

基于改进极限学习机的应急通信网络 多重拥堵风险预警方法

钱立遥[†]

(浙江省应急管理数字与技术中心, 浙江 杭州 310000)

摘 要: 对风险数据特征提取不准确, 导致预警精度低, 因此, 提出了基于改进极限学习机的应急通信网络多重拥堵风险预警方法。采集与标准化处理数据, 实现对风险数据的预处理, 在改进极限学习机的支持下, 进行特征差和特征向量权重的计算, 完成对风险数据的特征提取, 通过对不同数据进行加权处理, 构建风险预警模型, 通过计算通信网络的风险值划分风险预警等级, 实现通信网络风险预警。通过上述设计, 完成对应急通信网络多重拥堵风险预警方法的设计。在仿真实验中, 与以往的应急通信网络多重拥堵风险预警方法相比, 设计的基于改进极限学习机的应急通信网络多重拥堵风险预警方法预警精度为 100%, 对风险的预警更准确。

关键词: 改进极限学习机; 应急通信网络; 多重拥堵; 风险预警

中图分类号: G642

文献标识码: A

Multiple Congestion Risk Warning Method for Emergency Communication Networks Based on Improved Extreme Learning Machine

QIAN Liyao[†]

(Zhejiang Provincial Emergency Management Digital and Technology Center, Hangzhou, Zhejiang 310000, China)

Abstract: Inaccurate feature extraction of risk data leads to low warning accuracy. Therefore, a multiple congestion risk warning method for emergency communication networks based on improved extreme learning machine is proposed. Collect and standardize data to preprocess risk data. With the support of improved extreme learning machine, calculate feature differences and feature vector weights to complete feature extraction of risk data. By weighting different data, construct a risk warning model, calculate the risk value of the communication network, classify the risk warning level, and achieve communication network risk warning. Through the above processes, the design of multiple congestion risk warning methods for emergency communication networks is completed. In the simulation experiment, compared with previous emergency communication network multiple congestion risk warning methods, the designed multiple congestion risk warning method for emergency communication network based on improved extreme learning machine has a warning accuracy of 100%, and is more accurate in risks warning.

Key words: improved extreme learning machine; emergency communication networks; multiple congestion; risk warning

在现代生活中,应急通信网络的存在至关重要^[1-2]。然而,通信网络在使用的过程中,很容易产生大量复杂、冗余的数据,对应急通信网络的通信安全会造成一定的威胁,导致应急通信网络出现拥堵等问题,影响人们的生命财产安全^[3]。因此,为解决应急通信网络中出现的拥堵问题,不少研究者提出了各种风险预警方法。

文献[4]提出基于异常辨识的方法,从多个角度分析风险数据,针对不同的风险数据类型,提出了相应的挖掘方法,确保风险预警的准确性。实验结果表明,该方法风险预警实时性差。文献[5]提出基于改进在线极限学习机的预测方法,利用改进在线极限学习机算法提取风险数据的特征,并将其中与分类强相关的特征向量划分出来,以此作为依据来预测拥堵风险。实验结果表明,该方法响应时间较长。文献[6]提出基于改进混合核极限学习机的预测方法,通过对数据进行预处理,确定通信网络多重拥堵风险数据特征集,划分风险等级,结合相关系数法,筛选风险数据特征向量,实现风险预警。实验结果表明,该方法通信效率过低。

本文在以往研究的基础上,设计了基于改进极限学习机的应急通信网络多重拥堵风险预警方法,通过采集风险数据,利用改进极限学习机提出风险数据的特征,构建风险预警模型,实现通信网络的风险预警。本文设计的方法风险预警精确度更高,有很高的实用价值。

