

分类号_____

密级_____

UDC_____

编号_____

清 华 大 学
博 士 后 研 究 工 作 报 告

基于智能算法的生成对抗网络参数优化方法及应用

肖 泽 青

工作完成日期 2018年9月—2020年9月

报告提交日期 2020年9月

清 华 大 学 （北京）

2020年9月

基于智能算法的生成对抗网络参数优化方法及应用

METHODS AND APPLICATIONS OF PARAMETER OPTIMIZATION
FOR GENERATIVE ADVERSARIAL NETWORKS BASED ON
INTELLIGENT ALGORITHMS

博 士 后 姓 名 肖 泽 青

流动站（一级学科）名称 清华大学控制科学与工程

专 业（二级学科）名称

研究工作起始时间 2018 年 9 月 3 日

研究工作期满时间 2020 年 9 月 30 日

清华大学人事部（北京）
2020 年 9 月

摘要

生成对抗网络（generative adversarial networks, GAN）目前已经成为人工智能领域的一个研究热点,它为无监督学习的研究带来了新的活力,对生成式模型的发展具有举足轻重的意义。GAN的生成性能对于参数的选择比较敏感,目前,有关对GAN参数进行选择的方法报道较少,实际应用中基本上都是凭经验确定参数或采用试算法,导致由于参数选择不合适而使最后的生成精度低于目标精度。

基于数据驱动的深度学习技术成为新一代人工智能的应用趋势,该技术对有标注训练数据的量级提出了更高的要求。为了获取更多有标注的数据以及增加数据的多样性,本文分别在故障电机单通道振动信号数据,单相和三相短路接地故障母线电压数据以及引力波数据的场景下,对GAN的生成器和判别器进行架构搭建,提出了基于粒子群（particle swarm optimization, PSO）和遗传算法（genetic algorithm, GA）优化GAN参数的训练样本生成算法。通过交替训练GAN的生成模型与判别模型,无需先验知识的指导,自主学习原始样本的分布规律,生成新的数据样本。

本文研究工作表明,比随机选择GAN参数和根据经验选择GAN参数具有选择盲目性的劣势相比,基于PSO和GA优化GAN参数可以根据应用场景自动寻找最优参数,更能有效学习样本的分布规律,增加样本的多样性,同时具有更好的泛化性,对深度学习技术在工程中的深入发展具有一定的指导意义。此外,研究表明基于PSO优化GAN参数生成数据比基于GA优化GAN参数生成数据,不但生成精度更高,

而且训练耗时更少，效率更高。PSO优化GAN参数生成数据的收敛曲线以及误差曲线随迭代次数增加的变化情况表明PSO优化GAN参数生成数据具有良好的收敛性。

关键词：生成对抗网络(GAN), 粒子群算法(PSO), 遗传算法(GA),
学习率, 批处理大小

Abstract

At present, generative adversarial networks (GAN) has become a research hotspot in the field of artificial intelligence. It brings new vitality to the research of unsupervised learning and is of great significance to the development of generative model. The generation performance of GAN is sensitive to the selection of parameters. At present, there are few reports on the method of selecting GAN parameters. In practical application, the parameters are determined by experience or trial calculation method, which leads to the final generation accuracy lower than the target accuracy due to improper selection of parameters.

Data driven deep learning technology has become the application trend of the new generation of artificial intelligence, which puts forward higher requirements for the magnitude of labeled training data. In order to obtain more labeled data and increase the diversity of data, this paper proposes training sample generation algorithm based on particle swarm optimization (PSO) and genetic algorithm (GA) to optimize GAN parameters under the scenarios of single channel vibration signal data of fault motor, single-phase and three-phase short-circuit grounding fault bus voltage data and gravitational wave data. The generator and discriminator of GAN are constructed. By training the generation model and discrimination model of GAN alternately, we can learn the distribution law of original samples and generate new data samples

without the guidance of prior knowledge.

The research work in this paper shows that, compared with the random selection of GAN parameters and the selection of GAN parameters according to experience which has the disadvantage of blindness in choosing GAN parameters, the optimal parameters can be automatically found under the application scenarios. The intelligent optimization method can effectively learn the distribution law of samples, increase the diversity of samples and has better generalization ability, which has certain guiding significance for the in-depth development of deep learning technology in engineering. In addition, the research shows that the data generated by PSO-GAN method is more accurate than that by GA-GAN method. The time consumption of PSO-GAN is far less than that of GA-GAN method. And the efficiency of PSO-GAN is higher than that of GA-GAN method. The change of the convergence curve and error curve with the increase of iteration times indicates that the data generated by PSO-GAN method has good convergence.

Keywords: generative adversarial networks(GAN), particle swarm optimization(PSO), genetic algorithm(GA), learning rate, batch size

目 录

第一章 绪论.....	1
1.1 引言.....	1
1.2 基本数据生成方法.....	6
1.3 先进的数据生成方法.....	12
1.4 研究报告概要.....	15
第二章 生成对抗网络参数优化.....	17
2.1 简介.....	17
2.2 经典 GAN 基本原理及其优劣.....	17
2.3 粒子群 (PSO) 算法和遗传算法 (GA).....	24
2.4 GAN 模型架构搭建.....	34
2.5 PSO 和 GA 优化 GAN 参数.....	35
2.6 本章小结.....	38
第三章 故障电机振动信号应用.....	39
3.1 背景介绍.....	39
3.2 研究内容.....	40
3.3 算值仿真.....	41
3.4 本章小结.....	45
第四章 单相及三相短路接地故障应用.....	47
4.1 背景介绍.....	47
4.2 研究内容.....	48
4.3 单相短路故障算例应用.....	48
4.4 三相短路故障算例应用.....	59
4.5 本章小结.....	69
第五章 引力波应用.....	71
5.1 背景介绍.....	71
5.2 研究内容.....	72
5.3 理想引力波应用.....	72
5.4 GW150914 事件应用.....	77
5.5 本章小结.....	84
第六章 结论.....	86
参考文献.....	87
致谢.....	97
博后期间的成果.....	98

第一章 绪论

1.1 引言

1.1.1 人工智能的发展趋势

“人工智能”（artificial intelligence, AI）这一概念 1956 年在达特茅斯会议上被首次提出，到现在已经有了 60 多年的发展历程。AI 是一门交叉科学，具有高效解决复杂问题的突出优点，它的研究目的是使机器能够像人类一样识别、学习、思考^[1]。

随着互联网技术的高速发展，AI 技术不断革新，应用领域不断扩大。AI 领域的研究主要包括自然语言处理^[2]，计算机视觉^[3]，语音识别^[4]等。AI 的应用近年来发展迅速，已经广泛应用到能源互联网^[1]、医疗^[5]、文教^[6]、会计^[7]、媒体传播^[8]、制造业^[9]和服务业^[10]等领域。科研人员试图使用减少人工干预的自主智能方法来降低人员成本，未来人机混合智能将会成为主要发展方向^[11]。

AI 技术为能源互联网的设计、模拟、预测、控制、优化、评估、检测、故障诊断和容错、需求侧管理和消费者分类等应用提供了强大的工具。但是在电力系统中，各方面的管理工作还存在着自动化、智能化程度偏低，即使有很多工作已经在智能化水平上有一定成果，但成果之间往往相互独立，未能充分发挥出有效的协同作用。AI 的作用之一就是有效整合现有系统，发挥系统之间的协同效用，极大化发掘现有系统的潜在价值，实现管理优化。信息化管理是能源互联网领域的必然趋势，然而各类能源、各类角色的数据各不相同，难于统一管

理，这将影响信息化的协同建设。如何有效归整各类数据，提取关键信息，建立关联关系，是AI在推进信息化建设进程中的重要内容^[1]。

1.1.2 数据生成研究背景

近几年随着AI的蓬勃发展，深度学习（deep learning, DL）也随之快速发展。DL对于非线性问题的拟合以及对于图像、语音等物理特征的快速有效提取，使得这些原本在传统方法上需要人为设定并人工提取特征的问题变得简单。DL的模型训练和学习变得更为方便和快速^[13]。DL在计算机视觉（computer vision, CV）、自然语言处理和语音处理等许多领域都取得了显著的成功。近年来，DL越来越多地被用于解决时间序列相关的任务，包括时间序列分类^[14]、时间序列预测^[14]，以及时间序列异常检测^[16]。虽然DL有效解决了一些非线性问题的模型拟合，但是DL模型的实现需要大量的训练数据^[13]。DL的成功很大程度上依赖于大量的训练数据，以避免过度拟合。DL是典型的数据驱动技术，其能够利用大量的数据训练模型，通过学习发现规律，提取数据特征，完全避免了基于物理特性建模的局限性^{[17], [18], [19], [20]}。

由于DL采用了多层网络结构，其模型复杂度比传统的单隐含层模型要大得多，为了确保模型的泛化能力，就必须相应地增大训练数据^{[20], [21]}。当前在工业界取得突破的基于机器学习或DL的AI应用对训练样本都有着数量上的要求。而训练模型所必须的海量训练数据样本难以获取已经成为阻碍DL技术进一步推广的一个普遍性难题。数据扩充作为提高训练数据量和质量的有效工具，对DL模型的成功应用

至关重要。数据扩充的基本思想是在保持正确的标签的同时生成覆盖未探测输入空间的合成数据集。数据扩充在许多应用中都显示了它的有效性，例如AlexNet用于ImageNet分类^[22]。数据扩充又称为数据生成或数据增强（数据增广）。

为了有效解决小样本学习问题，一种常见思路是通过改进算法来使其更适应于小样本环境。文献[23]提出了一种融合专业知识和机器学习算法的引导学习方法，利用可表示的专业知识和经验，指导学习器对样本数据进行训练，优化学习模型参数，从而减少对海量样本数据的依赖。但是该方法在先验知识与机器学习算法融合的机理研究以及具体的经验知识提取和封装等方面还需要进行进一步的深入研究；文献[24]将 DL 技术与迁移学习相结合，先在相关领域的大数据集中对卷积神经网络模型进行预训练，提取出预训练模型的权重和样本特征，用于目标小数据集中对模型进行初始化，以帮助模型对目标小数据集展开训练。该方法需要目标小数据集在相关领域中有可以辅助的大规模数据集，而在智能电网应用中缺少可辅助的大数据集，因此该方法无法很好地在电网领域进行应用。

另一种常用方法是通过对已有数据样本进行一定的处理来增加样本的数量。文献[25]利用支持向量机（support vector machine, SVM）结合网格搜索（grid search, GS）法对原始小样本数据进行预测扩充。但是 SVM 对缺失数据、参数和核函数的选择比较敏感，目前还没有好的方法来解决核函数的选取问题。

在基于数据驱动理论的软测量建模过程中，样本的数量会对所建

模型的精度产生影响。针对训练样本数量较少的情况，文献[26]提出了一种利用欧氏距离和角度原则进行数据扩充的方法。该方法通过分析数据的分布特征来确定样本扩充的区间范围，利用扩充数据完善建模对象在各阶段的信息，并进一步重构建模数据集，从而提升了所建模型的预测精度。通过 2 个工业过程的仿真研究，验证了该方法具有良好的泛化性能和建模精度。

处理存在有偏性的数据（阳性数据和隐性数据不平衡），最简单的方法是随机复制，即随机复制少数类样本数据，从而达到阳性数据和隐性数据平衡的目的。但是随机复制会在判别分析中产生过度拟合问题，影响模型的效果^[27]。

针对时间序列数据寻找更好的数据扩充方法的研究较少。时间序列数据的数据扩充方法存在一些挑战。首先，现有的数据扩充方法没有充分利用时间序列数据的内在特性。时间序列数据的一个独特特性就是所谓的时间依赖性。与图像数据不同的是，时间序列数据可以在频率域和时频域进行变换，并且可以在变换域中设计和实现有效的数据扩充方法。当我们对多变量时间序列建模时，这就变得更加复杂，因为我们需要考虑这些变量在时间上的潜在复杂动态。因此，简单地应用来自图像和语音处理的数据增强方法可能不会产生有效的合成数据。其次，数据扩充方法也是任务相关的。例如，适用于时间序列分类的数据扩充方法对于时间序列异常检测可能无效。此外，在许多涉及时间序列数据的分类问题中，经常会出现类不平衡的现象。在这种情况下，如何用较少的样本有效地生成大量的合成数据仍然是一个

挑战^[30]。

与 CV^[28]或 speech^[29]的数据扩充不同，时间序列的数据扩充尚未得到系统的审查。下面总结了不同任务中时间序列的常用数据扩充方法，包括时间序列预测、异常检测、分类等；提出了时间序列数据扩充方法的分类，如图 1.1 所示。

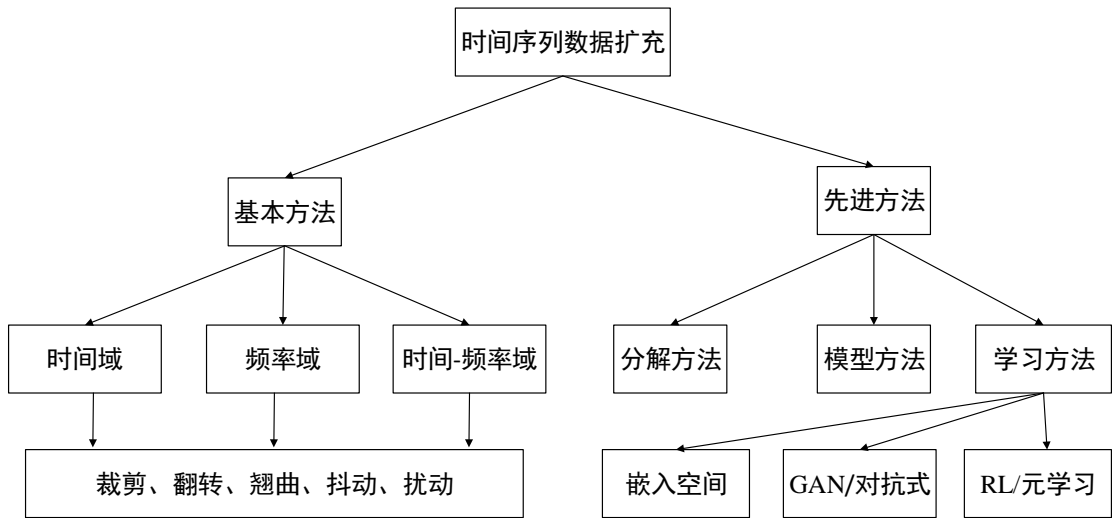


图 1.1 时间序列数据扩充的分类法^[30]

基于所提出的分类法，本章系统地回顾了这些数据扩充方法。首先从时域的简单变换开始讨论。然后讨论了时间序列在变换频率域和时频域上的更高级变换。除了对时间序列进行不同领域的变换外，本章还介绍了更先进的方法，包括基于分解的方法、基于模型的方法和基于学习的方法。在基于分解的方法中，首先将输入的时间序列分解为趋势、季节性和残差等不同的分量，然后对不同的分量进行不同的处理，得到不同的数据扩充方法。在基于模型的方法中，首先从数据中学习一个统计模型，然后对学习模型的参数空间进行扰动以生成更多的综合数据。本章也回顾了嵌入空间中进行数据扩充的一些工作。特别是，由于生成对抗网络（generative adversarial networks, GAN）

[31]可以有效地生成合成数据和增加训练集，本章总结了近年来 GAN 在时间序列数据上的应用研究进展。

1.2 基本数据生成方法

1.2.1 时域变换

时域变换是时间序列数据最直接的数据扩充方法。大多直接对原始输入时间序列进行操作，如注入高斯噪声或更复杂的噪声模式，如尖峰、阶跃趋势和斜率趋势。一种用于时间序列异常检测的特殊数据扩充方法，即时域中的标签扩展^[32]中提到了窗口裁剪或切片。文献[33]中介绍，窗口种植类似于CV区域的种植。它是一种从原始时间序列中随机提取连续切片的子样本方法。切片的长度是一个可调参数。对于分类问题，切片样本的标签与原始时间序列相同。在测试阶段，利用所学习的分类器对测试时间序列中的每一个片段进行分类，并使用多数投票产生最终的预测标签。对于异常检测问题，将异常标签与值序列一起切片。

窗口翘曲是一种独特的时间序列增强方法。与动态时间规整（dynamic time warping, DTW）类似，该方法选择一个随机的时间范围，然后压缩（下采样）或扩展（上采样），而其他时间范围保持不变。窗口翘曲会改变原始时间序列的总长度，因此对于DL模型，窗口扭曲应该与窗口裁剪一起进行。该方法包含了正态下采样，它在原始时间序列的整个长度上取下样本。文献[34]介绍了另一种有趣的扰动和基于系综的方法。该方法利用DTW生成新的时间序列，并通过DBA算法的加权版本进行集成显示了一些UCR数据集的分类改进。

噪声注入是一种在不改变相应标签的情况下，将少量噪声/离群值注入时间序列的方法。这包括注入高斯噪声、尖峰、阶跃趋势和斜率趋势等。对于尖峰，我们可以随机选取指数和方向，随机指定大小，但以原始时间序列标准差的倍数为界。对于阶跃趋势，它是从左指数到右指数的累计峰值总和。类似斜率的趋势是在原始时间序列中加入一个线性趋势^[35]。在时间序列异常检测中，异常通常在连续的时间跨度内持续足够长的时间，所以起点和终点有时“模糊”。因此，在时间距离和值距离方面接近标记异常的数据点很可能是异常。在这种情况下，我们提出了标签扩展方法，将这些数据点及其标签更改为异常（通过为其分配一个异常分数或切换其标签），从而提高了时间序列异常检测的性能^[36]。

1.2.2 频域数据扩充

现有的数据增广方法大多集中在时域，很少有研究从频域的角度对时间序列进行数据扩充。文献[36]中最近的一项工作提出利用频域中振幅谱和相位谱的扰动来增强卷积神经网络检测时间序列异常的数据。具体来说，对于输入时间序列 x_1, x_2, \dots, x_N ，其频谱 $F(\omega_k)$ 通过傅里叶变换计算：

$$F(\omega_k) = \frac{1}{N} \sum_{t=0}^{N-1} x_t e^{-j\omega_k t} = R[F(\omega_k)] + jD[F(\omega_k)] = A(\omega_k) \exp[j\theta(\omega_k)]$$

其中 $R[F(\omega_k)]$ 和 $jD[F(\omega_k)]$ 分别是光谱的实部和虚部， $\omega_k = \frac{2\pi k}{N}$ 是角频率， $A(\omega_k)$ 是振幅谱， $\theta(\omega_k)$ 是相位谱。对于振幅谱 $A(\omega_k)$ 中的扰动通过考虑振幅谱的原始均值和方差，用高斯噪声代替随机选取的分段

的振幅值。而对于相位谱 $\theta(\omega_k)$ 在相位谱中加入一个额外的零均值高斯噪声。基于振幅和相位扰动的数据增强与上述时域增强方法相结合带来了显著的时间序列异常检测的改进^[36]。

Lee^[37]的另一项最新工作提出利用替代数据来提高深度神经网络中康复时间序列的分类性能。文献[30]采用了两种传统的替代时间序列：振幅调整傅里叶变换（amplitude adjusted fourier transform, AAFT）和迭代AAFT（iterative amplitude adjusted fourier transform, IAAFT）。其主要思想是对傅里叶变换后的相位谱进行随机相位洗牌，然后对时间序列进行逆傅立叶变换后的秩排序。由AAFT和IAAFT生成的时间序列可以近似地保持原始时间序列的时间相关性、功率谱和振幅分布。在文献[37]的实验中，通过AAFT和IAAFT方法将数据扩展 10 到 100 倍，进行了两种类型的数据扩充，并证明了与未进行数据扩充的原始时间序列相比，分类精度有了很大提高。

1.2.3 时频域数据增广

时频分析是一种应用广泛的时间序列分析技术，可以作为深度神经网络的输入特征。然而，与频域数据增广相似，很少有研究考虑时间序列的时频域数据增广^[30]。

文献[38]中的作者采用短时傅立叶变换（short-time fourier transform, STFT）生成传感器时间序列的时频特征，并通过深度长短期记忆LSTM（long short-term memory）神经网络对人类活动分类的时频特征进行数据增强。具体来说，提出了两种增强技术。一种是基于定义的准则进行局部平均，生成的特征附加在特征集的尾部。另

一种方法是对特征向量进行洗牌，以在数据中产生变化。同样，在语音时间序列中，最近提出了SpecAugment^[39]在Mel频率（基于STFT的语音时间序列的时间频率表示）中进行数据增强，其中增强方案包括扭曲特征、频道屏蔽块和时间步距屏蔽块。文中总结了几种典型的时频增强方法，并对几种典型的时频增强方法进行了时间序列分析。

传统的数据生成算法有SMOTE（synthetic minority over-sampling technique, SMOTE）算法^[40]、回归填充法^[41]、K-means算法^[42]、Bootstrap算法^[43]等。这些传统方法合成的数据和实际电网数据相关性不强，忽略了电力系统中量测的时序特性和相关性，对电力系统中数据的重建和生成效果并不理想，在具体处理小样本数据时忽略了样本数据聚集与离散程度对数据关系度量的重要性。下面简要介绍一下文献中常用的Bootstrap算法和SMOTE算法。

1.2.4 Bootstrap算法

Bootstrap重抽样法是对小样本数据进行扩充的较好的方法^[44]。文献[45]针对小样本数据的区间估计问题，将Bootstrap重抽样^[46]、^[47]引入到灰色估计理论中，对小样本数据进行了重抽样扩充，比较了3种不同灰色区间估计的性能。然而上述文献在具体处理小样本数据时都忽略了样本数据聚集与离散程度对数据关系度量的重要性。

文献[44]考虑到小样本数据分布的密集程度，建立基于数理统计概念的新的灰色距离测度，以便确定包含信息更全面的灰色置信区间，在数据向密集方向变化时具有更好的区分度。对于灰色点估计问题，建立了全面衡量小样本数据稀缺性和有效性的灰色距离矩阵，据此改

进熵权法确定更客观的权值。考虑到Bootstrap重抽样是一种重要的数据扩充法，文献[44]引入Bootstrap重抽样，比较重抽样之前和之后，采用该方法所建立的灰色点估计和灰色置信区间的差异性。最后通过实例验证了该方法的有效性。

