

序列数据的数据增强方法综述

葛轶洲^{1,2}, 许翔³⁺, 杨锁荣³, 周青^{1,2}, 申富饶³

1. 通信信息控制和安全技术重点实验室, 浙江 嘉兴 314033
 2. 中国电子科技集团公司 第三十六研究所, 浙江 嘉兴 314033
 3. 计算机软件新技术国家重点实验室(南京大学), 南京 210023
- + 通信作者 E-mail: xux@smail.nju.edu.cn

摘要:为了追求精度,深度学习模型框架的结构越来越复杂,网络越来越深。参数量的增加意味着训练模型需要更多的数据。然而人工标注数据的成本是高昂的,且受客观原因所限,实际应用时可能难以获得特定领域的的数据,数据不足问题非常常见。数据增强通过人为地生成新的数据增加数据量来缓解这一问题。数据增强方法在计算机视觉领域大放异彩,让人们开始关注类似方法能否应用在序列数据上。除了翻转、裁剪等在时间域进行增强的方法外,也描述了在频率域实现数据增强的方法;除了人们基于经验或知识而设计的方法以外,对一系列基于GAN的通过机器学习模型自动生成数据的方法也进行了详细的论述。介绍了应用在自然语言文本、音频信号和时间序列等多种序列数据上的数据增强方法,亦有涉及它们在医疗诊断、情绪判断等问题上的表现。尽管数据类型不同,但总结了应用在这些类型上的数据增强方法背后的相似的设计思路。以这一思路为线索,梳理应用在各类型序列数据类型上的多种数据增强方法,并进行了一定的讨论和展望。

关键词:序列数据;数据增强;深度学习

文献标志码:A **中图分类号:**TP391

Survey on Sequence Data Augmentation

GE Yizhou^{1,2}, XU Xiang³⁺, YANG Suorong³, ZHOU Qing^{1,2}, SHEN Furao³

1. Science and Technology on Communication Information Security Control Laboratory, Jiaxing, Zhejiang 314033, China
2. No.36 Research Institute, China Electronics Technology Group Corporation, Jiaxing, Zhejiang 314033, China
3. State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023, China

Abstract: To pursue higher accuracy, the structure of deep learning model is getting more and more complex, with deeper and deeper network. The increase in the number of parameters means that more data are needed to train the model. However, manually labeling data is costly, and it is not easy to collect data in some specific fields limited by objective reasons. As a result, data insufficiency is a very common problem. Data augmentation is here to alleviate the problem by artificially generating new data. The success of data augmentation in the field of computer vision leads people to consider using similar methods on sequence data. In this paper, not only the time-domain methods such as flipping and cropping but also some augmentation methods in frequency domain are described. In addition to experience-based or knowledge-based methods, detailed descriptions on machine learning models used for automatic

基金项目:国家自然科学基金(61876076)。

This work was supported by the National Natural Science Foundation of China (61876076).

收稿日期:2020-12-16 **修回日期:**2021-03-02

data generation such as GAN are also included. Methods that have been widely applied to various sequence data such as text, audio and time series are mentioned with their satisfactory performance in issues like medical diagnosis and emotion classification. Despite the difference in data type, these methods are designed with similar ideas. Using these ideas as a clue, various data augmentation methods applied to different types of sequence data are introduced, and some discussions and prospects are made.

Key words: sequence data; data augmentation; deep learning

深度学习在计算机视觉、自然语言处理等多个机器学习的子领域上均取得了耀眼的成绩,这归功于越来越庞大复杂的神经网络模型。以图像分类任务为例,解决这类问题的网络层数由2012年的8层增加到如今的101层,甚至有人尝试过1 202层的卷积神经网络(convolutional neural network, CNN)^[1]。神经网络层数的增加,意味着待学习参数数量的增加。为了学习更多的参数,就需要更多的训练数据。当前效果最好的自然语言处理模型GPT-3,其参数量达到了1 700亿,为此需要45 TB的数据进行训练^[2]。尽管GPT-3的情况较为极端,但想要将最先进的模型应用到一个现实任务时,经常面临数据不足的问题,数据增强技术应运而生。

“数据增强”一词还没有一个统一的定义,数据增强可以认为是基于少量样本构造出更多样本以扩充数据量的方法。以数据增强技术应用最广泛的计算机视觉任务为例,通过对一张图片进行旋转(rotations)、翻转(flipping)、裁剪(cropping)等操作,就可以把一张图片“增强”成至少四张图片。若对数据集中的所有图片都进行类似的操作,该数据集可以增加至原来的四倍。

数据增强一般被认为是在训练数据集上实施的操作,在训练前进行。可以选择先对数据集整体进行操作,再把增强后的数据集送入整个机器学习流程的后续部分,这种方法被称为线下增强(offline augmentation)。这种方法会显式地增加数据集的大小,只适用于数据较少的情况。更为常用的是线上增强(online augmentation),对即将送入到模型的每一批(batch)数据执行转换,不必显式地占用磁盘空间。现有的机器学习框架实现的图片增强方法大多为线上增强方法,并基于GPU进行加速^[3]。本文介绍的针对序列数据的数据增强大多采用线下增强方法。本文将先介绍针对序列数据的数据增强的基础方法,再介绍基于深度学习的数据增强方法。

1 序列数据增强的基础方法

不同于图像数据,序列数据的样本间具有时序关系,因此对序列数据进行增强时要特别关注新生成样本间的时序关系。序列数据的类型很多,如连续取值的时间序列数据、离散取值的文本数据、音频数据等。尽管数据类型不同,但应用的数据增强方法背后有共通的设计思路,例如翻转、拉伸或添加噪声等。

本章主要介绍在各类序列数据上通用的基于人们的直观经验设计的数据增强基础方法。图1^[4](a)展示了一个原始的时间序列,本章将基于此展示部分方法的效果。

1.1 几何变换

几何变换(geometric transformations)是最简单和常用的数据增强方法,如变换取值维度的翻转、缩放(scaling)或变换时间维度的窗口规整(window warping)^[4]等,分别如图1(b)~(d)所示。图中蓝色虚线是原始序列,红色实线是变换序列(下同)。类似“翻转”方法也可以应用在时间维度上,被称作时间镜像操作^[5]。窗口规整、下采样(down sampling)^[6]等操作会改变序列长度,可能需要引入额外操作来保持整体长度不变。

应用不同几何变换会产生不同的结果。例如,对于异常检测任务,缩放操作可能会将异常值缩放到正常范围内,窗口规整就不会;窗口规整或下采样操作可能会丢失异常点;翻转操作不适合预测任务,因为操作彻底改变了原序列的趋势。总而言之,几何变换方法相对简单、直观,易于结合具体任务分析不同操作的合理性,但每次只对一个序列进行操作,没有考虑数据集整体的分布特点。

1.2 窗口裁剪

对序列数据进行裁剪,被称为窗口裁剪(window cropping)或窗口切片(window slicing)^[4],通过一个滑动窗口在序列上不断滑动取样,生成多个长度更短的新序列。可将新序列拉长到与原序列长度相同,

如图 1(e)所示;或在采样过程中引入随机性,只保留部分新序列。将这种方法应用在异常检测任务时要小心异常点是否被裁去。

对于自然语言文本,类似的做法是随机删除(random deletion)^[7]。针对文本数据的很多数据增强方法会改变文本长度,但自然语言模型对于文本长度并不敏感,长度的变化不影响数据进入后续的训练流程。