1 应急通信网络多重拥堵风险预警方法设计

1.1 预处理应急通信网络风险数据

为提高设计的风险预警方法的预测精度,需要对采集的风险数据进行预处理。预处理过程如图1所示。

如图1所示,在对数据进行预处理时,主要从四个方面入手:数据清洗、数据转换、数据集成、异常数据值诊断。从上述四个方面对风险数据中存在的不同数据问题进行处理,保证采集风险数据的完整性。如果采集的风险数据样板中存在空缺值,在处理时,可以直接剔除,或者选择平均值或中位数将空缺的数值替换。同时,在进行数据处理时,设置数据重复识别规则,并根据数据之间的逻辑关系识别重复样本并将其清除^[7]。其次,在采集数据时,由于数据的类型存在差异,很容易导致采集的数据存在维度差异,如果直接使用将会影响后续的

结果。因此,在使用前应将其标准化处理。其具体处理过程如下所示:

$$X' = \frac{1}{2} + \frac{1}{2} \sin \left(\frac{\pi}{X_{\max} - X_{\min}} \times \frac{X - (X_{\max} - X_{\min})}{2} \right) \quad (1)$$

在上述公式中, X' 表示经过标准化处理后的风险数据, X 表示原始的风险数据, $X_{\max}$ 表示该数据的最大取值, $X_{\min}$ 表示该数据的最小取值。

通过式(1)对采集到的数据进行标准化处理,保证采集数据的统一性。同时,将采集的数据汇集到同一个数据集时,由于数据类型的多样性,要对数据进行交叉验证,将以往的风险数据与采集的数据进行对比,将其中与多种拥堵风险数据无关的数据剔除,避免多余的数据干扰后续的预测结果^[8]。此外,采集的样本数据中很容易存在极大数据、极小数据、无意义数据等异常数据,这些异常的数据会导致风险预警的准确度降低,因此在预处理时,要对这些数据进行甄别和清除,以保证经过预处理后的数据都是符合要求的^[9]。至此,应急通信网络风险数据的预处理完成。




图1 风险数据预处理过程

1.2 基于改进极限学习机提取风险数据特征

当通信网络出现多重拥堵时,说明当前的网络状态已经处于一种持续过载的状态,通信网络的链路带宽、存储空间以及处理器的处理能力等都超过了固有的容量^[10]。根据采集的多重拥堵风险数据分析,可以将通信网络出现拥堵的原因分为四类,分别为通信网络缓冲区容量有限、通信传输线路频带有限、通信节点处理能力有限、通信网络部分出

现故障^[11]。因此,为保证风险预警的精度,需要对预处理过的风险数据进行特征提取,筛选出关联度最强的特征向量。其具体的特征提取过程如图 2 所示。




图 2 基于改进极限学习机的风险数据特征提取

如图 2 所示,本文使用的改进极限学习机是一种典型的特征选择方法,能够将数据中的每个特征都赋予一定的权重,根据权重值的大小来提取显著度较高的特征向量。本文提取风险数据特征时,先进行特征差的计算,其具体计算过程如下所示:

$$D(a,X,Y)=\begin{cases}\frac{X(a)-Y(a)}{\max(a)-\min(a)},a\text{ 为连续量}\\0,a\text{ 为离散量 }X(a)\neq Y(a)\\1,a\text{ 为离散量 }X(a)=Y(a)\end{cases}\quad (2)$$

在上述公式中, X,Y 表示从样本集中抽取的样本数据, a 表示提取的特征, $X(a)$ 表示样本 X 在特征 a 上的数值, $Y(a)$ 表示样本 Y 在特征 a 上的

数值, $\max(a)$ 表示特征 a 在样本集中的最大数值, $\min(a)$ 表示特征 a 在样本集中的最小数值, $D(a,X,Y)$ 表示特征 a 在两个不同数据样本上的差值。

通过式(2)计算出样本数据集的特征差值,并在改进极限学习机的支持下,计算样本数据的特征向量,其具体计算过程如下所示:

$$W=W_a-\sum_{i=1}^k\frac{D(a,X,Y)}{\tau k}+\sum\frac{\frac{N(a)}{1-N(c(a))}\sum_{i=1}^kD(a,X,Y)}{\tau k}\quad (3)$$