1.2.5 SMOTE算法

过抽样算法是对少数类样本人为地增加其数目以达到整个数据集趋于平衡的方法。典型的过抽样算法为2002年由Chawla等人针对过抽样引起的过分拟合问题而提出的SMOTE算法^[48]，其基本思想是通过少数类样本同类之间的线性插值合成新的同类样本以达到平衡数据集分布的目的。然而，SMOTE算法却忽略了靠近分类边界的样本以及孤立点对少数类分类性能的影响^[49]。鉴于此，Han等人^[50]提出的Borderline-SMOTE算法在SMOTE算法的基础上做了改进。其基本思想为仅仅使用少数类样本中的边界样本进行新样本的合成。该算法虽然在一定程度上提高了少数类样本的分类性能，但由于忽略了安全样本和孤立点，故在分类性能的提高上存在一定的局限性^[49]。为了提高少数类样本的识别率，文献[49]在BSMOTE算法的基础上增加了对孤立点和安全样本的处理，并在采样倍率的设置和合成规则的处理上做了改进，提出了NSMOTE算法。NSMOTE算法首先采用“分而治之”的思想把训练集中的少数类样本归为三类：边界样本、孤立点及安全样本；然后对三类样本分别进行处理合成新的样本；最后把合成的新样本和原始数据集归并为新的训练集，并采用Biased-SVM分类算法对其进行建模学习。数据实验结果表明，该算法在提高不平衡数

据集整体分类性能的同时有效地提高了少数类的分类性能。

此外，对于文献[48]中所采用的线性插值，得到的少数类实例只能分布在少数类之间的线段中，这就严格限制了生成少数类实例的分布范围。为了消除这种限制，文献[51]提出了一种数据分布不均衡条件下的过抽样方法ISMOTE，把生成少数类实例的范围推广到n维球体，这样可以减小数据的不均衡程度，提高少数类实例的分类精确度。

SMOTE算法的主要缺点有^[52]：1) 负类集合中的噪声负类样本参与新样本的合成，使得产生的新样本质量较差；2) 没有对少数类样本进行区别性的选择，而是同等对待所有的少数类样本；3) 生成新样本时，负类样本的k近邻可能是正类样本，这容易产生正负类边界模糊问题；4) 合成样本仅在 2 个点的连线上产生，分布区域较小，分类器分类时易过拟合。

针对SMOTE算法的缺点，一些人对SMOTE算法提出了改进。董燕杰^[53]提出Random-SMOTE算法，该算法对SMOTE算法的第 4 个缺点进行了改进，在样本点与 2 个近邻点所形成的三角形区域里面随机插值。王超学等人^[54]提出了改进型SMOTE算法，该算法对SMOTE算法的第 2 个缺点进行了改进，使用轮盘赌算法来选择少数类集合中的少数类样本。Santos等人^[55]提出了CB-SMOTE算法，该算法对SMOTE算法的第 3 个缺点进行了改进，生成新样本时的类别标签由该样本与其最近邻样本的类别标签共同决定。袁铭^[56]提出了R-SMOTE算法，该算法对SMOTE算法的第 3 个缺点与第 4 个缺点进行了改进，在 2 个少数类样本上使用N维球面使生成的样本不在原样本与其近邻的

直线上。古平等^[57]提出了SD-ISMOTE算法，该算法对SMOTE算法的第2个缺点、第3个缺点与第4个缺点进行了改进，根据近邻分布对少数类样本进行类别细分，对不同细分的少数类样本分别使用R-SMOTE与SMOTE算法合成新样本。

以上算法对SMOTE算法做出了许多改进，但总体分类性能还是稍显不足^[52]。文献[52]利用删去噪音样本的少数类样本集簇心与不大于样本属性数的对应类别少数集数据，使用新的样本生成公式，提出了一种新的改进型SMOTE算法—ImprovedSMOTE算法。

1.3 先进的数据生成方法

1.3.1 基于分解的方法

基于分解的时间序列增强方法也被应用于许多与时间序列相关的任务中，如预测、聚类和异常检测。在文献[58]中，作者讨论了生成新时间序列的重组方法。它首先基于STL (seasonal and trend decomposition using loess)将时间序列 x_t 分解为趋势、季节性和残差^[59]：

$$x_t = \tau_t + s_t + r_t, \quad t = 1, 2, \dots, N$$

其中 τ_t 是趋势信号， s_t 是季节性/周期性信号， r_t 表示剩余信号。然后，将新的时间序列与确定性成分和随机成分进行重组。确定性部分通过调整基础、趋势和季节性的权重来重建。随机部分是通过建立基于残差的复合统计模型（如自回归模型）生成的。通过检测与原始信号的基于特征的距离是否在一定范围内，验证了所生成的时间序列的有效性。同时，文献[60]中的作者建议对分解后的残差应用Bootstrapping来生成增强信号，然后将这些信号与趋势和季节性相加，以组合新的

时间序列。基于增广时间序列的一组预测模型的综合性能一直优于原预测模型，证明了基于分解的时间序列增广方法的有效性。最近，在文献[36]中，作者指出，对使用RobustSTL^[61]和RobustTrend^[62]生成的分解残差应用时域和频域增强可以帮助提高异常检测的性能。

综上所述，通常将时间序列分解为不同的分量，如趋势、季节性和残差，其中每个分量可以使用Bootstrapping或基本的时域和（时间）频域增强方法进行扩充。

1.3.2 基于模型的方法

基于模型的时间序列扩充方法通常涉及到用统计模型对时间序列的动态进行建模。在文献[63]中，作者提出了一种简化的统计模型，称为混合高斯树，用于建模多模态少数类时间序列数据，以解决分类不平衡的问题，与现有的不利用相邻点间时间序列相关性的过采样方法相比，该方法显示出了优势。文献[64]中的作者使用了一种称为LGT（局部和全局趋势）的统计算法计算的参数和预测路径样本。最近，在文献[65]中，研究人员使用混合自回归模型来模拟时间序列集合，并从本质上研究生成的时间序列在时间序列特征空间中的多样性和覆盖率，这些模型通过假设时间 t 的值依赖于前面的点来描述时间序列的条件分布。一旦初始值受到扰动，就可以根据条件分布生成一个新的时间序列。

1.3.3 基于学习的方法

在文献[66]中，建议在学习空间中执行数据扩充。文中假设，由于流形在特征空间展开，应用于编码输入而不是原始输入的简单变换

将产生更合理的合成数据。此框架中表示模型的选择是开放的，取决于特定的任务和数据类型。当处理时间序列数据时，在文献[66]中选择序列自动编码器。具体来说，内插和外推用于生成新的样本。在变换后的空间中识别出具有相同标签的前 k 个最近的标签。然后对每一对相邻样本生成一个新样本，这是它们的线性组合。插值与外推的区别在于样本生成中权重的选择。这种技术对于时间序列分类特别有用。

强化学习也被引入到数据扩充^[67]中，以自动搜索改进的数据扩充策略。具体地说，强化学习定义了一个搜索空间，在这个空间中，扩充策略由许多子策略组成。每个子策略由两个操作组成，每个操作定义为一个图像处理函数，如平移、旋转或剪切。正如前面所讨论的，数据扩充与数据和任务密切相关。因此，如何将强化学习框架引入到时间序列数据和不同的任务中仍然是个未知数。

作为一种生成模型，GAN可以有效地生成合成样本并增加训练集。尽管GAN框架在许多领域得到了广泛的关注，但是如何生成时间序列仍然是一个有待解决的问题。在GAN中，需要为时间序列数据建立一个良好的、通用的生成模型。文献[68]提出了一种循环GAN来生成真实的合成数据。此外，还提出了一种多GAN结构来生成更接近测试数据的合成时间序列数据，以实现个性化训练。在文献[69]中，提出了一种递归GAN和递归条件GAN来生成真实值的多维时间序列数据。文献[70]提出了TimeGAN，这是一个在不同领域生成真实时间序列数据的自然框架。TimeGAN是一个生成的时间序列模型，它通过一个学习的嵌入空间进行对抗和联合训练，同时有监督和无监

督损失。该文中还引入了一个嵌入网络来提供特征和潜在表征之间的可逆映射，以降低对抗性学习空间的高维性。通过联合训练嵌入网络和生成网络，使监督损失最小化。

虽然近年来对GAN的研究已经取得了长足的进展，但还没有建成完整的理论体系，比如对参数的选择没有理论依据。在使用GAN生成数据的过程中对以下参数的选择还是停留在靠经验选取或反复实验的基础之上^{[71], [72], [73]}：生成器的学习率 r_G （learning rate of generator）和判别器的学习率 r_D （learning rate of discriminator），以及批处理大小 B （batch size）。

1.4 研究报告概要

鉴于以上所述基本数据生成方法在数据生成方面的难点和问题，以及先进数据生成方法GAN在参数选择上的盲目性问题，本报告分别在故障电机单通道振动信号数据，单相和三相短路接地故障母线电压数据以及引力波数据的场景下，在对GAN架构进行搭建的基础上，提出基于PSO和GA优化GAN参数的训练样本生成技术，以解决样本数据生成问题，增加数据的多样性。通过对已有样本数据的学习，利用PSO和GA强大的优化能力提高GAN的学习效果，最终能够自主生成全新的样本数据。该方法不需要领域内其他信息的辅助，模型能够自主学习样本特征，生成的样本更贴近真实数据，很好地解决了当前数据真实样本不足，样本缺乏多样性以及GAN参数选择盲目性的问题。

本研究报告的其余内容主要分为五个部分：第二章介绍了GAN、

粒子群算法 (particle swarm optimization, PSO) 和遗传算法 (genetic algorithm, GA), 并对本报告所做的主要理论研究工作, 即GAN模型架构搭建, PSO和GA优化GAN参数的流程进行了详细阐述。第三章, 第四章, 第五章分别为将所做的理论创新工作应用到故障电机振动信号, 单相和三相短路接地故障数据以及引力波数据的生成。第六章对本报告进行了总结和展望。

第二章 生成对抗网络参数优化

2.1 简介

本章首先介绍经典GAN理论及其优劣势，PSO和GA理论。然后阐述本报告所做的研究工作：设置GAN网络架构；对PSO和GA优化GAN参数（ r_G 、 r_D 和 B ）的流程进行详细说明，为第三章故障电机振动信号的应用，第四章单相及三相短路接地故障的应用，第五章引力波的应用提供理论基础。本章阐述了本报告的理论贡献部分。

2.2 经典GAN基本原理及其优劣

2.2.1 GAN基本原理

Goodfellow于2014年首次提出的GAN是一种新兴的半监督和无监督学习技术，其特点是训练一对相互竞争的网络^[31]。GAN不再像传统的监督式DL那样需要海量带有类别标记的数据，不需任何数据标记即可训练，也就是进行无监督条件下的DL。

GAN的架构如图2.1所示。 G 称为生成器（generator），目的是制作逼真的样本，其输入为随机噪声向量（通常服从均匀分布或正态分布）； D 为判别器（discriminator），接收来自生成器 G 伪造的样本和真实的样本，并旨在将它们区分开来，其输出为样本是真实的而不是虚假的概率，即判别概率。

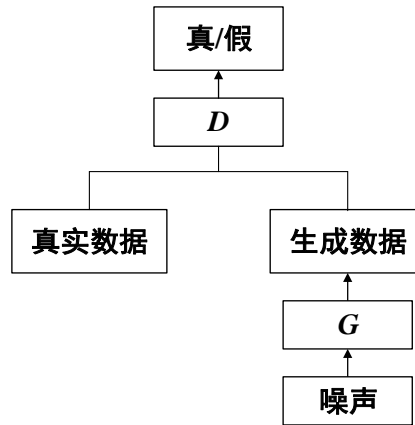


图 2.1 GAN结构图^[74]

G 和 D 一般都是由神经网络组成，两者都是同时训练的，并且相互竞争（博弈）。 G 的输出是 D 的输入， D 的输入还包含真实样本集。这样， D 对真实样本尽量输出判别概率高一些，对 G 产生的样本尽量输出判别概率低一些。每次循环迭代， G 网络不断优化网络参数，使 D 无法区分真假；而 D 网络也在不断优化网络参数，提高辨识度，让真假样本的判别概率有差距。当 D 不能确定数据是来自真实数据集还是来自 G 时，即达到所谓的纳什均衡，此时得到的 G 已经学习到真实数据的分布，从而掌握了整体真实数据的分布情况。最终的GAN模型中， G 生成的样本能以假乱真， D 输出的判别概率接近0.5，即表示真假样本难以区分， D 收敛。

从损失函数的角度可以得到 D 的损失函数如下^[31]：

$$\tilde{J} = -\frac{1}{m} \sum_{i=1}^m \log D(x^i) - \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^i))), \quad (2.1)$$

其中， x 是真实样本， m 表示样本量， $G(z)$ 是 G 生成样本。 $D(x)$ 越大越好， $D(G(z))$ 越小越好，也就是希望 $-D(x)$ 越小越好， $-\log(1 - D(G(z)))$ 越小越好。 D 的得分（score）定义为 $-\tilde{J}$ ，当 D 的得分趋于-1.38时， G 是收敛的。

2.2.2 GAN的优劣势

GAN这种竞争的方式不再要求一个假设的数据分布，而是直接进行取样，能够比其它模型产生更好的样本，从而真正达到理论上可以完全逼近真实数据。GAN无需马尔科夫链，仅使用反向传播来获取梯度，学习过程中不需要推理，且模型中可融入多种函数。对抗的网络的另一优点是可表示退化的分布，而基于马尔科夫链的方法为混合模式而要求模糊的分布^[31]。

GAN无法学习是因为 G 开始退化，学习难以进行，方案之间振荡，或 G 有崩溃的倾向^[75]，即 G 坍塌产生一小部分类似样本（部分崩溃），最坏的情况下只产生一个样本（完全崩溃）^[76]。一种解决GAN生成样本多样性不够好的方法是增加 G 的多样性，使用多个GAN来覆盖概率分布的不同模式^[77]；另一种减轻模式崩溃的方法是改变用于比较统计分布的距离度量。由于GAN模型是高度非线性的，具有随机初始化功能，因此可以很容易地陷入局部极小值。

所有的理论都认为GAN应该在纳什均衡上有卓越的表现，但梯度下降只有在凸函数的情况下才能保证实现纳什均衡，且寻找纳什均衡解是一个难点^[78]。当博弈双方都由神经网络表示时，在没有实际达到均衡的情况下，可以让博弈双方对自己策略进行调整来达到纳什均衡。GAN不需要预先建模使得GAN太过自由了，解决办法之一是给GAN加约束^[79]；还有一个想法就是不要让GAN一次完成全部任务，而是一次生成一部分，比如分多次生成一张完整的图片^[80]。

2.2.3 GAN的改进综述

针对原始GAN的劣势，近年来出现了各种出色的GAN改进变体^[81]。本节从训练技巧及模型架构改进两个方面阐述主流的GAN改进及其应用。

（1）训练技巧改进

Salimans等提出的特征匹配、小批量的训练判别器、历史平均和类别标签平滑这几种稳定训练的技术，能够训练以前无法解决的模型^[82]。InfoGAN处理的是图像外观中错综复杂的因素，包括姿态、光照和面部图像的情感内容的变化^[83]。虽然批量规范化（batch normalization, BN）能够在早期阶段加速训练，但可能会对训练模型的质量和训练过程的稳定性产生负面影响。在此基础上，提出了一种新的权重归一化方法，该方法可以提高神经网络的重构能力和训练速度，特别是神经网络的稳定性，因此在GAN训练中应采用权重归一化方法来代替BN^[84]。

文献[85]通过强制D网络输出类标签，将GAN扩展到半监督上下文。该方法可用于建立一个更高效的数据分类器，并能生成比常规GAN更高质量的样本。文献[84]采用Wasserstein距离的近似，替代了GAN的成本函数，提出了WassersteinGAN（WGAN）。与原始的GAN成本函数不同，WGAN更可能提供对更新G有用的梯度。虽然WGAN在稳定训练方面取得了进展，但有时仍然只能生成较差的样本或无法收敛。Mescheder等^[86]提出的统一变分自编码器（variational autoencoders, VAEs），以对抗型的变分贝叶斯（adversarial variational bayes, AVB）框架的形式进行对抗性训练，使推理模型更加灵活，

保留了标准变分自编码器的大部分优点，易于实现。Goodfellow的NIPS 2016教程^[87]也提出了类似的想法。AVB尝试优化与VAEs相同的标准，但使用对抗训练目标而不是Kullback-Leibler (K-L) 散度。AVB明确规定了要使用散度量，因此无法应用WGAN^[86]。

在条件熵的框架下，文献[88]提出了对抗性和非对抗性两种方法来学习无监督和有监督任务的理想匹配联合分布，将各种GAN模型统一理解为节点匹配的观点来解决双向对抗性网络的不可识别性问题，稳定了无监督双向对抗性学习方法的学习。然而，这种模式与AVB和对抗自动编码器 (adversarial autoencoder, AAE) 有很多共同之处。这些类似于VAEs的自动编码器的潜在空间是通过使用对抗训练而不是通过编码样本和先验样本之间的K-L散度来调节的^[89]。Dumoulin等人^[75]引入了对抗学习推理 (adversarially learned inference, ALI) 模型，该模型利用逆过程对生成网络和推理网络进行联合学习。使用双向GAN (bidirectional generative adversarial networks, BiGAN) 作为学习逆映射的一种方法，所得到的学习特征表示对于辅助监督辨别任务是有用的^[90]。然而，观察到的重建结果往往只是模糊地类似于输入，而且往往只是语义上的，而不是术语上的像素值^[86]。

Sønderby等在超分辨率技术上，应用GAN对结果进行优化，通过在将样本送入 D 之前向样本添加噪声来挑战 D ，得到了比对比方法更好的结果，能还原打码图片^[91]。但该超分辨率技术只能为低分辨率图像添加有限的细节，不能像StackGAN^[92]那样纠正较大的缺陷。在数据样本中添加噪声以稳定训练的过程后来被Arjovsky等人证明是正

确的^[78]。

（2）模型架构改进

给GAN加一些约束，可得到条件GAN（conditional generative adversarial networks, CGAN）^[93]。CGAN可以解决GAN太过自由、本身不可控的缺点。CGAN模型可以生成以类标签为条件的MNIST数字，还可以使用此模型来学习多模态模型。然而，使用一位有效编码，对包含数千个类的标签向量进行条件设置在内存开销和计算时间开销方面是不可行的^[94]。

Radford等人^[95]提出的深度卷积GAN（deep convolutional generative adversarial networks, DCGAN）使得 G 和 D 都可以学习良好的上采样和下采样操作，有助于提高图像合成的质量。而且 G 表现得更加可控和稳定。DCGAN将BN用在了 G 和 D 上，能够避免崩溃。研究表明，在 D 中间层之间使用泄漏ReLU激活函数比使用常规ReLU具有更好的性能。此外，DCGAN还可以支持图像“语义”层面的加减。但DCGAN难以训练，训练过程只能是启发式的^[78]。

Akbari等人提出了用于序列数据生成的半递归混合VAE-GAN模型，提出的两种测试框架可用来合成任意帧数的序列^[96]。在数据集CIFAR-10上进行的早期实验表明，与用于监督学习的网络相比，使用具有相同容量和表示能力的CNNs训练 G 和 D 网络更加困难。建立在GAN和CGAN基础上的拉普拉斯金字塔GAN（laplacian generative adversarial networks, LAPGAN）为这个问题提供了一个解决方案^[80]。然而，训练GAN需要用连续的高维参数确定非凸博弈的纳什均衡。

当用于寻求纳什均衡时，LAPGAN算法可能无法收敛^[82]。文献[97]提出了一个可通过对抗性训练进行训练的递归生成模型（recurrent generative model, GRAN）。Mou等人设计了一种具有PReLU的门控循环单元GRU（gated recurrent unit），它能够处理长期序列数据（比如高光谱序列），并且更适合于少量训练样本^[98]。

Wu等人利用体积卷积网络和GAN的最新进展，研究了三维对象生成问题，提出了三维GAN（3D-GAN）^[99]。Gulrajani等人提出了一种裁剪权值的替代方法，比标准WGAN表现更好，并且能够在几乎没有超参数调整的情况下对各种GAN架构进行稳定的训练^[100]。基于梯度的随机裁剪能够准确地恢复潜在向量，对噪声具有较强的鲁棒性。随机裁剪比标准裁剪更精确、更健壮^[101]。采用全卷积神经网络（fully convolutional network, FCN）^[102]能让GAN自己学习更合适的空间下采样方法，应用在图像彩色化和图像检测等方面取得了较好的效果^[103]。为了解决生成的图像无效的问题，Heusel等人使用真实和生成图像的激活之间的Wasserstein-2 距离作为Frechet初始距离得数^[104]。

Gurumurthy等人^[105]提出将潜在的生成空间作为混合模型重新参数化，建模为高斯混合，并与GAN模型一起学习混合模型的参数。这种基于GAN的新的体系结构—DeLiGAN尽管只使用有限的数据进行训练，但生成的样本具有多样性，这并不一定意味着给定的所有图像都具有良好的质量。如果生成器在一个类中为所有类合成了各种各样但完美的图像，那么得分就会失败^[106]。

文献[107]研究表明基于生成式卷积网络的STGConvNet不仅可

以自动合成动态纹理，同时还可以合成声音。文献[108]介绍了利用任意一种预先训练的GAN将图像样本投影到潜在空间的技术，并给出了计算图。该方法以期望的输出为优化目标，虽然非常简单，但速度很慢^[109]。文献[110]提出了一种直接从数据中提取策略的通用框架，就好像它是通过反强化学习后的强化学习得到的一样。

2.3 粒子群（PSO）算法和遗传算法（GA）

2.3.1 PSO基本原理

PSO算法是一种基于社会心理学隐喻的种群随机启发式优化算法^{[111], [112], [113]}，它模拟鸟群在多维空间中为达到精确的目标而蜂拥到一个有希望的位置时的社会行为^[113]。PSO算法具有简洁、易于实现、不需要梯度信息、参数少、搜索速度快和效率高等优点^[114]，在连续优化问题和离散优化问题中都取得了良好的效果，特别是其自然实数编码特性更适合于求解实数优化问题^[115]。

