



(12) 发明专利申请

(10) 申请公布号 CN 119398525 A

(43) 申请公布日 2025. 02. 07

(21) 申请号 202411910534.8	G06F 18/23213 (2023.01)
(22) 申请日 2024.12.24	G06F 18/2337 (2023.01)
(71) 申请人 中国标准化研究院	G06F 18/2411 (2023.01)
地址 100080 北京市海淀区知春路4号	G06F 18/2433 (2023.01)
(72) 发明人 张超 秦挺鑫 王皖 黄帅	G06F 18/243 (2023.01)
徐凤娇 孟祥程	G06F 18/2451 (2023.01)
(74) 专利代理机构 北京艾格律诗专利代理有限公司 11924	G06F 18/26 (2023.01)
专利代理师 宋杰	G06N 3/0499 (2023.01)
(51) Int. Cl.	G06N 3/084 (2023.01)
G06Q 10/0635 (2023.01)	G06N 3/086 (2023.01)
G06Q 50/26 (2024.01)	G06N 3/0985 (2023.01)
G06F 18/25 (2023.01)	G06N 5/01 (2023.01)
G06F 18/2135 (2023.01)	G06N 5/025 (2023.01)
G06F 18/22 (2023.01)	G06N 20/20 (2019.01)

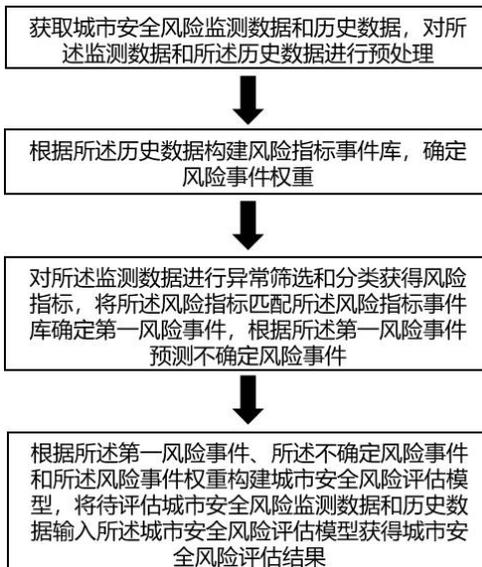
权利要求书5页 说明书11页 附图1页

(54) 发明名称

基于数字化标准的城市安全风险评估方法及系统

(57) 摘要

本发明公开了基于数字化标准的城市安全风险评估方法及系统,包括获取城市安全风险监测数据和历史数据,根据所述历史数据构建风险指标事件库,对所述监测数据进行异常筛选和分类获得风险指标,匹配所述风险指标与所述风险指标事件库确定第一风险事件,根据所述第一风险事件预测不确定风险事件,根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果。该方法不仅可以提高城市安全风险评估的效率和准确性,同时具有较好的可解释性,可以直接应用于城市安全风险评估系统中。



1. 基于数字化标准的城市安全风险评估方法,其特征在於,包括以下步骤:

S1、获取城市安全风险监测数据和历史数据,对所述监测数据和所述历史数据进行预处理;

S2、根据所述历史数据构建风险指标事件库,确定风险事件权重;

S3、对所述监测数据进行异常筛选和分类获得风险指标,将所述风险指标匹配所述风险指标事件库确定第一风险事件,根据所述第一风险事件预测不确定风险事件;所述不确定风险事件包括并发风险事件和概率风险事件;

S4、根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果。

2. 根据权利要求1所述基于数字化标准的城市安全风险评估方法,其特征在於,根据所述历史数据构建风险指标事件库并确定所述风险事件权重的方法,包括:

采用聚类法确定历史数据中不同类别的风险事件,对风险事件进行特征提取获得对应风险指标,根据风险事件和对应风险指标构建风险指标库;

