络后，两域分布趋势基本相同，数据映射到二

维后空间分布基本重合，即两域此时的特征分布近似一致。上述过程表明所搭建的 DSAN 具有较强的领域自适应能力，完成了强迫振荡样本向实际系统次/超同步振荡样本的迁移泛化。

综上，通过算例验证可以说明，本文所提的振荡源定位方法初步解决了实际系统次/超同步振荡数据匮乏的问题，具有较高的精准度，基本可以满足在线应用的需求。

3.4.2 不同振荡源定位方法对比

3.4.2.1 本章所提定位模型与传统深度学习定位模型的对比

为了进一步测试本文所提方法在两数据域差距较大时的领域自适应能力，本节基于卷积神经网络设计针对强迫振荡的深度学习定位模型，将其直接用于实际振荡定位中。模型结构如图 3-11 所示，同时，在网络中额外加入了 Dropout 层用于防止模型的过拟合。




图 3-11 基于传统深度学习的定位模型

利用源域中强迫振荡的数据进行定位模型的训练，当源域的测试精度达到 100% 时，目标域测试精度只有 52.74%。即未经过迁移的情况下，源域与目标域的数据分布差异是较大的，源域所训练的定位模型并不可以直接用于目标域中。同样，仿真系统中强迫振荡样本并不可以直接扩充实际振荡样本集。而本文提出通过子领域自适应方法，进行两域的特征迁移，最终目标域定位模型的准确度可达到 96.43%。两种定位模型的对比可以表明：由于两种振荡特征差距较大，利用仿真系统强迫振荡所训练获得的振荡源定位模型，无法直接用于实际次/超同步振荡源定位。进行两域之间的迁移学习是利用仿真系统中的强迫振荡来解决实际振荡数据缺失的必要选择。

3.4.2.2 本章所提定位模型与基于对抗迁移的定位模型的对比

域对抗神经网络(Domain-Adversarial Neural Network, DANN)将深度学习中对抗生成网络的对抗思想引入到迁移学习中，是目前常用的一种基于特征的迁移学习方法^[69]。该方法将网络主要分为特征提取器、标签分类器以及域判别器。该方法通过不断优化网络参数，使域判别器无法正确识别出数据的域来源，以此来获得域不变特征。本文尝试基于该方法进行强迫振荡与实际次/超同步振荡

之间的迁移，构建的振荡源定位模型基本架构如图 3-12 所示。




图 3-12 基于对抗迁移的振荡源定位模型

为防止模型过拟合，在网络中也额外加入了 Dropout 层。模型准确度曲线与本文所提模型准确率曲线对比如图 3-13 所示。




图 3-13 DANN 与 DSAN 的准确率对比

如图 3-13 所示，当训练次数达到 300 次时，本文所提模型准确度基本稳定在 90% 以上，而基于 DANN 的振荡源定位模型精度仍处于较低水平。为防止 DANN 训练不充分导致模型准确度较低，继续对模型进行训练，当训练次数大于 1000 次时，模型基本收敛，保留最优模型，其模型精度与本文所提方法的模型精度测试结果对比如表 3-4 所示。

表 3-4 基于 DANN 与 DSAN 振荡源模型性能对比

数据域	准确率/%	训练次数
DANN	85.44	1000
DSAN	96.43	350

由表 3-4 可知，基于 DANN 的振荡源定位模型在训练次数达到 1000 次时，其最高准确率仅为 85.44%，准确度远低于本文所提定位模型。且与本文所提的基于 DSAN 的振荡源定位方法相比较，其训练收敛速度也较慢。同时，在训练

过程中, 由于对抗网络的存在, DANN 的训练难度远大于 DSAN。综上可知, 基于 DANN 的振荡源定位模型在实际电力系统振荡源定位的在线应用中适应性不强。而本文所提振荡源定位方法在训练收敛难易程度、收敛速度以及模型准确率上相较于基于对抗的迁移定位模型存在着较大优势。

3.4.3 样本构造对模型精度影响研究

本章所提模型本质属于数据驱动模型, 模型的性能依赖于数据样本的构造。本节分别从样本数量、数据长度、采样起始时间三个方面验证本文所提定位模型在不同样本构造时的性能。

3.4.3.1 样本数量对模型精度影响的研究

为探索所提模型使用时对实际样本的需求, 进行了关于目标域样本数量对模型准确率影响的对比实验。在源域数量不变的情况下, 设置了 5 组目标域数量不同的对比实验, 其中, 目标域数量分别为 100、200、300、400、500。在每个实验中, 通过调节获取当前实验条件下的最优参数, 定位准确率结果分别为 89.56%、92.85%、94.78%、96.43%、96.5%, 如图 3-14 所示。




图 3-14 目标域数量对于模型准确率的影响

模型准确率随着目标域训练样本的增加逐步上升, 呈现出一种正相关趋势。但模型准确度增长的速率随着目标域数量的增加而呈现下降趋势, 即当目标域数量增加到一定后, 模型准确率趋于平稳, 此时增加样本容量对于模型准确率的提升作用较小。

同时, 根据实验结果可得, 在目标域数量仅为 100 时, 本章所提振荡源定位模型的定位准确率已经达到 89.56% 的较高水平。因此, 当目标域数量较少时, 本章所提方法依然有较好的性能, 为具有少量实际振荡数据时利用数据驱动进行振荡源定位提供了一个可行的解决方案。

3.4.3.2 样本时间长度对模型精度影响的研究

为探求样本长度对模型准确率的影响，分别设定样本采样时长为 0.25 s、0.5 s、1 s 的三组对比实验。在每组实验中，通过多次调参获取最优训练模型为最终定位模型，模型定位结果如表 3-5 所示。同时，采样时长对振荡源定位精度的影响如图 3-15 所示。