1.3 添加噪声

在训练数据中添加噪声被认为是防止机器学习模型过拟合的有效手段。对于数值型序列数据,可以对每一个取值随机地添加一定的噪声来生成新的序列^[4,8],且不影响序列的整体性质和标签信息,如图 1(f)所示。最常被用来添加的噪声是高斯噪声(Gaussian noise)。

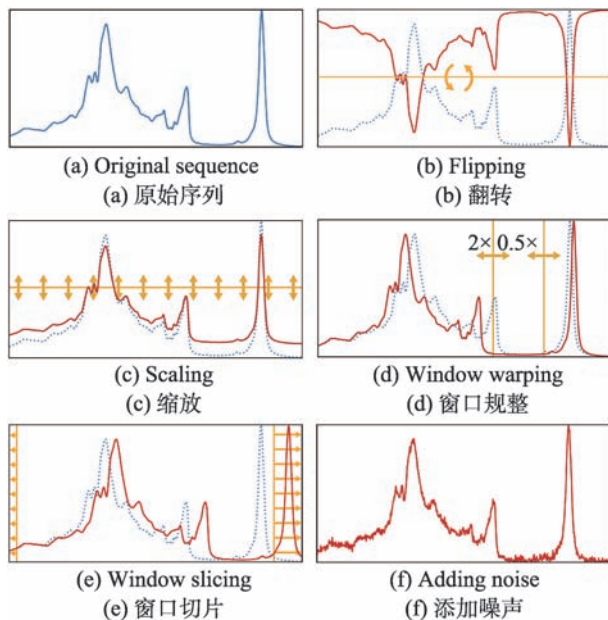


Fig.1 Data augmentation methods applied on time series
图 1 在时间序列上应用的一些数据增强方法

除时间域外,频率域也可实现类似操作。时间域上的序列经过傅里叶变换后可以得到其在频率域的振幅谱(amplitude spectrum)和相位谱(phase spectrum)。在振幅谱上随机选择区间,用基于原始振幅的统计参数重新生成一段信号替换,如图 2(b)所示;在相位谱上随机选择区间并添加白噪声(white noise),如图 2(c)所示。在时间域对比用这种方法的前后效果如图 2(a)所示。这种方法不改变序列的整体性质。

噪音也可添加到音频上模拟嘈杂的环境^[10],常用

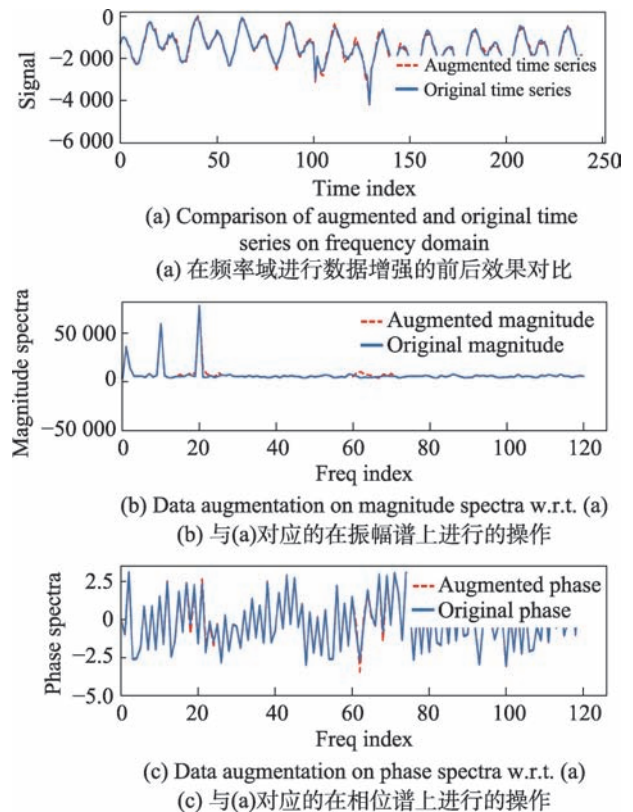


Fig.2 Data augmentation on frequency domain
图 2 在频率域进行数据增强

信噪比(signal to noise ratio, SNR)量化。

也可向自然语言文本添加噪音,如用一个双向语言模型来生成新词,以替换原始文本中某个单词^[11]。基于语言模型产生的单词可以保证文本中的语法、语义等信息不被破坏。一个简化版本是用同义词替换的方法替代上述的语言模型^[7],将过程简化为查表,降低计算量。相关方法还有随机交换(random swap)和同义词的随机插入(random insertion)。这两种方法连同前述的随机删除和同义词替换方法,被统一命名为EDA(easy data augmentation)方法^[7],已被证明在文本分类上有效,但相对本文后续方法而言EDA的数据生成过程较为机械。

1.4 在频率域变换

时频变换是常见的信号分析思路,同样可用于数据增强。在频率域添加噪声是方法之一。

有研究者首先对传感器信号应用短时傅里叶变换(short Fourier transform, STFT)得到具有时序关系的谱特征,再在谱特征上应用两种数据增强方法^[12]。一是对每一个属性做局部平均,将局部平均序列并

接在原始序列的后面;二是打乱时序顺序(shuffling),以增加数据的方差。这种方法会使得数据尺寸发生变化。由于STFT变换得到的谱特征仍然具有时序关系,这种数据增强方法也被认为是在时间-频率域上进行的。

赋值调整傅里叶变换(amplitude adjusted Fourier transform, AAFT)^[13]及其衍生的IAAFT(improved amplitude adjusted Fourier transform)^[14]可实现只在频率域进行数据增强。Lee等人将这些方法应用在信号分类上,可以令原本只有约45%~60%的准确率提高到80%以上^[15]。这类方法很好地保留了时域和频域特征,但不适合短周期信号。

对于音频数据,SpecAugment^[16]是一种在时间-频率域上做数据增强的方法,在信号的对数梅尔频谱(log Mel spectrogram)上操作。图3^[16](a)展示了一段信号的对数梅尔频谱,频谱图的横轴是时间轴,纵轴是频率大小。在时间轴上,可以进行时间规整(time warping)或时间掩蔽(time masking),分别如图3(b)和图3(c)。时间规整是在序列中随机选择一个时间点,拉伸该点之前(之后)的信号,压缩该点之后(之前)的信号,保证序列的长度不发生改变;时间掩蔽是在整个序列中用指定值填充一随机片段。在频率轴也可以进行类似的掩蔽操作,形成图3(d)的效果,被称为频率掩蔽(frequency masking)。实验证明该方

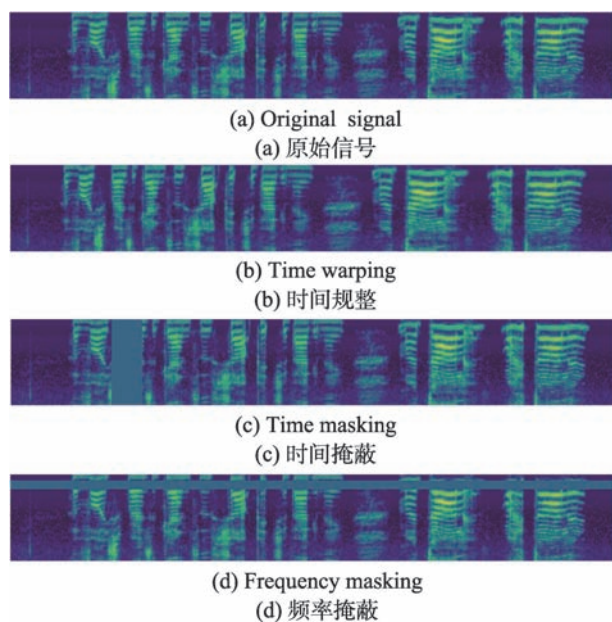


Fig.3 Data augmentation on log Mel spectrogram
图3 对信号的对数梅尔频谱图进行数据增强

法在语音识别任务上可以显著降低字错误率(word error rate, WER)。上述方法都是针对单个序列做数据增强,生成的效率更高,但只利用序列本身的性质,没有考虑数据集整体的分布。

