

基于深度神经网络的电压暂降经济损失评估模型

王璐,肖先勇,汪颖,刘阳

(四川大学电气工程学院,四川成都 610065)

摘要:为进一步简化电压暂降经济损失评估流程、提高经济损失预测的适用性和准确度,提出了一种基于深度神经网络(DNN)的电压暂降经济损失评估模型。首先分析了影响电压暂降经济损失的特征因子,分别从电压暂降故障信息、工业过程信息、敏感设备信息和用户基本信息中提取19维特征向量作为DNN预测模型的输入向量,将经济损失结果作为输出,并基于Tensorflow深度学习架构对DNN预测模型进行训练。在此基础上,提出2种数据增强的策略,有效解决了电压暂降样本数据少的窘境,并通过构建4种DNN架构,对比了不同随机失活概率、神经元数量、架构深度对经济损失预测准确度的影响。训练后的DNN模型可以准确提取特征,快速实现收敛并对经济损失进行合理预测。最后,基于我国某大型电子工业企业的电压暂降实际采样数据,对DNN模型进行了训练和性能评估,结果表明了所提方法的有效性。

关键词:电压暂降;经济损失;深度神经网络;随机失活层;数据增强

中图分类号:TM 761

文献标志码:A

DOI:10.16081/j.epae.202003016

0 引言

短路故障、大容量设备启动或投切、雷击等造成的电压暂降不仅严重威胁系统中敏感负荷的正常运行,而且还会造成设备损坏、工业过程中断、产品报废等严峻问题以及巨额经济损失^[1-2]。早在2007年,欧洲25国调查表明,工业部门因电能质量造成的年损失高达1500亿欧元,其中电压暂降(包括短时电压中断)造成的损失约占电能质量总损失的60%^[3]。对电压暂降造成的损失进行有效、准确的评估是解决电压暂降问题的重要前提,不仅为电压暂降治理过程中的成本-效益分析提供了有力的依据,还可以指导用户进行合理投资决策。

近年来,国内外学者对电压暂降的损失评估已开展了大量研究,现有的方法可分为确定性评估方法^[4-6]和不确定性评估方法^[7-10]。确定性评估方法主要是对特定用户通过调查统计来进行经济损失评估,在实际中可操作性不强;不确定性评估方法主要有概率评估法^[7-8]和模糊评估法^[9-10],侧重于研究用户侧敏感设备或工业过程对电压暂降的响应情况,通过计算过程故障或中断概率来评估损失。事实上,准确易行的电压暂降经济损失评估ELA(Economic Loss Assessment)一直未得到很好的实现,目前主流电压暂降经济损失的评估方法一般具有如下局限性:①经济损失评估方法针对特定的行业、特定的生产过程,不具有普适性和扩展性;②在经济评估过程中,主要是根据人为经验构建损失评估公式,通常情

况下经验公式均具有场景受限性。为科学合理地对电压暂降经济损失进行预测,必须构建不同场景下从原始输入到抽象层语义信息的映射关系,而且不可依赖单一经验公式进行评估,以确保评估的一致性和方法的实用性。

深度神经网络DNN(Deep Neural Network)是近年来在计算机科学领域备受瞩目的监督学习算法之一^[11-12],其通过建立具有多个隐层的非线性模型获取特征,有效弥补了人工提取特征和基于物理模型的不足,其强大的非线性建模能力为复杂问题的回归或分类提供了高效的解决方法^[13-14]。

本文首先阐述了DNN的工作原理,然后对关键电压暂降经济损失特征因子进行分析并提取了合理科学的特征向量,提出了一种基于DNN的电压暂降经济损失预测模型。针对小样本数据的缺点,提出了2种数据增强策略:基于各维度变量高斯分布密度函数进行采样以及基于样本加噪处理,对样本数据进行了有效扩充。最后基于某大型电子工业企业的电压暂降实际采样数据对DNN模型进行训练,并在同时考虑不同随机失活概率、不同神经元数量、不同神经网络架构深度对经济损失评估影响的基础上进行性能评估,验证了DNN经济损失评估模型的有效性。

1 DNN

1.1 DNN架构与工作原理

DNN是由多层神经元堆叠而成的,其输入层为一个实数型向量 $X=(x_1, x_2, \dots, x_m)^T$,最后一层的输出为当前输入向量的预测值 $h_{w,b}(X)$,其中 W 、 b 为DNN中待学习的参数。图1为一个4维输入向量的3层DNN架构图,对于第 l 层的第 j 个神经元而言,其输