与其他进化算法（例如GA或混合GA）一样，PSO使用从一个迭代更新到另一个迭代的个体种群来执行搜索^[113]。不同的是，PSO不会利用选择操作，所有种群成员（称为粒子）从试验开始到试验结束都可以存活，它们之间的相互作用导致其质量的迭代改进，量化为适应度值^[111]。此外，PSO算法具有广泛的全局寻优能力^[116]。针对任何问题，如果存在最佳解决方案，PSO通常会找到一个好的解决方案。

最初的PSO由Reynolds首次提出^{[117], [118]}，并由Kennedy和Eberhart模拟^[119]。PSO的主要目标是在搜索空间中搜索接近最佳解决方案的位置。在PSO算法中，种群称为群体，个体称为粒子^[113]，并且每个

粒子代表 d 维空间中问题的一种解决方案。因此，每个粒子代表搜索空间中的一个点。粒子数(N)由用户确定。粒子位置随机初始化^[112]，候选解初始化为与随机速度相关的粒子群^[120]，并根据目标函数对候选解进行迭代优化^[112]。在搜索空间中，每个粒子都跟踪它的坐标，这些坐标与到目前为止它所获得的最佳适应度 ($pbest$) 相关^[120]。为了找到最优解或近似最优解，每个粒子根据两种信息改变其搜索方向，即自身的最佳以往经验和整个群体的最佳以往经验。每个粒子都是优化问题的一个可能的解^[113]。自身的最佳以往经验由先前的最佳位置 (粒子达到最佳适应值的位置) 表示，该位置由下式表示：

$$P^{(t)}(i) = [P^{(t)}(i,1), \dots, P^{(t)}(i,d)]。$$

整个群体的最佳以往经验称为全局最佳位置 ($P(t)(g)$)，它表示具有最佳适应性值的粒子的位置，其中 g 表示群中所有粒子中最佳粒子的索引。

群是一组粒子，向种群中最适合的个体移动^[111]。一个粒子代表一个 \tilde{D} 维空间中的一个点，它的状态通过它的位置和速度来表征。粒子 i 在迭代 k 次时的位置可以用 \tilde{D} 维向量 $X_i^k = \{x_{i1}^k, x_{i2}^k, \dots, x_{i\tilde{D}}^k\}$ 表示^[113]；这个粒子的速度可以用另一个 \tilde{D} 维向量 $V_i^k = \{v_{i1}^k, v_{i2}^k, \dots, v_{i\tilde{D}}^k\}$ 来表示。利用优化问题的目标函数可以对每个粒子的适应度进行评价。在每一次迭代中，每个粒子都加速向以前的最佳位置和全局最佳位置运动^[116]。第 i 个粒子直到迭代 k 次记忆的最佳先前位置表示为：

$$PB_i^k = \{p_{i1}^k, p_{i2}^k, \dots, p_{i\tilde{D}}^k\},$$

整个群中的最佳位置表示为：

$$GB^k = \{g_1^k, g_2^k, \dots, g_{\tilde{D}}^k\}。$$

为了寻找最佳解，每个粒子根据以下两个公式更新其速度和位置：

$$v_{id}^k = \omega \cdot v_{id}^{k-1} + c_1 \cdot r_1 \cdot (p_{id}^{k-1} - x_{id}^{k-1}) + c_2 \cdot r_2 \cdot (g_d^{k-1} - x_{id}^{k-1})$$

(2.2)

$$x_{id}^k = x_{id}^{k-1} + v_{id}^k$$

(2.3)

$$i = 1, 2, \dots, n ; \quad d = 1, 2, \dots, \tilde{D}$$

其中， v_{id}^k 为第*i*个粒子第*k*次迭代中飞行速度的第*d*维分量； x_{id}^k 为第*i*个粒子第*k*次迭代中位置的第*d*维分量^[121]；式中，*d*为每个粒子的维数， c_1 ， c_2 为加速度正常数，用于控制最大步长，*k*为迭代次数， r_1 ， r_2 为两个随机数，范围为[0,1]， ω 为惯性权重因子，它控制粒子先前速度对当前速度的影响^[113]。通常 ω 从 ω_{max} 到 ω_{min} 随迭代次数的增加而线性减小：

$$\omega = \omega_{max} - T \times (\omega_{max} - \omega_{min}) / T_{max}$$

(2.4)

其中，*T*表示当前迭代次数， T_{max} 表示最大迭代次数。

在每一代中，每个粒子都会根据其当前速度、与先前最佳位置的距离以及与全局最佳位置的距离计算新的速度值。由式（2.2）可知，新速度是根据其以前的速度和当前位置到其最佳历史位置和整个种群的全局最佳位置的距离来更新的。然后使用新的速度值计算粒子在搜索空间中的下一个位置，即根据式（2.3），粒子移动到一个新的位置。重复这个过程，直到满足结束条件^[116]。图 2.2 为PSO算法的流程图^[122]。

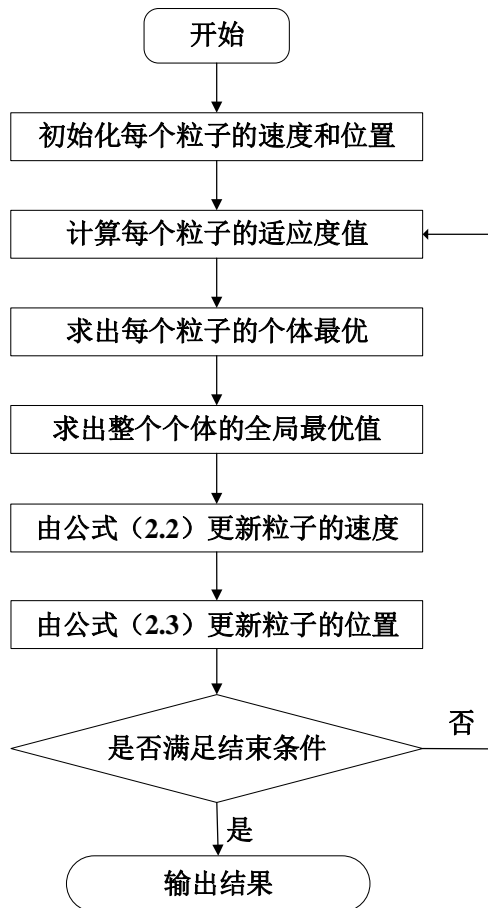


图 2.2 PSO算法流程图

2.3.2 PSO优化参数综述

所谓对神经网络参数的优化，就是寻找神经网络较好的网络连接权值和阈值，使得神经网络的全局误差最小化^[123]。选择良好的超参数可以看作是优化问题，通常是凸优化问题，其中模型的超参数是决策变量。要优化的成本是使用这些超参数进行训练所导致的验证集误差。超参数选择主要有两种方法：手动选择和自动选择^[111]。手动检索超参数假设存在对超参数如何影响模型结果的理解，相当于依靠人工经验或有限的（重复）试验来选择参数，并使其具有良好的泛化能力，这严重阻碍了深度神经网络（deep neural networks, DNN）的模型优化，而自动超参数选择方法大大减少了这种理解的需要，但传统

自动化方法的可扩展性差。超参数自动优化的所有方法都可以分为无模型方法和基于模型的方法^[111]。

此外，PSO算法用于调整反向传播（back propagation, BP）神经网络的权重取得了良好的效果。PSO作为一种新兴的进化算法，其收敛速度快、鲁棒性高、全局搜索能力强，且不需要借助问题本身的特征信息（如梯度）^[123]，早已广泛用于各类连续问题和离散问题的参数优化^{[114], [124]}。用GA来优化神经网络的参数，可以达到搜索的遍历性，但以增加迭代次数为代价，因此收敛速度比较慢。PSO算法应用到神经网络参数优化中既可以达到搜索的遍历性，又省去了GA算法中选择、交叉、变异等基本操作，在搜索速度和学习能力上得到了提高^[123]。

在PSO算法中，一组候选解（表示超参数值的元组）在时间上演化，以寻找可能的最佳DNN参数。大量的实验研究表明，PSO不仅能够优化神经网络的结构和参数（例如神经网络的中心参数^{[121], [125]}或权值^{[126], [127], [128], [129], [130], [131]}），从而提高神经网络的稳健性和预测精度^{[111], [114], [127], [128], [129], [130], [131]}，而且还可以显著地改进由经验丰富的从业者开发的现有模型^[111]。PSO算法用于神经网络优化中主要有两个方面：一是优化网络的拓扑结构^[123]；二是用于网络训练，用PSO算法优化网络各层之间的连接权值和阈值^{[123], [129], [131], [132]}。PSO比GA等其他算法能够更加有效地改善神经网络结构和参数的优化效率^{[125], [126]}。

将已有的DL网络与GAN和自我训练思想相结合，通过PSO算法

对超参数进行优化，使用更少的数据，便可获得比代表性监督学习更好性能的视网膜血管分割^[115]。GS通常仅在DNN超参数数量很少的情况下用于优化DNN超参数，并且通过使用超参数值的所有联合规范来训练底层DNN体系结构而起作用。然后，为每个DNN检索验证集错误，并获得最佳性能的超参数。这种方法的明显缺点是可扩展性差，搜索空间中每个维度的成本都呈指数级增长^[111]。随机搜索（random search, RS）对于实现GS的替代方案来说是微不足道的，使用起来更方便，收敛到可接受的参数也更快^[111]。尽管可以对RS添加不同的改进，但是它通常不是自适应的。

传统上通过反复实验来得到较好核参数的SVM核参数选择方法往往会造成较高的时间代价和对每一次实验结果进行人工选择而造成的人工浪费。基于PSO算法和BP神经网络的SVM参数选择方法克服了梯度法受最优搜索方向的限制，同时在神经网络的较强拟合能力和PSO优化能力的基础上可实现SVM核参数选优的较小时间代价^[133]。采用量子行为PSO算法对SVM的参数进行优化，可减小分类误差^[119]。

PSO能够有效估计Gamma-Poisson模型的参数，且不受样本容量的限制，计算复杂度也大大降低了^[112]。将蚁群算法与PSO算法相结合，提出了一种优化参数选择的方法。利用PSO算法寻找最优参数集，证明了蚁群算法在求解TSP（traveling salesman problem）问题上的良好性能^[134]。

正交动量型PSO算法结合FFD算法（first fit decreasing）能有效地解决大参数优化问题^[135]。文献[116]提出了一种基于PSO的SVM参数

优化模型。PSO一旦找到SVM的最优参数，就可以对模型进行优化。以历史负荷数据为训练数据，以预测误差为优化目标，将该模型应用于电力系统短期负荷预测。仿真结果表明，与单SVM模型相比，PSO-SVM模型在精度和效率上都有较大提高。该模型具有实用性和高效性，为电力负荷预测提供了一种新的方法。

文献[136]提出了一种利用PSO技术来确定非并行SVM（non-parallel support vector machine, NPSVM）参数的混合方法。此外，为了增加NPSVM的稀疏性和减少训练时间，该文献将支持向量的数量和分类精度作为加权目标函数。在多个公共数据集上的实验表明，该方法与TWSVM和NPSVM方法相比，具有更好的分类精度，且计算时间更短。文献[120]提出了一种基于PSO的高斯混合模型（gaussian mixture model, GMM）参数确定方法。PSO-GMM基于一种新的误差准则对GMM中的参数进行优化，该误差准则是基于真密度函数与估计密度的积分平方误差导出的。为了验证PSO-GMM算法的可行性和有效性，该文献对四种一维人工数据集：均匀数据集、正态数据集、指数数据集和瑞利数据集进行了数值实验。最终的比较结果表明，当为PSO选择适当的参数时，该文献策略性能良好，并且PSO-GMM可以获得更好的估计性能。

文献[137]提出了一种通过集成PSO优化的新型支持向量回归算法（support vector regression, SVR）。优化机制将离散值PSO与连续值PSO相结合，以优化输入特征子集选择和SVR内核参数设置。结合两种PSO算法，对SVR的参数和输入特征同时进行优化。文献[138]

针对PSO算法的早熟收敛问题，提出了自适应PSO（adaptive particle swarm optimization, APSO）。APSO算法使用总体多样性信息调整非线性惯性权重，引入速度突变因子和位置交换因子，明显提高了全局性能。将APSO算法应用于SVM优化模型参数优化，该文提出了一种基于APSO的SVM参数确定和特征选择方法，称为APSO+SVM。实例表明，APSO+SVM分类精度高于其他传统分类方法，因此采用APSO+SVM方法进行分类是可行和有效的。文献[139]提出了一种基于PSO的分类方法，即PSOBPN，以获得适合于反向传播网络（back propagation network, BPN）的参数设置，并选择有利于提高分类准确率的特征子集。该方法提高了大多数测试问题的分类准确率。

2.3.3 GA基本原理

GA是一种基于生物界规律和自然遗传机制的并行搜索算法。1975年，J.Holland教授首次在书中提出“自然组合人工智能系统的适应性”。GA是一种多参数，多组合同时优化方法，模拟自然进化过程中“自然选择，适者生存”的原则。其主要特征是群体间的搜索方法以及群体中个体信息的交换。GA非常适合解决传统搜索方法难以解决的非线性问题^[140]。

与旧的搜索算法不同，GA从种群的初始解决方案开始其搜索过程。群体中的每个个体被称为染色体。在迭代过程中染色体的不断更新称为遗传。GA主要通过交叉、变异、选择算子来实现。染色体的优点和缺点通常通过适应性来评估。根据适合度值的大小，从父母和后代中选择一定比例的个体作为后代的群体，然后继续迭代计算直到

它收敛到全局最佳染色体。适应度是GA用来评价种群在进化过程中所能达到最优值的一个概念。为了证明染色体的适应性，引入了测量每条染色体的功能函数，称为适应度函数^[140]。

GA的流程如图 2.3 所示。其主要组成部分包括^[140]：

(1) 编码方式。GA通常根据问题本身进行编码，并将问题的有效解决方案转化为GA的搜索空间。工业中常用的编码方法包括实数编码，二进制编码，整数编码和数据结构编码。

(2) 适应度函数。适应度函数，也称为目标函数，是对整个个体与其适应度之间的对应关系的描述。具有高适应性的个体中包含的高质量基因具有较高的传递给后代的概率，而具有低适应性的个体的遗传概率较低。

(3) 遗传操作。基本的遗传操作包括：选择、交叉、变异。

a) 选择。选择操作基于个体适应度评估，选择群体中具有较高适应度的个体，并且消除具有较低适应度的个体。当然不同的选择操作也会带来不同的结果，有效的选择操作可以显著的提高搜索的效率和速度，减少无用的计算量。

常见的选择方法有：基于比例的适应度分配方法，期望值选择方法，基于排名的适应度分配方法，轮盘赌选择方法等。

b) 交叉。在自然界生物进化过程中，两条染色体通过基因重组形成新的染色体，因此交叉操作是遗传算法的核心环节。交叉算子的设计需要根据具体的问题具体分析，编码操作和交叉操作互相辅助，交叉产生的新的个体必须满足染色体的编码规律。父代染色体的优良

性状最大程度上遗传给下一代染色体，在此期间也能够产生一些较好的性状。

常见的交叉算子包括实质重组，中间重组，离散重组，线性重组，二进制交叉，单点交叉，均匀交叉，多点交叉和减少代理交叉。

c) 变异。通过随机选择的方法改变染色体上的遗传基因。变异本身可以被视为随机算法，严格来说，是用于生成新个体的辅助算法。

几个与浮点数编码和二进制编码个体匹配的交叉运算：单点交叉，均匀交叉，算术交叉，两点交叉和多点交叉。

(4) 算法终止条件。算法终止一般指适应度函数值的变化趋于稳定或者满足迭代终止的公式要求，也可以是迭代到指定代数后停止进化。

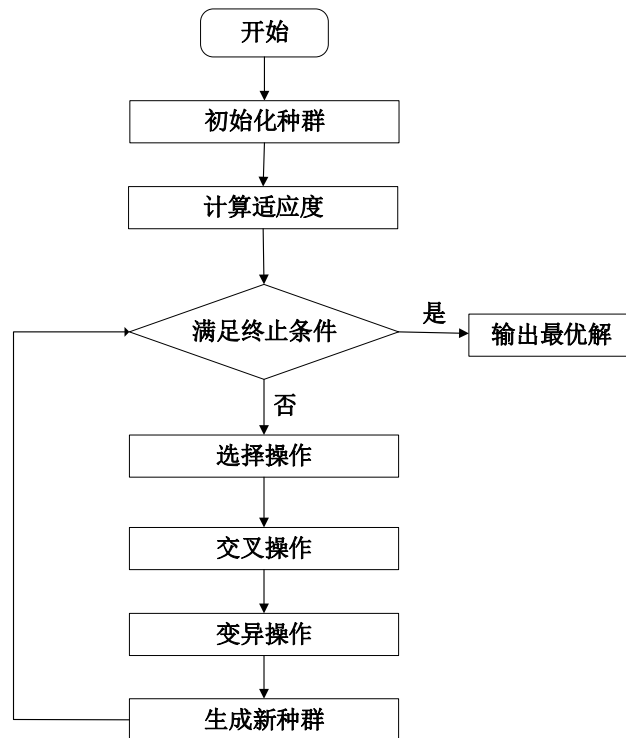


图 2.3 GA流程图

2.3.4 GA优化参数综述

文献[141]针对某地区的短期电力负荷预测，通过GA对SVM参数进行自动搜索和确定，提高了SVM的预测精度。针对SVM三个关键参数（核函数类型、核函数参数及错误惩罚因子）的优选问题，文献[142]提出一种基于GA的SVM参数组合优化技术，能够实现同时对三个参数组合的优化，在UCI标准数据库上的实验结果说明了提出方法的有效性。

为提高SVM的分类性能，文献[143]提出了一种小生境GA参数优化SVM的方法，并将其应用于滚动轴承的故障诊断中，提高了分类的准确率。针对SVM参数很难确定的问题，文献[144]通过改进的遗传操作（选择、交叉、变异）对SVM的参数进行优化，从而得到SVM的最佳参数，接着用取得最佳参数的SVM进行葡萄酒种类的识别，优化之后获得的SVM准确率明显好于没有经过优化的SVM，克服了人为选取SVM参数的随意性。

下面介绍本报告所做的理论工作：设置GAN网络架构；描述PSO和GA优化GAN参数的流程。

2.4 GAN模型架构搭建

GAN模型的基本框架如图 2.1 所示。本报告生成器 G 的模型包含 6 层网络结构。在GAN中， G 的参数更新不是直接来自于数据样本，而是来自于判别器 D 的反向传播，因此，GAN往往可以生成比其他模型更接近真实数据的样本。本报告采用的GAN的 G 和 D 层次结构分别如表 2.1 和表 2.2 所示。该 G 和 D 模型共有 5 层卷积层（Conv），每一

层卷积层都使用LeakyRelu激活层，之后连接全连接层（FC）， D 最后经过Sigmoid层输出置信度。 D 以 G 生成的样本与真实样本作为输入，输出的值是置信度。若置信度值大于 0.5，则判定该输入样本为真实样本。

表 2.1 G 模型参数

	Layers	Size
1	Conv	$N_IDEAS \times 64$
2	Conv	64×64
3	Conv	64×64
4	Conv	64×64
5	Conv	64×64
6	FC	$64 \times ART_COMPONENTS$

表 2.2 D 模型参数

	Layers	Size
1	Conv	$ART_COMPONENTS \times 128$
2	Conv	128×128
3	Conv	128×128
4	Conv	128×128
5	Conv	128×128
6	FC	128×1
7	Sigmoid	-

2.5 PSO和GA优化GAN参数

2.5.1 PSO优化GAN参数

将GAN参数（ r_G 、 r_D 和 B ）所取范围的值编码成实数向量来表示种群中的个体；随机生成这些向量的群体，接着按照PSO算法原步骤（图 2.2）迭代；迭代中新生成的个体向量还原为GAN参数值，计算所有样本通过GAN产生的平均相对误差（这一步骤等同于PSO算法中计算粒子的适应度），如果误差小于系统指定的误差精度，则训练过程停止，否则迭代继续进行，直到达到最大迭代次数。

可见，对于给定的GAN网络结构，只需对GAN参数进行编码，将其映射为码串所表示的个体，同时将训练中产生的平均相对误差作为评价个体的适应函数，此时神经网络的训练就可转化为寻找一组使误差最小的最佳参数值的优化问题，整个算法的具体流程如图 2.4 所示。

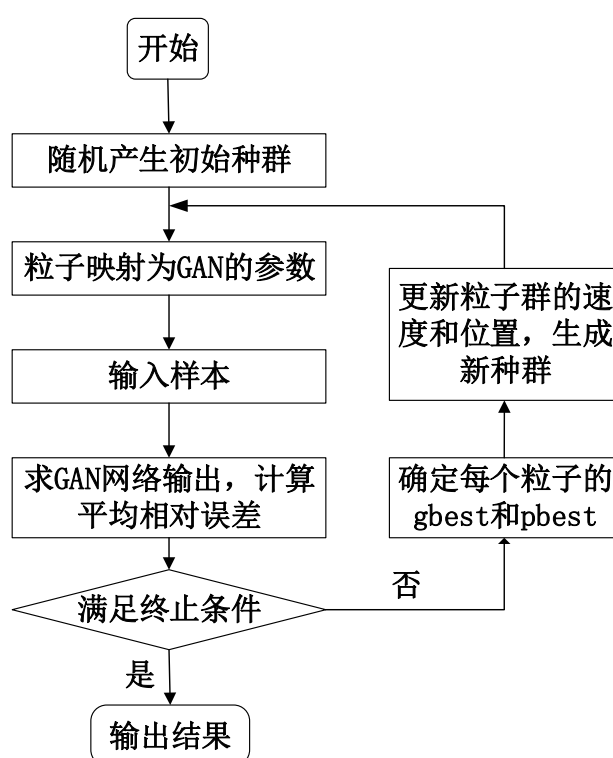


图 2.4 PSO算法优化GAN参数流程图

2.5.2 GA优化GAN参数

从 2.3 节中了解到了GA的全局搜索能力和GAN网络易陷入局部极小值的不足，本报告结合这两种算法，采用GA优化GAN的三个参数 (r_G , r_D 和 B)，充分发挥两者的优点，以实现更精确的数据生成。设计的GA优化GAN参数的具体步骤为：(a) 根据GAN网络结构决定参数的编码方案，生成初始群体；(b) 分别使用不同的初始化参数值