1.5 基于分解或混合的方法

研究时间序列的一种常见思路是用STL(seasonal and trend decomposition using Loess)^[17]方法将序列分解为基础项、趋势项、季节项和残差项,前三者是确定性部分,包含了原序列的绝大部分信息。为了在新序列中保持这部分信息,Kegel等人基于相似矩阵(similarity matrix)和最近邻搜索等方法为不同成分分配权重,组合新的时间序列^[18]。随机的残差项则利用其分布特征和自相关特征重新建模生成。

Bergmeir等人的方法更为简单。对时间序列信号进行分解后得到除趋势项和季节项以外的剩余项(reminder)。对剩余项进行有放回的重复采样(bootstrap),可以得到新的剩余项序列,再和前两者混合成新的时间序列^[19]。这种方法很好地保留了原始时间序列所具有的性质。在M3数据集^[20]上的实验证明这种方法在月频数据上对预测精度的提升最为突出,但在长度较短的序列数据上表现一般。

二者相比,第一种方法以数据集为单位产生新的序列,第二种方法以序列为单位产生新的序列。第一种方法更能利用数据集整体的分布特征来进行数据增强,避免出现使用第二种方法可能会发生的对不典型的序列进行增强的情况。

混响(reverberation)可以看作是在音频数据上一种基于混合的数据增强方法。混响一词本身描述的是在如音乐厅、礼堂等地发生的室内声波经过多次反射和吸收而产生的一种声音现象,在计算机上可以通过混合多个不同强度且具有一定时间差的声音序列来模拟混响效果,用于数据增强^[21]。相比于SpecAugment,混响以数据集为单位生成新的数据,但是并没有学习和利用数据之间的内在关系。弥补这一缺点的是后续的基于深度学习的模型。

1.6 异常标签扩展

异常标签扩展(label expansion)是一种仅针对异常检测任务的数据增强方法。出于类别平衡的目的,人们想要增加数量较少的异常标签的数量。Gao等人利用了异常的模糊性和持续性,将与已经标注为异常的数据点在时间上和属性取值上都接近的点

也标注成异常点,来达到增加异常数据点的目的。图4^[9]对比了原始序列数据和异常标签扩展后的数据。这种方法操作方便,在雅虎数据集^[22]上的实验证明了该方法的有效性。

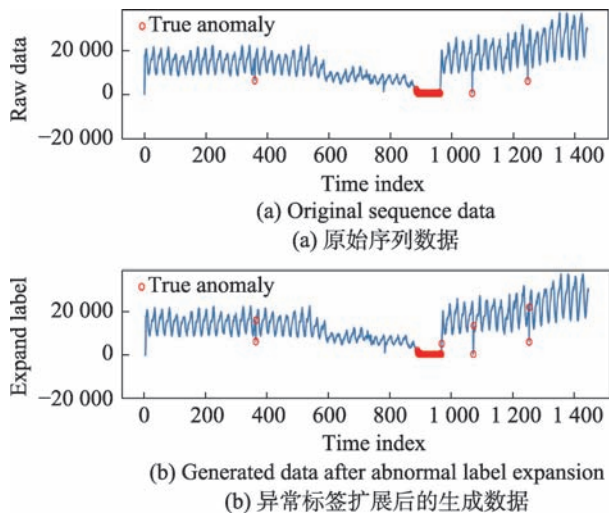


Fig.4 Abnormal label expansion

图4 异常标签扩展

2 基于深度学习的序列数据增强方法

使用数据增强方法是避免模型在较小的原始数据集上发生过拟合。如果像中小学的教辅材料那样对难题进行重点突破,可以构造出模型学不好的数据,让模型显式地在这些数据上也进行学习,就有可能提高模型的“答题能力”,从而取得更好的精度或准确度。基于生成对抗网络(generative adversarial network, GAN)的一系列方法即出于此目的,生成人类无法分辨但可以让模型判断错误的的数据。

生成对抗网络最先应用在计算机视觉领域,应用在序列数据上的方法可以看作是这些方法的扩展。因此,本章会介绍一些应用在图像数据上的研究成果,帮助读者更好地理解这类基于深度学习的数据增强方法。

2.1 生成式对抗网络

生成式对抗网络直接生成能“以假乱真”的与训练数据非常接近的新数据。Goodfellow 等人在2014年提出的GAN^[23]是后续深度卷积GAN(deep convolutional generative adversarial network, DCGAN)^[24]、CycleGAN^[25]等各类衍生结构的基础。GAN由生成器(generator)和判别器(discriminator)组成,如图5^[26]

所示。判别器判断样本是原始数据集的还是模型生成的,而生成器尽可能地最大化判别器判断错误的概率,整个模型的优化是一个二元极大极小博弈(mini-max two-player game)。如今神经网络已经成为了生成器和判别器的默认选择,整个GAN的优化都通过反向传播来实现。

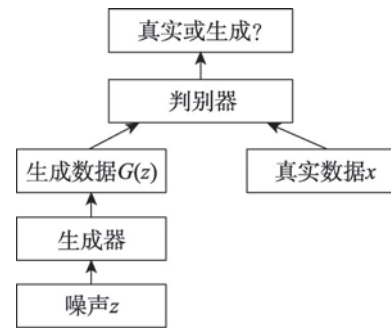


Fig.5 Generative adversarial network

图5 生成式对抗网络

生成器把一个简单的分布映射到一个和真实数据集相近的复杂分布,这一简单的分布可以视作一种隐分布。如果同时得到把复杂分布映射回一种隐分布的方法,这种方法就可以被用来做特征表示,双向GAN(bidirectional GAN, BiGAN)^[27]就是出于此目的而被发明的一种无监督方法。其学习到的特征表示不仅可以用作后续监督学习模型的输入,从数据增强的角度,GAN也可以在这个特征空间生成新的数据,而不一定在原始的输入空间生成。有人认为GAN是最值得期待能用于数据增强的生成式建模方法^[28]。

2.2 基于CNN的GAN

DCGAN^[24]利用了CNN的特征提取能力,条件GAN(conditional GAN, CGAN)^[29]则同时在生成器和判别器引入额外的条件输入,让模型生成指定标签的数据。也有人设计不同的损失函数应用在GAN结构上,具体实现有CycleGAN^[25]、StarGAN及其变体^[30]等。

后续会介绍将RNN(recurrent neural network)和GAN结合起来应用在序列数据上的方法。尽管RNN及其变种被认为是处理序列数据的默认选择,但实验证明CNN在处理序列数据方面的能力并不亚于RNN,还拥有可以并行化等优点,用基于CNN的GAN来生成序列数据自然而然地成为了一个选择。基于CGAN的时间条件GAN(time-conditional GAN, T-CGAN)^[31]是在GAN上使用一维卷积的工作之一,将时间戳作