表 3-5 不同样本长度下模型最高精度表

	0.25 s	0.5 s	1 s
模型精度	95.27 %	96.43 %	94.75 %




图 3-15 定位精度随样本采样时间变化图

由定位结果可知，随着样本数据长度的延长与缩短，模型精度都会有略微的下降。这是由于在数据长度较短时，数据所表达的信息较少，可以用于振荡源定位的隐藏特征表达不够丰富；而当数据较长时，会形成信息冗余与信息干扰，模型会学到其余无用信息，影响振荡源定位精度，同时也会减缓模型训练收敛的速度。

但上述结果表明，针对不同数据长度的振荡样本，本文所提振荡源定位模型均有较高的模型精准度，满足实际系统振荡源定位要求。

3.4.3.3 样本采样初始时间对模型精度影响的研究

为了阐明振荡样本数据时间段选择与定位准确率的关系，针对振荡样本选取时间段进行了如下对比实验。

实验 1：所采用的样本均为振荡起始阶段 0.5s 的振荡数据。

实验 2：所采用的样本均为振荡平稳阶段 0.5s 的振荡数据。

分别基于所建立的 DSAN 振荡源定位模型进行调参训练，保留精度最高模型为最终振荡源定位模型。两个实验最终结果如下表 3-6 所示，实验 1 的定位准确率为 96.43%。实验 2 的定位准确率为 96.28%。可以看出在本章所提的基于 DSAN 振荡源定位方法下，选取振荡起始阶段采样和平稳阶段采样准确率基

本相同。

表 3-6 不同时间段样本对比实验结果

对比项	实验 1	试验 2
模型准确率	96.43 %	96.28 %

综上所述，本章所提模型对于任意时间段的振荡数据定位准确率都是较高的，都是适用的。振荡样本的选取时间段对于模型的精度影响并不大，因此本章所提的基于 DSAN 的振荡源定位方法在实际使用时对于样本选取时间段没有具体要求。

3.4.4 定位模型不同场景适应性研究

3.4.4.1 大规模算例模型适应性

为进一步说明并网风场风机台数增加后本章所提的基于 DSAN 的振荡源定位模型的适用性，在如图 3-16 的直驱风机并网场景下进行振荡源定位模型精度验证。按照 3.3.1 节所述样本集构造方式，构建源域与目标域如表 3-7 所示。

表 3-7 两域样本数量分布

数据域	样本集名称	样本数量
源域	训练集	2184
	测试集	400
目标域	训练集	400
	测试集	240






图 3-16 八风机并网接入弱交流系统结构图

根据本章 3.3.2 节网络结构建立适应于八风机并网系统的振荡源定位模型进行离线训练(此时模型参数 $b=8$)，通过调参优化保存精度最高的模型为最终所得振荡源定位模型。模型最高精度可达 98.75 %。模型训练的准确率曲线与最终混淆矩阵如图 3-17 所示。

由上述结果可知，本章所提基于 DSAN 的振荡源定位模型并不会随风机台数增加而失效，仍具有较高的定位精度。对于大规模风电并网振荡源识别具有较高适用性。



a) 定位模型混淆矩阵



b) 模型准确率随训练次数变化曲线

图 3-17 八风机振荡源定位实验精度结果图

3.4.4.2 宽频带振荡模型适应性

本章所提模型直接依托于数据特征信息进行振荡源的定位识别，因此，区别于传统基于机理的振荡源定位方法，模型不会随着振荡机理改变、振荡频带变宽而失效。为进一步验证本文所提振荡源定位方法在次/超同步较宽频段内的适应性，针对系统存在不同频段次/超同步振荡的情况进行了算例验证。


通过进行风机控制参数、电网运行方式的大范围调节，激发系统宽频带次

/超同步振荡(16~18 Hz/82~84 Hz、44~48 Hz/144~148 Hz)。按照本章 3.3.1 节样本集构造方式,构建包含系统两类次/超同步振荡样本情况下的源域与目标域样本集。最终形成的两域样本集如表 3-8 所示。


表 3-8 两域样本数量分布

数据域	样本集名称	样本数量
源域	训练集	2580
	测试集	600
目标域	训练集	400
	测试集	320

根据 3.3.2 节网络结构搭建振荡源定位模型,通过进行网络参数的调节获取模型最优训练结果,最终模型的准确率曲线图与混淆矩阵如图 3-18 所示。



a) 模型准确率随训练次数变化曲线



b) 定位模型混淆矩阵

图 3-18 宽频段定位模型结果图

由实验结果可知,模型的最终定位精度为 94.69%,且模型对于每个类别的精准率以及召回率都在 90%以上,在各标签中表现平稳,基本可以实现实际应用中振荡源的精准定位。上述结果表明,本章所提振荡源定位模型对于次/超同步较宽频段内的振荡都具有较高的准确性,进一步验证了所提振荡源定位方法在次/超同步宽频段的有效性和适应性。

3.5 本章小结

本章针对直驱风机经弱交流电网并网引发次/超同步振荡的场景,提出了一种基于深度子领域自适应的次/超同步振荡源定位方法,并给出了振荡源定位方法的具体实现过程。通过将仿真系统中的强迫振荡迁移到实际次/超同步振荡领域,解决了实际次/超同步振荡数据匮乏所造成的数据瓶颈,完成实际风机系统次/超同步振荡源的精准定位。最后,设计了直驱风机经弱交流系统并网的仿真算例,验证了所提方法的有效性与优越性,并得出以下结论:

(1) 本章提出基于迁移学习将仿真获取的强迫振荡样本迁移到实际次/超同步振荡领域中,初步解决了实际系统振荡数据匮乏、获取困难的问题。相较于其他源域的选择方法,本章提出的将仿真系统中利用周期性强迫源激发的系统强迫振荡作为源域样本,使得样本数据获取更加简单。该方法为由于振荡数据匮乏导致人工智能在振荡溯源领域发展受限的问题提供了一种解决思路。

(2) 通过算例分析可知,所提模型基于深度子领域自适应的迁移思想,进一步考虑了颗粒度对齐,具有更强的迁移效果。相较于其余基于特征的迁移学习方法在训练难易程度、模型收敛速度以及定位准确度上都有着较大的优越性,模型的可塑性较强。

(3) 通过实验验证,本章所提基于 DSAN 的振荡源定位模型在目标域数量较少时仍然有效,且对于不同样本采样时刻、样本长度均具有较好的性能表现;对于不同系统规模、次/超同步频段的宽频段振荡都具有较高的适应性。

第4章 基于 GRU-DSAN 的振荡源定位方法

4.1 引言

第三章提出通过采用迁移学习进行仿真系统次/超同步频段强迫振荡的迁移泛化,解决了实际电力系统振荡的数据瓶颈,实现了电力系统次/超同步振荡源定位。但随着新能源系统电力电子化程度的不断加深,振荡时变性逐渐加强,振荡波动数据中的时序特征对振荡参数辨识准确性影响变大。而在上述模型中所采用的卷积特征提取网络挖掘振荡数据深度时序关系的能力较差,对于振荡波动信号的时序特征敏感性不高,时序特征提取不完善,在一定程度上会降低模型最终的识别精度。

因此,本章针对第三章的研究成果,进行了模型的进一步的改进提升。利用第二章所提的门控循环单元进行了深度子领域自适应网络结构的改善,提出了一种基于 GRU-DSAN 的次/超同步振荡源定位方法。首先,基于门控循环单元的作用原理,对深度子领域自适应网络的特征提取器、两级网络的连接方式以及适配层进行了改进,从而提高了模型对于时序特征的敏感度。其次,设计搭建基于 GRU-DSAN 的振荡源定位模型,给出了基于 GRU-DSAN 的振荡源定位方法的具体实施架构。最后,本章采用四台直驱风机接入弱交流电网的电力系统场景算例对所提振荡源定位方法进行验证分析,表明了所提方法的有效性;同时,与相关模型进行了对比实验,证明了本章所提改进后的 GRU-DSAN 模型在定位精度与训练速度上较第三章未改进 DSAN 模型相比具有更进一步的优越性。

4.2 基于 GRU-DSAN 的振荡源定位

4.2.1 GRU-DSAN 振荡源定位模型建立

为充分利用振荡波形的时序信息,提高模型的辨识精度,本节对第三章所设计的 DSAN 网络进行了改进。通过进行考虑两域数据时序特征信息的迁移学习,实现对实际系统次/超同步振荡源定位。本章所提的改进后 GRU-DSAN 振荡源定位模型结构如下图 4-1 所示。




图 4-1 基于 GRU-DSAN 的网络结构图

图中：ConV 代表卷积层；BN 即代表归一化；Dropout 用以防止过拟合；Max-pooling 为最大池化层；Linear 为全连接层；Bottleneck 为瓶颈层结构；Softmax 为输出环节激活函数。

（1）特征提取环节改进

考虑到现如今新能源系统振荡的强时序特性，通过在特征提取网络的卷积层网络后嵌入 GRU 形成了 CNN-GRU 特征提取网络。通过卷积层进行振荡初步特征提取，利用门控循环单元神经网络进一步深度提取振荡数据波动的时序特征，通过特征融合最终获取含深层时序信息的数据特征。进一步，在特征提取层环节，为提高所设计 GRU-DSAN 模型的收敛性能与防过拟合能力，进行了 BN 层以及 Dropout 环节的设置。

（2）CNN-GRU 连接环节改进

卷积层特征提取后的特征输出为三维数据(例如： $a \times b \times c$)，GRU 的输入层接收要求为二维数据(例如： $m \times n$)。因此，CNN 与 GRU 无法直接连接传递数据特征，传统深度网络对于前级网络输出与后级网络输入要求不一致时的处理方式是通过直接展开前级网络输出的多通道特征矩阵，再对所展开的数据进行维度重塑以重新生成符合后级模型输入格式的矩阵维度来实现网络连接。传统处理方式简单易操作，但在数据维度重组时无法避免在一定程度上改变了前级卷积层网络所提取的数据特征分布，影响数据特征的有效性。

因此，为更好保留前级网络所提取的特征有效性，本章提出利用 1×1 卷积运算来直接进行卷积层特征提取网络与 GRU 网络两级网络的连接处理， 1×1 的卷积层在特征提取器中的设置位置如上图 4-1 所示。通过利用 1×1 卷积运算进行卷积层特征提取网络所提取前级数据特征的降维，实现了跨通道信息交互，

如图 4-2 所示。相较于输出特征直接展开再重塑，利用 1×1 卷积降维能更好保留前级网络输出特征所包含信息的同时，也同样生成了符合 GRU 输入层要求的数据特征矩阵。




图 4-2 1×1 卷积降维原理示意图

(3) 适配层环节改进

为提高模型的训练速度，降低振荡源定位模型的离线训练成本，本章除在适配网络部分同样采用单层适配网络外，进一步加入了瓶颈层的设计。瓶颈层的原理示意图如图 4-3 所示，图中 $n < k$, $n < m$ 。瓶颈层利用 1×1 卷积的通道改变作用进行先降维后升维操作，在减小了网络训练参数数量的同时加深了网络的深度，从而提高模型的计算与收敛速度^[70]。另一方面，瓶颈层通过降维环节可以更加直观、有效进行两域数据分布特征的拉近，降低模型训练成本。