收稿日期:2019-06-13;修回日期:2020-01-15

基金项目:国家自然科学基金资助项目(51807126)

Project supported by the National Natural Science Foundation of China(51807126)

入和输出分别如式(1)和式(2)所示。

$$g = \sum_{i=1}^{S_{l-1}} W_{ji}^{(l)} a_i^{(l-1)} + b_i^{(l)} \quad (1)$$

$$a_i^{(l)} = F(g) \quad (2)$$

其中, S_{l-1} 为 DNN 第 $l-1$ 层神经元数量; $W_{ji}^{(l)}$ 为连接第 $l-1$ 层第 i 个神经元和第 l 层第 j 个神经元之间的权重值; $a_i^{(l-1)}$ 为第 $l-1$ 层第 i 个神经元的激励响应; $b_i^{(l)}$ 为第 l 层第 i 个神经元的输入偏置项; $F(x)$ 为激活函数。




图1 DNN模型典型架构

Fig.1 Typical architecture of DNN model

由于修正线性单元 ReLU(Rectified Linear Unit) 函数相比于函数 $\text{sigmoid}(x)$ 和 $\text{tanh}(x)$ 可以避免梯度消失的问题^[13], 更容易迭代收敛到全局最优解或者局部最优解, 所以本文在 DNN 中的非线性映射函数 $F(x)$ 采用 ReLU 函数, 如式(3)所示。

$$F(x) = \begin{cases} x & x > 0 \\ 0 & \text{其他} \end{cases} \quad (3)$$

1.2 随机失活层机制

随机失活层(dropout layer)是为了防止 DNN 在训练数据集上过拟合(overfitting)的主要技术之一^[15], 其一般设想是在全连接层后按照预定义的失活概率来阻断某些神经元的向后传导, 在不同的训练迭代周期中, 不同的神经元会被阻断, 因此各节点的“重要性”会被平衡。随机失活层工作原理图如附录 A 中的图 A1 所示。随机失活层的引入使得 DNN 的输出与每个神经元都构建联系, 具有更强的鲁棒性和可靠性。

1.3 损失函数与基于 Batch 的 DNN 训练过程

DNN 模型训练是根据损失函数(loss function)进行监督学习的过程, 对于回归模型而言, 损失函数通常定义为欧氏距离, 即:

$$L(\mathbf{W}, \mathbf{b}) = \frac{1}{2} \sum_{i=1}^N (h_{\mathbf{w}, \mathbf{b}}(X_i) - G_i)^2 \quad (4)$$

其中, $h_{\mathbf{w}, \mathbf{b}}(X_i)$ 、 G_i 、 $L(\mathbf{W}, \mathbf{b})$ 分别为第 i 个数据样本的预测值、真实值和损失函数值; N 为数据样本训练集的数据量。

为了加快 DNN 模型的训练效率, 在训练过程中一般使用基于 Batch 的训练方式, 即在计算损失函数值和进行梯度回传时并不是针对训练集中 N 个样本进行计算, 而是根据部分训练集数据进行损失函数值的计算, 故式(4)更新为:

$$L(\mathbf{W}, \mathbf{b}) = \frac{1}{2} \sum_{i=1}^{S_B} (h_{\mathbf{w}, \mathbf{b}}(X_i) - G_i)^2 \quad (5)$$

其中, S_B 为 Batch 的尺度。基于 Batch 的 DNN 模型训练过程即为不断更新模型参数 $\mathbf{W}$ 、 $\mathbf{b}$ 来最小化式(5)中的损失值, 每一次训练迭代 $\mathbf{W}$ 、 $\mathbf{b}$ 的更新方程为:

$$W_{ji}^{(l)} = W_{ji}^{(l)} - \alpha \frac{\partial L(\mathbf{W}, \mathbf{b})}{\partial W_{ji}^{(l)}} \quad (6)$$

$$b_i^{(l)} = b_i^{(l)} - \alpha \frac{\partial L(\mathbf{W}, \mathbf{b})}{\partial b_i^{(l)}} \quad (7)$$

其中, α 为迭代步长。

2 电压暂降经济损失特征因子

基于 DNN 进行经济损失预测的关键问题之一是输入特征向量的选取, 由于不同用户所包括的工业过程、敏感设备耐受属性、负载故障概率分布以及电压暂降严重程度等均有很大差异, 往往给电压暂降经济损失评估带来极大的不确定性。本文将电压暂降经济损失特征划分为暂降故障信息、工业过程信息、敏感设备信息和用户基本信息四大部分, 将以此组成的特征向量作为 DNN 的输入。以下选取几个重要的特征向量进行分析, 其余特征向量均可通过统计直接获得, 在此不再赘述。

