



(21) 申请号 202010802820.8

G06N 3/0464 (2023.01)

(22) 申请日 2020.08.11

G06N 3/08 (2023.01)

G06N 20/20 (2019.01)

(65) 同一申请的已公布的文献号

申请公布号 CN 111931851 A

(43) 申请公布日 2020.11.13

(73) 专利权人 辽宁工程技术大学

地址 123000 辽宁省阜新市细河区中华路
47号

(56) 对比文件

CN 109026563 A, 2018.12.18

CN 109299705 A, 2019.02.01

审查员 邵金

(72) 发明人 杨莹 沈学利 秦鑫宇 项海菊

(74) 专利代理机构 北京华夏正合知识产权代理

事务所(普通合伙) 11017

专利代理师 韩登营 张丽萍

(51) Int. Cl.

G06F 18/214 (2023.01)

G06F 18/24 (2023.01)

权利要求书1页 说明书8页 附图1页

(54) 发明名称

一种基于一维残差神经网络的风机叶片结
冰故障诊断方法

(57) 摘要

本发明公开了一种基于一维残差神经网络的风机叶片结冰故障诊断方法,包括:获取风力发电机的SCADA数据和叶片状态数据;通过标记标签、重采样、类间平衡和归一化对SCADA数据进行预处理;对预处理后的数据进行基于叶片结冰物理机制和XGBoost特征重要性计算选取与叶片结冰最相关的特征;构建一维残差神经网络;将特征重要度排序后递增特征维度比较一维残差神经网络模型诊断的准确率;利用测试集进行测试,评估模型的诊断性能。本发明利用一维卷积层自适应的提取特征并做出叶片结冰诊断,加入残差块加深网络的同时解决网络优化的过程中存在梯度消失和梯度爆炸的问题,具有更高的综合性能和泛化能力,具有较高的预测准确度,可以将除冰系统的效率提高到最大值。



1. 一种基于一维残差神经网络的风机叶片结冰故障诊断方法,其特征在于,包括以下步骤:

步骤1:获取风力发电机的SCADA数据和叶片状态数据;

步骤2:对上述SCADA数据进行标记数据标签、数据重采样、数据归一化和SMOTE过采样一系列预处理操作;

步骤3:对预处理后的数据进行基于叶片结冰物理机制和XGBoost特征重要性计算;

步骤4:构建一维残差神经网络;

步骤5:将特征重要度排序后递增特征维度比较一维残差神经网络模型诊断的准确率;

步骤6:利用测试集进行测试,评估模型的风叶结冰故障诊断性能;

在步骤2中,SCADA数据进行预处理,包括:

S21、根据叶片状态数据将SCADA数据进行标记,去除无效数据;

S22、通过进行重采样,对数据重新划分,对原始数据集进行每隔一分钟对数据进行重新采样,取每组样本数值的平均值作为新的样本特征;

S23、通过归一化处理来消除不同特征间数值的范围差异,提高模型的学习效率;

S24、通过对结冰样本进行SMOTE过采样方法,将结冰数据与正常数据比例设置约为1:

1;

在步骤3中,根据风叶结冰物理机制补充相关的特征,最后通过Xgboost算法进行特征选择。

一种基于一维残差神经网络的风机叶片结冰故障诊断方法

技术领域

[0001] 本发明属于风机叶片故障诊断的技术领域,尤其涉及一种基于一维残差神经网络的风机叶片结冰故障诊断方法。

背景技术

[0002] 近年来,由于不可再生能源的逐渐枯竭,风能作为一种可再生资源得到广泛的发展和利用。风力发电机作为风力发电的主要设备得到了广泛的应用,风机通常被安装在海上和偏远的高海拔陆地地区,以获得最大的风速和最小的利益冲突。但是这些地区湿度高温度低,风力发电机的叶片特别容易出现不同程度的结冰现象。风力发电机的叶片结冰会使叶片的气动外形、结构性能及载荷发生改变,从而导致一系列与结冰相关的问题,如能量的损失、风机故障、安全隐患和经济损失等。因此,为了保证风力发电机的正常运行以及降低维护成本,风叶早期结冰故障检测变得至关重要。