图 4-3 瓶颈层原理示意图

4.2.2 基于 GRU-DSAN 的振荡源定位方法实施架构

本节给出基于 GRU-DSAN 的振荡源定位方法的具体实施架构与流程，如图 4-4 所示。本章所提振荡源定位方法可以分为四个部分：样本生成、样本处理、模型训练、在线应用。




图 4-4 GRU-DSAN 振荡源定位方法实施架构

(1) 样本生成

本章目标域样本为少量实际系统次/超同步振荡数据，源域为仿真系统人为加入扰动源所产生的大量次/超同步频段的强迫振荡数据。

步骤一：通过实际系统次/超同步振荡历史数据，获取各风机并网 PCC 点发生振荡时的单相电压、电流、有功以及无功数据，形成目标域初始数据集。并根据历史振荡的事后溯源分析结果，以引发振荡风机的标号为标签形成目标域的真实标签集 Y_t 。

步骤二：搭建时域仿真模型，通过在不同风机出口母线加入扰动源(扰动频率变化范围包含实际系统真实可以产生的次/超同步振荡频率)，引发系统次/超同步频段的强迫振荡。获取系统振荡时各个风机并网 PCC 点的单相电压、电流、有功和无功数据，形成源域初始数据集。并根据注入扰动源的风机编号构建对应源域标签集 Y_s 。

(2) 样本处理

步骤一：设置采样时长与采样频率，对目标域初始数据特征进行采样，构建符合网络输入维度的目标域样本 $x_t=[P_1, Q_1, U_1, I_1, \dots, P_n, Q_n, U_n, I_n]$ ，形成目

标域样本集 X_t 。

步骤二：同理，构建源域样本 $x_s=[P_1, Q_1, U_1, I_1, \dots, P_n, Q_n, U_n, I_n]$ ，形成源域样本集 X_s 。

步骤三：采用 min-max 进行数据预处理，通过将不同量级的有功、无功、电压、电流数据都映射到[0,1]区间，形成模型直接可用的两域样本集。

步骤四：采用交叉验证方法将数据集(包含源域、目标域)划分为训练集与测试集。

(3) 模型训练

步骤一：利用训练集样本进行模型 GRU-DSAN 的训练，并计算模型每一轮次训练的损失。模型损失包含由 DSAN 所产生的迁移损失以及分类器所产生的分类损失两部分。

步骤二：利用测试集进行模型准确率校验，当准确率未达到阈值时，将模型损失按照梯度下降方式更新网络参数。若达到阈值时，停止训练并保存网络。

步骤三：更改模型训练超参数，包括学习率、批次大小、损失权重等。重复步骤一、步骤二。比较不同超参数下所得网络模型准确率，保留准确率最高模型为最终的次/超同步振荡源定位模型。

(4) 在线应用

步骤一：根据系统实际量测设备采样获取系统各风机出口并网 PCC 点的单相电压、电流、有功、无功数据。

步骤二：利用 min-max 进行数据归一化预处理，获得可输入样本数据。

步骤三：将样本输入第(3)步训练最终保存的模型中，输出振荡源标签。

步骤四：根据标签与位置的对应关系，便可定位至振荡源所在 PCC 点，实现次/超同步振荡源定位。

4.3 算例分析

4.3.1 算例构建与验证

本章算例验证基于四台直驱风机接入弱交流电网的场景进行，算例场景结构如图 3-6 所示，该场景的详细控制参数以及电网运行参数与表 3-2 中模型参数设置一致。

4.3.1.1 两域样本集构建

目标域样本生成：因无法获取实际工程系统振荡历史录波数据，本章采用搭建的仿真系统根据振荡机理模拟实际系统振荡发生过程产生少量次/超同步振荡形成目标域训练样本以及测试样本，进行所提振荡源定位方法有效性的验证。通过调节风机控制参数，设置四台风机分别作为振荡源，与交流系统耦合

产生次/超同步振荡。考虑实际系统运行工况受风速变化影响,设定各机组出力水平变化为 0.5~1 p.u.。设置采样频率为 2 kHz,采样时长为 0.5 s。获得振荡频率随运行点变化波动于 16~18 Hz/82~84 Hz 的少量次/超同步振荡数据 $x_t=[P_1, Q_1, U_1, I_1, P_2, Q_2, U_2, I_2, P_3, Q_3, U_3, I_3, P_4, Q_4, U_4, I_4]$,形成目标域样本集 X_t 。进一步根据振荡源设置情况,获得由少量标签组成的目标域标签数据集 Y_t 。经过数据预处理与样本集划分后,获得目标域有效训练样本 400 个,测试样本 364 个。

源域样本生成:在算例仿真系统中,通过在风机出口处注入周期性谐波扰动(谐波频率变化于 15~19 Hz/81~85 Hz,步长为 1 Hz),设置四台风机分别作为振荡源,引发系统振荡频率为次/超同步频段的强迫振荡。各风机出力水平变化于 0.5~1,谐波扰动振幅范围为 0.01~0.06。同理,设置采样频率为 2 kHz,采样时长为 0.5 s。获得大量源域样本 $x_s=[P_1, Q_1, U_1, I_1, P_2, Q_2, U_2, I_2, P_3, Q_3, U_3, I_3, P_4, Q_4, U_4, I_4]$,形成源域样本集 X_s 。进一步根据被注入谐波扰动的风机编号,获取源域对应标签数据集 Y_s 。形成包含 2568 个有效样本的源域训练集与 500 个有效样本的源域测试集。