按照风险类别、风险事件和风险指标划分安全风险层次,结合层次分析法和专家咨询法确定各层次评估单元的权重。

3. 根据权利要求1所述基于数字化标准的城市安全风险评估方法,其特征在於,对所述监测数据进行异常筛选和分类获得风险指标的方法,包括:

按照区域风险评估标准确定安全风险项目,获取安全风险项目监测数据,标准化处理监测数据并代入模糊分簇聚类算法中,根据监测数据间相似度划分n个样本空间分簇,并确定分簇目标函数,表达式为:

$$Aim = \sum_{j=1}^n \sum_{i=1}^m \mu_{ij}^2(x_j A_i) \pm \sqrt{\frac{(x_j - A_i)^2}{(\bar{x}_j - A_i)^2}},$$

其中 Aim 为分簇目标函数, m 为簇内样本的类别维度, x_j 为 j 簇监测数据样本, \bar{x}_j 为 j 簇监测数据均值, A_i 为样本在 i 维度的聚类中心, μ_{ij} 为监测数据样本 x_j 属于 i 维度的隶属度;

计算监测数据样本中数据对象的密度值,选取密度值最大的数据点作为第一个簇聚类中心点,并计算其余数据点的密度值,表达式为:

$$D_i = \mu_{ij} \sum_{j=1}^n \exp\left\{-\frac{Aim}{x_j(0.5r_a)^2}\right\},$$

$$D_i^i = D_i - D_0 \exp\left\{-\frac{Aim}{x_j(0.5r_b)^2}\right\},$$

其中 D_i 为聚类中心点的密度值, D_i^i 为聚类中心点以外数据点的密度值, r_a 为领域半径, r_b 为领域半径更新值, D_0 为初始最大聚类中心的密度值;

更新聚类中心和监测数据样本的隶属度,一直迭代直到最大迭代次数或满足目标函数时停止迭代,获得分为数据类别不同的 K 个簇;

进行多超球面学习,根据所有监测数据进行宏观超球面学习,根据监测数据分簇聚类结果对每个簇监测数据进行介观超球面学习,表达式为:

$$L^g = \frac{1}{|V^{train}|} \sum_{v_i \in V^{train}} \|z_i - c_0\|_2^2 + \lambda_2 \sum_{i=1}^{|V^{train}|} \|z_i\|_2^2,$$

$$L^l = \frac{1}{K|V^{train}|} \sum_{v_i \in V^{train}} \|z_i - c_{k_i^*}\|_2^2 + \lambda_2 \sum_{i=1}^{|V^{train}|} \|z_i\|_2^2,$$

$$L^c = -\frac{1}{K} \sum_{k=1}^K \log \left\{ \frac{\exp[\text{Sim}(q_k, q_k^+)]}{\sum_{k'}^K \exp[\text{Sim}(q_k, q_k^+)]} \right\},$$

其中 L^g 为宏观超球面学习损失函数, L^l 为介观超球面学习损失函数, L^c 为对比学习损失函数, v_i 为训练集的节点, V^{train} 为训练节点集合, $|V^{train}|$ 为训练节点数量, z_i 为节点 v_i 在空间的表征, c_0 为宏观超球体中心, $\|\cdot\|_2$ 为 L_2 范数, λ_2 为正则化参数, $c_{k_i^*}$ 为节点 v_i 所属超球体中心, k_i^* 为节点 v_i 所属簇索引, $\text{Sim}(\cdot)$ 为余弦相似度函数, q_k 为第 k 个样本的查询向量, q_k^+ 为第 k 个正样本增强向量, q_t^+ 为所有正样本增强向量集合;

根据宏观超球面学习损失函数、介观超球面学习损失函数和对比学习损失函数确定多球体学习目标,进行异常判定获得风险指标,表达式为:

$$L = L^g + \lambda_l \cdot L^l + \lambda_c \cdot L^c,$$

$$s(v_i) = \|z_i - c_0\|_2^2 + \lambda_l \cdot \|z_i - c_{k_i^*}\|_2^2,$$

其中 L 为多球体学习目标, λ_l 为介观超球面学习参数, λ_c 对比学习参数, $s(v_i)$ 为节点 v_i 的异常评分;