[0003] 现有技术中,一般采用基于安装额外传感器的方法,例如基于热遥感的结冰探测,通过采用热红外传感器测量叶片表面的辐射,由于冰与其他材料在辐射率方面存在差异,通过分析辐射值可以诊断叶片是否结冰。该方案增加了风机的安装及设计复杂度,并且产生了额外的维护成本,传感器的老化和故障也会影响信号的准确性。

[0004] 另外,基于传统机器学习的风机故障诊断首先需要对信号进行降噪和信号处理等预处理步骤,然后通过对风机故障的先验知识对其进行特征提取,将提取后的特征向量通过机器学习的方法进行故障诊断。机器学习方法包括:支持向量机(SVM)、随机森林(RF)、k近邻(KNN)等。然而,由于SCADA数据量大且信息复杂,特征选择的质量对模型诊断能力有着较大的影响,诊断模型往往无法有效利用这些特征,造成过拟合问题并且增加模型训练复杂度,影响模型诊断的准确率和泛化能力。

[0005] 基于深度神经网络(DNN)的风机叶片结冰诊断模型,该类模型基于风机的SCADA数据,对数据进行预处理和特征工程选择与结冰故障相关的特征,然后利用DNN建立风叶结冰故障诊断模型。但基于深度神经网络的方法在网络优化的过程中神经网络随着网络深度的增加,导致模型的训练困难和性能下降的问题。

发明内容

[0006] 基于以上现有技术的不足,本发明所解决的技术问题在于提供一种基于一维残差神经网络的风机叶片结冰故障诊断方法,通过对风机叶片结冰物理机制分析和SCADA数据可视化建立丰富的特征,基于XGBoost算法进行特征选取,挖掘更好表征叶片结冰的特征数据,减小特征选择中人为选择特征的不足,同时增强模型的诊断性能和泛化能力,实施简单,成本低。

[0007] 为了解决上述技术问题,本发明通过以下技术方案来实现:

[0008] 本发明提供一种基于一维残差神经网络的风机叶片结冰故障诊断方法,包括以下步骤:

- [0009] 步骤1:获取风力发电机的SCADA数据和叶片状态数据;
- [0010] 步骤2:对上述SCADA数据进行标记数据标签、数据重采样、数据归一化和SMOTE过采样一系列预处理操作;
- [0011] 步骤3:对预处理后的数据进行基于叶片结冰物理机制和XGBoost特征重要性计算;
- [0012] 步骤4:构建一维残差神经网络;
- [0013] 步骤5:将特征重要度排序后递增特征维度比较一维残差神经网络模型诊断的准确率;
- [0014] 步骤6:利用测试集进行测试,评估模型的风叶结冰故障诊断性能。
- [0015] 可选的,在步骤2中,SCADA数据进行预处理,包括:
- [0016] S21、根据叶片状态数据将SCADA数据进行标记;
- [0017] S22、通过进行重采样,对数据重新划分,对原始数据集进行每隔一分钟对数据进行重新采样,取每组样本数值的平均值作为新的样本特征;
- [0018] S23、通过归一化处理来消除不同特征间数值的范围差异,提高模型的学习效率。
- [0019] S24、通过对结冰样本进行SMOTE过采样方法,将结冰数据与正常数据比例设置约为1:1
- [0020] 可选的,在步骤3中,根据风叶结冰物理机制补充相关的特征,最后通过Xgboost算法进行特征选择。
- [0021] 由上,本发明通过对SCADA数据分析选择和生成的特征对原始特征进行粗过滤,然后通过XGBoost对特征重要性排序选择风叶结冰敏感的特征,增强模型的准确性和通用性。使用一维残差神经网络自适应提取有效的故障特征并作出预测,使用来自实际风电场的SCADA数据验证所提方法的综合性能。一维卷积层自适应的提取特征并做出叶片结冰诊断,加入残差块加深网络的同时解决网络优化的过程中存在梯度消失和梯度爆炸的问题,具有较高的综合性能和泛化能力。该方法可以利用深度学习强大的学习能力获得最佳的分类效果,具有较高的预测准确度和泛化能力,可以将除冰系统的效率提高到最大值。
- [0022] 本发明的基于一维残差神经网络的风机叶片结冰故障诊断方法具有如下有益效果:
- [0023] (1) 通过基于风机结冰物理机制的分析和基于XGBoost算法选择的特征作为训练诊断模型的输入特征,相较于原始特征,1DRes-CNN在基于XGBoost选择的特征上具有更好的风叶结冰诊断准确率。
- [0024] (2) 将一维卷积残差神经网络应用于叶片结冰故障诊断,利用一维卷积层自适应的提取特征并做出叶片结冰诊断,加入一维残差块加深网络的同时解决网络优化的过程中存在梯度消失和梯度爆炸的问题。
- [0025] (3) 减小风机叶片结冰故障诊断的成本以及方法实施复杂度。
- [0026] (4) 减小特征选择中人为特征选择的不足,同时增强模型的诊断性能和泛化能力
- [0027] (5) 在网络优化的过程中神经网络随着网络深度的增加,导致DNN的训练困难和性能下降的问题。
- [0028] 上述说明仅是本发明技术方案的概述,为了能够更清楚了解本发明的技术手段,而可依照说明书的内容予以实施,并且为了让本发明的上述和其他目的、特征和优点能够

更明显易懂,以下结合优选实施例,并配合附图,详细说明如下。

附图说明

[0029] 为了更清楚地说明本发明实施例的技术方案,下面将对实施例的附图作简单地介绍。

[0030] 图1为本发明的基于一维残差神经网络的风机叶片结冰故障诊断方法的流程图;

[0031] 图2为一维残差神经网络图。

具体实施方式

[0032] 下面结合附图详细说明本发明的具体实施方式,其作为本说明书的一部分,通过实施例来说明本发明的原理,本发明的其他方面、特征及其优点通过该详细说明将会变得一目了然。在所参照的附图中,不同的图中相同或相似的部件使用相同的附图标号来表示。

[0033] 如图1所示,本发明提出了一种基于XGBoost算法特征选择的一维残差神经网络(1DRes-CNN)的叶片结冰诊断方法,步骤如下:

[0034] 一、获取风力发电机的SCADA数据和叶片状态数据(叶片正常时间段和叶片故障时段)。

[0035] 本发明使用的SCADA数据集来源于国内某公司提供的WT A和WT B风力发电机SCADA数据集。每条数据包含26个变量,包括风机的工况(运行)参数、环境参数和状态参数。SCADA系统采样间隔为7秒。此外,此监测变量中,风速、发动机转速、网侧有功功率、温度等变量均经过人工加密处理,与真实数值不同,失去原始的物理意义。其中,WT A风机的数据量为393886条,正常数据369994条,结冰数据23892。WT B风机的数据量为190494条,正常数据179856,结冰数据10638条。

[0036] 二、对SCADA数据进行预处理,包括:数据标记、重采样处理、数据类间不平衡问题、数据归一化。将数据集划分为训练集和验证集。

[0037] 首先,根据叶片状态数据将SCADA数据进行标记:风叶结冰为正样本,标记为1,风叶正常为负样本,标记为0,剔除无效数据;然后通过进行重采样,对数据重新划分,对原始数据集进行每隔一分钟对数据进行重新采样,取每组样本数值的平均值作为新的样本特征;数据归一化处理,通过归一化处理来消除不同特征间数值的范围差异,提高模型的学习