2.1 电压暂降严重程度

IEEE Std 1564—2014^[16]刻画电压暂降严重程度的单一事件指标主要有电压暂降能量指标和严重程度指标。

(1)电压暂降能量指标。

$$E_{US} = \int_0^T [1 - (U(t)/U_{\text{norm}})^2] dt \quad (8)$$

其中, E_{US} 为电压暂降能量损失; $U(t)$ 为电压暂降过程中的实时电压幅值; U_{norm} 为无电压暂降时的正常电压幅值; T 为单次电压暂降事件的持续时间。

(2)电压暂降的严重程度指标。

$$S_e = \frac{1 - U}{1 - U_{\text{curve}}(d)} \quad (9)$$

其中, U 为电压幅值; d 为电压暂降持续时间; $U_{\text{curve}}(d)$ 采用 SEMI F47 曲线中横坐标 d 对应的参考电压值。

2.2 敏感设备负载电压耐受曲线

在分析电压暂降事件对经济损失的影响时, 确定负载设备对电压扰动的敏感程度是非常关键的步骤。大量研究表明, 常见敏感设备的电压耐受曲线 VTC(Voltage Tolerance Curve)呈矩形^[17], 其不确定区域如附录中图 A2 所示。图中, 阴影区域(区域 A、B、C)为典型敏感设备对于电压承受能力的不确定区域, 在该区域内设备既可能正常工作也可能处于故障状态。不同设备所对应的最大电压 U_{max} 、最小电压 U_{min} 、最大持续时间 T_{max} 、最小持续时间 T_{min} 各不相同, 这些参数值在评估电压暂降导致的经济损失

时具有极其重要的指导意义。

2.3 过程参数免疫时间

在电压暂降事件发生时,由于电气设备具有一定的对抗扰动的免疫能力,电气设备往往并不是立刻对扰动产生响应,而是有一个时间延迟。C4.110联合工作组提出使用过程参数免疫时间PIT(Parameter Immunity Time)刻画负载对电压扰动的过程行为^[18],其定义为设备受一定幅值的电压暂降扰动后,过程参数越限的时间,如图2所示。图中, P_{nom} 为物理参数额定值; P_{limit} 为可接受的限制值; t_1 为暂降发生时刻; Δt_1 为过程响应延时; t_2 为物理参数越过 P_{limit} 的时刻。




图2 过程参数免疫时间

Fig.2 PIT of process

PIT定义如式(10)所示。

$$t_{\text{PIT}} = t_2 - t_1 \quad (10)$$

PIT的提出为评估电压暂降导致的经济损失提供了新的视角,也是DNN模型的重要输入特征。

2.4 负载故障概率分布

根据上述分析,当电网中的负载设备状态处于图A2中的区域A、B和C中时,这些设备的电气特性将不再是单一确定的曲线,而是表征为一束以似然估计概率存在的电气特性曲线簇^[19]。此时描述设备负载的故障状态通常是将电压幅值 U 和电压暂降持续时间 T 作为2个统计独立的离散随机变量,通过概率密度函数刻画负载的状态,即为:

$$f(U, T) = f(U)f(T) \quad (11)$$

其中, $f(U)$ 为设备关于电压暂降的故障概率分布; $f(T)$ 为设备关于电压暂降持续时间的故障概率分布。根据对电压暂降响应敏感性的差异,典型的负载设备可以被分为均匀敏感性、低敏感性、中等敏感性和高敏感性4种类型。

(1)均匀敏感性设备。

均匀敏感性设备的负载故障概率密度函数如式(12)所示,其认为设备的故障概率仅与 U_{max} 、 U_{min} 、 T_{max} 和 T_{min} 相关。

$$f(U, T) = \frac{1}{(T_{\text{max}} - T_{\text{min}})(U_{\text{max}} - U_{\text{min}})} \quad (12)$$

(2)低敏感性设备。

低敏感性设备对电压暂降的免疫能力非常高,它在较大幅值的电压暂降和持续时间较长时故障概率才会显著升高,其故障概率密度分布为:

$$f(U, T) = \lambda_U e^{-\lambda_U(U - \mu_U)} \lambda_T e^{-\lambda_T(T - \mu_T)} \quad (13)$$