训练个体集中的结构；(c) 通过训练结果对每个个体的适应度进行分辨，并筛选出多个适应度较高的个体直接进入下一代；(d) 对当前筛选出的群体采取遗传操作，通过交叉、变异等方法生成新的群体；(e) 循环重复步骤 (b) ~步骤 (d)，直到满足终止条件（达到设定的最大迭代次数），结束整个优化步骤。

按照上述步骤设计的GA优化GAN参数算法流程图如图 2.5 所示。当遗传进化到某一代中出现个体的适应度达到要求或遗传进化到预定的最大代数后，迭代结束。将GA得到的最优种群个体赋给GAN，作为初始参数。

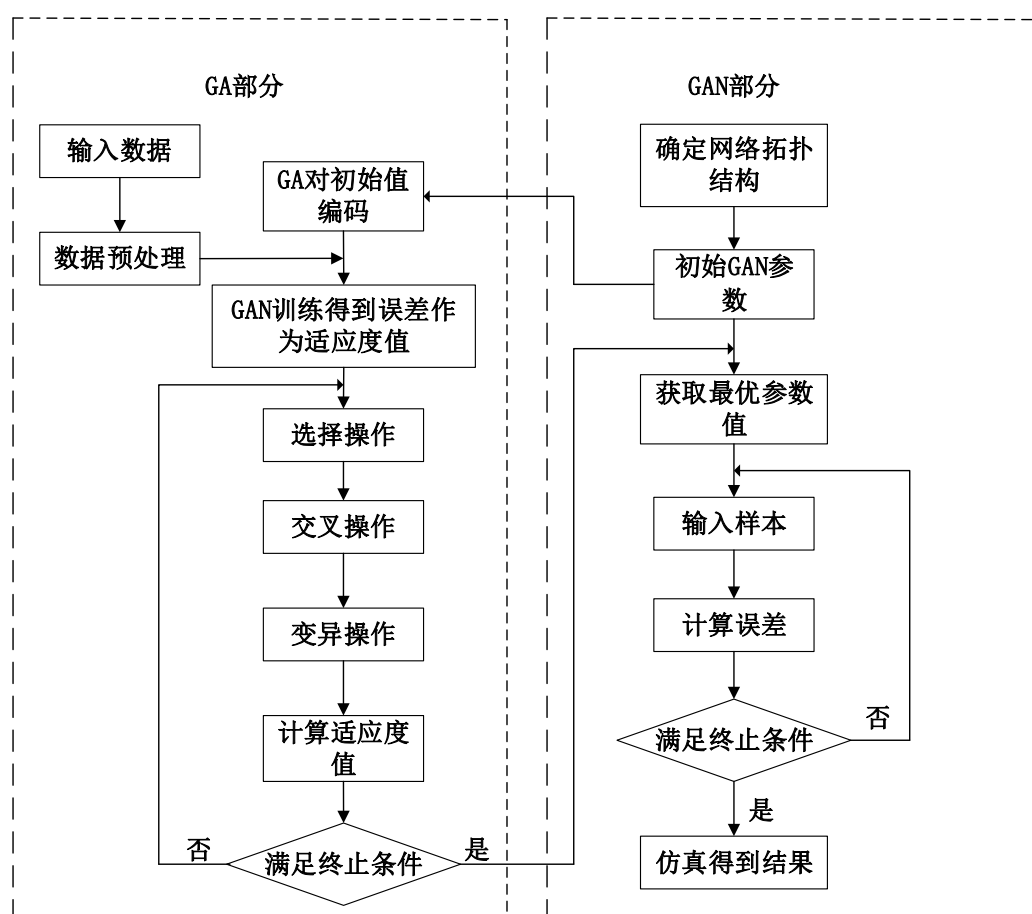


图 2.5 GA优化GAN参数流程图

本报告数值仿真环境为：Intel(R) Xeon(R) Silver 4114 CPU @

2.20GHz, 20 GB内存, 0.8 GB活动内存。整体模型在Pytorch深度学习框架中进行编程实现。以下章节将在前文所述的应用场景中分别进行仿真研究。

2.6 本章小结

本章首先对GAN, PSO和GA的基本原理进行了阐述, 接着对本报告中所要研究的GAN架构进行了搭建, 然后详细描述了本报告采用PSO和GA对GAN参数进行优化的流程, 为后文中的应用奠定了理论基础。

第三章 故障电机振动信号应用

3.1 背景介绍

一般来说，滚动轴承是机械设备中最重要的部件之一。由于轴承结构和工作条件的复杂性，轴承极易损坏，造成巨大的损坏甚至人员伤亡。因此，对滚动轴承故障进行监测和诊断是一项重要的任务。故障振动信号能快速、真实、全面地反映机械故障的性质和范围。由于实际工况和数据采集设备的原因，采集到的轴承工作数据实际上是有限的。同时，由于滚动轴承大部分时间处于正常工作状态，容易出现故障类型不平衡问题，制约了诊断的准确性和稳定性^[145]。

针对轴承故障诊断中的数据不平衡问题，从数据和算法两个方面进行了大量的研究工作。从数据角度来看，Chawla等人^[48]提出了一种合成少数过采样技术SMOTE，通过随机插入虚拟样本来平衡训练集。在这种情况下，合成样本的质量可能不足以为不平衡故障诊断提供有用的信息。因此，Ramentol等人^[46]提出了一种基于粗糙集理论的改进SMOTE算法对少数样本进行过采样。Gao等人^[47]将SMOTE与PSO优化和RBF分类器相结合，提高了少数样本的重要性。Mao等人^[48]提出了一种基于主曲线的少数样本过采样和多数样本欠采样的方法。从算法的角度来看，目前的工作主要是对传统算法结构进行改进或利用数据特征设计新的算法。Jia等^[49]提出了一种深度归一化卷积神经网络和神经元激活最大化算法用于不平衡故障分类。针对数据不平衡问题，Yin^[150]提出了一种核函数线性判别分析方法。Sun等人^[151]在

AdaBoost学习框架中增加了一个成本项来调整少数样本的权重。利用类似的思想，Xiong等^[152]通过一种局部聚类集成学习方法改进了用于少数类分析的AdaBoost框架。

这些方法虽然取得了良好的效果，但仍存在一些不足，其中之一就是适应性差，无法自动学习样本的数据分布特征。随着DL技术的快速发展，2014年由Goodfellow等^[31]首先提出的GAN在计算机视觉^[153]、文本分析^[154]等领域受到广泛关注。GAN能够学习原始样本的数据分布特征，然后生成具有相似分布的新合成样本，有效解决了由于样本获取难度与成本等因素导致的数据量不足的问题^[155]。文献[145]利用故障样本的频谱数据作为GAN的输入，根据真实样本的数据分布生成样本。但GAN参数的选取是依据经验，具有一定的随机性，而GAN参数的选取对合成样本的有效性会有一定的影响。

3.2 研究内容

为了获取更多有效的故障样本数据，增加样本的多样性，为后续故障诊断研究提供基础，本章采用第二章中提出的基于PSO和GA优化GAN参数的训练样本生成算法对故障样本数据进行训练生成。该方法通过交替训练改进GAN的生成模型与判别模型，无需先验知识的指导，自主学习原始样本的分布规律，生成新的故障电机振动数据。基于PSO和GA优化GAN参数的算法流程如图 2.4 和图 2.5 所示。本章所研究的故障电机单通道振动信号原始数据来源于网络，网址为：

https://download.csdn.net/download/qq_24598387/10739131

3.3 算值仿真

3.3.1 参数设置

本实验中PSO参数设置如下：学习因子 c_1 和 c_2 分别随迭代次数的增加而线性减小和增加。 $c_{min} = 1.4$, $c_{max} = 2.5$; $\omega_{min} = 0.3$, $\omega_{max} = 1.0$, 粒子数为 100, 最大迭代次数为 100。

GA参数设置如下： $n = 100$; $p_c = 0.7$; $p_e = 0.5$; $p_m = 0.02$; 最大迭代次数为 100。其中 n 表示种群规模， p_c 表示交叉概率， p_e 表示交换概率， p_m 表示变异概率。

在本章所述的参数优化仿真过程中，GAN的参数 r_G 、 r_D 和 B 是优化的对象。GAN的迭代次数为 10000 次。实验中采用Adam作为优化工具，根据训练数据迭代更新神经网络权值，使 G 和 D 的损失最小。以平均相对误差为目标函数，基于PSO算法和GA优化GAN参数生成数据，通过最小化目标函数得到最优参数组合。GAN参数的取值范围如表 3.1 所示。

表 3.1 GAN参数范围

参数	r_G	r_D	B
取值范围	[0.000001, 0.01]	[0.0000001, 0.01]	[100, 200]

3.3.2 仿真结果

利用优化后的参数得到改进的GAN来生成数据。为了进行比较分析，将PSO算法与GA进行了参数优化比较。除上述两种优化方法外，还对GAN参数值取随机数（random number, RN）来生成数据。结果见表 3.2 所示。

表 3.2 优化结果

	PSO	GA	RN
r_G	0.000216	0.000426	0.004685
r_D	0.000022	0.000064	0.000563
B	198	168	156
ERR (%)	1.66	8.70	17.35
$TIME$ (s)	143658.6	268759.6	25679.8

从表中可以看出，在所研究的数据场景中，PSO优化GAN参数的生成误差最小，其次是GA优化方法和RN方法。从时间消耗来看，RN方法的运行时间远小于PSO和GA方法，但RN方法的误差最大，PSO方法的运行时间小于GA方法。

图 3.1 和图 3.2 分别是用PSO和GA优化GAN参数生成数据的结果；图 3.3 是随机取GAN参数值生成数据得到的结果。纵坐标A表示振幅，通常振幅或功率谱以对数单位分贝（dB）的形式显示。红线代表真实数据，绿线代表G生成的数据，从图 3.1 和图 3.2 可以看出，经过 5000 次迭代，G已经学习到了实际样本的近似分布，但是生成的数据与实际样本的偏差很大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO优化方法的优化结果明显优于GA方法和RN方法。

图 3.4、图 3.5 和图 3.6 是PSO优化GAN生成数据的收敛性和误差随迭代次数的变化图。从图 3.4 可以看出，判别概率在迭代次数达到 2000 次之后收敛到 0.5；在迭代次数为 6000 次到 7000 次之间时，出现小的波动，表明训练还没有稳定，迭代 7000 次后，模型稳定下来，判别概率保持在 0.5，即表示真假样本难以区分，训练成功。从图 3.5 可以看出，D的得分在迭代次数达到 2000 次之后逐渐收敛到-1.38，

表明训练收敛性良好。图 3.6 表明随着训练次数的增加，平均相对误差有逐渐减小的趋势，这从图 3.4 中也可以看出，随着迭代次数的增加，生成的数据与真实数据的总体差距越来越小。由以上分析可知 PSO 优化 GAN 的收敛性良好。

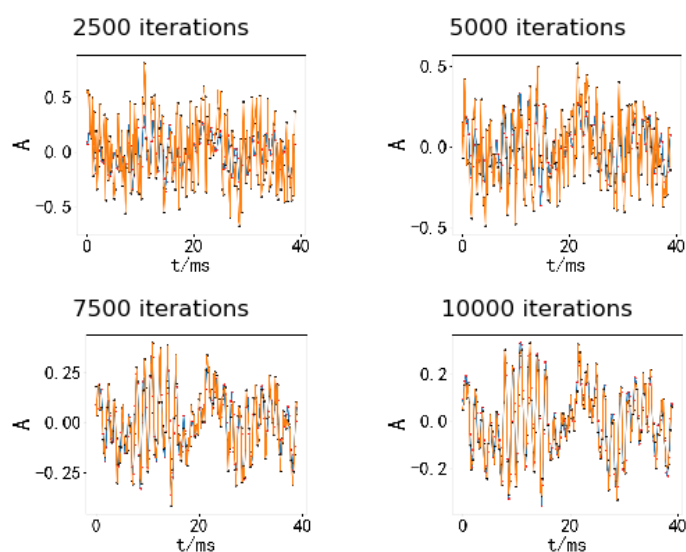


图 3.1 PSO 优化 GAN 参数

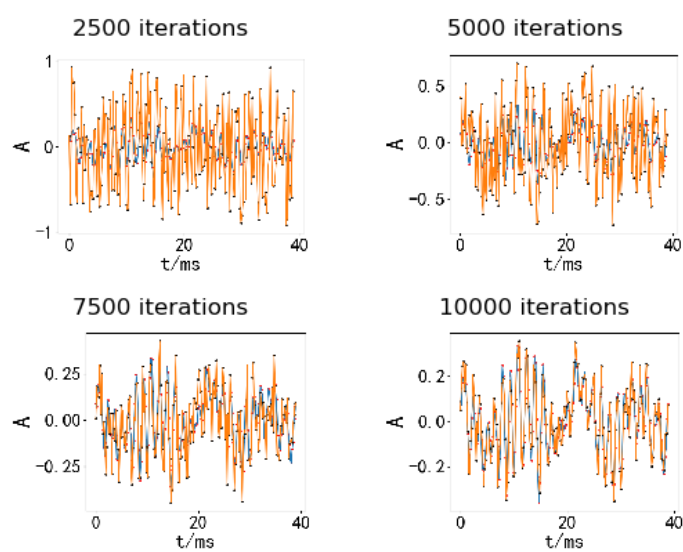


图 3.2 GA 优化 GAN 参数

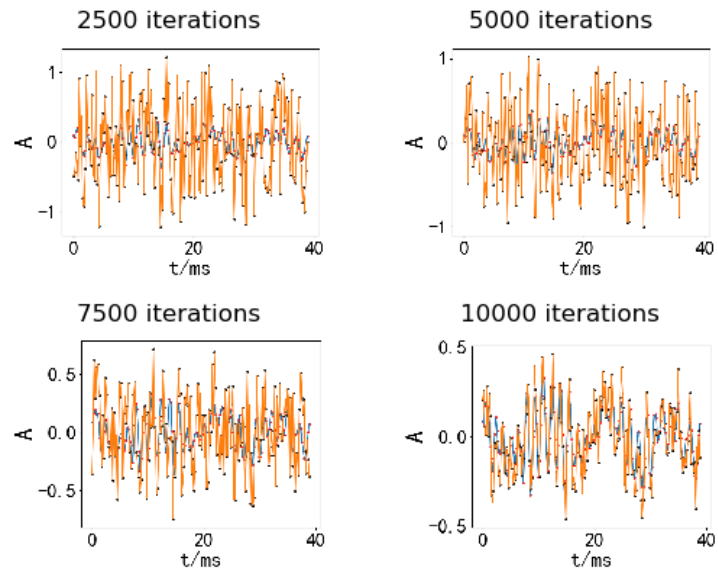


图 3.3 GAN参数随机取值




图 3.4 PSO优化GAN判别概率曲线




图 3.5 PSO优化GAN D 的得分




图 3.6 PSO优化GAN平均相对误差

3.4 本章小结

本章采用PSO算法和GA对GAN的参数 (r_G 、 r_D 和 B) 进行优化, 生成故障电机的单通道振动信号数据。此外, 还使用随机获取GAN

参数值的方法来生成这些数据。结果表明，PSO优化参数不仅在时间消耗上，而且在数据生成精度上都明显优于GA，由于随机参数法的盲目性，很难控制GAN生成数据的精度，而且生成误差往往较大，建议不要使用这种方法。PSO优化GAN参数生成数据的收敛曲线和误差曲线也表明PSO优化方法具有良好的收敛性。今后的研究将把合成的样本放入训练集中，建立叠层去噪自动编码器故障诊断模型。

第四章 单相及三相短路接地故障应用

4.1 背景介绍

近年来，随着改革开放的深入，国民经济得到飞跃发展，工业用电和生活用电均对电力系统的可靠性提出了新的要求。优质、稳定、可靠的电力供应已成为我国经济发展的基础之一。然而，由于自然环境、电器老化、人为等多种因素，电力系统中的设备会不可避免发生故障，从而造成局部供电中断，影响供电质量。为减少电力系统因故障所带来的不利影响，并及时识别故障的种类，国内外科研工作者利用多种技术开发了电力系统故障识别、诊断系统，主要技术有：专家系统、不确定性推理、粗糙集理论、模糊集理论等^[156]。这些技术均可提高故障的识别率。但数据采集的规模受到模拟电压故障数据的软件（如PSASP）或硬件计算能力的限制。目前，大多数方法都采用基于模型的方法^{[157], [158], [159], [160]}来生成数据。首先从历史数据中拟合一个显式的概率模型，然后对其进行抽样以生成新的情景^{[161], [162], [163], [164], [165]}。其中一些方法可能还需要对数据进行预处理。例如，ARMA模型可能要求输入的数据是高斯分布的，因此通常需要进行预处理。

然而，尽管有这些巨大的进步，数据生成仍然是一个具有挑战性的问题。非线性和有界功率转换过程，以及复杂的时空相互作用，使得基于模型的方法难以应用和难以规模化，特别是当考虑多个可再生能源发电厂时。这些模型通常是基于统计假设构建的，这些假设在实践中可能不成立或难以测试，并且从高维分布（或非高斯分布）中进

行采样也是非常重要的^[166]。此外，其中一些方法依赖于某些概率预测作为输入，这可能会限制生成情景的多样性，并低估可再生资源的整体可变性。

为了克服这些困难，在本章中提出了一个数据驱动（或无模型）的方法，即利用GAN的机器学习概念来完成数据生成的任务^[31]。生成模型可以利用大量未标记的训练数据，已成为计算机视觉和机器学习领域的研究前沿。应用此类方法有两个主要好处。首先，它们可以根据历史数据直接生成新的场景，而无需明确指定模型或拟合概率分布。第二，他们使用无监督的学习，避免了繁琐的手工标注，而这些标注对于大型数据集来说有时是不可能的。在图像处理领域，与其他方法相比，GAN能够生成质量更好的真实图像^{[31], [93], [95]}。

4.2 研究内容

针对电压故障的数据扩充问题，本章以单相和三相短路接地故障的母线电压故障前正常数据和发生故障后数据为应用背景，采用第二章中所描述的PSO和GA优化GAN参数的流程进行数据生成，并比较分析了PSO优化GAN参数、GA优化GAN参数和随机取GAN参数（RN）的结果。

4.3 单相短路故障算例应用

4.3.1 数据来源

本节所研究的单相短路故障数据是通过电力仿真软件PSASP仿真所得。36节点单线图如图4.1所示。采用电力系统分析综合程序（PSASP）对母线20与母线16之间50%的单相接地短路故障进行仿

真。支路AC30 的电压曲线如图 4.2 所示，这是本节的研究对象。由于短路接地故障发生在电压突变的 1 秒，将采用分段生成的方法，即分别生成故障前的正常数据（图 4.3）和故障后的数据（图 4.4）。

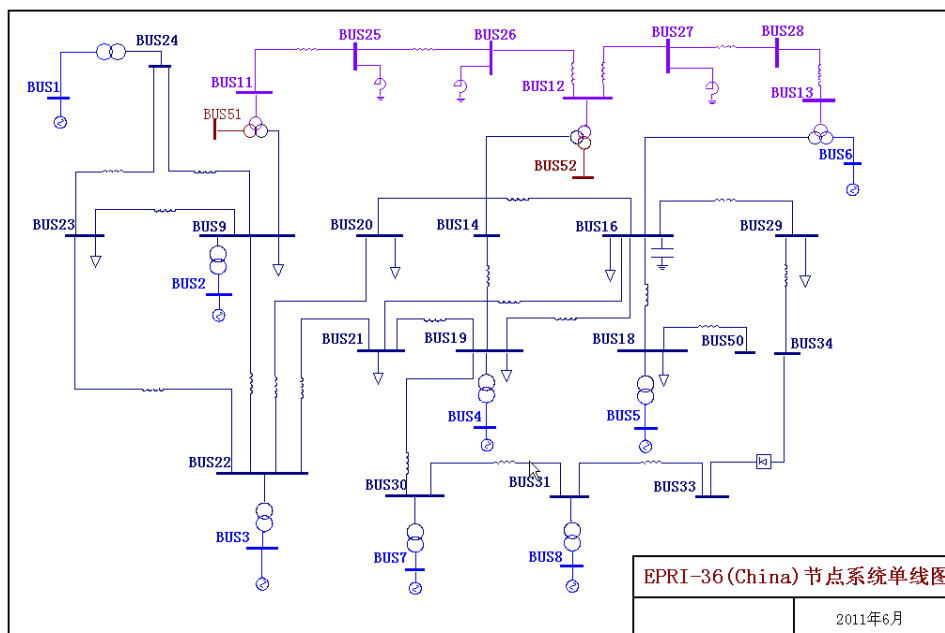


图 4.1 36 节点单线图




图 4.2 支路AC30 的电压曲线




图 4.3 故障前正常数据




图 4.4 故障后数据

下面将在此数据场景下，采用第二章中所描述的PSO和GA优化GAN参数的流程进行数据生成。

4.3.2 参数设置

本实验中PSO参数设置如下：学习因子 c_1 和 c_2 分别随迭代次数的

增加而线性减小和增加。 $c_{min} = 1.4$, $c_{max} = 2.5$; $\omega_{min} = 0.1$, $\omega_{max} = 0.9$, 粒子数为 100, 最大迭代次数为 100。

GA参数设置如下: $n = 100$; $p_c = 0.8$; $p_e = 0.5$; $p_m = 0.1$; 最大迭代次数为 100。其中 n 表示种群规模, p_c 表示交叉概率, p_e 表示交换概率, p_m 表示变异概率。

在本章所述的参数优化仿真过程中, GAN的参数 r_G 、 r_D 和 B 是优化的对象。GAN的迭代次数为 10000 次。实验中采用Adam作为优化工具, 根据训练数据迭代更新神经网络权值, 使 G 和 D 的损失最小。以平均相对误差为目标函数, 基于PSO算法和GA优化GAN参数生成数据, 通过最小化目标函数得到最优参数组合。

4.3.3 生成正常数据

共有 100 个正常数据, 随机取其中 80%的样本数据作为训练集, 剩余部分样本作为测试集。GAN参数的设定范围见表 4.1 所示。优化后的结果见表 4.2。

表 4.1 GAN参数取值范围

参数	r_G	r_D	B
取值范围	[0.00001, 0.01]	[0.000001, 0.01]	[64, 100]