按数据类别和数据采集定位为风险指标贴标签。

4. 根据权利要求1所述基于数字化标准的城市安全风险评估方法,其特征在于,确定所述第一风险事件的方法,包括:

定义多个风险指标有概率引发一起或多起风险事件,对风险指标进行主成分分析获得主成分特征,一个主成分特征对应一组风险指标,通过计算主成分特征与风险指标相关系数确定该主成分特征对应的风险指标组,表达式为:

$$r_{ij} = \frac{(x_i - \bar{x})(y_j - \bar{y}) + \alpha \cdot f(x_i, y_j)}{\sqrt{\sum_{i=1}^p (x_i - \bar{x})^2} \sqrt{\sum_{j=1}^q (y_j - \bar{y})^2}} - \beta \zeta,$$

$$r_i = \frac{1}{q} \sum_{j=1}^q |r_{ij}|,$$

其中 r_{ij} 为第 i 个主成分特征值 x_i 与第 j 个风险指标值 y_j 的相关系数, r_i 为第 i 个主成分特征值与所有风险指标值的相关系数绝对值均值, \bar{x} 为所有主成分特征值均值, \bar{y} 为所有风险指标值均值, p 为主成分特征数量, q 为风险指标数量, α 为非线性项权重, $f(x_i, y_j)$ 为非线性函数用于捕捉 x_i 与 y_j 非线性关系, β 为正则化系数, ζ 为正则化强度;

选择 $r_{ij} > r_i$ 的风险指标组成第 i 个主成分特征的风险指标组,定义主成分特征向量集合为 $A_i = \{\psi_i, i = 1, 2, \dots, p\}$, ψ_i 为特征向量元素,风险事件向量集合

$B_h = \{\psi_h, h = 1, 2, \dots, s\}$, ψ_h 为风险事件向量元素,由第 h 个风险事件对应的风险指标阈值构成, s 为风险指标事件库中风险事件的数量,计算多个风险指标组合与风险指标事件库中风险事件的相关性确定第一风险事件,表达式为:

$$D_{ih} = \frac{1}{4}(E_{A_i} - E_{B_h})^T (\Sigma_{A_i} - \Sigma_{B_h})^{-1} (E_{A_i} - E_{B_h}) + \frac{1}{2} \ln \left\{ \frac{\det[0.5(\Sigma_{A_i} + \Sigma_{B_h})]}{\sqrt{\det(\Sigma_{A_i}) \det(\Sigma_{B_h})}} \right\},$$

$$E_{A_i} = \frac{1}{p} \sum_{i=1}^p \psi_i, \Sigma_{A_i} = \frac{1}{p-1} (\psi_i - E_{A_i})(\psi_i - E_{A_i})^T,$$

$$E_{B_h} = \frac{1}{s} \sum_{h=1}^s \psi_h, \Sigma_{B_h} = \frac{1}{s-1} (\psi_h - E_{B_h})(\psi_h - E_{B_h})^T,$$

其中 D_{ih} 为主成分特征 i 与风险事件 h 的距离, E_{A_i} 为第 i 个主成分特征样本的均值向量, E_{B_h} 为第 h 个风险事件样本的均值向量, Σ_{A_i} 为第 i 个主成分特征样本的协方差矩阵, Σ_{B_h} 为第 h 个风险事件样本阈值的协方差矩阵, $\det(\cdot)$ 为矩阵行列式;

设定距离阈值 D_0 ,当 $D_{ih} < D_0$ 时判定主成分特征 i 对应的风险指标组可能引发风险事件 h ,否则主成分特征 i 对应的风险指标组不引发风险事件;

按数据类别和数据采集定位为第一风险事件贴标签。

5. 根据权利要求1所述基于数字化标准的城市安全风险评估方法,其特征在于,根据所述第一风险事件预测并发风险事件的方法,包括:

构建FP-growth算法模块,挖掘风险事件间的关联性,通过已知风险事件确定并发风险事件,FP-growth算法模块的构建步骤为:

扫描历史数据统计项的频数,设定最小支持度选出频繁项,由频繁项和频数构建项头表;

根据项头表筛选和排序事务中的项,由筛选结果构建FP-tree;

根据项头表确定频繁项的条件模式基和事务项集合,根据条件模式基建立条件FP树,采用历史数据训练FP-tree条件实例,采用深挖和递归方法探索常见项集合,输出FP-tree;

将第一风险事件输入FP-growth算法模块获得其并发风险事件,按数据类别和数据采集定位为并发风险事件贴标签。

6. 根据权利要求1所述基于数字化标准的城市安全风险评估方法,其特征在于,据所述第一风险事件预测概率风险事件的方法,包括:

定义第一风险事件对应风险指标的特征向量为 u ,定义风险指标事件库目标风险事件对应风险指标阈值的特征向量为 v ,计算第一风险事件特征向量和目标风险事件特征向量的综合相似度,表达式为:

$$S(u_f, v_g) = \gamma \frac{I_{u_f} \cap I_{v_g}}{I_{u_f} \cup I_{v_g}} + \frac{1-\gamma}{t \cdot K} \cdot \left(\sum_{x=1}^t \sqrt{\frac{n(u_f)n(v_g)}{n^2(s)}} \right) \cdot \left[\frac{e^{-|E_{u_f}-E_{v_g}| |\sigma_{u_f}-\sigma_{v_g}|}}{1 + e^{-|E_{u_f}-E_{v_g}| |\sigma_{u_f}-\sigma_{v_g}|}} \right],$$

$$\cdot \left(\sum_{k=1}^K \frac{|\min N_{u_f} - \min N_{v_g}| + \rho |\max N_{u_f} - \max N_{v_g}|}{|N_{u_f} - N_{v_g}| + \rho |\max N_{u_f} - \max N_{v_g}|} \right)$$

其中 $S(u_f, v_g)$ 为第 f 个第一风险事件特征向量 u_f 与第 g 个目标风险事件特征向量 v_g 的综

合相似度, γ 为权重系数, I_{u_f} 为特征向量 u_f 的风险指标集合, I_{v_g} 特征向量 v_g 的风险指标阈值集合, t 为所有项目风险指标数量, $n(s)$ 为最大项目风险指标数量, $n(u_f)$ 为特征向量 u_f 的风险指标数量, $n(v_g)$ 为特征向量 v_g 的风险指标阈值数量, E_{u_f} 、 σ_{u_f} 为特征向量 u_f 风险指标均值和方差, E_{v_g} 、 σ_{v_g} 为特征向量 v_g 的风险指标阈值均值和方差, K 为向量维度, N_{u_f} 为特征向量 u_f 的元素值, N_{v_g} 为特征向量 v_g 的元素值, $\rho \in [0,1]$ 为分辨系数;

设定综合相似度阈值,根据综合相似度确定第一风险事件对应的概率风险事件,按数据类别和数据采集定位为概率风险事件贴标签。

7. 根据权利要求1所述基于数字化标准的城市安全风险评估方法,其特征在于,获得所述城市安全风险评估结果的方法,包括:

将第一风险事件、并发风险事件、概率风险事件、风险指标和风险事件权重组成安全风险数据集,采用随机森林算法将安全风险集按照7:3划分成训练集和测试集;

构建城市安全风险评估模型,所述城市安全风险评估模型包括贝叶斯网络、多模态预测模型和策略层;

贝叶斯网络根据已知的第一风险事件、并发风险事件和概率风险事件发生的历史数据来估计风险事件的概率关系,计算每个风险事件在给定其它风险事件下的发生概率;