效率,归一化公式如下所示:
$$X_{norm} = \frac{(X - X_{min})}{(X_{max} - X_{min})};$$
一般风叶正常数据远远多于风叶结冰数

据,属于类别不平衡问题,通过对结冰样本进行SMOTE(synthetic minority oversampling technique)过采样方法,将结冰数据与正常数据比例设置约为1:1。

[0038] 三、对预处理后的数据进行基于风机结冰物理机制分析和XGBoost特征重要性计算的特征工程。首先根据风叶结冰物理机制分析补充相关的特征,最后通过XGBoost算法进行特征选择。

[0039] a. 由于风机所处环境的特殊性,环境温度容易随时间发生较大的变化。这些变化将导致机舱温度发生变化。因此,为了消除环境温度变化的影响,环境温度减去机舱温度作为新的特征变量更容易区分风叶结冰与正常状态,得到的新特征记作:tmps。

[0040] b. 风速和功率是叶片结冰预测的主要特征。风机的实际输出功率可表示为:

$$[0041] \quad P = \frac{1}{2} \rho_a S C_p V^3$$

[0042] 式中, ρ_a ——空气密度; S ——叶片扫风面积; C_p ——风能利用率; V ——风速。

[0043] 正常情况下, C_p 与风机的叶尖速比和翼型升阻比的比值相关, 风机叶片覆冰会造成叶片翼型的空气动力学结构改变, 翼型升力减小, 阻力增大, 升阻比减小, 最终风机的风能利用率下降。同时, 风机叶片覆冰会导致直接叶片扫风面积的改变, 因此在一定的风速和空气密度条件下, 风机叶片结冰和风机P有明显的对应关系。

[0044] c. 风速和功率是叶片结冰预测的主要特征。当叶片处于非结冰情况下, 风机功率会遵循正常模式风机功率模型, 当发生结冰情况时, 风机功率会与正常模式风机功率发生偏差, 无法达到额定功率。通过强规则过滤掉此部分数据。然后通过最小二乘法对数据集的正常样本进行拟合得到正常功率曲线, 最后通过该基线模型预测在给定风速的情况下风机的功率输出。数据集中所有的样本得到对应风速下的预测输出功率与真实功率的偏离程度可以表示为:

$$[0045] \quad P = \frac{P_{pre} - P_{true}}{P_{pre}}$$

[0046] 式中, P_{pre} ——通过基线模型预测的功率, P_{true} ——风机输出的实际功率。

[0047] d. 风机叶片覆冰后风机叶片表面的粗糙程度以及风叶翼型的气动外形发生改变, 导致风机输出功率降低, 风速一定的情况下, 输出功率和风速的比值降低, 根据实际数据生成新的特征, 能够较好的表示叶片结冰的状态, 新特征记作Power_wind_speed。

[0048] e. 风力发电机为三叶片结构, 风机一般安装完成后会根据严格的重量和力矩配平校准, 使得叶片保持相对平衡的角度。由于结冰属于不确定因素, 每个叶片结冰程度不同, 可能会造成叶片重量和力矩的不平衡。然而, 此数据集中风机三个叶片的角度和速度数据分布相对一致, 难以从其中分辨结冰和不结冰的状态且容易造成模型过拟合, 因此将其均值作为新的特征, 分别记作: mean_pitch_angle、mean_pitch_speed。

[0049] f. 最后通过XGBoost进行特征选择。XGBoost可用于特征重要性选择, 算法构造增强树设计时, 通过获得特征得分来表明每个特征对训练模型的重要性。当一个特征被更多的用于增强树的关键决策, 其得分就越高。通过风机叶片结冰物理机制分析生成的特征与原始特征作为XGBoost算法的输入, 以获得得到数据的特征重要度, 重要度为特征划分树结点的次数, 每次划分时通过贪心法选择信息增益最大的特征作为分裂点, 信息增益的计算公式如下所示:

$$[0050] \quad Gain = \frac{1}{2} \left[\frac{g_l^2}{h_l^2 + \lambda} + \frac{g_r^2}{h_r^2 + \lambda} - \frac{(g_l + g_r)^2}{(h_l + h_r)^2 + \lambda} \right] - \gamma$$