表 4.2 优化结果

	PSO	GA	RN
r_G	0.000197	0.000253	0.0003345
r_D	0.000025	0.000032	0.0000526
B	75	90	82
ERR (%)	1.38	9.56	26.88
TIME (s)	113928.9	182783.5	27895.5

从表中可以看出, 在所研究的数据场景中, PSO优化GAN参数生成数据的误差最小, 其次是GA优化方法和RN方法。从时间消耗来看,

RN方法的运行时间远小于PSO和GA方法，但RN方法的误差最大，PSO方法的运行时间小于GA方法。

图 4.5 和图 4.6 分别为PSO和GA优化GAN参数生成数据的结果。图 4.7 是随机取GAN的参数值得到的结果。红线代表实际数据，绿线代表G生成的数据，从图 4.5 和图 4.6 可以看出，经过 5000 次迭代，生成器已经学习到了实际样本的近似分布，但是生成的数据与实际样本的偏差比较大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO优化GAN参数生成数据的结果明显优于GA和RN方法的结果。图 4.8、图 4.9 和图 4.10 是PSO优化GAN参数生成数据的收敛性和误差随迭代次数的变化图，由图可知收敛性良好。

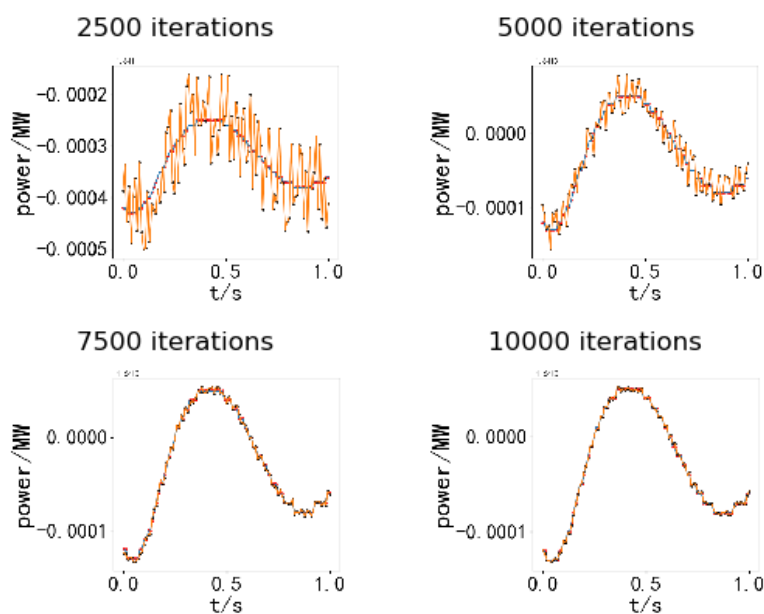


图 4.5 PSO优化GAN参数

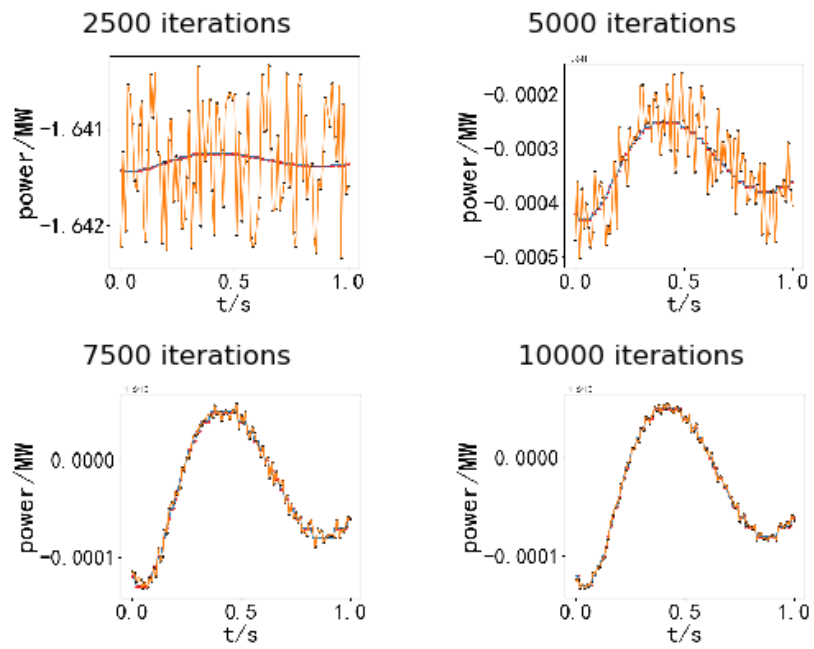


图 4.6 GA优化GAN参数

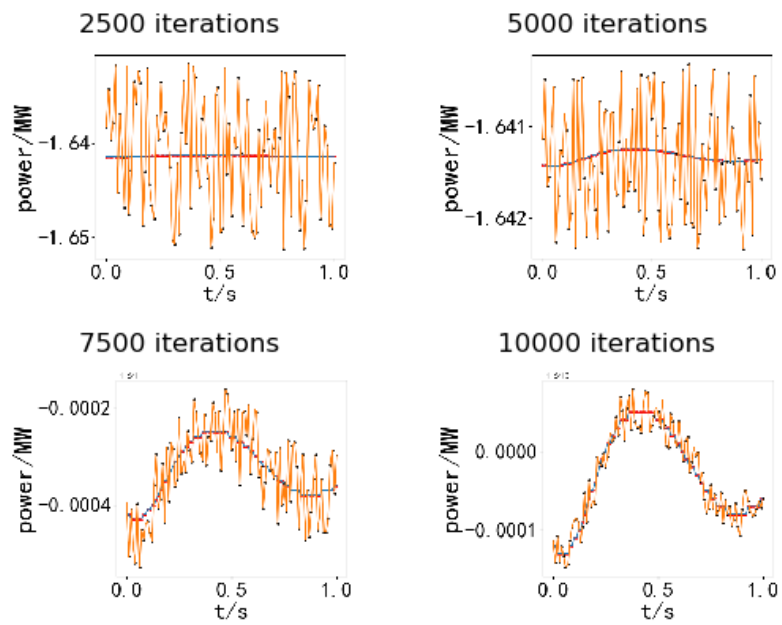


图 4.7 GAN参数随机取值

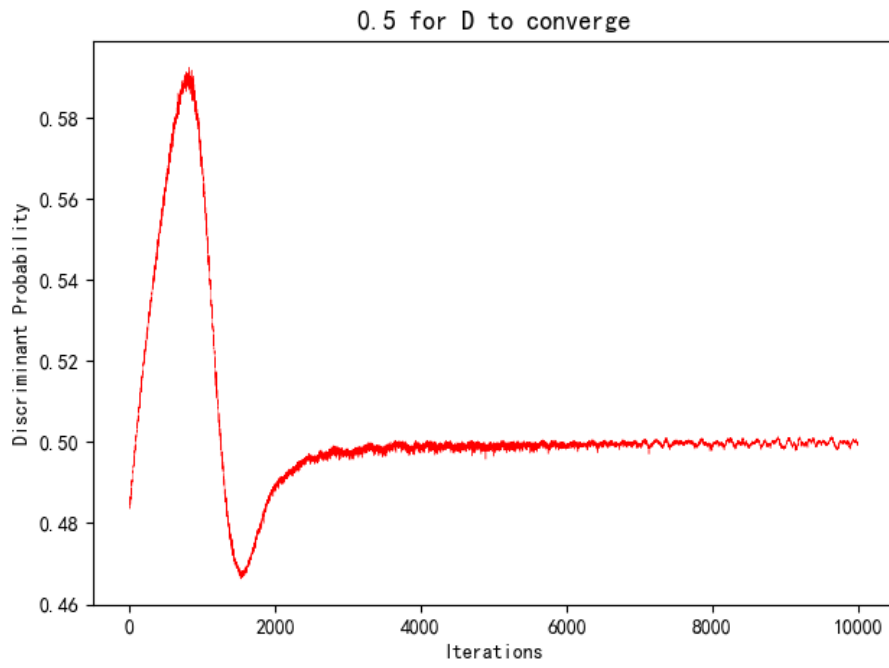


图 4.8 PSO优化GAN判别概率曲线




图 4.9 PSO优化GAN D的得分




图 4.10 PSO优化GAN平均相对误差

4.3.4 生成故障后数据

共有 900 个正常数据，随机取其中 80% 的样本数据作为训练集，剩余部分样本作为测试集。GAN参数的设定范围见表 4.3 所示。

表 4.3 GAN参数取值范围

参数	r_G	r_D	B
取值范围	[0.00001, 0.01]	[0.000001, 0.01]	[450, 900]

结果见表 4.4 所示。从表中可以看出，在所研究的数据场景中，PSO优化GAN参数生成数据的误差最小，其次是GA优化方法和RN方法。从时间消耗来看，RN方法的运行时间远小于PSO和GA方法，但RN方法的误差最大，PSO方法的运行时间小于GA方法。

表 4.4 优化结果

	PSO	GA	RN
r_G	0.000238	0.000261	0.0000968
r_D	0.0000243	0.0000286	0.0000976
B	824	887	684
ERR (%)	2.49	12.38	30.65
TIME (s)	526842.6	569376.5	62928.7

图 4.11 和图 4.12 分别是PSO和GA优化GAN参数生成数据的结果。图 4.13 是随机取GAN的参数值得到的结果。红线代表真实数据，绿线代表G生成的数据，从图 4.11 和图 4.12 可以看出，经过 5000 次迭代，生成器已经学习到了真实样本的近似分布，但是生成的数据与真实样本的偏差还是比较大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO优化方法的优化结果明显优于GA方法和RN方法（图 4.13）。图 4.14、图 4.15 和图 4.16 是PSO优化GAN参数生成数据的收敛性和误差随迭代次数的变化图，由图可知收敛性良好。

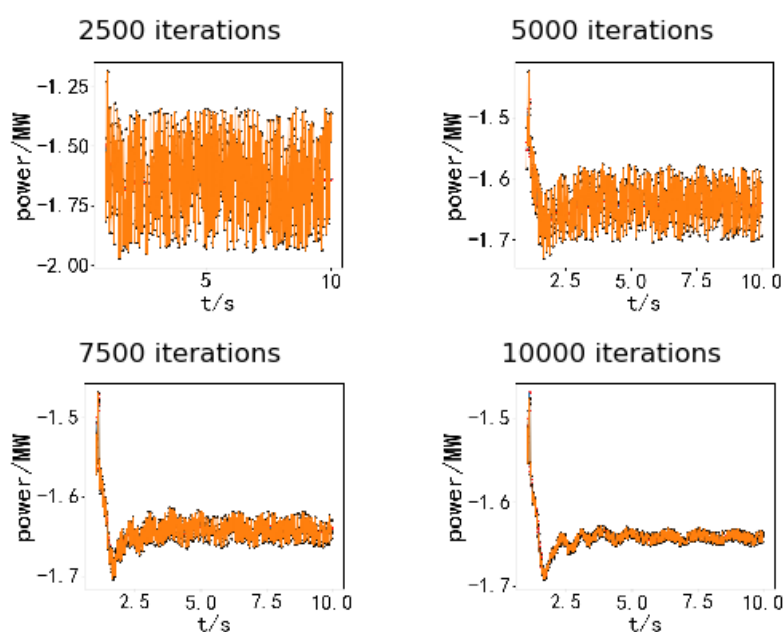


图 4.11 PSO优化GAN参数

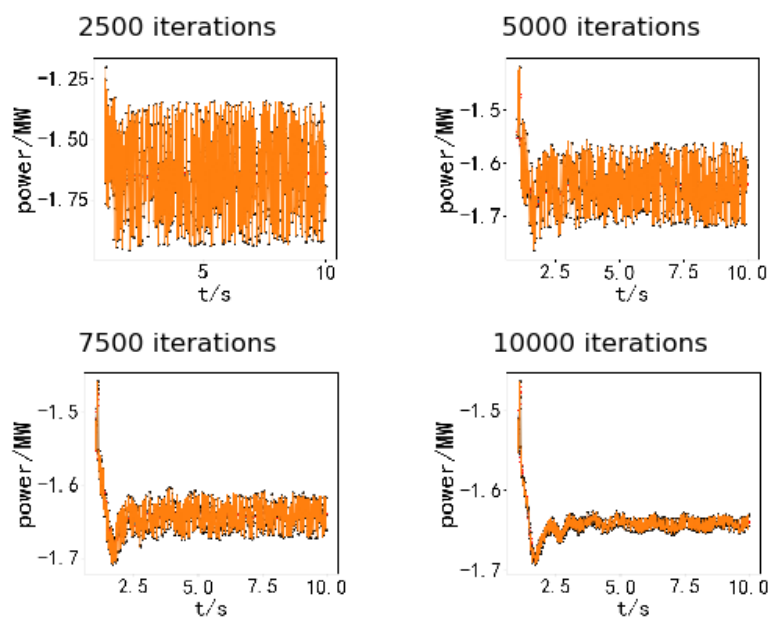


图 4.12 GA优化GAN参数

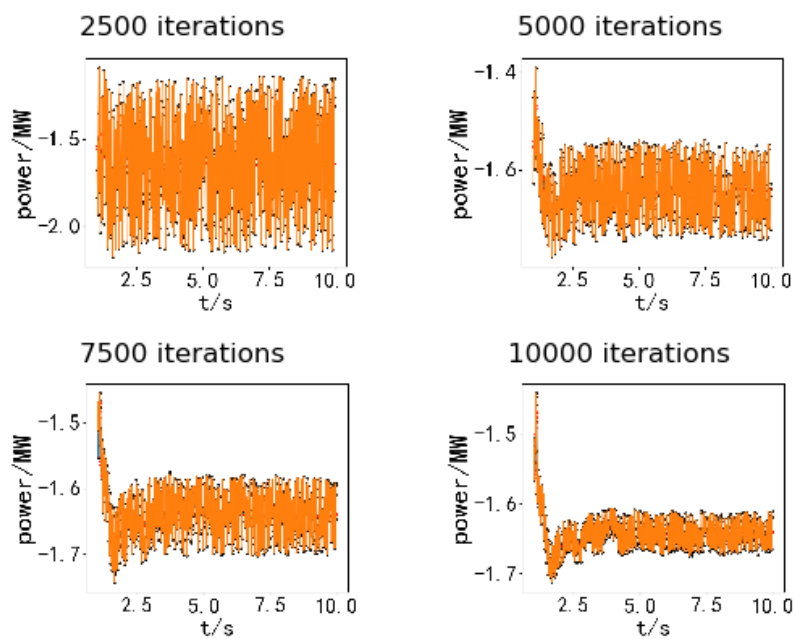


图 4.13 随机取GAN参数




图 4.14 PSO优化GAN判别概率曲线

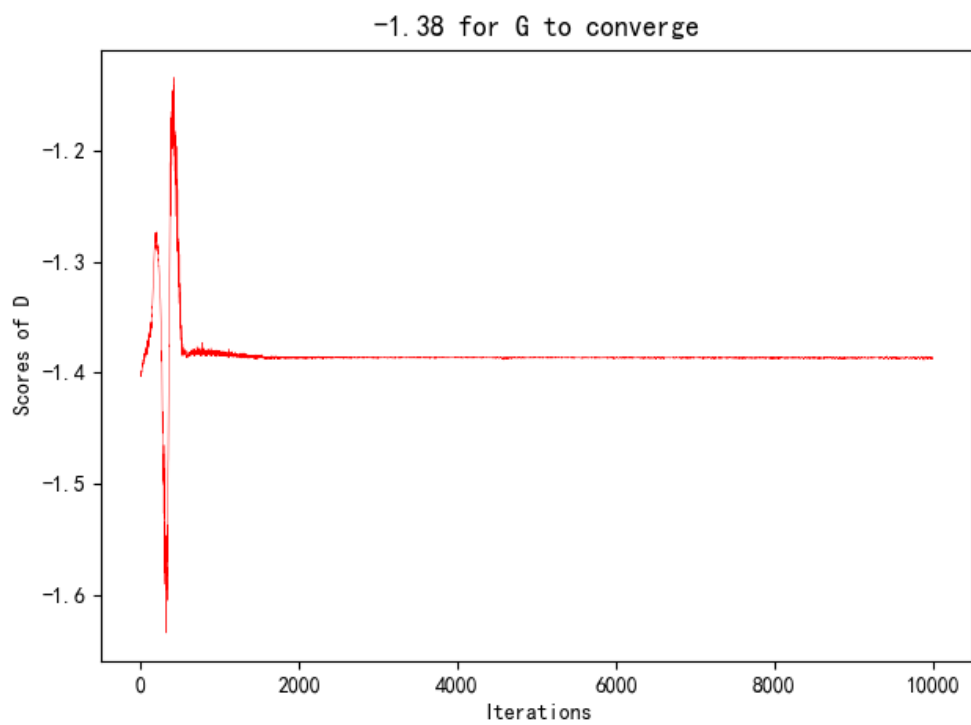


图 4.15 PSO优化GAN D的得分

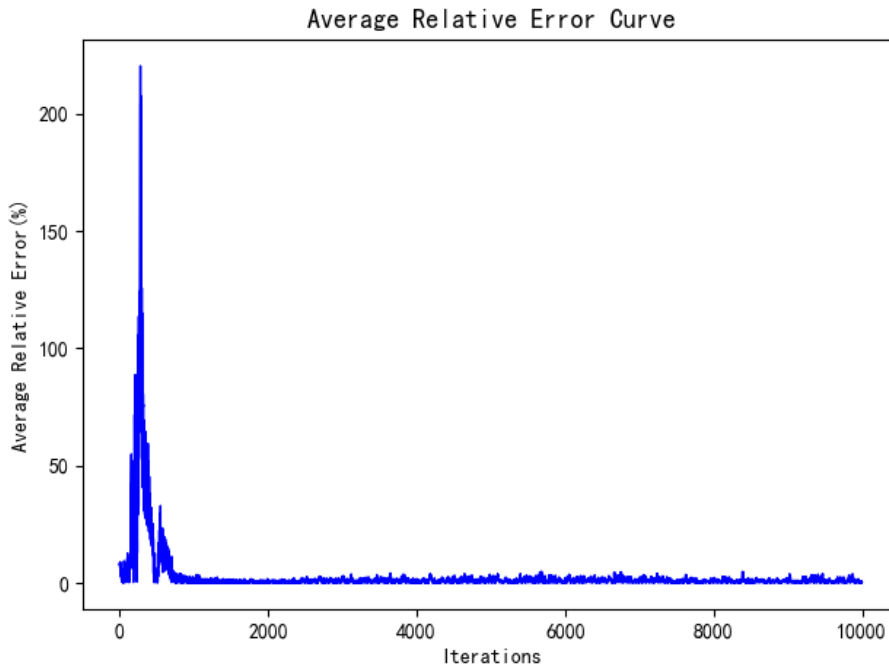


图 4.16 PSO优化GAN平均相对误差曲线

4.4 三相短路故障算例应用

4.4.1 数据来源

本节所研究的三相短路故障数据是通过电力仿真软件PSASP仿真所得。36节点单线图如图 4.17 所示。

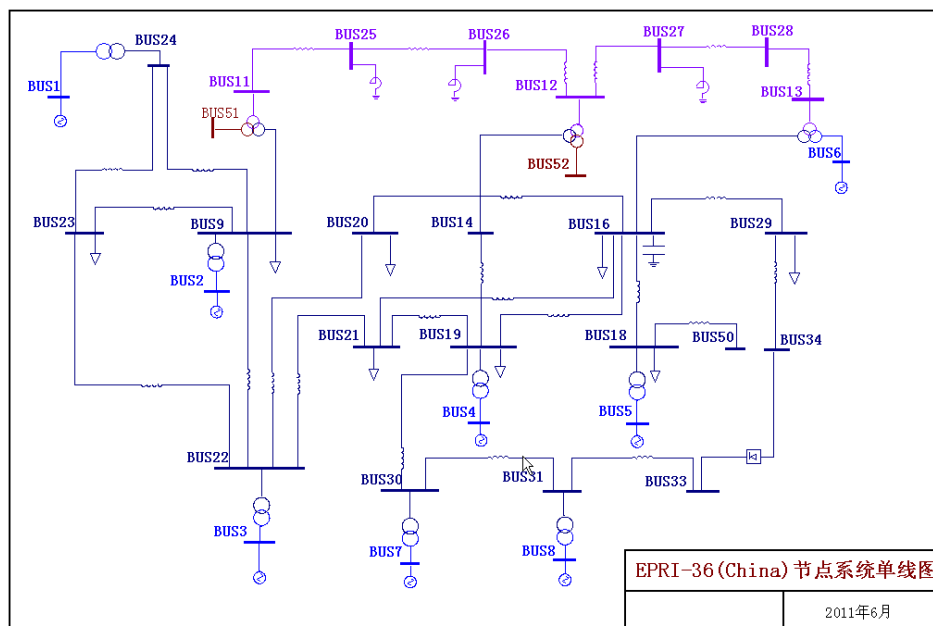


图 4.17 36 节点单线图

采用电力系统分析综合程序 (PSASP) 对母线 20 与母线 16 之间 50% 的三相接地短路故障进行仿真。支路 AC30 的电压曲线如图 4.18 所示, 这是本节的研究对象。由于短路接地故障发生在电压突变的 1 秒, 将采用分段生成的方法, 即分别生成故障前的正常数据 (图 4.19) 和故障后的数据 (图 4.20)。




图 4.18 支路 AC30 电压曲线




图 4.19 故障前正常数据




图 4.20 故障后数据

下面将在此数据场景下，采用第二章中所描述的PSO和GA优化GAN参数的流程进行数据生成。

4.4.2 参数设置

本实验中PSO参数设置如下：学习因子 c_1 和 c_2 分别随迭代次数的增加而线性减小和增加。 $c_{min} = 1.4$, $c_{max} = 2.5$; $\omega_{min} = 0.1$, $\omega_{max} = 0.9$, 粒子数为 100, 最大迭代次数为 100。

GA参数设置如下： $n = 100$; $p_c = 0.8$; $p_e = 0.5$; $p_m = 0.1$; 最大迭代次数为 100。其中 n 表示种群规模， p_c 表示交叉概率， p_e 表示交换概率， p_m 表示变异概率。

在本节所述的参数优化仿真过程中，GAN的参数 r_G 、 r_D 和 B 是优化的对象。GAN的迭代次数为 10000 次。实验中采用Adam作为优化工具，根据训练数据迭代更新神经网络权值，使 G 和 D 的损失最小。