为条件输入使模型可以处理时间间隔不规则的情形。同样使用了一维卷积的 ehrGAN^[32]被用于增强电子健康记录数据,半监督学习的引入让生成样本和原始样本的类别更有可能一致。也有人尝试将RNN和CNN结合起来用在生成对抗网络:BiLSTM-CNN GAN^[33]将RNN用于生成器,将CNN用于判别器。RNN生成时间序列可以充分利用时序依赖性,基于前一刻的值决定下一刻的值;用CNN做判别器可以在不影响准确度的基础上通过并行化加快判别速度。

对于音频数据,有人参考在频率域进行数据增强的方法,将频谱图看作图片,用DCGAN生成新的频谱图,如SpecGAN^[34]。将DCGAN扩展到一维的情况,直接对音频信号应用一维CNN得到WaveGAN。在不同的评价标准下,SpecGAN和WaveGAN二者各有优劣^[6]。SpecGAN更能充分利用数据间的内在关系,WaveGAN简化了增强流程,生成的数据和原始数据更加相似。不过二者都只能生成1s左右的短音频,离实际应用仍有差距。

字词天生的离散特性为GAN应用在自然语言处理任务上增加了难度。前述方法往往只针对实值的、具有连续特征的数据。生成字词的最后一步是选择最大可能性的单词,这一argmax操作是不可导的。若直接利用现有的语言生成模型作为生成器,整个模型无法反向传播判别器计算的损失。一种方法是引入自编码器(auto-encoder),利用GAN生成其中的连续的编码表示^[35]。不过性能优良的自编码器需要大量的真实语料做训练,与进行数据增强的目的相悖。

2.3 基于RNN的GAN

类比于DCGAN和CGAN,有研究者将RNN引入GAN设计出循环GAN(recurrent GAN, RGAN)和循环条件GAN(recurrent conditional GAN, RCGAN)^[36],生成实值的多维时间序列数据,如图6^[36]所示。RGAN在每一时间点都根据不同的随机数种子生成一个随机值,交给生成器生成一段时间序列;判别器在每一时间点都给出一个关于当前时间序列是否为真实序列的判断,最后通过投票机制得到判别结果。RCGAN在此基础上引入条件输入。在医学领域的二分类问题上,尽管使用RGAN生成的数据进行训练并没有直接使用真实数据训练的效果好,但是考虑到医学领域的很多数据难以获得等现实问题,这种方法仍然具有其应用价值。

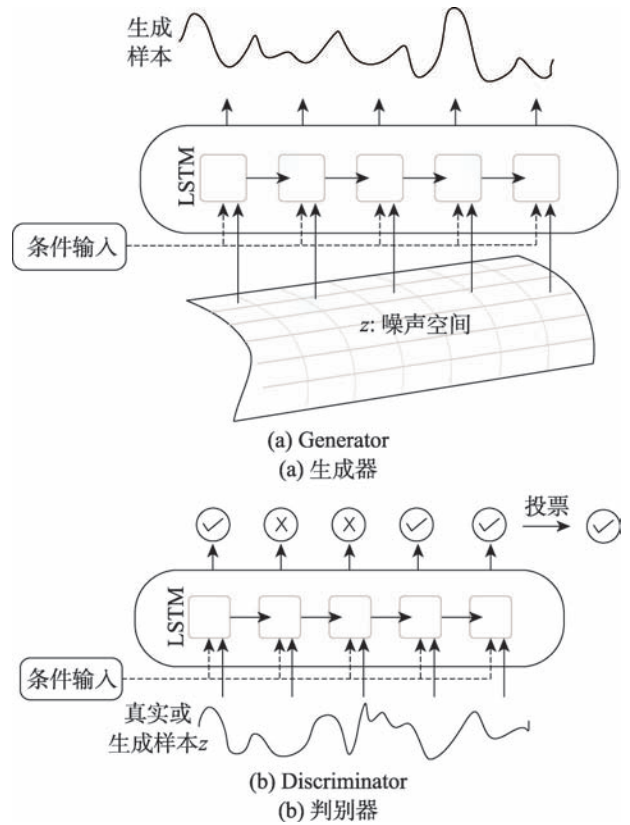


Fig.6 RGAN and RCGAN
图6 RGAN和RCGAN

时间序列GAN(time-series GAN, TimeGAN)^[37]则在基于RNN的GAN的基础上引入可学习的嵌入空间(embedding space),用监督学习和对抗学习共同训练。用有监督的损失函数指导模型学习,可以让模型学习到每一时间点的条件分布,而不是只让模型判断每一个序列的真假;嵌入网络用来降低对抗学习空间的维度。在股票、能源等多个数据集上的实验表明TimeGAN显著优于RCGAN等模型,其中TimeGAN的有监督的损失函数、嵌入网络和共同训练这三点都发挥了非常重要的作用。

在实际应用中,一个数据集可能包含从多种分布产生的时间序列。可以将数据分成多个子集,对每一个子集应用一个GAN来生成符合具有这一部分子集特点的数据,最后将所有GAN生成的数据汇总起来。这种使用多个GAN的方法的有效性在多种数据集上被验证^[38-39],但会引入较大计算量。

基于RNN的GAN在音频数据上的应用多集中在音乐生成任务上。音乐被视为是离散的符号序列,同样会面对与用GAN生成自然语言文本类似的

不可导问题。为了解决这一问题,在生成器和判别器都使用了RNN的C-RNN-GAN^[40]将每一时刻的音乐特征化为了连续值,SeqGAN^[41]则引入了强化学习的策略梯度方法,但只在生成器使用RNN。用于人声和伴奏分离任务的G-RNN-GAN^[42]将判别器简化成了多层感知机。简单的结构有助于提高模型效率,但是该方法的作者并没有证明使用多层感知机的充分性,判别器的性能提升空间仍有待探索。DCRGAN(deep convolutional recurrent generative adversarial network)^[43]是将RNN结构的生成器用于语音增强任务的一例,而判别器使用CNN。相比于CNN,RNN在音频数据上的应用很少且多只在生成器上应用,判别器使用CNN等可以并行化的结构有助于提高判别效率。

增强自然语言文本同样存在不可导问题。前述

的引入自编码器的思路也可以在编码空间使用RNN生成和判别^[44],但相应的缺陷依然存在。有人提出了更为简单的方法,用可导的Gumbel-Softmax函数替代原来的argmax操作^[45]。这种方法有对现有模型的修改小,“即插即用”的优点,但只被证明在简单符号序列上有效。整体而言,用GAN做语料生成的技术并不成熟,距离工业应用有一定差距。

3 总结与讨论

3.1 总结

本文以应用在不同序列数据上的增强方法背后的共同点为线索,介绍了在时间序列、音频、自然语言等多种序列数据上进行数据增强的方法,分别如表1~表3所示。这些方法更多地适用于分类问题,而应用在其他任务上的数据增强方法还有待更多的研究。