多模态预测模型用于学习训练集数据和风险事件发生概率进行安全风险评估,包括遗传-BP神经网络基模型、支持向量机回归基模型和随机森林基模型;

遗传-BP神经网络用于根据输入数据预测风险评分,采用均方误差损失函数评估预测值与实际值的差异,采用遗传算法优化网络结构和参数,采用Adam优化器调整学习率;

支持向量机回归通过输入数据找到超平面来区分不同风险等级的事件并进行风险评分预测,采用 ϵ -不敏感损失函数在 ϵ 范围内预测评分误差,采用SMO算法求解最优超平面;

随机森林通过构建决策树进行投票提高风险评分的准确性和稳定性,采用均方误差损失函数评估预测值与实际值差异,根据信息增益选择最佳分裂点;

策略层采用加权投票法整合基模型预测风险评分,输出层提取风险事件的类别和发生位置,最终输出安全风险评估结果,采用测试集评估城市安全风险评估模型;

将待评估城市安全风险监测数据和历史数据输入城市安全风险评估模型获得安全风险评估结果。

8. 基于数字化标准的城市安全风险评估系统,用以执行权利要求1-7任一项所述的方法,其特征在于,包括:

数据采集模块:用于获取城市安全风险监测数据和历史数据,对所述监测数据和所述历史数据进行预处理;

数据处理模块:用于确定风险事件权重,用于对所述监测数据进行异常筛选和分类获得风险指标,用于匹配所述风险指标与风险指标事件库,用于预测不确定风险事件;

评估模型模块:根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果;

智能监管模块:用于储存、查看和管理所述监测数据和所述历史数据和所述城市安全风险评估结果,用于根据所述城市安全风险评估结果确定安全风险等级和向用户进行风险

预警和建议,用于根据位置信息在安全风险地图上标注风险事件及其类别、安全风险等级和发生概率。

基于数字化标准的城市安全风险评估方法及系统

技术领域

[0001] 本发明涉及质量评价领域,尤其涉及基于数字化标准的城市安全风险评估方法及系统。

背景技术

[0002] 全球城市化进程的不断加速,其规模和复杂性的发展也伴随着一系列安全风险的挑战,因此进行城市安全风险的管理和评估对于保障城市居民的生命财产安全、维护社会稳定和促进可持续发展具有重要意义。而信息技术的飞速发展,特别是大数据、云计算和人工智能等技术的应用,为城市安全风险评估提供了新的机遇。

[0003] 传统的评估方式往往依赖于人工经验判断,缺乏数据支持和科学分析,导致评估结果不够准确且难以实时更新,同时城市安全风险涉及多个领域和层面,这些因素相互交织、相互影响,使得风险评估工作更加复杂。虽然已有一些基于数字化技术的城市安全风险评估方法,但这些方法大多停留在数据收集和分析的初级阶段,缺乏系统性和综合性的评估模型。因此,通过历史风险数据构建系统性的标准数据库,对监测数据进行有效的预处理识别风险事件,预测风险事件引发的不确定事件,基于机器学习技术构建城市安全风险评估模型对城市安全风险评分、预测风险事件及发生的概率,设计一种基于数字化标准的城市安全风险评估方法及系统来克服现有评价模型的不足,推动城市安全风险管理向数字化、智能化方向发展,对构建和谐、安全的城市环境具有重要意义。

发明内容

[0004] 本发明的目的是要提供基于数字化标准的城市安全风险评估方法及系统。

[0005] 为达到上述目的,本发明是按照以下技术方案实施的:

本发明包括以下步骤:

获取城市安全风险监测数据和历史数据,对所述监测数据和所述历史数据进行预处理;

根据所述历史数据构建风险指标事件库,确定风险事件权重;

对所述监测数据进行异常筛选和分类获得风险指标,将所述风险指标匹配所述风险指标事件库确定第一风险事件,根据所述第一风险事件预测不确定风险事件;所述不确定风险事件包括并发风险事件和概率风险事件;