以平均相对误差为目标函数，基于PSO算法和GA优化GAN参数生成数据，通过最小化目标函数得到最优参数组合。

4.4.3 生成正常数据

共有 100 个正常数据，随机取其中 80% 的样本数据作为训练集，剩余部分样本作为测试集。GAN参数的设定范围见表 4.4。

表 4.4 GAN参数取值范围

参数	r_G	r_D	B
取值范围	[0.00001, 0.01]	[0.000001, 0.01]	[64, 100]

优化后的结果见表 4.5 所示。从表中可以看出，在所研究的数据场景中，PSO优化GAN参数生成数据的误差最小，其次是GA优化方法和RN方法。从时间消耗来看，RN方法的运行时间远小于PSO和GA方法，但RN方法的误差最大，PSO方法的运行时间小于GA方法。

表 4.5 优化结果

	PSO	GA	RN
r_G	0.000189	0.000225	0.0006275
r_D	0.000023	0.000045	0.0000887
B	86.5878	82.7947	78
ERR (%)	3.6859	12.8956	37.7945
$TIME$ (s)	106847.9	153928.94	64689.8

图 4.21 和图 4.22 分别是PSO和GA优化GAN参数生成数据的结果。图 4.23 是随机取GAN的参数值得到的结果。红线代表实际数据，黄线代表G生成的数据，从图 4.21 和图 4.22 可以看出，经过 5000 次迭代，生成器已经学习到了实际样本的近似分布，但是生成的数据与实际样本的偏差比较大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO的优化结果明显优于GA和RN方法。图 4.24、图 4.25 和图 4.26 是PSO优化GAN参数生成数据的收敛性和

误差随迭代次数的变化图，由图可知收敛性良好。

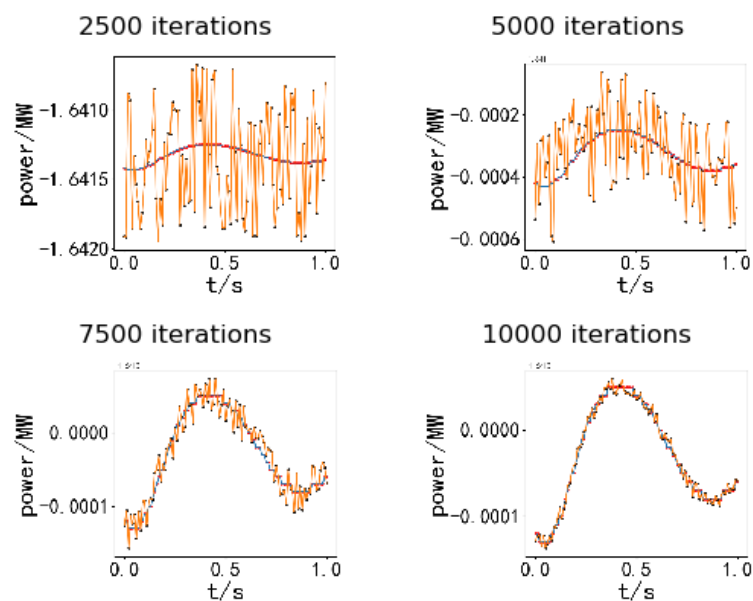


图 4.21 PSO优化GAN参数

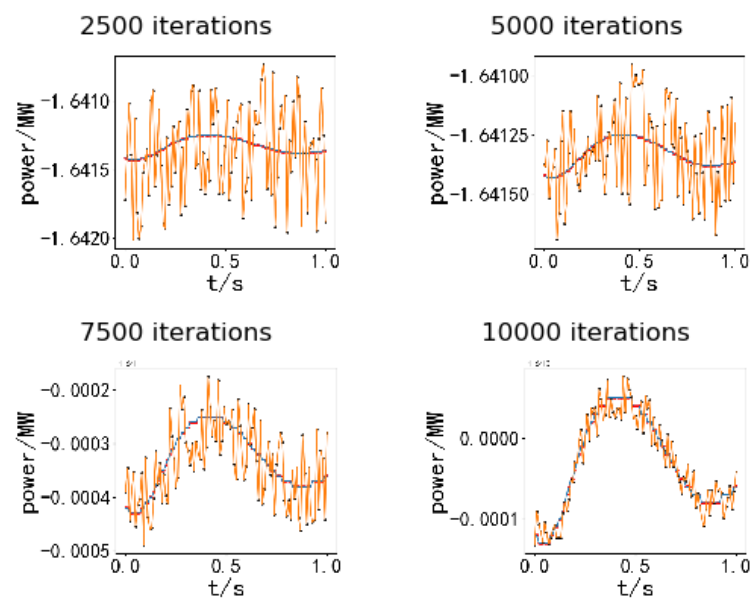


图 4.22 GA优化GAN参数

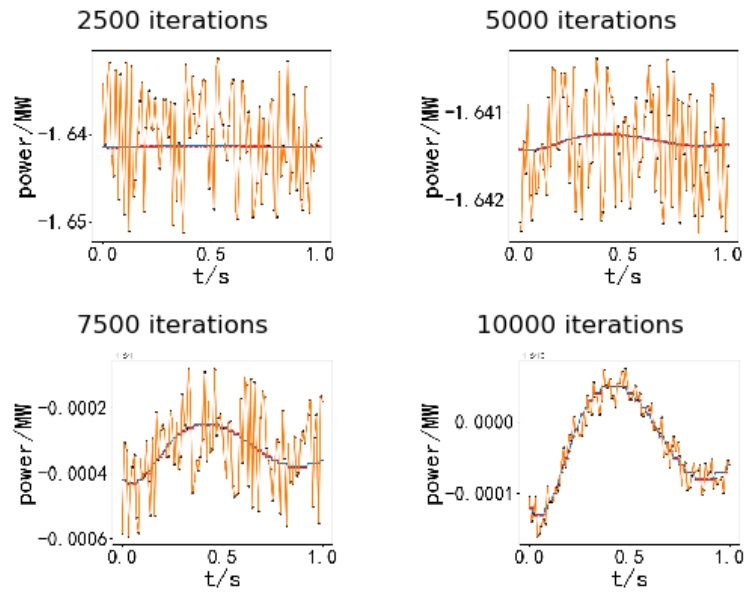


图 4.23 GAN参数随机取值




图 4.24 PSO优化GAN判别概率曲线




图 4.25 PSO优化GAN D 的得分




图 4.26 PSO优化GAN平均相对误差曲线

4.4.4 生成故障后数据

共有 900 个故障后数据，随机取其中 80%的样本数据作为训练集，

剩余部分样本作为测试集。GAN参数的设定范围见表 4.6 所示。

表 4.6 GAN参数取值范围

参数	r_G	r_D	B
取值范围	[0.00001, 0.01]	[0.000001, 0.01]	[450, 900]

结果见表 4.7。从表中可以看出，在所研究的数据场景中，PSO 优化GAN参数生成数据的误差最小，其次是GA优化方法和RN方法。从时间消耗来看，RN方法的运行时间远小于PSO和GA优化方法，但RN方法的误差最大，PSO方法的运行时间小于GA优化方法。

表 4.7 优化结果

	PSO	GA	RN
r_G	0.000246	0.000287	0.0000875
r_D	0.0000268	0.0000253	0.0000168
B	946.9476	825.7948	647
ERR (%)	8.2468	16.7956	45.8496
TIME (s)	347836.8	658537.73	86537.9

图 4.27 和图 4.28 分别是PSO和GA优化GAN参数生成数据的结果。图 4.29 是随机取GAN的参数值得到的结果。红线代表真实数据，绿线代表G生成的数据，从图 4.27 和 4.28 可以看出，经过 5000 次迭代，生成器已经学习到了真实样本的近似分布，但是生成的数据与真实样本的偏差还是比较大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO优化方法的优化结果明显优于GA优化方法和RN方法。图 4.30、图 4.31 和图 4.32 分别是PSO优化GAN生成数据的收敛性和误差随迭代次数的变化图，由图可知收敛性良好。

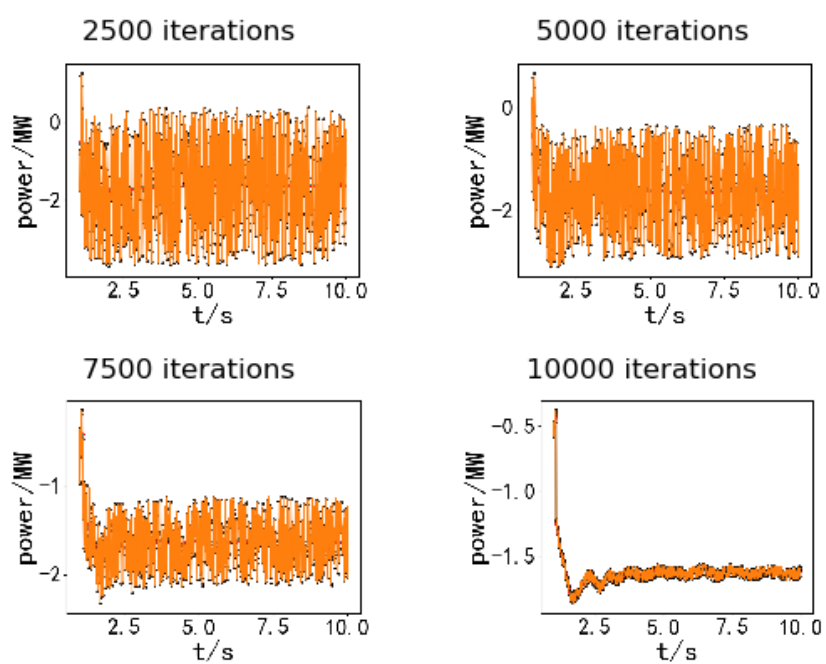


图 4.27 PSO优化GAN参数

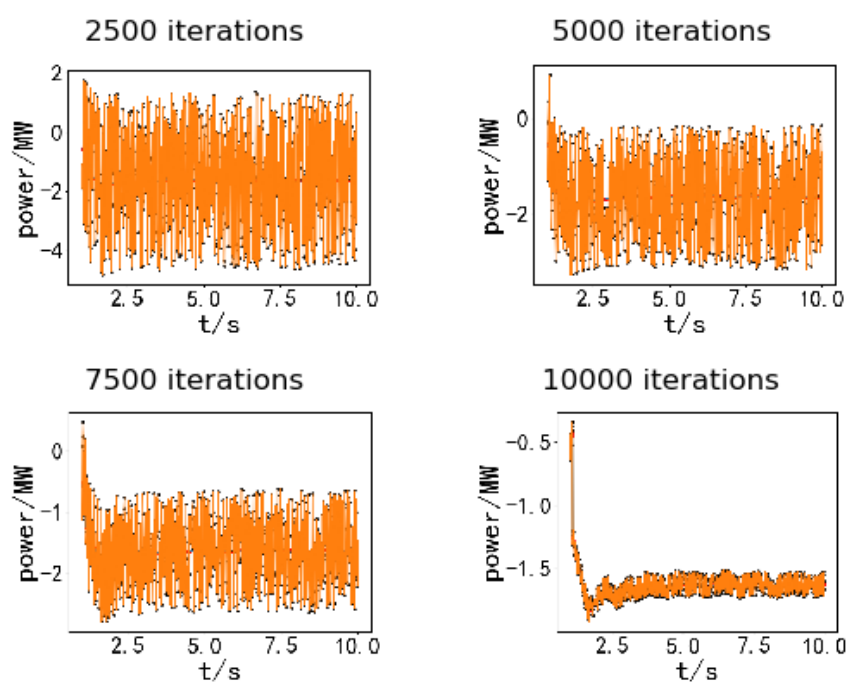


图 4.28 GA优化GAN参数

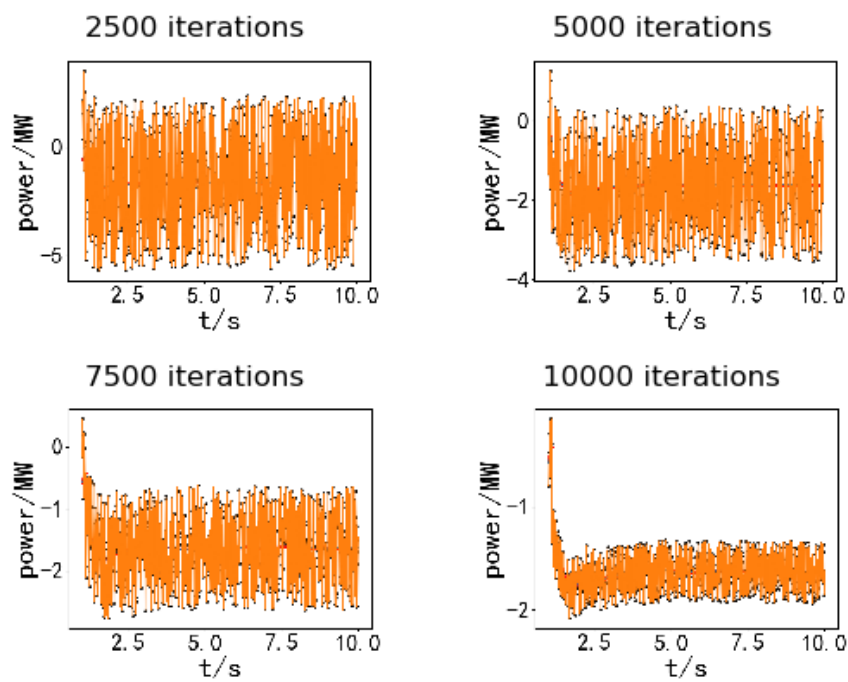


图 4.29 GAN参数随机取值




图 4.30 判别概率曲线




图 4.31 PSO优化GAN D 的得分




图 4.32 PSO优化GAN平均相对误差曲线

4.5 本章小结

本章采用PSO和GA对GAN的参数 (r_G 、 r_D 和 B) 进行优化, 生成单相和三相短路故障的母线电压数据。此外, 还使用随机获取GAN

参数值的RN方法生成这些数据。结果表明，PSO优化参数不仅在时间消耗上，而且在数据生成精度上都明显优于GA，由于RN方法的盲目性，很难控制GAN生成数据的精度，而且生成误差往往较大，建议不要使用这种方法。PSO优化GAN参数生成数据的收敛曲线和误差曲线也表明PSO优化方法具有良好的收敛性。

通过GAN的无监督训练，神经网络将自动学习到电压波动规律难以显式建模的复杂关系。利用智能优化算法优化GAN，使得训练后的生成器将能够生成高精度的数据。该方法完全依靠数据驱动，不涉及显式建模步骤，具有较高的生成精度，所重建的数据同真实数据之间具有相似的时序特性，保证了将生成数据作为伪量测的可行性。由于本章所提方法是通过所学到的相关性规律来生成数据，即便在系统中出现大量量测缺失的情况下仍能保持稳定、准确的生成效果。

第五章 引力波应用

5.1 背景介绍

物理学中，引力波是因为时空弯曲对外以辐射形式传播的能量。爱因斯坦基于广义相对论预言了引力波的存在。引力波是广义相对论最重要的理论预言之一。引力波探测是史无前例地在强场、强动态时空区对广义相对论的实验检验。更重要地，它将开创全新的宇宙观测窗口—引力波天文学。但引力波探测极其困难。2015年9月14日，LIGO实现了人类的第一次引力波直接探测^[167]。被探测到的引力波信号来自于13亿光年之外的双黑洞并合事件，是人类首次观测到双黑洞并合过程。该发现表明单黑洞质量大于25太阳质量的双黑洞系统在自然界存在，并且能在宇宙年龄时间内并合。除此之外，并合形成的黑洞符合克尔黑洞的性质，这是人类首次观测到黑洞的时空结构。这次发现为人类了解宇宙打开了一扇新的窗口，天文学进入新时代：由引力波参与的多信使天文学正式拉开序幕^[168]。该实验结果在2016年2月公布，并被命名为GW150914^[167]。这对引力波的研究起到了极大的推动作用，也是一种对爱因斯坦的跨世纪的回答^[169]。截至2018年1月16日，LIGO已成功探测引力波事件6次。引力波的成功探测还获得了2017年度的诺贝尔物理学奖^[167]。

只要两个天体以一定的速度碰撞，就足以产生引力波，所以对于单一的黑洞，也可以利用这种方法探测。只要那个黑洞正在吞噬恒星，它就一定会产生引力波，在探测单一黑洞时，需要利用由黑洞与其周

边天体的引力干涉现象产生的引力波来探测黑洞的存在。由于黑洞只在两极产生X喷流，所以在两级外的其他部位，不会有电磁波产生。即天体与黑洞碰撞产生的引力波里不含电磁波的成分^[169]。

由于电磁—引力干涉现象，两颗中子星互相公转时会产生电磁—引力波(引力波与电磁波杂交的产物)。如果两个类星体会相互公转，则它们会产生很大的向心力，并且发生碰撞，这将会是宇宙中最强的能量爆发，会爆发出电磁能、热能、光能以及引力能的复合能量。如果它们产生的和动量足够大，则会产生强大的引力波^[169]。

5.2 研究内容

引力波是自然界中很微弱、很不易察觉的波，所以引力波很难被探测到^{[170], [171]}。为了获取更多引力波数据，增加引力波数据的多样性，本章提出了一种基于GAN的训练样本生成引力波算法。该方法通过PSO和GA优化GAN参数，自动寻找GAN在理想引力波和GW150914事件场景下的最优参数，自主学习原始样本的分布规律，生成新的数据样本序列。算法流程图分别如图 2.4 和图 2.5 所示。

5.3 理想引力波应用

5.3.1 数据来源

L1 Strain和H1 Strain是由两个探测器探测到的引力波信号^[172]。首先从配置文档中读取时间相关数据，再读取应变数据；分别使用来自“L1”和“H1”探测器的带有噪声信息的引力波图像数据作图：画出以时间为X轴，应变数据为Y轴的图像并设置标题和坐标轴的标签(图 5.1 和图 5.2)。以完全相同的方法绘制理想情况下的引力波

Template Strain图像（图 5.3）。本节数据来源于网址：

[<https://wenku.baidu.com/view/cc6b31f4773231126edb6f1aff00bed5b8f373f0.html>]。

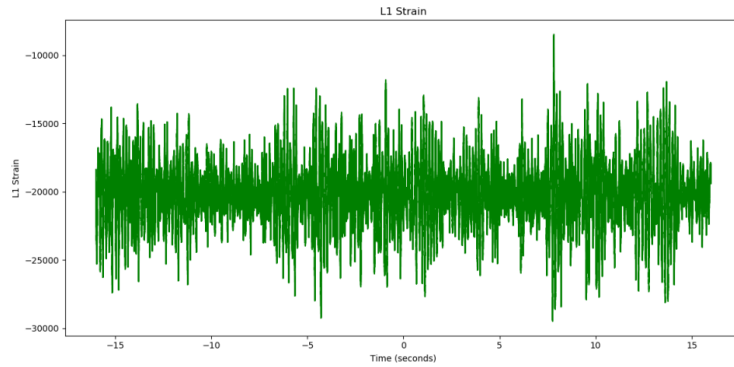


图 5.1 L1 Strain




图 5.2 H1 Strain




图 5.3 理想情况下的引力波

5.3.2 PSO, GA优化GAN参数生成理想引力波

共有 2769 个理想引力波数据，随机取其中 80% 的样本数据作为训练集，剩余部分样本作为测试集。GAN 参数的设定范围见表 5.1。

表 5.1 GAN 参数取值范围

参数	r_G	r_D	B
取值范围	[0.000001, 0.001]	[0.0000001, 0.001]	[1000, 1500]

优化结果见表 5.2。从表中可以看出，在所研究的数据场景中，PSO 优化 GAN 参数生成数据的误差最小，其次是 GA 优化方法和 RN 方法。从时间消耗来看，RN 方法的运行时间远小于 PSO 和 GA 方法，但 RN 方法的误差最大，PSO 方法的运行时间小于 GA 方法。

表 5.2 优化结果

	PSO	GA	RN
r_G	0.00000326	0.0000372	0.000885
r_D	0.000536	0.000385	0.0000476
B	1258	1435	1376
ERR (%)	6.9385	10.6833	28.5638
TIME (s)	237832.8	315837.5	164927.5

图 5.4 和图 5.5 分别是 PSO 和 GA 优化 GAN 参数生成数据的结果。图 5.6 是采用 RN 方法得到的结果。绿线代表 GAN 生成的数据，从图 5.4 和图 5.5 可以看出，经过 5000 次迭代， G 已经学习到了真实样本的近似分布，但是生成的数据与真实样本的偏差还是比较大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO 优化方法的优化结果明显优于 GA 方法和 RN 方法。图 5.7、图 5.8 和图 5.9 分别是 PSO 优化 GAN 参数生成数据的收敛性和误差随迭代次数的变化图，由图可知收敛性良好。