其中, λ_U 、 λ_T 为率参数; μ_U 、 μ_T 分别为电压幅值 U 、持续时间 T 的标准差。

(3)中等敏感性设备。

中等敏感性设备的负载故障概率密度函数为二维联合正态分布,如式(14)所示。

$$f(U, T) = \frac{1}{2\pi\sigma_U\sigma_T} e^{-\frac{1}{2}\left[\left(\frac{U - \mu_U}{\sigma_U}\right)^2 + \left(\frac{T - \mu_T}{\sigma_T}\right)^2\right]} \quad (14)$$

其中, σ_U 、 σ_T 分别为电压幅值 U 、持续时间 T 的平均值。

对于中等敏感性负载,设备的电气特性曲线会以较大的概率落在图A2的区域C内。

(4)高敏感性设备。

高敏感性设备的负载故障概率密度函数随着电压的降低和电压暂降持续时间值的升高而呈指数衰减,其对电压暂降的免疫能力非常低。高敏感性设备的故障分布密度函数如式(15)所示。

$$f(U, T) = \lambda_U e^{\lambda_U(U - \mu_U)} \lambda_T e^{\lambda_T(T - \mu_T)} \quad (15)$$

4种典型负载设备的故障概率密度模型参数取值如表1所示,参数取值参考文献[19]。这4种典型负载设备的故障概率三维分布图如附录A中图A3所示。

表1 4种典型负载设备的故障概率密度函数参数值

Table 1 Parameters configuration of malfunctions probabilities density function for four typical equipments

负载设备类型	故障概率密度模型参数取值
均匀敏感性	$T_{\text{max}} = 1 \text{ ms}, T_{\text{min}} = 1 \text{ ms}, U_{\text{max}} = 1 \text{ p.u.}, U_{\text{min}} = 1 \text{ p.u.}$
低敏感性	$\mu_T = 175, \mu_U = 0.74, \lambda_T = 0.0125, \lambda_U = 28.57$
中等敏感性	$\mu_T = 95, \mu_U = 0.775, \sigma_T = 26.67, \sigma_U = 0.012$
高敏感性	$\mu_T = 15, \mu_U = 0.81, \lambda_T = 0.0125, \lambda_U = 28.57$

2.5 电压暂降经济损失的输入特征向量

电压暂降引起的经济损失与电压暂降持续时间、幅值、PIT、设备不确定区间的电压边界、持续时间边界等因素密切相关。除此之外,还有相关特征因子在此不再赘述,电压暂降经济损失评估模型中使用的特征向量的各维度的定义及其物理意义在表2中列出。

3 电压暂降经济损失预测模型

3.1 建模流程

基于DNN的电压暂降经济损失评估模型建模流程如图3所示,流程主要分为数据收集与数据增强、训练和测试数据集划分、去量纲归一化预处理、搭建DNN预测网络、模型训练、测试集合前向预测以及性能评估等部分。

3.2 小样本数据增强

为了建立、训练DNN模型,需要收集相关统计数据来建立数据集,电压暂降引起的经济损失事件

表2 电压暂降经济损失模型中特征向量的定义

Table 2 Definition of feature vector used in prediction model of economic loss caused by voltage sag

类别	特征	含义
暂降故障信息	x_1	电压暂降持续时间
	x_2	电压暂降幅值
	x_3	故障清除时间
	x_4	过程中断时间
	x_5	电压暂降发生时参与运行的过程数量
	x_6	受影响的过程数
	x_7	电压暂降过程中的能量损失 E_{US}
	x_8	电压暂降的严重度 S_e
工业过程信息	x_9	过程数量
	x_{10}	过程容量
	x_{11}	PIT
	x_{12}	过程重要程度
敏感设备信息	x_{13}	设备不确定区间最小电压 $U_{\min}$
	x_{14}	设备不确定区间最大电压 $U_{\max}$
	x_{15}	设备不确定区间最小时间 $T_{\min}$
	x_{16}	设备不确定区间最大时间 $T_{\max}$
用户信息	x_{17}	工厂年营业额
	x_{18}	最大负载需求
	x_{19}	产品市场价格




图3 基于DNN的电压暂降经济损失评估建模流程

Fig.3 Modeling flowchart of economic loss estimation for voltage sag based on DNN

样本需要包括表2中的所有信息,但是在实际操作中往往面临小样本的窘境。数据增强(data augmentation)是处理小样本最为有效的实践策略之一^[20]。本文采用的2种数据增强策略如附录A中的图A4所示,具体如下:

(1)对实际采集的电压暂降数据样本建立高斯模型,然后根据各个特征维度的高斯参数(μ 和 σ)进行采样生成新样本,采样机制服从高斯密度函数;

(2)对实际采集的电压暂降数据样本的每一个维度进行高斯噪声处理,即随机采样出一个实际统计数据,并对其第 i 维添加一个服从 $n \sim N(0, \sigma_i^2/Q)$ 的噪声值,其中, σ_i 为第 i 维特征的标准差; Q 为控制噪声幅值的调节因子。

3.3 训练、测试数据集划分

在DNN中需将带有标签的数据集划分为训练

数据集和测试数据集两部分。训练数据集用来训练拟合DNN模型中的参数 W 、 b ,测试数据集用来评估训练得到的模型的性能。划分数据集的策略为将所有标注有标签的数据集合划分为若干等份,按照比例将部分数据子集选择为训练数据集,剩余数据子集为测试数据集。

本文中将电压暂降的数据集合划分为七等份($k=7$),每一次训练迭代周期中选择其中的六等份作为训练集,剩余的一等份作为性能测试集。

3.4 特征向量去量纲归一化

由于不同维度数据的量纲不同,且数据分布特性具有巨大差异,为了使得特征向量在任何一个维度上对最终的经济损失预测模型都保持相同的影响力,需要对特征向量进行去量纲和归一化操作,具体步骤如下。

(1)首先根据所有训练样本的特征向量计算其各维度的平均值与标准差,分别如式(16)、(17)所示。

$$\mu_{\text{data}} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m)^T \quad (16)$$

$$\sigma_{\text{data}} = (\sigma_{x_1}, \sigma_{x_2}, \dots, \sigma_{x_m})^T \quad (17)$$

其中, $\bar{x}_i$ 为第 i 个向量的平均值; σ_{x_i} 为第 i 个向量的标准差。

(2)对于任意一个特征向量 X ,可根据式(18)求得归一化后的特征向量 X_{norm} :

$$X_{\text{norm}} = (X - \mu_{\text{data}})/\sigma_{\text{data}} \quad (18)$$

对数据进行归一化处理后既可以去除量纲的影响,同时还可以将数据分布矫正到0附近,使得各维度特征量更加均匀化。

3.5 基于DNN模型的经济损失预测模型

本文DNN由全连接层和随机失活层构成,每2个全连接层后级联1个随机失活层,其中全连接层中的神经元个数和随机失活层的失活概率均可以由用户自行配置,该模型架构可以灵活变换,以适应不同规模数据量的经济损失预测任务。基于DNN模型的电压暂降经济损失模型架构如图4所示。




图4 基于全连接层和随机失活层的电压暂降经济损失预测模型

Fig.4 Model architecture based on fully connected layers and dropout layers for economic loss prediction of voltage sag

4 算例与结果分析

4.1 算例介绍

本文对我国粤西地区某大型电子工业企业进行实地调查统计及分析,该企业生产工艺过程主要包括印刷、贴片、回流焊接、组装(插件、点胶、焊接)、老化测试、打标、包装入库等环节,且各环节中均存在大量电压暂降敏感设备。

企业在遭受电压暂降时,上述相关敏感设备失效导致生产过程局部或整体中断,造成相关原材料损失与产能损失。此外,由于无法按期完成合同要求,导致企业违约罚款,同时客户满意度下降,引起一系列其他间接经济损失。据统计,该企业年均遭受电压暂降影响28~30次,单次电压暂降引起的损失为几十万元,累积损失高达523万元。利用实测统计法,在该企业10 kV进线处采集到7年电压暂降历史数据,共包括201次电压暂降数据样本,其电压暂降信息如图5所示。图中,电压幅值为标么值。




图5 电压暂降事件统计数据分布及严重程度分布

Fig.5 Data distribution and severity distribution of voltage sag events

4.2 基于Tensorflow的DNN模型训练与预测

本文基于Tensorflow深度学习架构对DNN进行开发实现,模型训练过程中的参数配置为:原始样本数量为201,经过数据增强后样本数量为4060,数据增强的方式以1:1的比例选择策略1和策略2进行,基于策略1和策略2进行数据增强的样本数量分别为1929和1930;每个训练周期选择3480条数据记录作为训练集,剩余的580条数据记录作为验证集合,Batch尺度为63,其中,训练集共54个Batch、验证集共9个Batch;模型在初始化时采用均值为0、标准差为0.01的高斯随机化方式,模型训练的迭代次数为30个Epoch;模型学习速率为 e^{-3} 。