根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果。

[0006] 进一步的,根据所述历史数据构建风险指标事件库并确定所述风险事件权重的方法,包括:

采用聚类法确定历史数据中不同类别的风险事件,对风险事件进行特征提取获得对应风险指标,根据风险事件和对应风险指标构建风险指标库;

按照风险类别、风险事件和风险指标划分安全风险层次,结合层次分析法和专家咨询法确定各层次评估单元的权重。

[0007] 进一步的,对所述监测数据进行异常筛选和分类获得风险指标的方法,包括:

按照区域风险评估标准确定安全风险项目,获取安全风险项目监测数据,标准化处理监测数据并代入模糊分簇聚类算法中,根据监测数据间相似度划分n个样本空间分簇,并确定分簇目标函数,表达式为:

$$Aim = \sum_{j=1}^n \sum_{i=1}^m \mu_{ij}^2 (x_j A_i) \pm \sqrt{\frac{(x_j - A_i)^2}{(\bar{x}_j - A_i)^2}},$$

其中 Aim 为分簇目标函数, m 为簇内样本的类别维度, x_j 为 j 簇监测数据样本, \bar{x}_j 为 j 簇监测数据均值, A_i 为样本在 i 维度的聚类中心, μ_{ij} 为监测数据样本 x_j 属于 i 维度的隶属度;

计算监测数据样本中数据对象的密度值,选取密度值最大的数据点作为第一个簇聚类中心点,并计算其余数据点的密度值,表达式为:

$$D_i = \mu_{ij} \sum_{j=1}^n \exp\left\{-\frac{Aim}{x_j(0.5r_a)^2}\right\},$$

$$D'_i = D_i - D_0 \exp\left\{-\frac{Aim}{x_j(0.5r_b)^2}\right\},$$

其中 D_i 为聚类中心点的密度值, D'_i 为聚类中心点以外数据点的密度值, r_a 为领域半径, r_b 为领域半径更新值, D_0 为初始最大聚类中心的密度值;

更新聚类中心和监测数据样本的隶属度,一直迭代直到最大迭代次数或满足目标函数时停止迭代,获得分为数据类别不同的 K 个簇;

进行多超球面学习,根据所有监测数据进行宏观超球面学习,根据监测数据分簇聚类结果对每个簇监测数据进行介观超球面学习,表达式为:

$$L^g = \frac{1}{|V^{train}|} \sum_{v_i \in V^{train}} \|z_i - c_0\|_2^2 + \lambda_2 \sum_{i=1}^{|V^{train}|} \|z_i\|_2^2,$$

$$L^l = \frac{1}{K|V^{train}|} \sum_{v_i \in V^{train}} \|z_i - c_{k_i^*}\|_2^2 + \lambda_2 \sum_{i=1}^{|V^{train}|} \|z_i\|_2^2,$$

$$L^c = -\frac{1}{K} \sum_{k=1}^K \log \left\{ \frac{\exp[\text{Sim}(q_k, q_k^+)]}{\sum_{k'}^K \exp[\text{Sim}(q_k, q_k^+)]} \right\},$$

其中 L^g 为宏观超球面学习损失函数, L^l 为介观超球面学习损失函数, L^c 为对比学习损失函数, v_i 为训练集的节点, V^{train} 为训练节点集合, $|V^{train}|$ 为训练节点数量, z_i 为节点 v_i 在空间的表征, c_0 为宏观超球体中心, $\|\cdot\|_2$ 为 L_2 范数, λ_2 为正则化参数, $c_{k_i^*}$ 为节点 v_i 所属超球体中心, k_i^* 为节点 v_i 所属簇索引, $\text{Sim}(\cdot)$ 为余弦相似度函数, q_k 为第 k 个样本的查询向量, q_k^+ 为第 k 个正样本增强向量, q_t^+ 为所有正样本增强向量集合;