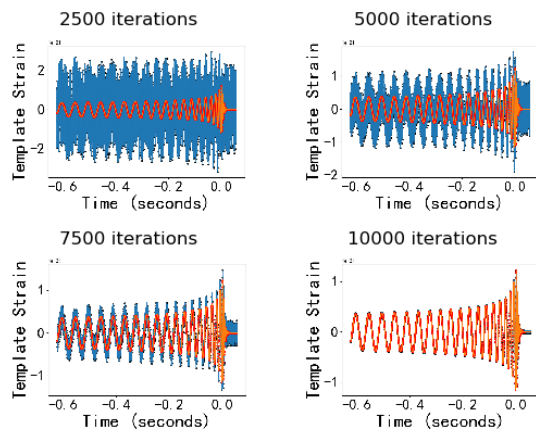


图 5.4 PSO优化GAN参数

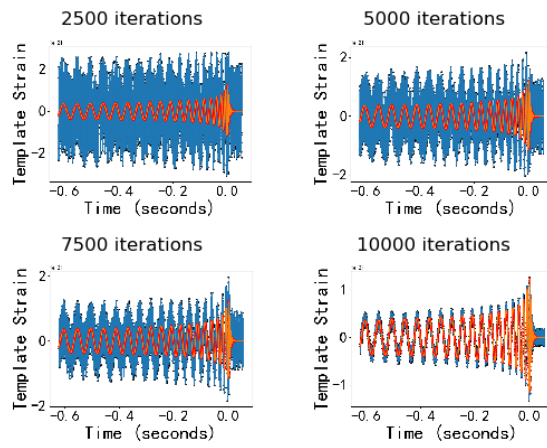


图 5.5 GA优化GAN参数

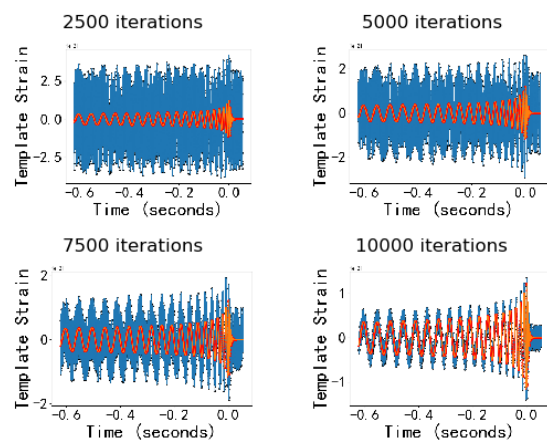


图 5.6 随机取GAN参数




图 5.7 PSO优化GAN判别概率曲线




图 5.8 PSO优化GAN D的得分




图 5.9 PSO优化GAN平均相对误差曲线

5.4 GW150914 事件应用

5.4.1 事件介绍

在经过半个世纪的艰苦探索之后，引力波探测终成正果。2015年9月14日，激光干涉引力波天文台（LIGO）探测到来自两个恒星质量黑洞并合所产生的引力波信号GW150914^[173]。美国当地时间2016年2月11日上午10点30分（北京时间2016年2月11日23点30分），美国国家科学基金委员会（NSF）召集来自加州理工学院、麻省理工学院以及LIGO科学合作组织的科学家代表在华盛顿国家新闻中心向世界宣布，加州理工学院、麻省理工学院和LIGO科学合作组SLC的科学家利用设在华盛顿州汉福德的高级激光干涉仪引力波探测器（Advanced LIGO）H1和位于路易斯安那州利文斯顿的相同的实验设备L1发现了引力波存在的直接证据。困扰科学家100年来的物理学难题得到破解。这是一项划时代的科学成就，具有极其深远的意义。美国科学家把该引力波事例命名为GW150914，以纪念这个人类科学史上极不寻常的日子^[174]。图5.10为所绘制的原始时间序列数据图。




图 5.10 原始时间序列数据

为了挑出目标信号，下面将绘制信号的幅度谱（amplitude spectral density, ASD）来进行初步分析，首先定义ASD。

功率谱密度一般作为频率的函数，表示物理过程的功率随频率的分布。对于持续过程，通过定义能量除以时间作为平均功率，后利用Parseval定理得到功率对于频率的函数：

$$P = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x^2(t) dt = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x^2(f) df$$

如此就可以定义功率谱密度S为平均功率对于某角频率的期望，由Wiener - Khinchin定理，功率谱密度（power spectral density, PSD）与信号的自相关函数是傅里叶对，假设自相关函数绝对可积，得到：

$$S_{xx}(\omega) = \lim_{T \rightarrow \infty} E(|\hat{x}_T(\omega)|^2) = \int_{-\infty}^{\infty} \langle X(t)X(t + \tau) \rangle e^{i\omega\tau} d\tau$$

最后，定义ASD为PSD的平方根。

然后只需要对信号做快速傅里叶变换（fast fourier transforms, FFTs），再求均方就得到了PSD，然后开根号即可。

对于aLIGO，信号用时空应变（strain）来衡量，通过以上操作使得ASD变成了一个以时空应变对于频率的分布，命名为“应变等效噪声”（strain-equivalent noise）。

给f设置了范围，来自于对LIGO探测范围的计算。aLIGO的设计减震极限在10Hz，实际上对于20Hz以下的低频噪声，地基的aLIGO无力回天。由于采样率是 $f_s = 4096\text{Hz}$ ，由采样定律（nyquist - shannon

sampling theorem), 对于采样率的一半=2048Hz (nyquist频率) 及以上的部分, 信号会混叠失真, 没有意义。

得到ASD图如图 5.11 所示。




图 5.11 ASD图

探测结果表明, 这里面藏了一个引力波事件信号, 然而尖尖却有很多个。理论计算表明噪声几乎完全主导了这段信号, 所以可以大胆假设, 这一段全是噪声, 且噪声远大于引力波信号。观察拟合曲线发现, 噪声高频亮, 低频足, 中频趋于平坦 (此处是log后的图像), 大概在 100-300Hz是平缓的。

通过把信号FFT一下, 除以ASD, 再逆FFT回来, 可以实现把ASD从信号中去掉。时域图如图 5.12 所示。由图可知 20Hz全是噪声。500, 1500, ……的这些整齐的噪声, 来源于aLIGO的悬挂系统。地球最纯硅镜片用绳子挂在 7 级悬吊系统上, 这样才可以和地球上的扰动隔离开来。而这些纤维本身会有规律的共振, 造成了这些 500Hz倍数的大横杠。





图 5.12 时域图

将数据进行白化处理和带通滤波处理后的图像如图 5.13 所示。

数据的q变换图如图 5.14 所示。




图 5.13 GW150914 事件




图 5.14 q变换图

下面将在此数据场景下，采用第二章中所描述的PSO和GA优化GAN参数的流程进行数据生成。

5.4.2 PSO, GA优化GAN生成GW150914 事件

GW150914 共有 131072 个引力波数据，随机取其中 80%的样本数据作为训练集，剩余部分样本作为测试集。GAN参数的设定范围见表 5.3。优化结果见表 5.4 所示。

表 5.3 GAN参数取值范围

参数	r_G	r_D	B
取值范围	[0.000001, 0.001]	[0.0000001, 0.001]	[5000, 100000]

表 5.4 优化结果

	PSO	GA	RN
r_G	0.00000658	0.0000165	0.000749
r_D	0.000473	0.000869	0.0000385
B	95834	85796	18594
ERR (%)	9.5973	15.8945	39.8947
TIME (s)	1609473.6	2053958.5	1543968.6

从表中可知，在所研究的数据场景中，PSO优化GAN参数生成数据的误差最小，其次是GA优化方法和RN方法。从时间消耗来看，RN

方法的运行时间远小于PSO和GA方法，但RN方法的误差最大，PSO方法的运行时间小于GA方法。

图 5.15 和图 5.16 分别是PSO和GA优化GAN参数生成数据的结果。图 5.17 是随机取GAN的参数值得到的结果。其中绿线代表GAN生成的数据。

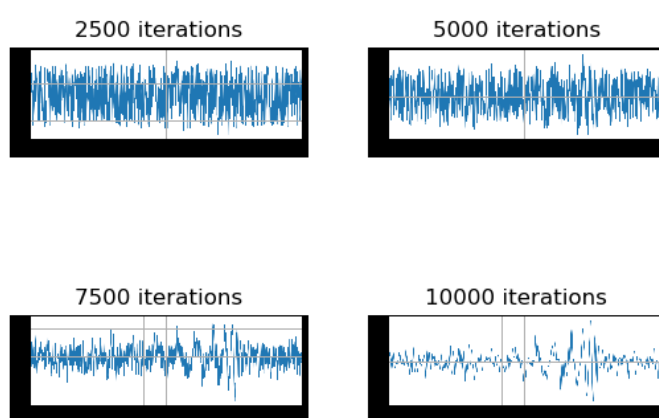


图 5.15 PSO优化GAN参数

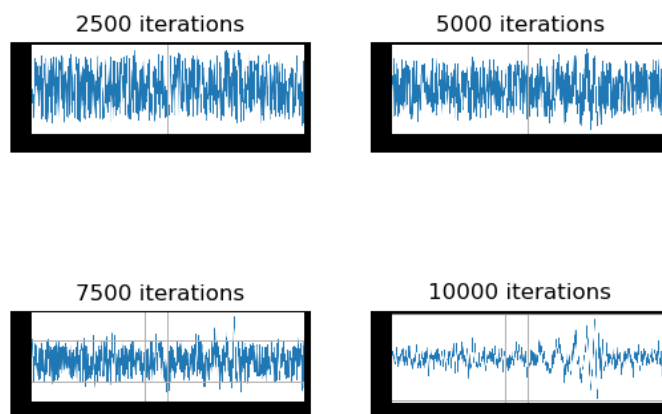


图 5.16 GA优化GAN参数

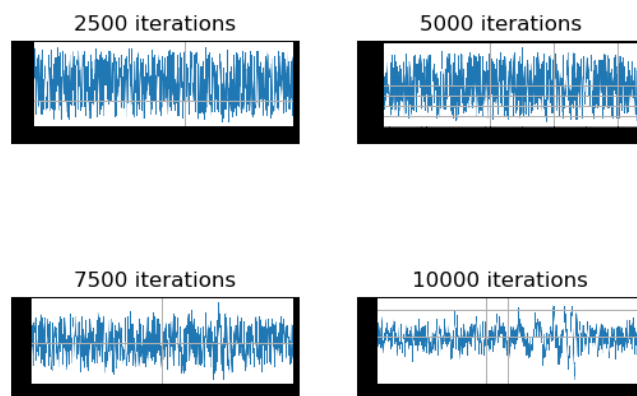


图 5.17 随机取GAN参数

从图 5.15 和图 5.16 可以看出，经过 5000 次迭代，生成器已经学习到了真实样本的近似分布，但是生成的数据与真实数据的偏差还是比较大。经过 7500 次训练，生成的样本与真实样本基本一致。从图中可以看出，PSO优化方法的优化结果明显优于GA优化方法和RN方法。图 5.18、图 5.19 和图 5.20 分别是PSO优化GAN参数生成数据的收敛性和误差随迭代次数的变化图，由图可知收敛性良好。




图 5.18 PSO优化GAN判别概率曲线




图 5.19 PSO优化GAN D 的得分




图 5.20 PSO优化GAN平均相对误差曲线

5.5 本章小结

针对引力波数据难以获取的问题，本章采用PSO算法和GA对GAN的参数 (r_G 、 r_D 和 B) 进行优化，学习引力波序列难以显式建模的时间相关性来生成理想引力波和GW150914事件样本数据，采用合成的样本对原始数据进行增强。此外，还使用随机获取GAN参数值的方法来生成这些数据。该方法完全依靠数据驱动，无需经过精心设计的建模过程。结果表明PSO优化GAN参数生成数据不仅在时间消耗

上，而且在数据生成精度上都明显优于GA优化GAN参数生成数据。此方法对增加引力波数据的多样性具有积极意义。由于随机取GAN参数的盲目性，很难控制GAN生成数据的精度，而且生成误差往往较大，建议不要使用这种方法。PSO优化GAN参数生成数据的收敛曲线以及误差曲线也表明PSO优化方法具有良好的收敛性。

第六章 结论

本研究报告主要针对GAN的三个参数 (r_G 、 r_D 和 B) 采用PSO和GA进行优化研究, 并分别在以下三个场景下进行应用分析: 故障电机振动信号, 单相和三相短路接地故障电压数据, 引力波数据。得到以下结论:

(1) GAN生成方法完全依靠数据驱动, 无需经过精心设计的建模过程。基于PSO优化GAN参数生成数据的算法通过对抗训练方式, 能够有效逼近样本的分布, 生成符合原始样本序列波动规律的合成样本, 该方法能有效解决原始数据难以获取的问题。

(2) 基于PSO优化GAN参数的算法所生成的样本并非与原始样本保持完全一致, 两者在保证波动规律大致相同的情况下也保持了一定的差异性, 这使得增强后的样本具有多样性特征。

(3) PSO优化GAN参数生成数据的精度和耗时明显优于GA优化方法。虽然RN方法耗时最短, 但生成精度最低, 且由于RN方法具有随机性和盲目性的特点, 不建议采用。PSO优化GAN参数生成数据的收敛曲线以及误差曲线也表明PSO优化方法具有良好的收敛性。

PSO和GA优化GAN参数生成数据的迭代耗时都比较长, 如何改进算法以减少耗时是下一步研究的重点。此外, 在故障诊断方向的研究中可进一步将优化的GAN与叠层去噪自动编码器故障诊断模型相结合进行故障诊断研究。

参考文献

- [1]. 肖泽青, 华昊辰, 曹军威. 人工智能在能源互联网中的应用综述[J]. 电力建设, 40(5):63-70, 2019.
- [2]. 王天笑. 自然语言处理的现状研究与未来发展初探[J]. 中国科技纵横, 000(002):196-197, 2017.
- [3]. 卢娜, 陈劲佑. 人工智能时代计算机视觉中若干问题实现技术研究[J]. 数码世界, 000(005):9-10, 2020.
- [4]. 郝欧亚, 吴璇, 刘荣凯. 智能语音识别技术的发展现状与应用前景[J]. 电声技术, 044(003):24-26, 2020.
- [5]. 姚东亮, 胡静怡, 张婷. 人工智能与智慧医疗[J]. 科学大众(科学教育), 000(005):150-151, 2020.
- [6]. 陈坤, 李腊梅, 徐亮. 人工智能在中小学语文教学中的应用研究[J]. 人文之友, 000(005):272-274, 2020.
- [7]. 殷嫣. 人工智能在会计领域的应用探讨[J]. 中国市场, 2020(3).
- [8]. 邓畅. 人工智能在媒体传播中的运用[J]. 新闻研究导刊, 2020.
- [9]. 张颖, 魏香梅, 邓峰, et al. 人工智能与制造业融合发展研究[J]. 科技创业月刊, 2020(6):15-17.
- [10]. 朱涛, 董凡. 人工智能在家庭服务业的应用问题及趋势研究[J]. 中州大学学报, 2020(1).
- [11]. 王嫒, 解文霞, 孔德莉, et al. 论人工智能技术应用研究现状和发展前景[J]. 微计算机信息, 2019, 000(020):18-21.
- [12]. Zichan, Yang. Application and Development Trend of Artificial Intelligence Technology[C]// 2019.
- [13]. 徐勇军. 基于少量样本的深度学习图像修复算法研究[D]. 2020.
- [14]. Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, et al. Deep learning for time series classification: a review. Data Mining and Knowledge Discovery, 33(4):917-963, 2019.
- [15]. Z Han, J Zhao, H Leung, K F Ma, and W Wang. A review of deep learning models for time series prediction. IEEE Sensors Journal, page 1, 2019.
- [16]. Raghavendra Chalapathy and Sanjay Chawla. Deep learning for anomaly detection: A survey. arXiv preprint arXiv:1901.03407, 2019.
- [17]. 郭丽丽, 丁世飞. 深度学习研究进展[J]. 计算机科学, 2015, 42(5): 28-33.
- [18]. 刘全, 翟建伟, 章宗长, 等. 深度强化学习综述 [J]. 计算机学报, 2018, 41(1):1-27.
- [19]. 陈伟宏, 安吉尧, 李仁发, 等. 深度学习认知计算综述 [J]. 自动化学报, 2017, 43(11):1886-1897.
- [20]. 杨懿男, 齐林海, 王红, 等. 基于生成对抗网络的小样本数据生成技术研究 [J]. 电力建设, 2019, 40(05):75-81.
- [21]. 赵俊华, 董朝阳, 文福拴, 等. 面向能源系统的数据科学:理论、技术与展望 [J]. 电力系统自动化, 2017, 41(4):1-11, 19.
- [22]. Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In NeurIPS 2012,

-
- pages 1097–1105, 2012.
- [23]. 何旭,姜宪国,张沛超,等. 基于SVM的小样本条件下继电保护可靠性参数估计 [J]. 电网技术,2015,39(5):1432-1437.
- [24]. 段萌,王功鹏,牛常勇. 基于卷积神经网络的小样本图像识别方法 [J]. 计算机工程与设计,2018,39(1) : 224-229.
- [25]. KAN Yingnan, YANG Zhaojun, LI Guofa. Bayesian reliability modeling and assessment solution for CN machine tools undersmall-sample data [J]. Chinese Journal of Mechanical Engineering, 2015, 28(6):1229-1239.
- [26]. 毕略, 熊伟丽. 基于数据分布的小样本扩充方法及应用[J]. 控制工程, 2019, 26(7).
- [27]. 孙涛, 吴海丰, 梁志刚, et al. SMOTE 算法在不平衡数据中的应用[J]. 北京生物医学工程, 2012(5):528-530.
- [28]. Connor Shorten and Taghi M Khoshgoftaar. A survey on image data augmentation for deep learning. Journal of Big Data, 6(1):60, 2019.
- [29]. X Cui, V Goel, and B Kingsbury. Data augmentation for deep neural network acoustic modeling. IEEE/ACM TASLP, 23(9):1469–1477, 2015.
- [30]. Wen Q, Sun L, Song X, et al. Time Series Data Augmentation for Deep Learning: A Survey[J]. 2020.
- [31]. I. Goodfellow, J. Pouget-Abadie, M. Mirza , et al. Courville, and Y. Bengio, “Generative adversarial nets,” in Advances in Neural Information Processing Systems, 2014, pp. 2672–2680.
- [32]. Arthur Le Guennec, Simon Malinowski, and Romain Tavenard. Data augmentation for time series classification using convolutional neural networks. In ECML/PKDD Workshop on AALTD, 2016.
- [33]. X Cui, V Goel, and B Kingsbury. Data augmentation for deep neural network acoustic modeling. IEEE/ACM TASLP, 23(9):1469–1477, 2015.
- [34]. Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, Lhassane Idoumghar, and Pierre-Alain Muller. Data augmentation using synthetic data for time series classification with deep residual networks. In ECML/PKDD Workshop on AALTD, 2018.
- [35]. Tailai Wen and Roy Keyes. Time series anomaly detection using convolutional neural networks and transfer learning. In IJCAI Workshop on AI4IoT, 2019.
- [36]. Jingkun Gao, Xiaomin Song, Qingsong Wen, Pichao Wang, Liang Sun, and Huan Xu. RobustTAD: Robust time series anomaly detection via decomposition and convolutional neural networks. arXiv preprint arXiv:2002.09535, 2020.
- [37]. Tracey Kah-Mein Lee, YL Kuah, Kee-Hao Leo, Saeid Sanei, Effie Chew, and Ling Zhao. Surrogate rehabilitative time series data for image-based deep learning. In EUSIPCO 2019, pages 1–5, 2019.
- [38]. Odongo Steven Eyobu and Dong Seog Han. Feature representation and data augmentation for human activity classification based on wearable IMU sensor data using a deep LSTM neural network. Sensors, 18(9):2892, 2018.
- [39]. Daniel S Park, William Chan, Yu Zhang, Chung-Cheng Chiu, Barret Zoph,

-
- Ekin D Cubuk, et al. SpecAugment: A simple data augmentation method for automatic speech recognition. In INTERSPEECH 2019, pages 2613–2617, 2019.
- [40]. 谢桦, 陈俊星, 赵宇明, et al. 基于 SMOTE 和决策树算法的电力变压器状态评估知识获取方法[J]. 电力自动化设备, 2020.
- [41]. 刘小艳. 基于成分数据缺失值的回归分析研究[D].
- [42]. 黄林, 常健, 杨帆, et al. 基于改进 k-means 的电力信息系统异常检测方法[J]. 深圳大学学报(理工版), 2020, 037(002):214-220.
- [43]. 肖辉. Bootstrap 技术在电力系统可靠性评估中的应用[J]. 广西电力, 2019, 42(002):46-50.
- [44]. 杨文光, 吴云洁, 王建敏. 基于熵权法的小样本灰色置信区间估计[J]. 郑州大学学报: 理学版, 2016(48):56.
- [45]. 刘恒, 梅卫, 单甘霖. 小样本数据的三种区间估计方法性能分析 [J]. 系统工程与电子技术, 2014, 36(10):1929—1933.
- [46]. XU L W, YANG F Q, CHEN RR, et al. A parametric bootstrap test for two-way ANOVA model without interaction under heteroscedasticity [J]. Communications in statistics-simulation and computation, 2015, 44: 1264—1272.
- [47]. PETER A D, EULOGIO P I, JUAN J E. The total bootstrap median: a robust and efficient estimator of location and scale for small samples [J]. Journal of applied statistics, 2015, 42(6): 1306—1321.
- [48]. Chawla N V, Bowyer K W, Hall L O, et al. SMOTE: Synthetic Minority Over-sampling Technique [J]. Journal of Artificial Intelligence Research, 2002, 16(1):321-357.
- [49]. 韩秋玲. 过抽样算法在不平衡数据学习中的应用[D]. 华南理工大学.
- [50]. Han Hui, Wang Wenyuan, Mao Binghuan. Borderline-SMOTE: A new over-sampling method in imbalanced datasets learning [C]// Proceedings of 2005 International Conference on Advances in Intelligent Computing. 2005, 3644(5):878-887.
- [51]. 许丹丹, 王勇, 蔡立军. 面向不均衡数据集的 ISMOTE 算法[J]. 计算机应用, 2011, 31(09):2399-2401.
- [52]. 易未, 毛力, 孙俊, et al. 改进 Smote 算法在不平衡数据集上的分类研究 [J]. 计算机与现代化, 2018.
- [53]. 董燕杰. 不平衡数据集分类的 Random-SMOTE 方法研究 [D]. 大连: 大连理工大学, 2009.
- [54]. 王超学, 潘正茂, 董丽丽, 等. 基于改进 SMOTE 的非平衡数据集分类研究 [J]. 计算机工程与应用, 2013, 49(2):184-187.
- [55]. Santos M S, Abreu P H, Garc á-Laencina P J, et al. A new cluster-based oversampling method for improving survival prediction of hepatocellular carcinoma patients [J]. Journal of Biomedical Informatics, 2015, 58:49-59.
- [56]. 袁铭. 基于 R-SMOTE 方法的非平衡数据分类研究 [D]. 保定: 河北大学, 2015.
- [57]. 古平, 杨炆. 面向不均衡数据集中少数类细分的过采样算法 [J]. 计算