[0051] 式中, g_ϕ ——损失函数的一阶导数, h_ϕ ——损失函数的二阶导数, λ 为 L_2 范式的系数, γ 表示收缩系数。

[0052] 四、构建一维残差神经网络(1DRes-CNN)

[0053] 一维残差神经网络(1DRes-cnn)在神经网络中加入残差块, 每个残差块由两层卷积层组成。加深网络层数以提高网络效率的同时避免原始特征的丢失(网络性能的衰减)。

[0054] 1DRes-CNN结构如图2所示, 模型输入为经过XGBoost算法选取的特征, 输出为1或0, 其中, 1表示叶片结冰, 0表示叶片正常。在该模型中, 卷积核的大小设置为 $3*1$, 卷积核的

数目为16。Dropout层的作用是按照一定比例随机丢弃一部分神经元和连接,该比例设置为0.25。由于叶片结冰诊断属于二分类问题,故损失函数选择交叉熵损失函数,具体步骤如下:

[0055] 采用一维卷积层来捕获数据信息流的局部序列特征。卷积层通过卷积核在输入数据进行滑动以提取其局部特征。神经网络输入数据可表示为 $x = [x_1, x_2 \cdots, x_n]$,其中n表示序列的长度。因此,卷积层的操作可表示为:

$$[0056] \quad x_i^l = f(w_i^l x^{l-1} + b_i^l)$$

[0057] 式中, $f(\cdot)$ —激活函数; b_i^l —偏置项; w_i^l —权重矩阵; x^{l-1} —第 $l-1$ 层的输出; x_i^l —第 l 层的第 i 个特征。

[0058] 残差网络处理步骤如下:

[0059] (1) 输入特征 x_1 ,经过残差模块中的第一个卷积层加权和激活函数操作输出 $F(x_1)$,如下式所示:

$$[0060] \quad F(x_1) = f(\omega_1 x_1 + b_1)$$

[0061] 式中, ω_1 —第一个卷积层的权重; b_1 —第一个卷积层的偏置; $f(\cdot)$ —ReLU激活函数。

[0062] ReLU激活函数 $f(\cdot)$ 表达公式如下:

$$[0063] \quad \varphi(x) = \max(0, x)$$

[0064] (2) 将 $F(x_1)$ 输入第二层卷积层得到输出如下式所示:

$$[0065] \quad F_1(x_1) = \omega_2 F(x_1) + b_2$$

[0066] 式中, ω_2 —第二个卷积层的权重; b_2 —第二个卷积层的偏置。

[0067] (3) 将 $F_1(x_1)$ 和 x_1 输入ReLU激活函数中,得到 $F_2(x_1)$,如下式所示:

$$[0068] \quad F_2(x_1) = f(F_1(x_1) + x_1)$$

[0069] 式中, $f(\cdot)$ —ReLU激活函数。

[0070] 网络训练通过BP算法反向传递误差,然后通过梯度下降法调整相关的参数。残差神经网络将输入 x_1 直接传到输出来拟合残差映射函数,只学习输入和输出之间的残差 $F_1(x_1)$,简化了学习的目标。从而可以更好的发挥深层次的CNN强大的学习能力。

[0071] 五、将特征重要度排序后递增特征维度比较1DRes-CNN模型诊断的准确率,当选择通过XGBoost选取特征的前9维特征时,1DRes-CNN模型具有最高的分类准确度,将9维特征作为1DRes-CNN模型的输入。选取的9维特征如下表所示:

[0072] SCADA数据

序号	参数名称	描述
1	P	预测功率与真实功率差值
2	int_tmp	机舱温度
3	environment_tmp	环境温度
[0073] 4	power_wind_speed	功率/风速
5	mean_moto_tmp	变桨电机平均温度
6	generator_speed	发电机转速
7	tmps	环境机舱温度差
8	mean_pitch_angle	叶片平均角度
9	power	网侧有功功率

[0074] 六、利用测试集进行测试,评估模型的风叶结冰故障诊断性能。

[0075] 将经过预处理和基于XGBoost算法选择的特征输入训练好的模型,通过精确度(Precision)、准确度(Accuracy)、召回率(Recall)、F1值等来进一步评估分类模型。

[0076] 本发明的效果可以通过以下的实验结果进行说明:

[0077] (1) 实验环境与准备工作

[0078] 本发明实验使用的深度学习框架为Pytorch,编程语言为python,CPU为i7-9750H,操作系统为Windows。本发明所采用的一维残差神经网络结构如图1所示,损失函数为交叉熵函数,优化器为Adam,学习率设置为0.01,批次大小设置为500,迭代次数为100次,激活函数为ReLU。

[0079] 本发明通过留出法(hold-out)对WT A风机数据进行划分,其中:70%为训练集,30%为验证集。此外,由于不同的风电机组位于不同的地理位置,因此风机SCADA数据分布之间存在很大的偏差,将WT A和WT B风机数据相互作为训练集和测试集进行实验分析。将经过预处理的SCADA数据经过基于XGBoost的特征选择选取的9维数据作为模型的输入。通过训练集对模型进行训练,然后通过测试集进行性能测评,以检验该模型的综合性能。

[0080] (2) 模型诊断性能测评指标

[0081] 混淆矩阵通常用来评估分类模型的性能,表1为混淆矩阵的表现形式。

[0082] 表1混淆矩阵

真实值	预测值	
	风叶结冰	风叶正常
风叶结冰	TP	FN
风叶正常	FP	TN

[0084] 基于混淆矩阵通过精确度(Precision)、准确度(Accuracy)、召回率(Recall)、F1值等来进一步评估分类模型:

$$[0085] \quad Precision = \frac{TP}{TP + FP}$$

$$[0086] \quad F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

$$[0087] \quad Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$[0088] \quad Recall = \frac{TP}{TP + FN}$$

[0089] 式中,Precision——实际结冰占预测为结冰情况之比;Recall——预测为结冰与实际结冰情况之比;F1——对Precision和Recall进行整体评价;Accuracy——正确分类的情况与错误分类的情况之比。

[0090] (3) 模型诊断性能对比

[0091] 为了评估所提模型的性能,本发明分别采用三个机器学习模型对比分析,对比模型分别为:卷积神经网络(Convolutional Neural Networks,CNN)、支持向量机(Support Vector Machine,SVM)和随机森林(RandomForest,RF)。为了公平起见,已对SVM和RF模型参数进行了优化,包括SVM的惩罚系数和RBF参数,以及RF中树的最大深度和树的数量。为防止深层卷积神经网络发生过拟合,经过实验选择,将CNN隐藏层设置为三层,其中包括一层卷积层两层全连接层。表2显示了集在不同训练模型上的结果。其中,1DRes-CNN模型对风叶结冰诊断效果最为突出,准确率和F1值均达到了95%以上,说明模型对风叶结冰或风叶正常情况具有较好的识别率。虽然RF精确率达到91%以上,召回率却仅仅达到82%,说明模型对叶片结冰的识别率较低,这显然不利于风叶结冰诊断任务。SVM性能与CNN相似,SVM算法需要较长的计算时间,而风机的SCADA数据量庞大,不适合选择SVM作为诊断模型。较浅层的CNN相较于1DRes-CNN模型,综合性能均低于后者,说明CNN不能很好的提取深层特征不能更好的区分风叶结冰与正常情况。通过对四个模型的综合性能分析对比,得知本发明提出的基于XGBoost特征选择的1DRes-CNN模型具有更好的整体诊断准确率。