4.3 样本增强评估性能

为验证小样本增强策略对DNN预测模型性能的影响,本文对无数据增强及有数据增强时的性能做出对比,在进行数据增强时,均使用3.2节的数据增强方法扩充了3859个样本,其中 Q 分别取1、2、4、6,其验证数据集的收敛曲线如附录中图A5所示。可以发现,数据增强对于小样本数据集具有十分显

著的作用,且 $Q=4$ 时的平均损失函数值为119.82,相比于原始小样本数据的平均损失函数值607.21提高了80.26%。

4.4 4种不同网络架构性能评估

为对比不同随机失活概率、神经元数量、架构深度对经济损失预测模型的影响,本文设计了4种DNN模型进行分析,其配置模式如表3所示。对比DNN1和DNN2模型可分析不同随机失活概率对经济损失预测精度的影响;对比DNN1和DNN3模型可分析不同神经元数量配置对经济损失预测精度的影响;对比DNN1和DNN4模型可分析不同的模型深度对经济损失预测精度的影响。

表3 4种不同配置下的神经网络架构以及参数数量统计

Table 3 Model architecture and parameters amount of four different neural networks

模型	模型架构	参数量
DNN1	19→24(ReLU)→32(ReLU)→dropout(0.9) 32→48(ReLU)→16(ReLU)→dropout(0.9)	3649
DNN2	19→24(ReLU)→32(ReLU)→dropout(0.7) 32→48(ReLU)→16(ReLU)→dropout(0.7)	3649
DNN3	19→24(ReLU)→48(ReLU)→dropout(0.9) 48→64(ReLU)→32(ReLU)→dropout(0.9)	6929
DNN4	19→24(ReLU)→32(ReLU)→dropout(0.9) 32→48(ReLU)→64(ReLU)→dropout(0.9) 64→48(ReLU)→24(ReLU)→dropout(0.9)	10321

基于表3中的4种神经网络架构,本文对电压暂降带来的经济损失数据集进行训练,其损失函数值如附录中的图A6、图A7所示。由图可知,本文提出的4种神经网络架构均实现了模型收敛,其中DNN3和DNN4的最终损失函数值在训练集和验证集上分别收敛于121.15、119.82和126.74、124.33,相比于DNN1和DNN2在训练集合和验证集合上最终收敛的损失函数值较小,即基于DNN3和DNN4神经网络架构的电压暂降经济损失预测模型性能较优。

在电压暂降训练集和验证集上分别实现模型收敛后,加载训练得到的模型参数进行前向预测,可得到相应的经济损失值。在实验中,引入逻辑回归LR(Logistic Regression)模型和支持向量机SVM(Support Vector Machine)回归模型进行性能比较,以式(4)中的损失函数(即预测误差)对经济损失的精确度进行评估,结果如表4所示。由表可见,相比于LR模型和SVM模型,DNN对电压暂降和经济损失之间的非线性映射更好,其精确度更高。

选取9个典型的电压暂降经济损失事件,通过本文的预测模型对其预测值和真实值进行对比,结果如图6所示,由图可见,DNN3和DNN4的预测性能相当且优于DNN1、DNN2,对于经济预测有良好的参考价值。

表4 基于LR、SVM和DNN模型的经济损失预测性能分析

Table 4 Prediction performance analysis of economic loss based on LR, SVM and DNN models

评估模型	损失函数值
LR	154.29
SVM	156.89
DNN1	139.19
DNN2	148.74
DNN3	119.82
DNN4	124.33




图6 基于典型电压暂降事件的经济损失预测性能比较

Fig.6 Comparison of economic loss prediction performance under typical voltage sag events

5 结论

本文针对电压暂降事件引起的经济损失问题建立了DNN预测模型,模型中引入随机失活层防止训练集过拟合,同时为了比较不同随机失活概率、神经元数量、神经网络深度对经济损失预测性能的影响,提出了4种DNN架构并对其进行训练和性能评估,得到以下结论:

(1)基于DNN的监督学习可以对电压暂降引起的经济损失进行科学的建模和合理预测,针对不同行业、不同设备合理设计输入的特征向量,可以实现模型的最终收敛,进行经济损失预测;

(2)对同一模型中全连接层后施加不同的随机失活概率时,随机失活概率的增大会导致模型最终的收敛损失函数值增大,使得经济损失预测精度下降;

(3)保持全连接层后的随机失活概率时,适当增加DNN模型中神经元的数量或者DNN的层数可以改善经济预测的精确度;

(4)数据增强技术能够有效改善DNN训练时在小样本上不收敛或者收敛差的问题,本文提出的根据高斯分布构建新数据样本和添加噪声生成新样本这2种方式可以对电压暂降数据集进行有效扩充。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] 谭秀美,肖先勇,张逸,等. 基于敏感过程运行状态的事件型电能质量扰动损失评估[J]. 电力系统保护与控制,2018,46(6):

84-89.