4.3.1.2 GRU-DSAN 振荡源定位模型搭建

如 4.2.1 节所述,基于 Pytorch1.7.0 架构搭建适应于本算例的 GRU-DSAN 迁移学习网络,网络具体参数设置如表 4-1 所示。

表 4-1 GRU-DSAN 结构与网络参数设置

网络类型	名称	参数
输入网络	输入层	16×1197
	卷积层	1,64,5
特征提取网络	BN 层	64
	Dropout	0.5
	池化层	2
	卷积层	64,1,1
	GRU	6,4
	全连接层	1000
适配网络	全连接层	500
	瓶颈层结构	128
标签分类网络	全连接层	4

在本算例中,模型训练所采用的超参数设置见下表 4-2 所示。

表 4-2 GRU-DSAN 模型超参数设置

参数名称	参数值
学习率	0.0001
批次大小	25
迁移损失权重	0.5
优化器	Adam
特征提取器激活函数	ReLU
适配层激活函数	ReLU
标签分类器激活函数	Softmax

4.3.1.3 模型训练结果

基于上述模型对所生成的两域样本进行训练，为分析本章所提 GRU-DSAN 网络的域适应效果，利用 t-SNE 算法^[68]，给出两域样本训练前后的数据分布对比如图 4-5 所示。




图 4-5 GRU-DSAN 训练前后两域数据特征分布图对比

由图 4-5 a)和图 4-5 b)对比可知，在经过 GRU-DSAN 前，两域样本特征分布差距较大，重合较少，源域样本无法迁移至目标域领域。经过 GRU-DSAN 后，

两域样本分布基本重合，两域此时特征空间近似一致，完成了源域样本向目标域的泛化。上述过程表明，本章所提 GRU-DSAN 网络具有较强的领域自适应能力，实现了仿真系统强迫振荡向实际次/超同步振荡的迁移。

进一步，为后续更好比较本章所提模型与第三章所提模型的性能表现，利用式(3-13)所提的 I_{acc} 作为模型定位准确度初步评价指标进行模型定位性能评估，模型的准确率 I_{acc} 随训练迭代次数变化曲线图如图 4-6 所示。




图 4-6 GRU-DSAN 振荡源定位模型准确率曲线图

由图 4-6 曲线可知，随着迭代次数的不断增加，模型准确率整体呈现上升趋势。当训练次数达到 250 次时，以 I_{acc} 衡量的模型准确率已经到达 90% 以上的较高水平，基本可以用于振荡源的初步定位。随着训练的不断深入，定位准确度进一步上升，模型训练达到 300 次后，模型基本收敛，定位准确度达到 99.18% 的较高水平，满足实际系统定位精度要求，可以实现实际系统次/超同步振荡源的精准定位。

同样，为进一步全面评估模型的性能，以式(3-14)、式(3-15)所定义的精查率 K 和召回率 ζ 对模型进行更深一层的指标评价。图 4-7 给出了模型的混淆矩阵与指标评价结果。

		预测振荡源标签				召回率
		1	2	3	4	
实际振荡源标签	1	91	0	0	0	100.0%
	2	1	88	1	1	96.70%
	3	0	0	91	0	100.0%
	4	0	0	0	91	100.0%
精查率		98.91%	100.0%	98.91%	98.91%	

图 4-7 GRU-DSAN 振荡源定位模型混淆矩阵

由上图可知，模型的混淆矩阵呈明显的对角占优的特点，因此具有较高的准确率。同时，模型在各个类别中表现都较为平稳，对于每个类别的精准率以及召回率都达到了 98% 以上的较高水平，模型在精度以及平稳性上都具有良好的性能表现。

综上所述，通过上述算例可以说明，本章所提振荡源定位方法实现了仿真系统人为生成的次/超同步频段强迫振荡与实际次/超同步振荡之间的迁移泛化，初步解决了实际系统次/超同步振荡数据匮乏的问题。同时所训练的定位模型具有较高的定位精准度，模型性能可以满足实际系统次/超同步振荡源在线精准定位的要求。

4.3.2 基于不同迁移学习定位模型精度对比

为体现本章所提改进后的 GRU-DSAN 迁移网络结构的优越性，分别以第三章未考虑时序特征学习的基础 DSAN 网络、基于对抗迁移的 DANN^[69]网络所建立的次/超同步振荡源定位模型作为两个对比模型与本章所提 GRU-DSAN 振荡源定位模型进行对比实验，所使用的 DSAN 与 DANN 模型的具体网络结构与参数见表 3-1 与图 3-12。

利用 4.3.1 节产生的两域样本集对所搭建的两个对比模型进行离线训练，通过超参数调整保存收敛后精度最高的模型为最终定位模型。给出 DSAN、DANN、GRU-DSAN 三种定位模型在最优超参数情况下准确率随训练次数变化的对比图，如图 4-8 所示。




图 4-8 三种定位模型准确率曲线图

进一步，总结 DANN、DSAN、GRU-DSAN 三种定位模型的最高精度以及模型收敛速度进行对比，如表 4-3 所示。

表 4-3 三种定位模型性能对比

模型名称	准确率	模型收敛时训练次数
GRU-DSAN	99.18%	300
DSAN	96.43%	350
DANN	85.44%	1000

由上述实验结果可知，本章所提 GRU-DSAN 模型在定位精度以及模型收敛速度上都远优于 DANN 定位模型，同时相较于第三章所提改进前的 DSAN 定位模型在准确率与收敛性上也具有一定的优势。