Table 1 Comparison of augmentation methods for time series

表1 时间序列数据的数据增强方法比较

方法	描述	优缺点	适用场景
几何变换、窗口裁剪、添加噪声等基础方法	翻转、缩放、窗口规整 ^[9] 、时间镜像 ^[5] 、下采样 ^[6] 、窗口切片 ^[4] 、在时间域或频率域添加噪声 ^[8] 等	简单直观,方便判断标签的保持性,但未考虑数据集整体的分布特点	通用
异常标签扩展 ^[9]	将与实际异常点在时间和属性取值上都接近的点也标注成异常点	操作方便,但仅针对异常检测任务	运维数据
文献[12]	一是对特征数据进行局部平均作下采样,二是打乱时序顺序	数据尺寸会发生变化,方法的通用性有待后续研究	可穿戴设备传感器信号
AAFT、IAAFT ^[15]	对傅里叶变换后的数据在振幅谱上进行调整	可以很好地保留时域和频域特征,但傅里叶变换应用在短周期信号上会损失信息	医疗时间序列
FBG ^[18]	将序列分解为不同成分,再为不同成分分配权重,组合新的时间序列	基于特征集的方法可以生成更相似的样本,但特征的选取和特征数据集的制作需要进一步研究	通用
Bagged.BLD.MBB.ETS ^[19]	有放回地重复采样剩余项,和趋势项与季节项混合	以序列为单位产生新的序列,在长度较短的序列数据上表现一般	通用
T-CGAN ^[31]	使用一维卷积的CGAN,条件输入是时间戳,时间戳可以是间隔不等的	可以针对时间间隔不规则的情况	通用
ehrGAN ^[32]	用一维卷积GAN生成医疗时间序列,引入了半监督学习	半监督学习让生成样本和原始样本的类别更有可能一致	医疗时间序列
BiLSTM-CNN GAN ^[33]	将RNN用于生成器,CNN用于判别器	RNN充分利用了时序依赖性,CNN可以加快判别速度,是应用创新,模型本身的创新点不明显	心电图
RGAN、RCGAN ^[36]	生成器和判别器都使用RNN结构,后者还引入了条件输入	并行化程度不足,只强调在医疗领域的应用,有待探索模型的通用性	医疗时间序列
TimeGAN ^[37]	基于RNN,用可学习的嵌入网络降低对抗学习空间的维度,引入监督学习让模型学习到每一时刻的条件分布	结合了无监督范式和有监督训练对数据生成的约束作用,不只是判断数据真假,生成的数据关注了时间步之间的时序关系	通用
混合多个GAN ^[38]	用多个GAN,每一个生成特定标签的数据	数据生成有针对性,可基于严重不平衡的数据集生成,但计算量大	医疗时间序列
应用DisturbLabel ^[48] 的方法 ^[47,49]	对标签做数据增强,随机修改一部分标签	方法新颖,但在序列数据上的应用研究有待继续探索	通用

Table 2 Comparison of augmentation methods for audio data

表2 音频数据的增强方法比较

方法	描述	优缺点	适用场景
添加噪音 ^[10]	添加高斯噪音模拟嘈杂环境	简单直观	通用
SpecAugment ^[16]	在时间-频率域的频谱上操作,包含时间规整/掩蔽、频域掩蔽	简单但操作的单位是单个序列,不是整个数据集,未考虑整体分布特点	语音识别
混响 ^[21]	混合不同强度且有时间差的声音序列	以数据集为单位进行增强,但没有学习和利用原始数据间的内在关系	语音识别
SpecGAN ^[34]	把频谱图看成图片,用DCGAN生成新的频谱图	生成式模型利用了数据间的内在关系,但只能生成1s左右的短音频	通用
WaveGAN ^[34]	直接使用一维的DCGAN	增强流程的简化令生成质量更高,但内在关系的利用不够充分,生成数据和原始数据看起来更相似	通用
C-RNN-GAN ^[40]	生成器和判别器都使用RNN,将每一时刻的音乐特征化为连续值	避免了离散的音乐符号带来的不可导问题,但使用双向LSTM的判别器不能并行化	音乐
SeqGAN ^[41]	将音乐建模成离散特征的词向量,用策略梯度方法学习整个模型	用强化学习方法解决不可导问题,但调参复杂,结果不稳定且效率低	音乐
G-RNN-GAN ^[42]	生成器使用多层RNN,判别器使用简单的多层感知机	简单的模型结构提高了模型的效率,但有待探索判别器的性能提升空间	人声和伴奏分离
DCRGAN ^[43]	结合使用了CNN和LSTM,后者用于提取长时信息	判别器只使用CNN提高了判别效率	语音增强
GANs for children ^[53]	在该任务中GAN反而优于CGAN	说明数据增强方法的好坏没有统一标准,效果取决于具体任务	儿童语音识别

Table 3 Comparison of augmentation methods for text data

表3 文本数据的增强方法比较

方法	描述	优缺点	适用场景
EDA ^[7]	随机删除/插入/交换/同义词替换	简单但较为机械	文本分类
单词替换 ^[11]	用双向语言模型生成替换词	不破坏语法语义关系且保持标签不变,但额外模型引入计算量	通用
LaTextGAN ^[35]	基于自编码器在连续的特征编码空间上增强,网络结构是CNN	避免了不可导,但训练自编码器需要大规模语料,与数据增强目的相悖	通用
PSGAN ^[44]	基于自编码器在连续的特征编码空间上增强,网络结构是RNN		搜索引擎
Gumbel-Softmax ^[45]	用可导函数替换原来的argmax	可直接替换现有模型的softmax函数,但只被证明在简单的符号序列上有效	简单符号序列
文献[60]			
TextGAIL ^[61]	利用强化学习方法解决不可导问题的思路	结果更精确合理,但存在鲁棒性差、调参困难等强化学习固有的缺点	通用
CTGAN ^[62]			

3.2 在测试集上应用数据增强方法

数据增强方法一般被应用在训练数据集上,实际也可以应用在测试数据集上,实现类似于集成学习的方法。这样的方法被称为测试时间的数据增强(test-time augmentation),用以和常见的训练时间的

数据增强(train-time augmentation)相区别。

例如在时间序列分类任务中,对一个原始序列应用窗口切片方法得到多个序列,分别预测这些序列的标签,再投票决定原始序列的标签输出^[4]。在通用的UCI数据集上的实验表明了该方法的有效性。类

似的方法也被应用在医学领域^[46-47],减少了以高置信度输出错误答案的情况。这类方法可以帮助模型输出更好的不确定性估计,但是会显著增加测试时间。

3.3 标签上应用数据增强方法

不同于常见的对输入数据变换的增强方法,DisturbLabel^[48]是对标签进行修改,在训练过程中的每一轮引入小部分标签被故意改错的数据。尽管这种做法是反直觉的,但这种方法被证明在心电图数据^[47]和调制信号^[49]等多个序列数据的分类任务中有效。在信噪比较高时DisturbLabel的效果最好。不过整体而言这种方法应用在序列数据上的情况较少,有待后续研究探索更多在序列数据上的应用。

3.4 用数据增强方法缓解数据不平衡问题

如果在使用数据增强方法时指定生成那些原始数据量较少的类的样本,数据增强方法可以用来缓解数据不平衡的问题。前述的异常标签扩展方法就是为了增加样本数量较少的异常数据而设计的。CycleGAN被用来生成情绪分类(emotion classification)数据中出现次数较少的情绪标签,使得分类任务的精度提升5%~10%^[50];GAN的一个变种对抗自编码器(adversarial autoencoder,AAE)^[51]被应用在异常检测任务中生成不频繁但是正常的的数据点,帮助异常检测算法更好地判断哪些是真正的异常点^[52]。这同时也证明了数据增强技术可以应用在无监督任务中并取得不错的效果。在这些例子中,GAN一类的方法可以看成是一种聪明的过采样的方法。