在上述公式中, W 表示样本数据的特征向量权重值, W_a 表示特征 a 的权重值, k 表示样本数据的数量, τ 表示对样本数据进行随机选取的次数, $c(a)$ 表示抽取的样本数占总样本数的比值函数, $N(\cdot)$ 表示基于改进极限学习机的特征提取函数。通过式(3)计算出特征向量的权重值,并判断计算出的特征向量权重是否符合标准。如果不符合,需要重新进行选取计算;如果符合,则直接输出特征向量的权重,并对其进行降维处理,最终输出风险数据特征的最优子集。至此,基于改进极限学习机的风险数据特征提取完成。

1.3 构建网络多重拥堵风险预警模型

当样本数据量较多时,数据量繁杂,不仅会导致风险预警模型的预测效果较差,还会产生较大的整体误差。为了避免出现此类结果,本文在构建网络多重拥堵风险预警模型时,按照不同的数据类型进行分别建模,之后对预警模型进行加权处理,再用求和的方法得到最终的预警模型^[12]。首先,对不同类型的数据进行预测,得到一个预测函数,具体表示如下:

$$\boldsymbol{h}(x_i)=\begin{bmatrix}P(y_i=1|x_i,\boldsymbol{\theta})\\P(y_i=2|x_i,\boldsymbol{\theta})\\\vdots\\P(y_i=k|x_i,\boldsymbol{\theta})\end{bmatrix}=\sum_{j=1}^ke^{\theta_j^Tx_i}\begin{bmatrix}e^{\theta_1^Tx_i}\\e^{\theta_2^Tx_i}\\\vdots\\e^{\theta_k^Tx_i}\end{bmatrix}\quad (4)$$

在上述公式中, $\boldsymbol{h}(x_i)$ 表示不同类型风险数据 x_i 的预测函数, $P(\cdot)$ 表示风险发生 y_i 的概率, $\boldsymbol{\theta}$ 表示风险数据的权重向量, i 表示样本对数据进行分类的个数, $\sum_{j=1}^ke^{\theta_j^Tx_i}$ 表示风险数据的归一化参数。

通过式(4)对于输入的任意类型的向量数据,都能对其进行预测。同时,为降低风险预警过程中

产生的误差,还设置了一个损失函数。损失函数的存在能够正确对样本数据进行分类,保证样本数据的统一性^[13]。在以往的研究中,在进行风险划分时,由于对样本数据分类的不准确,风险等级的误判将会带来极大的损失^[14]。例如,将高风险划分为低风险将会给通信网络的运行带来巨大的影响,而如果将低风险划分为高风险,带来的损失则相对较小。简单来说,正确地划分风险等级是非常重要的,否则将会导致样本数据不平衡,给后续的风险预警带来极大的困难^[15]。因此,在上述条件的支持下,构建的风险预警模型如下所示:

$$Z = -\frac{1}{m} \cdot \left\{ \sum_{i=1}^m \sum_{j=1}^k \left[\alpha_j \text{Ind}(y_i = j) \log \left(\frac{e^{\theta_j^T x_i}}{\sum_{j=1}^k e^{\theta_j^T x_i}} \right) \right] \right\} + \lambda \sum_{i=1}^n \sum_{j=1}^k \theta_{ij}^2 \quad (5)$$

在上述公式中, Z 表示构建的风险预警模型, α_j 表示 j 类样本数据的权重数值, λ 表示进行标准化处理的函数参数, $\sum_{i=1}^n \sum_{j=1}^k \theta_{ij}^2$ 表示设置的损失函数, $\text{Ind}(y_i = j)$ 表示指示函数,它的数值变化在 $[0, 1]$ 之间。通过式(5)构建出多重拥堵风险预警模型,调节样本数据之间的不平衡程度,获得较好的预警效果。同时,在构建过程中,为了避免模型出现拟合问题,对设置的损失函数进行了标准化处理,以提升风险预警模型的泛化能力和适用性。至此,应急通信网络多重拥堵风险预警模型的构建完成。