4.4 本章小结

论文第三章证明了基于 DSAN 迁移算法建立振荡源定位模型的可行性，但第三章所设计的模型结构无法深入提取振荡数据的时序特征，在一定程度上会限制模型的性能表现。针对该问题，本章提出了一种基于 GRU-DSAN 的振荡源定位方法。首先，进行了 GRU-DSAN 振荡源定位模型的设计。1) 利用门控循环单元改进传统 DSAN 架构的特征提取器环节，实现振荡数据深层隐藏时序波动特征的提取。2) 利用 1×1 卷积改进特征提取器两级网络的连接方式以更好传递前级网络所提取的数据特征。3) 通过在适配网络中加入瓶颈层的设计，加速模型收敛速度，降低模型训练成本。其次，详细说明了基于 GRU-DSAN 振荡源定位方法的具体实施框架。最后，在四台直驱风机接入弱交流电网的场景下进行算例验证，结果表明本章所提 GRU-DSAN 振荡源定位方法可以有效识别振荡源，同时，相较于第三章所提振荡源定位模型在精准度与模型收敛速度上都具有一定的优越性。

本章所提 GRU-DSAN 模型可以较好完成风电系统次/超同步振荡源的快速准确定位，提供了振荡的精准位置信息，为振荡发生后的快速抑制奠定了基础。

第5章 结论与展望

5.1 结论

随着风电等新能源渗透率的不断提高,新型次/超同步振荡问题频发,严重威胁电力系统安全稳定运行。为了快速有效地抑制振荡,本文针对次/超同步振荡特征辨识和振荡源定位展开研究工作。考虑风电并网系统次/超同步振荡特性,提出了基于深度学习网络的振荡参数辨识模型与基于迁移学习理论的振荡源定位模型,为后续振荡抑制工作提供了有效的信息基础。以下是本文的研究结论和工作总结:

(1)提出了一种基于 CNN-GRU 的次/超同步频段振荡参数在线辨识模型。通过分析参数辨识的数学本质,将其建模为回归拟合问题。针对新能源系统振荡的强非线性与强时序性特性,通过融合具有强非线性特征提取能力的 CNN 与具有时序波动特征提取能力的 GRU,建立了次/超同步频段振荡频率与衰减系数在线辨识网络模型。算例分析表明,所提振荡辨识模型可在较短时间窗口内实现振荡参数精准辨识。

(2)研究了一种基于 DSAN 迁移算法的次/超同步振荡源在线定位方法。提出利用具有类对齐效果的迁移学习算法将仿真系统中获取的强迫振荡样本迁移到实际次/超同步振荡领域中,为解决实际系统振荡数据匮乏、获取困难的问题提供了一种可行的解决思路。将振荡源定位问题建模为人工智能分类问题,基于神经分类网络实现与系统耦合引发振荡的源头风电机组精准定位。利用四风机并网算例验证了本文所提振荡源定位方法的有效性以及在收敛速度、模型精度上的优越性。同时,通过分析模型随样本数量变化时的性能变化,证明了模型在目标域数量较少时仍有较好的性能表现。进一步,通过实验设计,表明了所提 DSAN 模型对样本采样时刻的低敏感性,以及对于不同样本长度、不同系统规模、宽频段振荡较高的适应性。所提基于 DSAN 振荡源定位模型具有较为稳定且良好的性能表现,基本满足次/超同步振荡源在线定位的需求。

(3)提出了一种考虑振荡时序性的 GRU-DSAN 次/超同步振荡源在线定位模型。利用门控循环单元对第三章 DSAN 模型的特征提取网络部分进行优化,通过在卷积特征提取网络中嵌入门控循环单元,进一步提取数据的深层隐藏时序波动特征。同时,改进 GRU 与特征提取卷积网络的连接方式以提高特征传递的有效性。在模型适配层部分,通过建立瓶颈层以降低模型训练成本。算例分析表明,所提的改进模型可以进一步提高振荡源定位精度与模型训练速度,实现次/超同步振荡源在线精准定位。

5.2 展望

在本文研究基础上，未来可在以下方面继续开展深入研究：

(1) 本文所提振荡参数辨识方法主要针对单模态或者具有单一强势模态的多模态振荡辨识，后续可基于 CNN-GRU 网络进行进一步的改进研究，实现多模态耦合振荡参数的精准辨识。

(2) 通过本文研究表明所提迁移学习方法在次/超同步频段可有效解决实际振荡录波数据匮乏的问题，实现振荡源精准定位。但随着系统电力电子化程度逐渐加深，会产生更高频次的宽频振荡问题，因此，未来可研究本文所提方法在宽频领域的应用，以建立全频段振荡源在线定位模型。

参考文献

- [1] 国家能源局. 2023年全国电力工业统计数据[EB/OL]. (2024-01-28). [2024-02-26]
https://www.nea.gov.cn/2024-01/26/c_1310762246.htm.
- [2] 中华人民共和国国民经济和社会发展第十四个五年规划和2035年远景目标纲要[N]. 人民日报, 2021-03-13(001).
- [3] 李曦. 国家发改委等九部门: 印发《“十四五”可再生能源发展规划》[J]. 中国设备工程, 2022, (13): 1.
- [4] 谢小荣, 贺静波, 毛航银, 等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报, 2021, 41(02): 461-475.
- [5] Zhan Y, Xie X, Wang X, et al. Injection-Space Security Region for Sub/Super-Synchronous Oscillation in Wind Power Integrated Power Systems[J]. IEEE Transactions on Power Systems, 2024, 39(2): 3912-3920.
- [6] Cheng Y, Fan L, Rose J, et al. Real-world subsynchronous oscillation events in power grids with high penetrations of inverter-based resources[J]. IEEE Transactions on Power Systems, 2023, 38(1): 316-330.
- [7] 郑少明, 刘一民, 董鹏, 等. 张北工程风电柔直汇集系统次、超同步振荡分析[J]. 全球能源互联网, 2023, 6(06): 608-617.
- [8] Song Y, Blaabjerg F. Analysis of middle frequency resonance in DFIG system considering phase-locked loop[J]. IEEE Transactions on Power Electronics, 2018, 33(1): 343-356.
- [9] Leon A E. Integration of DFIG-based wind farms into series-compensated transmission systems[J]. IEEE Transactions on Sustainable Energy, 2016, 7(2): 451-460.
- [10] Xie X, Zhang X, Liu H, et al. Characteristic analysis of subsynchronous resonance in practical wind farms connected to series-compensated transmissions[J]. IEEE Transactions on Energy Conversion, 2017, 32(3): 1117-1126.
- [11] Du W, Chen C, Wang H. Subsynchronous interactions induced by DFIGs in power systems without series compensated lines[J]. IEEE Transactions on Sustainable Energy, 2018, 9(3): 1275-1284.
- [12] 王渝红, 王馨瑶, 廖建权, 等. 交直流电网宽频振荡产生、辨识及抑制研究综述[J]. 高电压技术, 2023, 49(08): 3148-3162.
- [13] Wen H, Guo S, Teng Z, et al. Frequency estimation of distorted and noisy signals in power systems by FFT-based approach[J]. IEEE Transactions on Power Systems, 2014, 29(2): 765-774.
- [14] Rueda J L, Juárez C A, Erlich I. Wavelet-based analysis of power system low-frequency electromechanical oscillations[J]. IEEE Transactions on Power Systems,