3.5 数据增强可能导致数据标签发生改变

在做数据增强时需要特别留心的一点,是使用增强方法后新得到的数据的训练目标(如分类标签)是否和原始数据一致。比如在异常检测任务中应用裁剪方法可能会将异常点裁剪出序列,此时序列的标签应是一个正常序列。不改变训练目标的数据增强方法被称为“标签保持的变换”(label-preserving transformation)^[28]。而当使用的方法不满足这一条件时,可能需要人工重新标注新生成的数据,这时需要平衡数据增强的效果和人工标注的成本。

3.6 数据增强方法的好坏没有统一标准

本篇文章所提及的数据增强方法大多适用于分类任务,对于其他任务的研究则相对匮乏。数据增强方法的好坏不能一概而论,具体应使用的方法取决于具体任务。例如,尽管CGAN是基于GAN衍生

出来的,且实验证明在许多任务上CGAN是优于GAN的,但Sheng等人针对儿童语音识别任务的研究^[53]发现,平均来看GAN反而优于CGAN^[4]。有研究者基于具体任务研究不同数据增强方法的优劣,或设计多种评价标准来评价方法的好坏,具体可以参考文献^[54]。

使用数据增强算法本身往往伴随着内存、训练时间等资源开销的增加,使用数据增强方法时应平衡任务效果的提升和引入的资源开销。另外,本文提及的各类数据增强方法可以组合使用,进而提升数据增强的效果,这已被多个研究证明^[55-56]。即使是同一个增强方法也可以在同一批数据上重复使用。图7^[12]展示了一个对序列数据进行数据增强的流程例,其中局部平均这一方法被重复使用了两次。

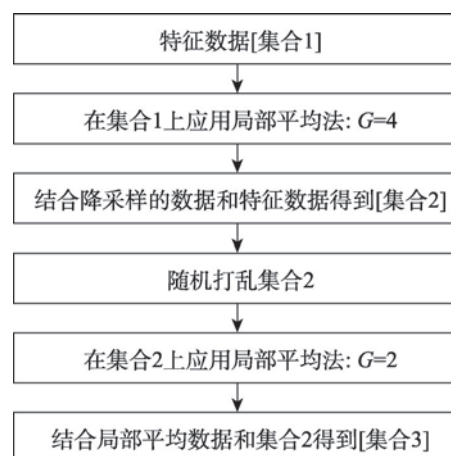


Fig.7 Flow chart of data augmentation on sequence data
图7 对序列数据进行数据增强的流程图

3.7 医学数据是数据增强常见的应用领域

不难发现,无论是序列数据,还是图片数据,数据增强研究和应用最为广泛的往往是医疗领域的数据^[15,32-33,36,38,56-57]。一些疾病的诊断依赖于专业医生在体征信号中根据时序关系的异常来发现,但由于保护患者隐私、商业竞争等原因,医学数据往往是匮乏的。GAN等方法不是简单地对现有的数据进行复制,因此基于GAN来生成相关的人造的医疗数据不仅可以起到增加训练数据的作用,共享相关的生成数据也不会侵犯个人隐私。这也是GAN被广泛应用在医疗数据上的一个原因。

3.8 将强化学习应用于数据增强

随着强化学习的兴起,出现了基于强化学习进

行数据增强的工作。强化学习模型通过与环境的不断交互,可以自己挑选出最优的数据增强方法^[58]或组合出最优的数据增强流程^[59]。

回顾增强文本数据或音乐数据时出现的不可导问题,强化学习解决不可导问题的方法给这一问题的解决提供了思路,如Hu等人的方法^[60]、TextGAIL(text generative adversarial imitation learning)^[61]、CTGAN(conditional text generative adversarial network)^[62]等。不过强化学习方法本身的鲁棒性差、调参困难等问题尚未得到解决,应用到数据增强时这些问题依然存在,相关方法还有很大的探索空间。

4 展望

基于深度学习的数据增强是当今机器学习领域研究最为火热的子领域之一,还有非常多的问题供研究者们探索,如结合元学习(meta-learning)和数据增强^[63],结合神经网络结构在特征空间进行数据增强,用强化学习方法来增强数据等。在讨论部分简单介绍了在测试阶段或对标签信息进行数据增强的方法,这方面的更多研究成果也值得期待。

有人可能认为数据增强技术更像是一个应用问题,依赖于深度学习技术的发展而无法给深度学习的理论研究带来帮助。事实上一些数据增强方法对于效果提升的帮助的原因还不清楚,了解其背后作用的机理不仅有助于人们更好地使用、设计数据增强方法,也可能帮助人们更深入地理解CNN等神经网络结构,提高神经网络的可解释性。

参考文献:


- [1] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Jun 26-Jul 1, 2016. Washington: IEEE Computer Society, 2016: 770-778.
- [2] BROWN T B, KAPLAN J, MANN B, et al. Language models are few-shot learners[J]. arXiv:2005.14165, 2020.
- [3] PASZKE A, GROSS S, MASSA F, et al. PyTorch: an imperative style, high-performance deep learning library[C]//Proceedings of the Annual Conference on Neural Information Processing System, Vancouver, Dec 8-14, 2019: 8026-8037.
- [4] IWANA B K, UCHIDA S. An empirical survey of data augmentation for time series classification with neural networks[J]. arXiv:2007.15951, 2020.
- [5] ZHU K F, WANG J G, LIU Y J. Radar target recognition algorithm based on data augmentation and WACGAN with a limited training data[J]. Acta Electronica Sinica, 2020, 48(6): 1124-1131.
朱克凡, 王杰贵, 刘有军. 小样本条件下基于数据增强和WACGAN的雷达目标识别算法[J]. 电子学报, 2020, 48(6): 1124-1131.
- [6] WEN Q S, SUN L, SONG X M, et al. Time series data augmentation for deep learning: a survey[J]. arXiv:2002.12478, 2020.
- [7] WEI J, ZOU K. EDA: easy data augmentation techniques for boosting performance on text classification tasks[J]. arXiv:1901.11196, 2019.
- [8] ZHOU Y Z, ZHA X Y, LAN J, et al. Transient stability prediction of power systems based on deep residual network and data augmentation[J]. Electric Power, 2020, 53(1): 22-31.
周艳真, 查显煜, 兰健, 等. 基于数据增强和深度残差网络的电力系统暂态稳定预测[J]. 中国电力, 2020, 53(1): 22-31.
- [9] GAO J K, SONG X M, WEN Q S, et al. RobustTAD: robust time series anomaly detection via decomposition and convolutional neural networks[J]. arXiv:2002.09545, 2020.
- [10] MCFEE B, HUMPHREY E J, BELLO J P. A software framework for musical data augmentation[C]//Proceedings of the 16th International Society for Music Information Retrieval Conference, Málaga, Oct 26-30, 2015. International Society for Music Information Retrieval, 2015: 248-254.
- [11] KOBAYASHI S. Contextual augmentation: data augmentation by words with paradigmatic relations[J]. arXiv:1805.06201, 2018.
- [12] STEVEN EYOBU O, HAN D S. Feature representation and data augmentation for human activity classification based on wearable IMU sensor data using a deep LSTM neural network[J]. Sensors, 2018, 18(9): 2892.
- [13] THEILER J, EUBANK S, LONGTIN A, et al. Testing for nonlinearity in time series: the method of surrogate data[J]. Physica D: Nonlinear Phenomena, 1992, 51(8): 77-94.
- [14] SCHREIBER T, SCHMITZ A. Improved surrogate data for nonlinearity tests[J]. Physical Review Letters, 1996, 77(4): 635.
- [15] LEE T K M, KUAH E Y L, LEO K H, et al. Surrogate rehabilitative time series data for image-based deep learning[C]//Proceedings of the 27th European Signal Processing Conference, A Coruña, Sep 2-6, 2019. Piscataway: IEEE, 2019: 1-5.
- [16] PARK D S, CHAN W, ZHANG Y, et al. SpecAugment: a simple data augmentation method for automatic speech recognition[J]. arXiv:1904.08779, 2019.