1.4 实现通信网络风险预警

在上述设计的基础上,为实现通信网络的风险预警,更加直观地展现设计的风险预警方法的精确度,进行风险等级的划分。通过设置判断矩阵,计算风险预警的指标权重,在此基础上,计算出通信网络的风险值。其具体计算过程如下所示:

$$\begin{cases} A = (a_{ij})_{m \times n} \\ k = \alpha \times \beta \end{cases} \quad (6)$$

在上述公式中, A 表示预警数据的指标权重, a_{ij} 表示出现的风险因素的重要性, m, n 表示判断矩阵的行数和列数, k 表示应急通信网络多重拥堵风险值, α 表示风险出现的概率, β 表示出现的风险所造成的损失。

通过式(6)计算输入风险数据的风险值,并按照比例将风险的取值范围定义在1—10之间,从而划分风险预警等级。其具体划分结果如表1所示。

表 1 划分风险预警等级

序号	风险值	风险预警等级
1	1—3	无风险
2	3—5	低风险
3	5—7	中风险
4	8—10	高风险

如表1所示,当通信网络风险信息达到预警界限,就会发出警告。预警界限一般为高风险或者自行设置。至此,基于改进极限学习机的应急通信网络多重拥堵风险预警方法的设计完成。

2 仿真实验

2.1 实验准备

为验证本文设计的基于改进极限学习机的应急通信网络多重拥堵风险预警方法的预警效果,本文进行了仿真实验。在本次实验中,为了提供一个良好的实验环境,进行了实验参数的设置。其具体参数设置情况如表2所示。

表 2 实验参数设置

序号	实验参数	参数设置
1	CPU	PIV—1.8 G 及以上
2	内存	512 GB 及以上
3	外设硬盘内存	40 GB 及以上
4	展示截面分辨率	800×600 ppi 及以上
5	网卡	100 M 及以上
6	其他配置	光驱、软驱等

在如表2所示的实验环境下,移动通信网络安装后的实验环境如图3所示。



图 3 实验环境实物图

在如图3所示的实验环境中,录入某时段应急通信网络风险波动数据,风险波动情况如图4所示。




图 4 某时段应急通信网络多重拥堵信息风险波动情况


如图 4 所示,本次实验设置的预警界限为 5,以此预警界限为依据进行实验测试。在本次实验中,为保证实验的可靠性设置了对照实验。其中,本文设计的基于改进极限学习机的应急通信网络多重拥堵风险预警方法为方法 1,基于集成学习优化的应急通信网络多重拥堵风险预警方法为方法 2,基于边缘计算的应急通信网络多重拥堵风险预警方法为方法 3。

2.2 实验结果与讨论


在如图 4 所示风险波动情况下,分别使用三种风险预警方法对其进行预警测试,得到对应的预警结果。在此次实验中,当风险预警等级低于 5 时,预警值为 0,未触发预警;当风险预警等级在 5—7 之间时,预警值为 1,触发预警;当风险预警等级在 7—10 之间,预警值 2,警告将会加强。三种风险预警方法的预警结果如图 5 所示。

如图 5 所示,在本次实验中,方法 1 的预警结果与风险波动情况完全相同,方法 2 和方法 3 无法准确识别风险情况,会出现对风险预警等级的错误判断,对出现的风险无法及时预警。同时,经过统计可知,方法 1 的预警精度为 100%,方法 2 的预警精度为 83.2%,方法 3 的预警精度为 54.2%,可见,方法 1 的预警效果最好。因此,本文设计的基于改进极限学习机的应急通信网络多重拥堵风险预警方法在实际应用中的效果最好,风险预警精度高。