- 2011, 26(3): 1733-1743.
- [15]李振华, 胡廷和, 杜亚伟, 等. 一种优化窗函数及其在电网谐波检测中的应用分析[J]. 高压电器, 2020, 56(10): 239-246+252.
- [16]张超, 王维庆, 邱衍江, 等. 大规模风电并网地区次同步谐波检测方法[J]. 高电压技术, 2019, 45(07): 2194-2202.
- [17]Lin H C. Power harmonics and interharmonics measurement using recursive group-harmonic power minimizing algorithm[J]. IEEE Transactions on Industrial Electronics, 2012, 59(2): 1184-1193.
- [18]王晓亮, 李娜. 基于加窗插值FFT算法的间谐波检测方法研究[J]. 现代电力, 2012, 29(05): 28-31.
- [19]杨京, 王彤, 唐俊刺. 基于滑窗FFT的次同步振荡时变幅频在线监测方法[J]. 中国电力, 2020, 53(11): 139-146.
- [20]Narduzzi C, Bertocco M, Frigo G, et al. Fast-TFM—Multifrequency phasor measurement for distribution networks[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(8): 1825-1835.
- [21]Bertocco M, Frigo G, Narduzzi C, et al. Resolution enhancement by compressive sensing in power quality and phasor measurement[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(10): 2358-2367.
- [22]He M, Nimmagadda S, Bayne S, et al. Subsynchronous oscillation detection using phasor measurements and synchrosqueezing transform[C]//2015 IEEE Power & Energy Society General Meeting. IEEE, 2015: 1-5.
- [23]刘君, 肖辉, 曾林俊, 等. 基于RSSD和ICA算法的低频振荡模态参数辨识[J]. 电工技术学报, 2018, 33(21): 5051-5058.
- [24]李光辉, 王伟胜, 刘纯, 等. 直驱风电场接入弱电网宽频带振荡机理与抑制方法(一): 宽频带阻抗特性与振荡机理分析[J]. 中国电机工程学报, 2019, 39(22): 6547-6562.
- [25]吕万. 风电系统次同步振荡检测及定位技术研究[D]. 南京: 东南大学, 2021.
- [26]Netto M, Mili L. A robust prony method for power system electromechanical modes identification[C]//2017 IEEE Power & Energy Society General Meeting. IEEE, 2017: 1-5.
- [27]Zhou X, Zhong Z, Jin X. Identification of low frequency oscillation parameters based on EEMD-SVD method and Prony algorithm[C]//2021 9th International Symposium on Next Generation Electronics (ISNE). IEEE, 2021: 1-4.
- [28]Rai S, Lalani D, Nayak S K, et al. Estimation of low-frequency modes in power system using robust modified Prony[J]. IET Generation, Transmission & Distribution, 2016, 10(6): 1401-1409.
- [29]董飞飞, 刘涤尘, 涂炼, 等. 基于MM-ARMA算法的次同步振荡模态参数辨识