-
- 机工程,2017,43(2):241-247.
- [58]. Lars Kegel, Martin Hahmann, and Wolfgang Lehner. Feature-based comparison and generation of time series. In *SSDBM 2018*, 2018.
- [59]. Robert B Cleveland, William S Cleveland, Jean E McRae, and Irma Terpenning. STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, 6(1):3–73, 1990.
- [60]. Christoph Bergmeir, Rob J. Hyndman, and Jose´ M. Ben´itez. Bagging exponential smoothing methods using STL decomposition and Box–Cox transformation. *International Journal of Forecasting*, 32(2):303–312, 2016.
- [61]. Qingsong Wen, Jingkun Gao, Xiaomin Song, Liang Sun, Huan Xu, and Shenghuo Zhu. RobustSTL: A robust seasonal-trend decomposition algorithm for long time series. In *AAAI*, pages 1501–1509, 2019.
- [62]. Qingsong Wen, Jingkun Gao, Xiaomin Song, Liang Sun, and Jian Tan. RobustTrend: A Huber loss with a combined first and second order difference regularization for time series trend filtering. In *IJCAI*, pages 3856–3862, 2019.
- [63]. Hong Cao, Vincent YF Tan, and John ZF Pang. A parsimonious mixture of gaussian trees model for oversampling in imbalanced and multimodal time-series classification. *IEEE TNNLS*, 25(12):2226–2239, 2014.
- [64]. Slawek Smyl and Karthik Kuber. Data preprocessing and augmentation for multiple short time series forecasting with recurrent neural networks. In *36th International Symposium on Forecasting*, June 2016.
- [65]. Yanfei Kang, Rob J Hyndman, and Feng Li. GRATIS: Generating time series with diverse and controllable characteristics. *arXiv preprint arXiv:1903.02787*, 2019.
- [66]. Terrance DeVries and Graham W. Taylor. Dataset augmentation in feature space. In *ICLR 2017*, pages 1–12, Toulon, 2017.
- [67]. Ekin D. Cubuk, Barret Zoph, Dandelion Mane, Vijay Vasudevan, and Quoc V. Le. AutoAugment: Learning augmentation strategies from data. In *IEEE CVPR 2019*, pages 113–123, June 2019.
- [68]. Konstantinos Nikolaidis, Stein Kristiansen, Vera Goebel, Thomas Plagemann, Knut Liestøl, and Mohan Kankanhalli. Augmenting physiological time series data: A case study for sleep apnea detection. In *ECML/PKDD 2019*, pages 1–17, 2019.
- [69]. Cristobal Esteban, Stephanie L Hyland, and Gunnar Ratsch. Real-valued (medical) time series generation with recurrent conditional gans. *arXiv preprint arXiv:1706.02633*, 2017.
- [70]. Jinsung Yoon, Daniel Jarrett, and Mihaelavan der Schaar. Time-series generative adversarial networks. In *NeurIPS 2019*, pages 5508–5518, 2019.
- [71]. Unterthiner T, Nessler B, Seward C, et al. Coulomb GANs: Provably Optimal Nash Equilibria via Potential Fields[J]. 2017.
- [72]. Locatello F , Vincent D , Tolstikhin I , et al. Competitive Training of Mixtures of Independent Deep Generative Models[J]. 2018.
- [73]. Y. Song, C. Ma, X. Wu, et al. “VITAL: visual tracking via adversarial

-
- learning,” Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, arXiv:1804.04273, June 2018.
- [74]. 张营营.生成对抗网络模型综述[J]. 电子设计工程, 2018, 26(5):34-37,43.
- [75]. Dumoulin V, Belghazi I, Poole B, et al. Adversarially Learned Inference[J]. 2016.
- [76]. Arora S, Ge R, Liang Y, et al. Generalization and Equilibrium in Generative Adversarial Nets (GANs)[J]. 2017.
- [77]. Tolstikhin I, Gelly S, Bousquet O, et al. AdaGAN: Boosting Generative Models[J]. 2017.
- [78]. Arjovsky M, Bottou L. Towards Principled Methods for Training Generative Adversarial Networks[J]. Stat, 2017, 1050.
- [79]. Wang B, Liu K, Zhao J. Conditional generative adversarial networks for commonsense machine comprehension[C]// International Joint Conference on Artificial Intelligence. AAAI Press, 2017.
- [80]. Denton E, Chintala S, Szlam A, et al. Deep Generative Image Models using a Laplacian Pyramid of Adversarial Networks[J]. 2015.
- [81]. 李洋, 肖泽青, 聂松松, 等. 生成对抗网络及其在新能源数据质量中的应用研究综述[J]. 南方电网技术, 2020, 014(002):25-33.
- [82]. T. Salimans, I. Goodfellow, W. Zaremba, et al. “Improved techniques for training gans,” in Advances in Neural Information Processing Systems, 2016, pp. 2226–2234.
- [83]. X. Chen, Y. Duan, R. Houthoof, et al. “Infogan: Interpretable representation learning by information maximizing generative adversarial nets,” in Advances in Neural Information Processing Systems, 2016.
- [84]. Xiang S, Li H. On the effect of Batch Normalization and Weight Normalization in Generative Adversarial Networks[J]. 2017.
- [85]. Odena, Augustus. Semi-supervised learning with generative adversarial networks. arXiv preprint arXiv:1606.01583, 2016.
- [86]. Mescheder L, Nowozin S, and Geiger A. Adversarial Variational Bayes: Unifying Variational Autoencoders and Generative Adversarial Networks[J]. 2017.
- [87]. Goodfellow I. NIPS 2016 Tutorial: Generative Adversarial Networks[J]. 2016.
- [88]. C. Li, H. Liu, C. Chen, et al. “Towards understanding adversarial learning for joint distribution matching,” in Advances in Neural Information Processing Systems, 2017.
- [89]. Creswell A, White T, Dumoulin V, et al. Generative Adversarial Networks: An Overview[J]. IEEE Signal Processing Magazine, 2017, 35(1):53-65.
- [90]. Donahue J, Krähenbühl, Philipp, et al. Adversarial Feature Learning[J]. 2016.
- [91]. C. K. Sønderby, J. Caballero, L. Theis, et al. “Amortised map inference for image super-resolution,” in International Conference on Learning Representations, 2017.
- [92]. Han Z, Tao X, Li H, et al. StackGAN: Text to Photo-Realistic Image

-
- Synthesis with Stacked Generative Adversarial Networks[C]// 2017 IEEE International Conference on Computer Vision (ICCV). 2016.
- [93].Mirza M, Osindero S. Conditional Generative Adversarial Nets[J]. Computer Science, 2014:2672-2680.
- [94].Mao X, Li Q, Xie H, et al. Least Squares Generative Adversarial Networks[J]. 2016.
- [95].A. Radford, L. Metz, and S. Chintala, “Unsupervised representation learning with deep convolutional generative adversarial networks,” in Proceedings of the 5th International Conference on Learning Representations (ICLR) - workshop track, 2016.
- [96].Akbari M, Liang J. Semi-Recurrent CNN-based VAE-GAN for Sequential Data Generation[J]. 2018.
- [97].Im D J, Kim C D, Jiang H, et al. Generating images with recurrent adversarial networks[J]. 2016.
- [98].Mou L, Ghamisi P, Zhu X X. Deep Recurrent Neural Networks for Hyperspectral Image Classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7):3639-3655.
- [99].Wu J, Zhang C, Xue T, et al. Learning a Probabilistic Latent Space of Object Shapes via 3D Generative-Adversarial Modeling[J]. 2016.
- [100].Gulrajani I, Ahmed F, Arjovsky M, et al. Improved Training of Wasserstein GANs[J]. 2017.
- [101].Lipton Z C, Tripathi S. Precise Recovery of Latent Vectors from Generative Adversarial Networks[J]. 2017.
- [102].Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4):640-651.
- [103].林家骏, 诸葛晶晶, 张晴. 基于像素级生成对抗网络的复杂场景灰度图像彩色化[J]. 计算机辅助设计与图形学学报, 2019, 31(03):93-100.
- [104].M. Heusel, H. Ramsauer, T. Unterthiner, et al. GANs trained by a two time-scale update rule converge to a local nash equilibrium. In Advances in Neural Information Processing Systems, pages 6626–6637, 2017. 6,7
- [105].Gurumurthy S, Sarvadevabhatla R K, Babu R V. DeLiGAN: Generative Adversarial Networks for Diverse and Limited Data[C]// IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2017.
- [106].Upadhyay Y, Schrater P. Generative Adversarial Network Architectures For Image Synthesis Using Capsule Networks[J]. 2018.
- [107].Xie J, Zhu S C, Wu Y N. Synthesizing Dynamic Patterns by Spatial-Temporal Generative ConvNet[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017:1061-1069.
- [108].Creswell A, Bharath A A. Inverting The Generator Of A Generative Adversarial Network[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016.
- [109].Junyu Luo, Yong Xu, Chenwei Tang, and Jiancheng Lv. Learning inverse mapping by autoencoder based generative adversarial nets. In Derong Liu,

-
- Shengli Xie, Yuanqing Li, Dongbin Zhao, and El-Sayed M. El-Alfy, editors, *Neural Information Processing*, pages 207–216, Cham, 2017. Springer International Publishing.
- [110].Ho J, Ermon S. Generative Adversarial Imitation Learning[J]. 2016.
- [111].Lorenzo P R, Nalepa J, Ramos L S, et al. Hyper-parameter selection in deep neural networks using parallel particle swarm optimization[C]// the Genetic and Evolutionary Computation Conference Companion. ACM, 2017.
- [112].Lu F, Mo D, Gao M. Particle swarm optimization algorithm for parameter estimation in Gamma-Poisson distribution model of k-tree distance[J]. *Computational Ecology & Software*, 2015.
- [113].Zhou J, Fang R, Li Y, et al. Parameter optimization of nonlinear grey Bernoulli model using particle swarm optimization[J]. *Applied Mathematics and Computation*, 2009, 207(2):292-299.
- [114].马军杰, 尤建新, 陈震, 等.基于改进粒子群优化算法的灰色神经网络模型[J]. *同济大学学报(自然科学版)*, 2012, 40(5):740-743.
- [115].Huo Q, Tang G, Zhang F. Particle Swarm Optimization for Great Enhancement in Semi-supervised Retinal Vessel Segmentation with Generative Adversarial Networks[M]// *Machine Learning and Medical Engineering for Cardiovascular Health and Intravascular Imaging and Computer Assisted Stenting*. 2019.
- [116].Lu N, Zhou J, He Y, et al. Particle Swarm Optimization for Parameter Optimization of Support Vector Machine Model[C]// *Intelligent Computation Technology and Automation*, 2009. ICICTA '09. Second International Conference on. IEEE, 2009.
- [117].R. C. Eberhart, J. Kennedy, “A new optimizer using particle swarm theory”, *Sixth international symposium on micro machine and human science*, pp. 39-43, 1995.
- [118].R. C. Eberhart, Y. Shi, “Particle swarm optimization: developments, applications and resources”, *Proceedings of the 2001 congress on evolutionary computation*, vol. 1, pp. 81-86, 2001.
- [119].Tharwat A, Hassanien A E. Quantum-Behaved Particle Swarm Optimization for Parameter Optimization of Support Vector Machine[J]. *Journal of Classification*, 2019.
- [120].Wang H B, Hou Y, Wang X. The particle swarm optimization based parameters determination for Gaussian mixture model[J]. 2011.
- [121].崔海青,刘希玉. 基于粒子群算法的 RBF 网络参数优化算法[J]. *计算机技术与发展*(12):117-119.
- [122].周慧.基于粒子群算法的最优值求解[J].*科技广场*, 2017, 000(012):32-34.
- [123].董延胜.粒子群算法在神经网络参数优化中的应用[D].河南科技大学. 2009.
- [124].Niu X, Qiu Y, Tong S, et al. Application of particle swarm system as a novel parameter optimization technique on spatiotemporal retina model[J]. *Conference proceedings: Annual International Conference of the IEEE*

-
- Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference, 2007, 2007:5795-5798.
- [125].岳恒, 张海军, 柴天佑. 基于混合粒子群算法的 RBF 神经网络参数优化[J]. 控制工程, 2006(06):17-21.
- [126].唐贤伦, 庄陵, 李银国, et al. 混合粒子群优化算法优化前向神经网络结构和参数[J]. 计算机应用研究, 2007(12):97-99.
- [127].高海兵, 高亮, 周驰, et al. 基于粒子群优化的神经网络训练算法研究[J]. 电子学报, 2004, 32(9):1572-1574.
- [128].贺永春.基于粒子群优化算法的径向基神经网络[J]. 榆林学院学报, 2018, v.28; No.138(04):18-21.
- [129].何勇, 李妍琰. 改进粒子群优化 BP 神经网络的洪水智能预测模型研究[J]. 西南师范大学学报(自然科学版), 2014(05):80-85.
- [130].张梅, 魏欣, 张贵红. 粒子群优化神经网络的体育动作识别[J]. 现代电子技术, 2016, 39(19):49-52.
- [131].王雪冬, 李广杰, 尤冰, et al. 基于粒子群优化 BP 神经网络的巷道位移反分析[J]. 煤炭学报, 2012, 37(S1):38-42.
- [132].何明慧, 徐怡, 王冉, et al. 改进的粒子群算法优化神经网络及应用[J]. 计算机工程与应用, 2018, 54(19):113-119+134.
- [133].李磊, 高雷阜, 赵世杰. 基于神经网络的粒子群算法优化 SVM 参数问题[J]. 计算机工程与应用, 2015, 51(4):162-164.
- [134].Dai Y, Liu L, Wang S. Parameter Optimization of Ant Colony Algorithm Based on Particle Swarm Optimization[C]// Information Computing and Automation - The International Conference. 2008.
- [135].Jenn-Long L, Chao-Chun C. Novel Orthogonal Momentum-Type Particle Swarm Optimization Applied to Solve Large Parameter Optimization Problems[J]. Journal of Artificial Evolution and Applications, 2008, 1(6088):9.
- [136].Bamakan S M H, Wang H, Ravasan A Z. Parameters Optimization for Nonparallel Support Vector Machine by Particle Swarm Optimization[J]. Procedia Computer Science, 2016, 91:482-491.
- [137].Guo Y C. An integrated PSO for parameter determination and feature selection of SVR and its application in STL[C]// Machine Learning and Cybernetics, 2009 International Conference on. IEEE, 2009.
- [138].Chen X. A Novel Classification Approach Based on Support Vector Machine and Adaptive Particle Swarm Optimization Algorithm[C]// International Symposium on Knowledge Acquisition & Modeling. IEEE, 2008.
- [139].Lin S W, Chen S C, Wu W J, et al. Parameter determination and feature selection for back-propagation network by particle swarm optimization[J]. Knowledge & Information Systems, 2009, 21(2):249-266.
- [140].李岩, 袁弘宇, 于佳乔, 等. 遗传算法在优化问题中的应用综述[J]. 山东工业技术, 2019, 290(12):186+248-249.
- [141].吴景龙, 杨淑霞, 刘承水. 基于遗传算法优化参数的支持向量机短期负荷预测方法[J]. 中南大学学报:自然科学版, 2009(01):184-188.

-
- [142].刘靖洁, 陈桂明, 刘小方, et al. 基于遗传算法的SVM参数组合优化[J]. 计算机应用与软件, 2012(04):100-102+106.
- [143].李雅梅, 贺西. 基于遗传算法参数优化支持向量机的应用研究[J]. 2013.
- [144].刘虎, 罗斌, 吴晟,等. 改进的遗传算法在 SVM 参数优化中的应用[J]. 云南师范大学学报:自然科学版, 2012(4):47-51.
- [145].Mao W, Liu Y, Ding L, et al. Imbalanced fault diagnosis of rolling bearing based on generative adversarial network: a comparative study[J]. IEEE Access, 2019:9515-9530.
- [146].E. Ramentol, Y. Caballero, R. Bello, and F. Herrera, "SMOTE-RSB: A hybrid preprocessing approach based on oversampling and undersampling for high imbalanced data-sets using SMOTE and rough sets theory," *Knowl. Inf. Syst.*, vol. 33, no. 2, pp. 245–265, 2012.
- [147].M. Gao, X. Hong, S. Chen, and C. J. Harris, "A combined SMOTE and PSO based RBF classifier for two-class imbalanced problems," *Neurocomputing*, vol. 74, no. 17, pp. 3456–3466, 2011.
- [148].W. Mao, L. He, Y. Yan, and J. Wang, "Online sequential prediction of bearings imbalanced fault diagnosis by extreme learning machine," *Mech. Syst. Signal Process.*, vol. 83, pp. 450–473, Jan. 2017.
- [149].F. Jia, Y. Lei, N. Lu, and S. Xing, "Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization," *Mech. Syst. Signal Process.*, vol. 110, pp. 349–367, Sep. 2018.
- [150].J.-M. Yin, M. Yang, and J.-W. Wan, "A kernel Fisher linear discriminant analysis approach aiming at imbalanced data set," *Pattern Recognit. Artif. Intell.*, vol. 23, no. 3, pp. 414–420, 2010.
- [151].Y. Sun, M. S. Kamel, A. K. C. Wong, and Y. Wang, "Cost-sensitive boosting for classification of imbalanced data," *Pattern Recognit.*, vol. 40, no. 12, pp. 3358–3378, 2007.
- [152].H. Xiong, Y. Yang, and S. Zhao, "Local clustering ensemble learning method based on improved AdaBoost for rare class analysis," *J. Comput. Inf. Syst.*, vol. 8, no. 4, pp. 1783–1790, 2012.
- [153].Liang X, Hu Z, Zhang H, et al. Recurrent topic-transition GAN for visual paragraph generation[C]// 2017 IEEE International Conference on Computer Vision (ICCV). IEEE, 2017.
- [154].Fedus W, Goodfellow I, Dai A M. MaskGAN: Better text generation via filling in the _____. [J]. 2018.
- [155].王德文, 杨凯华. 基于生成式对抗网络的窃电检测数据生成方法[J]. 电网技术, 2020, 44(2).
- [156].王哲, 刘梓健, 邱宇. 人工智能技术在电力系统故障诊断中的应用研究[J]. 电子设计工程, 2020, 28(02):148-151.
- [157].J. R. Birge and F. Louveaux, *Introduction to stochastic programming*. Springer Science & Business Media, 2011.
- [158].S. Mitra, "Scenario generation for stochastic programming," *OPTIRISK*

-
- systems, Tech. Rep., 2006.
- [159]. T. Wang, H.-D. Chiang, and R. Tanabe, "Toward a flexible scenario generation tool for stochastic renewable energy analysis," in 2016 Power Systems Computation Conference (PSCC), 2016, pp. 1–7.
- [160]. J. E. B. Iversen and P. Pinson, "RESGen: Renewable energy scenario generation platform," in Proceedings of IEEE PES General Meeting, 2016.
- [161]. G. Papaefthymiou, P. Schavemaker, L. Van der Sluis, W. Kling, D. Kurowicka, and R. Cooke, "Integration of stochastic generation in power systems," *International Journal of Electrical Power & Energy Systems*, vol. 28, no. 9, pp. 655–667, 2006.
- [162]. P. Pinson, H. Madsen, H. A. Nielsen, G. Papaefthymiou, and B. Klockl, "From probabilistic forecasts to statistical scenarios of short-term wind power production," *Wind energy*, vol. 12, no. 1, pp. 51–62, 2009.
- [163]. X.-Y. Ma, Y.-Z. Sun, and H.-L. Fang, "Scenario generation of wind power based on statistical uncertainty and variability," *IEEE Transactions on Sustainable Energy*, vol. 4, no. 4, pp. 894–904, 2013.
- [164]. K. Høyland and S. W. Wallace, "Generating scenario trees for multistage decision problems," *Management Science*, vol. 47, no. 2, pp. 295–307, 2001.
- [165]. A. Papavasiliou, S. S. Oren, and R. P. O'Neill, "Reserve requirements for wind power integration: A scenario-based stochastic programming framework," *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 2197–2206, 2011.
- [166]. J. M. Morales, R. Minguez, and A. J. Conejo, "A methodology to generate statistically dependent wind speed scenarios," *Applied Energy*, vol. 87, no. 3, pp. 843–855, 2010.
- [167]. 曹周键, 王赫, 朱建阳. 深度学习在引力波数据处理中的应用初探[J]. 河南师范大学学报(自然科学版), 2018, 046(002):26-39.
- [168]. David B, Li J U, Chunnong Z, et al. Gravitational wave astronomy: the current status[J]. 中国科学:物理学力学天文学(英文版), 2015, 058(012):3-43.
- [169]. 何泊杉. 引力波的产生及性质探究[J]. 产业与科技论坛, 2019, 018(007):77-78.
- [170]. 杨子龙. 密近双星系统的引力波探测[J]. 中国科技纵横.
- [171]. 陈琨, 蔡志鸣, 侍行剑, et al. 用于引力波关键技术验证的近地低成本商业卫星设计[J]. 中国光学, 2019, 12(3):477-485.
- [172]. 赵宗华. 引力波事件 GW150914 的弱等效原理研究[D]. 2017.
- [173]. 胡一鸣. LIGO 发现引力波:一个新时代的起点[J]. 自然杂志, 2016, 38(2):79-86.
- [174]. 朱宗宏, 王运永. 引力波的预言、探测和发现[J]. 物理, 2016, v.45(05):300-310.

致谢

时光似剑，短短两年的博士后生涯已经画上了圆满的句号。清华大学的学术氛围非常好，给予了我很好的研究环境。感谢合作导师吉老师和曹老师的指导和教诲，以及在生活上的帮助。感谢课题组同事的合作交流。在清华大学做博士后的两年将会给我以后的教学和研究工作提供不少的帮助和启发。此外，还要感谢支持我工作的父母和姐姐。

博后期间的成果

论文：

1. J. CAO, W. Zhang, Z. Xiao, and H. Hua*. “Reactive power optimization for transient voltage stability in energy Internet via deep reinforcement learning approach,” *Energies*, 12(8), Art.no.1556, 2019.
2. 肖泽青, 华昊辰, 曹军威*. 人工智能在能源互联网中的应用综述. 电力建设, 40(5):63-70,2019.
3. 李洋, 肖泽青*, 聂松松, 曹军威, 华昊辰. 生成对抗网络及其在新能源数据质量中的应用研究综述. 南方电网技术, 14(2): 25-33, 2020.
4. Zeqing Xiao, Junwei Cao*. “Generating vibration signal data with swarm intelligence-optimized generative adversarial networks,” ICDIS2020, accepted.

专著：

5. 曹军威, 华昊辰, 郭健, 肖泽青, 杨洁, 袁仲达, 明阳阳, 梁宏, 王同贺. 《电力物联网概论》, 中国电力出版社, 2020.

获奖：

6. 中文核心论文“人工智能在能源互联网中的应用综述”获得《电力建设》2019年度优秀论文奖。