为了验证本文方法的时效性,分别使用三种风险预警方法对其进行预警测试,平均响应时间如图 6 所示。



(a) 方法1的预警结果



(b) 方法2的预警结果



(c) 方法3的预警结果

图 5 三种风险预警方法的预警结果

如图 6 所示,在本次实验中,方法 1 的响应时间最短,平均在 2 s 左右,方法 2 和方法 3 的响应时间较长且幅度较大,这说明了方法 1 具有更高的时效性和实时性,能够更快速地响应风险预警。相比之下,方法 2 和方法 3 可能存在一些计算上的瓶颈或者处理流程上的不足,导致其响应时间较长,并可能影响实时性和时效性。因此,在实际应用中,需要综合考虑算法的准确性、时效性和实时性等因素,选择合适的风险预警方法,保证应用效率。




图 6 三种风险预警方法的响应时间

3 结 论

本文设计的基于改进极限学习机的应急通信网络多重拥堵风险预警方法,通过对风险数据进行预处理,保证数据的统一性,并在极限学习机的支持下,对风险数据进行特征提取,提高了分类的性能,也提高风险预警方法的预警精度。同时,本文设计的预警方法针对不同的数据类型都有着较好的应用效果,适用性很强。

参考文献

[1] 刘志勇. 基于改进极限学习机的增量配电网线损率预测模型[J]. 自动化技术与应用,2023,42(2):155-157+182.

[2] 徐坤财,冯宝,陈业航,等. 结合深度学习与改进的极限学习机的集成学习胸腺瘤 CT 图像预测方法[J]. 计算机科学,2022,49(S2):455-460.

[3] 李斌,张一凡,颜世烨,等. 基于改进极限学习机 ELM 的光伏发电预测方法研究[J]. 热能动力工程,2022,37(10):207-214.

[4] 李一鹏,王亚军,栗维勋,等. 基于极限学习机的变电站监控系统负荷异常信息的辨识方法[J]. 电子器件,2022,45(5):1219-1224.

[5] 周伯荣,程伟国,许镇义,等. 基于改进在线极限学习机的短时交通流预测模型研究[J]. 计算机工程与科学,2022,44(5):944-950.

[6] 石智祖,常峻,吴斌平,等. 基于改进混合核极限学习机的坝基注浆量预测代理模型研究[J]. 水利水电技术(中英文),2021,52(9):57-66.

[7] 张斌,宫建锋,靳盘龙,等. 基于改进核极限学习机的短期负荷预测全网模型设计[J]. 自动化仪表,2021,42(8):64-67.

[8] 冯桂玲,郑鹭洲,蒋宏烨,等. 基于云计算和改进极限学习机的电网负荷预测[J]. 科学技术与工程,2021,21(22):9411-9417.

[9] 陈万圣,王珍,赵洪健,等. 基于压缩感知与改进的深度极限学习机的轴承故障诊断方法[J]. 机械强度,2021,43(4):779-785..

[10] 孙继泽,杜金其,王伟,等. 电力光纤通信网络实时安全风险量化参数优化算法[J]. 激光杂志,2021,42(12):176-180.

[11] 高立坡,康伟,郝军魁,等. 基于 OTN 技术的电力通信网络业务路由优化算法[J]. 自动化技术与应用,2021,40(11):75-79.

[12] 耿继朴,蒋锦霞,郑晓燕,等. 基于大数据驱动的配电网故障风险预警方法[J]. 电力信息与通信技术,2022,20(7):41-49.

[13] 蔡文斌,张焕域,林密,等. 基于量化分析的电力通信网多维度风险预警优化研究[J]. 微型电脑应用,2021,37(12):103-105.

[14] 刘新展,刘鹏,张珮明. 基于保底电网的通信网智能风险管理与动态控制技术研究[J]. 通信技术,2021,54(4):904-910.

[15] 王海燕,王湾,侯华保,等. 基于改进 GA-BP 的邮轮建造仓储物流风险预警研究[J]. 中国航海,2022,45(3):57-64.