- [J]. 高电压技术, 2013, 39(05): 1252-1257.
- [30] 吴超, 陆超, 韩英铎, 等. 基于类噪声信号和ARMA-P方法的振荡模态辨识[J]. 电力系统自动化, 2010, 34(06): 1-6.
- [31] Jain S K, Singh S N. Exact model order ESPRIT technique for harmonics and interharmonics estimation[J]. IEEE Transactions on Instrumentation and Measurement, 2012, 61(7): 1915-1923.
- [32] Hosur S, Duan D. Subspace-driven output-only based change-point detection in power systems[J]. IEEE Transactions on Power Systems, 2019, 34(2): 1068-1076.
- [33] Paternina M R A, Tripathy R K, Zamora-Mendez A, et al. Identification of electromechanical oscillatory modes based on variational mode decomposition[J]. Electric Power Systems Research, 2019, 167: 71-85.
- [34] Tripathy P, Srivastava S C, Singh S N. A modified TLS-ESPRIT-based method for low-frequency mode identification in power systems utilizing synchrophasor measurements[J]. IEEE Transactions on Power Systems, 2011, 26(2): 719-727.
- [35] 王渝红, 王宏宇, 于光远, 等. 基于同步相量数据的次同步振荡检测与模态参数辨识方法[J]. 高电压技术, 2023, 49(06): 2557-2568.
- [36] 赵兰明, 李宽, 张友泉, 等. 基于FastICA-MP算法的次同步振荡模态参数辨识[J]. 电力系统保护与控制, 2018, 46(08): 37-42.
- [37] 李宽, 李兴源, 赵睿, 等. 基于希尔伯特—黄变换的次同步振荡检测研究[J]. 华东电力, 2012, 40(01): 62-66.
- [38] Wang B, Sun K. Location methods of oscillation sources in power systems: a survey[J]. Journal of Modern Power Systems and Clean Energy, 2017, 5(2): 151-159.
- [39] 栾某德. 电力系统强迫振荡扰动源定位研究[D]. 杭州: 浙江大学, 2020.
- [40] 朱振山, 刘涤尘, 廖清芬, 等. 基于最小均方时延估计法的强迫功率振荡扰动源定位方法[J]. 电力系统自动化, 2015, 39(4): 58-62.
- [41] Chen L, Sun M, Min Y, et al. Online monitoring of generator damping using dissipation energy flow computed from ambient data[J]. IET Generation, Transmission & Distribution, 2017, 11(18): 4430-4435..
- [42] Estevez P G, Marchi P, Galarza C, et al. Non-stationary power system forced oscillation analysis using synchrosqueezing transform[J]. IEEE Transactions on Power Systems, 2020, 36(2): 1583-1593.
- [43] 姜涛, 李孟豪, 李雪, 等. 电力系统强迫振荡源的时频域定位方法[J]. 电力系统自动化, 2021, 45(9): 98-106.
- [44] 姜涛, 高滢, 李雪, 等. 电力系统强迫振荡源定位的耗散能量谱方法[J]. 中国电机工程学报, 2023, 43(8): 2940-2953.
- [45] 冯双, 崔昊, 陈佳宁, 等. 人工智能在电力系统宽频振荡中的应用与挑战[J]. 中国电机工程学报, 2021, 41(23): 7889-7905.

- [46]Ma J, Zhang P, Fu H, et al. Application of phasor measurement unit on locating disturbance source for low-frequency oscillation[J]. IEEE Transactions on Smart Grid, 2010, 1(3): 340-346.
- [47]Ul Banna H, Solanki S K, Solanki J. Data - driven disturbance source identification for power system oscillations using credibility search ensemble learning[J]. IET Smart Grid, 2019, 2(2): 293-300.
- [48]Meng Y, Yu Z, Lu N, et al. Time series classification for locating forced oscillation sources[J]. IEEE Transactions on Smart Grid, 2020, 12(2): 1712-1721.
- [49]Meng Y, Yu Z, Shi D, et al. Forced oscillation source location via multivariate time series classification[C]//2018 IEEE/PES Transmission and Distribution Conference and Exposition (T&D). IEEE, 2018: 1-5.
- [50]崔昊, 冯双, 陈佳宁, 等. 基于自编码器与长短期记忆网络的宽频振荡广域定位方法[J]. 电力系统自动化, 2022, 46(12): 194-201.
- [51]郝琪, 刘崇茹, 王瑾媛, 等. 基于深度子领域自适应的直驱风机次/超同步振荡源定位[J]. 电力系统自动化, 2023, 47(17): 27-37.
- [52]陈剑, 杜文娟, 王海风. 采用深度迁移学习定位含直驱风机次同步振荡源机组的方法[J]. 电工技术学报, 2021, 36(1): 179-190.
- [53]陈剑, 杜文娟, 王海风. 基于对抗式迁移学习的含柔性高压直流输电的风电系统次同步振荡源定位[J]. 电工技术学报, 2021, 36(22): 4703-4715.
- [54]Fu Y, Chen L, Yu Z, et al. Data-driven low frequency oscillation mode identification and preventive control strategy based on gradient descent[J]. Electric Power Systems Research, 2020, 189: 106544.
- [55]田芳, 周孝信, 史东宇, 等. 基于卷积神经网络综合模型和稳态特征量的电力系统暂态稳定评估[J]. 中国电机工程学报, 2019, 39(14): 4025-4032.
- [56]秦心筱, 张昌华, 徐子豪, 等. 基于卷积神经网络的电力系统低频振荡主导模态特征定性辨识[J]. 电力系统保护与控制, 2021, 49(10): 51-58.
- [57]Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 3431-3440.
- [58]冯双, 彭祥佳, 陈佳宁, 等. 基于时空图卷积神经网络的强迫振荡定位与传播预测[J/OL]. 中国电机工程学报, 1-13[2024-03-08].
- [59]Elman J L. Finding structure in time[J]. Cognitive Science, 1990, 14(2): 179-211.
- [60]Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [61]陆友文, 崔昊, 陈佳宁, 等. 基于RA-CNN和同步相量的风电场次/超同步振荡参数智能辨识方法[J]. 中国电力, 2023, 56(04): 46-55+67.
- [62]Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge

-
- and Data Engineering, 2009, 22(10): 1345-1359.
- [63]Zhu Y, Zhuang F, Wang J, et al. Deep subdomain adaptation network for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(4): 1713-1722.
- [64]陈骁, 杜文娟, 王海风. 开环模式谐振条件下直驱风机接入引发电力系统宽频振荡的研究[J]. 中国电机工程学报, 2019, 39(9): 2625-2636.
- [65]苏晨博. 大规模风电场并网引发系统宽频振荡的机理分析及抑制措施[D]. 北京: 华北电力大学, 2022.
- [66]陈厚合, 张赫, 王长江, 等. 基于卷积神经网络的直流送端系统暂态过电压估算方法[J]. 电网技术, 2020, 44(8): 2987-2999.
- [67]谢小荣, 刘华坤, 贺静波, 等. 直驱风机风电场与交流电网相互作用引发次同步振荡的机理与特性分析[J]. 中国电机工程学报, 2016, 36(9): 2366-2372.
- [68]Van der Maaten L, Hinton G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.
- [69]Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation[C]//International Conference on Machine Learning. PMLR, 2015: 1180-1189.
- [70]He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.