- [17] CLEVELAND R B, CLEVELAND W S, MCRAE J E, et al. STL: a seasonal-trend decomposition procedure based on Loess[J]. *Journal of Official Statistics*, 1990, 6(1): 3-33.
- [18] KEGEL L, HAHMANN M, LEHNER W. Feature-based comparison and generation of time series[C]//*Proceedings of the 30th International Conference on Scientific and Statistical Database Management, Bozen-Bolzano, Jul 9-11, 2018*. New York: ACM, 2018: 1-12.
- [19] BERGMEIR C, HYNDMAN ROB J, BENÍTEZ JOSÉ M. Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation[J]. *International Journal of Forecasting*, 2016, 32(2): 303-312.
- [20] MAKRIDAKIS S, HIBON M. The M3-competition: results, conclusions and implications[J]. *International Journal of Forecasting*, 2000, 16(4): 451-476.
- [21] KHARITONOV E, RIVIRE M, SYNNAEVE G, et al. Data augmenting contrastive learning of speech representations in the time domain[J]. arXiv:2007.00991, 2020.
- [22] LAPTEV N, AMIZADEH S, FLINT I. Generic and scalable framework for automated time-series anomaly detection[C]//*Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Sydney, Aug 10-13, 2015*. New York: ACM, 2015: 1939-1947.
- [23] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems, Montreal, Dec 8-13, 2014*. New York: ACM, 2014: 2672-2680.
- [24] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. arXiv:1511.06434, 2015.
- [25] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//*Proceedings of the 2017 IEEE International Conference on Computer Vision, Venice, Oct 22-29, 2017*. Piscataway: IEEE, 2017: 2223-2232.
- [26] ZHANG A, LIPTON Z C, LI M, et al. Dive into deep learning[EB/OL]. [2020-11-10]. <https://d2l.ai>.
- [27] DONAHUE J, KRÄHENBÜHL P, DARRELL T. Adversarial feature learning[J]. arXiv:1605.09782, 2016.
- [28] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. *Journal of Big Data*, 2019, 6: 60.
- [29] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. arXiv:1411.1784, 2014.
- [30] SUN X, DING X L. Data augmentation method based on generative adversarial networks for facial expression recognition sets[J]. *Computer Engineering and Applications*, 2020, 56(4): 115-121.
孙晓, 丁小龙. 基于生成对抗网络的人脸表情数据增强方法[J]. *计算机工程与应用*, 2020, 56(4): 115-121.
- [31] RAMPONI G, PROTOPAPAS P, BRAMBILLA M, et al. T-CGAN: conditional generative adversarial network for data augmentation in noisy time series with irregular sampling[J]. arXiv:1811.08295, 2018.
- [32] CHE Z P, CHENG Y, ZHAI S F, et al. Boosting deep learning risk prediction with generative adversarial networks for electronic health records[C]//*Proceedings of the 2017 IEEE International Conference on Data Mining, New Orleans, Nov 18-21, 2017*. Washington: IEEE Computer Society, 2017: 787-792.
- [33] ZHU F, YE F, FU Y C, et al. Electrocardiogram generation with a bidirectional LSTM-CNN generative adversarial network[J]. *Scientific Reports*, 2019, 9(1): 6734.
- [34] DONAHUE C, MCAULEY J, PUCKETTE M. Adversarial audio synthesis[J]. arXiv:1802.04208, 2018.
- [35] DONAHUE D, RUMSHISKY A. Adversarial text generation without reinforcement learning[J]. arXiv:1810.06640, 2018.
- [36] HYLAND S L, ESTEBA C, RÄTSCH G. Real-valued (medical) time series generation with recurrent conditional GANs[J]. arXiv:1706.02633, 2017.
- [37] YOON J, JARRETT D, VAN DER SCHAAR M. Time-series generative adversarial networks[C]//*Proceedings of the Annual Conference on Neural Information Processing Systems, Vancouver, Dec 8-14, 2019*: 5509-5519.
- [38] NIKOLAIDIS K, KRISTIANSEN S, GOEBEL V, et al. Augmenting physiological time series data: a case study for sleep apnea detection[C]//*LNCS 11908: Proceedings of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases, Würzburg, Sep 16-20, 2019*. Berlin, Heidelberg: Springer, 2019: 376-399.
- [39] WEI X, LI J, SUN X, et al. Cross-view image generation via mixture generative adversarial network[J/OL]. *Acta Automatica Sinica*[2021-01-24]. <https://doi.org/10.16383/j.aas.c190743>.
卫星, 李佳, 孙晓, 等. 基于混合生成对抗网络的多视角图像生成算法[J/OL]. *自动化学报*[2021-01-24]. <https://doi.org/10.16383/j.aas.c190743>.
- [40] MOGREN O. C-RNN-GAN: continuous recurrent neural networks with adversarial training[J]. arXiv:1611.09904, 2016.
- [41] LEE S, HWANG U, MIN S, et al. Polyphonic music genera-