TAN Xiumei, XIAO Xianyong, ZHANG Yi, et al. Assessment of economic loss caused by event power quality disturbances based on sensitive process running states[J]. Power System Protection and Control, 2018, 46(6): 84-89.

[2] 李春海,李华强,刘勃江. 基于过程免疫不确定性的工业用户电压暂降经济损失风险评估[J]. 电力自动化设备,2016,36(12):136-142.

LI Chunhai, LI Huaqiang, LIU Bojiang. Risk assessment based on process immunity uncertainty for industrial customers' financial losses due to voltage sags[J]. Electric Power Automation Equipment, 2016, 36(12): 136-142.

[3] CHAN J Y. Framework for assessment of economic feasibility of voltage sag mitigation solutions[D]. Manchester, UK: University of Manchester, 2010.

[4] SALIM F, NOR K M, SAID D M, et al. Voltage sags cost estimation for Malaysian industries[C]//2014 IEEE International Conference on Power and Energy (PECon). Kuching, Sarawak, Malaysia: IEEE, 2014: 41-46.

[5] VEGUNTA S C, MILANOVIĆ J V. Estimation of cost of downtime of industrial process due to voltage sags[J]. IEEE Transactions on Power Delivery, 2011, 26(2): 576-587.

[6] 甄晓晨,陶顺,肖湘宁,等. 电压暂降的工厂级经济损失评估模型研究[J]. 电力系统保护与控制,2013,41(12):104-111.

ZHEN Xiaochen, TAO Shun, XIAO Xiangning, et al. An evaluation model of plant-level economic loss due to voltage dips[J]. Power System Protection and Control, 2013, 41(12): 104-111.

[7] MILANOVIĆ J V, GUPTA C P. Probabilistic assessment of financial losses due to interruptions and voltage sags: part I: the methodology[J]. IEEE Transactions on Power Delivery, 2006, 21(2): 918-924.

[8] CEBRIAN J C, KAGAN N, MILANOVIĆ J V. Probabilistic estimation of distribution network performance with respect to voltage sags and interruptions considering network protection setting: part II: economic assessment[J]. IEEE Transactions on Power Delivery, 2018, 33(1): 52-61.

[9] CEBRIAN J C, MILANOVIĆ J V, KAGAN N. Case studies of application of process immunity time in assessment of financial losses due to system faults induced industrial process interruptions[C]//2015 IEEE Power & Energy Society General Meeting. Denver, CO, USA: IEEE, 2015: 1-5.

[10] CEBRIAN J C, MILANOVIĆ J V, KAGAN N. Probabilistic assessment of financial losses in distribution network due to fault-induced process interruptions considering process immunity time[J]. IEEE Transactions on Power Delivery, 2015, 30(3): 1478-1486.

[11] 张蕾, 章毅. 大数据分析的无限深度神经网络方法[J]. 计算机研究与发展, 2016, 53(1): 68-79.

ZHANG Lei, ZHANG Yi. Big data analysis by infinite deep neural networks[J]. Journal of Computer Research and Development, 2016, 53(1): 68-79.

[12] 郑智聪,王红,齐林海. 基于深度学习模型融合的电压暂降源识别方法[J]. 中国电机工程学报, 2019, 39(1): 99-106.

ZHENG Zhicong, WANG Hong, QI Linhai. Recognition method of voltage sag sources based on deep learning models' fusion[J]. Proceedings of the CSEE, 2019, 39(1): 99-106.

[13] 屈相帅,段斌,尹桥宣,等. 基于稀疏自动编码器深度神经网络的电能质量扰动分类方法[J]. 电力自动化设备, 2019, 39(5): 157-162.