[0092] 表2四种算法分类结果

性能指标	模型			
	1DRes-CN N	SVM	RF	CNN
[0093] Accuracy	0.9611	0.8760	0.9164	0.8992
Precision	0.9824	0.9305	0.9880	0.9494
Recall	0.9287	0.7760	0.8227	0.8204
F1	0.9549	0.8462	0.8982	0.8802

[0094] (4) 模型泛化能力对比

[0095] 为了进一步验证所提模型的泛化能力,分别将WT A和WT B相互作为训练集和测试集用于模型性能的评估。由于测试数据集具有严重的数据不均衡现象,选取叶片结冰和叶片正常的正确识别率作为性能指标可以更直观的表达模型的泛化能力。实验结果如表3所示,基于1DRes-CNN风叶结冰检测模型在新的测试集上有较好的表现,叶片结冰的识别率可达到平均84%的水平,但是均低于在训练集上的表现。因为在实际生产生活中,由于不同的风电机受不同的地理位置和风机型号参数的影响,因此风机的在运行参数和环境参数等方面存在很大的差异,造成了数据分布之间的偏差,在一定程度上影响了模型的诊断能力。以上验证结果表明了1DRes-CNN模型的具有良好的泛化能力。

[0096] 表3叶片结冰与叶片正常识别率

测试集	训练集	识别率 (%)	
		叶片结冰	叶片正常
[0097] WT A	WT B	82.1%	89.6%
WT B	WT A	86.0%	95.8%

[0098] 本发明通过基于叶片结冰物理机制和XGBoost特征重要性计算选取与叶片结冰最

相关的特征,增强模型的准确性和通用性。使用一维残差神经网络自适应提取有效的故障特征并作出预测,使用来自实际风电场的SCADA数据验证所提方法的的综合性能。一维卷积层自适应的提取特征并做出叶片结冰诊断,加入残差块加深网络的同时解决网络优化的过程中存在梯度消失和梯度爆炸的问题,减少人工特征选择不足的同时具有更高的综合性能和泛化能力。该方法可以利用深度学习强大的学习能力获得最佳的分类效果,具有较高的预测准确度和泛化能力,可以将除冰系统的效率提高到最大值。

[0099] 以上所述是本发明的优选实施方式而已,当然不能以此来限定本发明之权利范围,应当指出,对于本技术领域的普通技术人员来说,在不脱离本发明原理的前提下,还可以做出若干改进和变动,这些改进和变动也视为本发明的保护范围。



图1

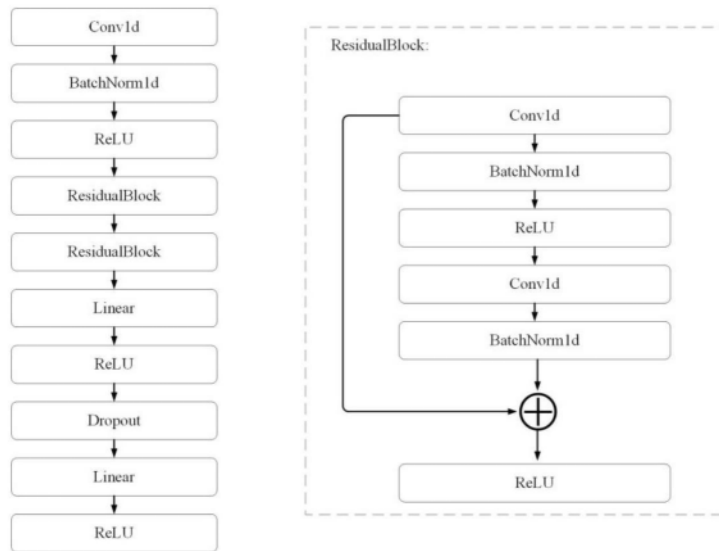


图2