- tion with sequence generative adversarial networks[J]. arXiv:1710.11418, 2017.
- [42] ZHANG H, XIAO N N, LIU P S, et al. G-RNN-GAN for singing voice separation[C]//Proceedings of the 5th International Conference on Multimedia Systems and Signal Processing, Chengdu, May 28-30, 2020. New York: ACM, 2020: 69-73.
- [43] HUANG H X, WU R J, HUANG J B, et al. DCCRGAN: deep complex convolution recurrent generator adversarial network for speech enhancement[J]. arXiv:2012.10732, 2020.
- [44] LU S Q, DOU Z C, JUN X, et al. PSGAN: a minimax game for personalized search with limited and noisy click data [C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, Paris, Jul 21-25, 2019. New York: ACM, 2019: 555-564.
- [45] KUSNER M J, HERNÁNDEZ-LOBATO J M. GANs for sequences of discrete elements with the Gumbel-softmax distribution[J]. arXiv:1611.04051, 2016.
- [46] WANG G T, LI W Q, AERTSEN M, et al. Test-time augmentation with uncertainty estimation for deep learning-based medical image segmentation[J]. arXiv:1807.07356, 2018.
- [47] YAO Q H, WANG R X, FAN X M, et al. Multi-class arrhythmia detection from 12-lead varied-length ECG using attention-based time-incremental convolutional neural network[J]. Information Fusion, 2020, 53: 174-182.
- [48] XIE L X, WANG J D, WEI Z, et al. DisturbLabel: regularizing CNN on the loss layer[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Jun 26-30, 2016. Washington: IEEE Computer Society, 2016: 4753-4762.
- [49] ZHENG Q H, ZHAO P H, LI Y, et al. Spectrum interference-based two-level data augmentation method in deep learning for automatic modulation classification[J]. Neural Computing and Applications, 2020: 1-23.
- [50] ZHU X Y, LIU Y F, LI J H, et al. Emotion classification with data augmentation using generative adversarial networks [C]//LNCS 10939: Proceedings of the 22nd Pacific-Asia Conference on Knowledge Discovery and Data Mining, Melbourne, Jun 3-6, 2018. Berlin, Heidelberg: Springer, 2018: 349-360.
- [51] MAKHZANI A, SHLENS J, JAITLY N, et al. Adversarial autoencoders[J]. arXiv:1511.05644, 2015.
- [52] LIM S K, LOO Y, TRAN N T, et al. DOPING: generative data augmentation for unsupervised anomaly detection with GAN[C]//Proceedings of the 2018 IEEE International Conference on Data Mining, Singapore, Nov 17-20, 2018. Washington: IEEE Computer Society, 2018: 1122-1127.
- [53] SHENG P Y, YANG Z L, QIAN Y M. GANs for children: a generative data augmentation strategy for children speech recognition[C]//Proceedings of the 2019 IEEE Automatic Speech Recognition and Understanding Workshop, Singapore, Dec 14-18, 2019. Piscataway: IEEE, 2019: 129-135.
- [54] TAYLOR L, NITSCHKE G. Improving deep learning with generic data augmentation[C]//Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence, Bangalore, Nov 18-21, 2018. Piscataway: IEEE, 2018: 1542-1547.
- [55] RASHID K M, LOUIS J. Times-series data augmentation and deep learning for construction equipment activity recognition[J]. Advanced Engineering Informatics, 2019, 42: 100944.
- [56] UM T T, PFISTER F M J, PICHLER D, et al. Data augmentation of wearable sensor data for Parkinson's disease monitoring using convolutional neural networks[C]//Proceedings of the 19th ACM International Conference on Multimodal Interaction, Glasgow, Nov 13-17, 2017. New York: ACM, 2017: 216-220.
- [57] HATAMIAN F N, RAVIKUMAR N, VESAL S, et al. The effect of data augmentation on classification of atrial fibrillation in short single-lead ECG signals using deep neural networks[C]//Proceedings of the 2020 IEEE International Conference on Acoustics, Speech and Signal Processing, Barcelona, May 4-8, 2020. Piscataway: IEEE, 2020: 1264-1268.
- [58] CUBUK E D, ZOPH B, MANÉ D, et al. AutoAugment: learning augmentation strategies from data[C]//Proceedings of the 2019 IEEE Conference on Computer Vision and Pattern Recognition, Long Beach, Jun 16-20, 2019. Piscataway: IEEE, 2019: 113-123.
- [59] MINH T N, SINN M, LAM H T, et al. Automated image data preprocessing with deep reinforcement learning[J]. arXiv:1806.05886, 2018.
- [60] HU Z T, TAN B W, SALAKHUTDINOV R, et al. Learning data manipulation for augmentation and weighting[C]//Proceedings of the Annual Conference on Neural Information Processing Systems, Vancouver, Dec 8-14, 2019: 15738-15749.
- [61] WU Q Y, LI L, YU Z. TextGAIL: generative adversarial imitation learning for text generation[J]. arXiv:2004.13796, 2020.

[62] CHEN J Y, WU Y Y, JIA C Y, et al. Customizable text generation via conditional text generative adversarial network[J]. Neurocomputing, 2020, 416: 125-135.

[63] PAL M, KUMAR M, PERI R, et al. Meta-learning with latent space clustering in generative adversarial network for speaker diarization[J]. arXiv:2007.09635, 2020.



葛轶洲(1988—),男,浙江绍兴人,硕士,高级工程师,主要研究方向为信号与信息处理。

GE Yizhou, born in 1988, M.S., senior engineer. His research interests include signal and information processing.



许翔(1998—),男,江苏东台人,硕士研究生,主要研究方向为神经网络、数据分析。

XU Xiang, born in 1998, M.S. candidate. His research interests include neural networks and data analysis.



杨锁荣(1996—),男,甘肃兰州人,硕士研究生,主要研究方向为数据增强、神经网络。

YANG Suorong, born in 1996, M.S. candidate. His research interests include data augmentation and neural networks.



周青(1973—),男,江西九江人,研究员,主要研究方向为通信信号处理。

ZHOU Qing, born in 1973, researcher. His research interest is communication signal processing.



申富饶(1973—),男,江苏泰州人,博士,教授,博士生导师,CCF会员,主要研究方向为神经计算、机器人智能。

SHEN Furao, born in 1973, Ph.D., professor, Ph.D. supervisor, member of CCF. His research interests include neural computing and robotic intelligence.

《计算机工程与应用》投稿须知

中国科技核心期刊、北大中文核心期刊、RCCSE核心学术期刊、中国科学引文数据库(CSCD)来源期刊、中国学术期刊综合评价数据库统计源期刊、中国科技论文与引文数据库统计源期刊、中文科技期刊数据库收录期刊、《中国学术期刊文摘》首批收录源期刊,被收录在英国《科学文摘》(SA/INSPEC)、俄罗斯《文摘杂志》(AJ)、美国《剑桥科学文摘》(CSA)、美国《乌利希期刊指南》(Ulrich's PD)、《日本科学技术振兴机构中国文献数据库》(JST)、波兰《哥白尼索引》(IC)、中国计算机学会会刊、中国期刊方阵双效期刊、中国精品科技期刊、工业和信息化部精品期刊、中国最具国际影响力学术期刊、中国百强科技期刊、中国期刊数字影响力100强,入选庆祝中华人民共和国成立70周年精品期刊展

《计算机工程与应用》是由中国电子科技集团公司主管,华北计算技术研究所主办的面向计算机全行业的综合性学术刊物。

办刊方针 坚持走学术与实践相结合的道路,注重理论的先进性和实用技术的广泛性,在促进学术交流的同时,推进科技成果的转化。覆盖面宽、信息量大、报道及时是本刊的服务宗旨。

报导范围 行业最新研究成果与学术领域最新发展动态;有独立和创新见解的学术报告;具有先进性和推广价值的工程方案;先进、广泛、实用的开发成果。

主要栏目 热点与综述,理论与研发,大数据与云计算,网络、通信与安全,模式识别与人工智能,图形图像处理,工程与应用,以及其他热门专栏。

投稿须知 为保护知识产权和国家机密,在校学生投稿必须先征得导师的同意,所有稿件应保证不涉及及侵犯他人知识产权和泄密问题,否则由此引起的一切后果应由作者本人负责。

论文要求 学术研究:报道最新研究成果,以及国家重点攻关项目和基础理论研究报告,要求观点新颖,创新明确,论据充实。技术报告:有独立和创新学术见解的学术报告或先进实用的开发成果,要求有方法、观点、比较和实验分析。工程应用:方案采用的技术应具有先进性和推广价值,对科研成果转化为生产力有较大的推动作用。

投稿格式 采用学术论文标准格式书写,要求文笔简练、流畅,文章结构严谨完整、层次清晰(包括标题、作者、单位、摘要、关键词、基金资助情况、所有作者简介(含通信作者电子信箱)、中图分类号、正文、参考文献等,其中前5项应有中、英文)。中文标题必须在20字内(可采用副标题形式)。正文中的图、表必须附有中英文图题、表题,公式要求用MathType编排。中文参考文献需有英文对照。论文字数根据论文内容需要,不做严格限制,对于一般论文建议7500字以上为宜。

投稿方式 请通过网站(<http://www.ceaj.org>)作者投稿,一栏投稿(首次投稿须注册)。