QU Xiangshuai, DUAN Bin, YIN Qiaoxuan, et al. Classification method of power quality disturbances based on deep neural network of sparse auto-encoder[J]. Electric Power Automation

- Equipment, 2019, 39(5): 157-162.
- [14] 尹雪燕, 同炯程, 刘玉田, 等. 基于深度学习的暂态稳定评估与严重程度分级[J]. 电力自动化设备, 2018, 38(5): 64-69.
YIN Xueyan, YAN Jiongcheng, LIU Yutian, et al. Deep learning based transient stability assessment and severity grading [J]. Electric Power Automation Equipment, 2018, 38(5): 64-69.
- [15] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [16] SABIN D D, BOLLEN M H J. Overview of IEEE Std 1564-2014 guide for voltage sag indices [C] // 2014 16th International Conference on Harmonics and Quality of Power (ICHQP). Bucharest, Romania: IEEE, 2014: 497-501.
- [17] GUPTA C P, MILANOVIC J V. Probabilistic assessment of equipment trips due to voltage sags [J]. IEEE Transactions on Power Delivery, 2006, 21(2): 711-718.
- [18] 李丹丹, 肖先勇, 刘阳, 等. 利用过程免疫时间优化保护的电压暂降减缓方案[J]. 电力自动化设备, 2014, 34(9): 95-100.
LI Dandan, XIAO Xianyong, LIU Yang, et al. Voltage sag mitigation scheme using protection optimization with process immunity time [J]. Electric Power Automation Equipment, 2014, 34(9): 95-100.
- [19] GRILO A P, SALLES D, MURARI C A F. Analysis of the impact of induction generators on distribution systems voltage sags due to unbalanced faults [C] // 2007 Large Engineering Systems Conference on Power Engineering. Montreal, Quebec, Canada: IEEE, 2007: 203-207.
- [20] TANNER M A. Data Augmentation [EB/OL]. [2019-06-30]. <https://online-library.wiley.com/doi/abs/10.1002/9781118445112.stat00409>.

作者简介:



王璐

王璐(1995—),女,河北张家口人,硕士研究生,主要研究方向为电压暂降经济损失评估(E-mail: 2602640430@qq.com);

肖先勇(1968—),男,四川宜宾人,教授,博士,主要研究方向为电能质量与优质供电(E-mail: xiaoxianyong@163.com);

汪颖(1981—),女,重庆人,副教授,博士,主要研究方向为电能质量与优质供电(E-mail: 20312028@qq.com);

刘阳(1991—),男,新疆昌吉人,博士研究生,主要研究方向为智能供电系统、电能质量分析与评估(E-mail: liuyangscu910@163.com)。

(编辑 任思思)

DNN-based estimation model of economic loss caused by voltage sag

WANG Lu, XIAO Xianyong, WANG Ying, LIU Yang

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: In order to further simplify the process of economic loss assessment of voltage sag and improve the applicability and accuracy of economic loss prediction, an estimation model based on DNN (Deep Neural Network) for economic loss caused by voltage sag is proposed. The characteristic factors affecting the economic loss of voltage sag are analyzed. The 19-dimensional feature vectors are extracted from the sag information, industrial process information, sensitive equipment information and users' basic information as input vectors of DNN prediction model, and the economic loss results are taken as output. The DNN prediction model is trained based on Tensorflow deep learning framework. On this basis, two data augmentation strategies are proposed to effectively solve the dilemma of few sample data of voltage sag. By constructing four DNN architectures, the effects of different random inactivation probability, number of neurons and depth of architecture on the accuracy of economic loss prediction are compared. As a result, the trained DNN model can extract features accurately, converge quickly and predict economic losses reasonably. Finally, the DNN model is trained and evaluated based on the actual voltage sag sampling data of a large electronic industry enterprise in China, which shows the effectiveness of the proposed method.

Key words: voltage sag; economic loss; deep neural network; dropout layer; data augmentation




图 A1 随机失活层工作原理
Fig. A1 Function principle of dropout layer




图 A2 典型负载对电压暂降承受能力的 uncertain 区域
Fig. A2 Uncertainty area of typical equipments responding to voltage sag




图 A3 故障概率密度分布
Fig. A3 Malfunctions probabilities density distribution




图 A4 小样本数据增强的两种方式

Fig. A4 Two solutions of data augmentation for small size training dataset




图 A5 数据增强前后的经济损失预测训练过程对比

Fig.A5 Comparison of economic loss prediction with & without data augmentation during training phase




图 A6 四种神经网络架构在训练集上的预测损失函数值随迭代次数的分布关系

Fig. A6 Distribution of loss value with iteration times based on the proposed four neural networks over training datasets




图 A7 四种神经网络架构在验证集上的预测损失函数值随迭代次数的分布关系

Fig. A7 Distribution of loss value with iteration times based on the proposed four neural networks over validation datasets