根据宏观超球面学习损失函数、介观超球面学习损失函数和对比学习损失函数确定多球体学习目标,进行异常判定获得风险指标,表达式为:

$$L = L^g + \lambda_l \cdot L^l + \lambda_c \cdot L^c,$$

$$s(v_i) = \|z_i - c_0\|_2^2 + \lambda_l \cdot \|z_i - c_{k_i^*}\|_2^2,$$

其中 L 为多球体学习目标, λ_l 为介观超球面学习参数, λ_c 对比学习参数, $s(v_i)$ 为节点 v_i 的异常评分;

按数据类别和数据采集定位为风险指标贴标签。

[0008] 进一步的,确定所述第一风险事件的方法,包括:

定义多个风险指标有概率引发一起或多起风险事件,对风险指标进行主成分分析获得主成分特征,一个主成分特征对应一组风险指标,通过计算主成分特征与风险指标相关系数确定该主成分特征对应的风险指标组,表达式为:

$$r_{ij} = \frac{(x_i - \bar{x})(y_j - \bar{y}) + \alpha \cdot f(x_i, y_j)}{\sqrt{\sum_{i=1}^p (x_i - \bar{x})^2} \sqrt{\sum_{j=1}^q (y_j - \bar{y})^2}} - \beta \zeta,$$

$$r_i = \frac{1}{q} \sum_{j=1}^q |r_{ij}|,$$

其中 r_{ij} 为第 i 个主成分特征值 x_i 与第 j 个风险指标值 y_j 的相关系数, r_i 为第 i 个主成分特征值与所有风险指标值的相关系数绝对值均值, \bar{x} 为所有主成分特征值均值, \bar{y} 为所有风险指标值均值, p 为主成分特征数量, q 为风险指标数量, α 为非线性项权重, $f(x_i, y_j)$ 为非线性函数用于捕捉 x_i 与 y_j 非线性关系, β 为正则化系数, ζ 为正则化强度;

选择 $r_{ij} > r_i$ 的风险指标组成第 i 个主成分特征的风险指标组,定义主成分特征向量集合为 $A_i = \{\psi_i, i = 1, 2, \dots, p\}$, ψ_i 为特征向量元素,风险事件向量集合 $B_h = \{\psi_h, h = 1, 2, \dots, s\}$, ψ_h 为风险事件向量元素,由第 h 个风险事件对应的风险指标阈值构成, s 为风险指标事件库中风险事件的数量,计算多个风险指标组合与风险指标事件库中风险事件的相关性确定第一风险事件,表达式为:

$$D_{ih} = \frac{1}{4} (E_{A_i} - E_{B_h})^T (\Sigma_{A_i} - \Sigma_{B_h})^{-1} (E_{A_i} - E_{B_h}) + \frac{1}{2} \ln \left\{ \frac{\det[0.5(\Sigma_{A_i} + \Sigma_{B_h})]}{\sqrt{\det(\Sigma_{A_i}) \det(\Sigma_{B_h})}} \right\},$$

$$E_{A_i} = \frac{1}{p} \sum_{i=1}^p \psi_i, \Sigma_{A_i} = \frac{1}{p-1} (\psi_i - E_{A_i})(\psi_i - E_{A_i})^T,$$

$$E_{B_h} = \frac{1}{s} \sum_{h=1}^s \psi_h, \Sigma_{B_h} = \frac{1}{s-1} (\psi_h - E_{B_h})(\psi_h - E_{B_h})^T,$$

其中 D_{ih} 为主成分特征 i 与风险事件 h 的距离, E_{A_i} 为第 i 个主成分特征样本的均值向量, E_{B_h} 为第 h 个风险事件样本的均值向量, Σ_{A_i} 为第 i 个主成分特征样本的协方差矩阵, Σ_{B_h} 为第 h 个风险事件样本阈值的协方差矩阵, $\det(\cdot)$ 为矩阵行列式;

设定距离阈值 D_0 ,当 $D_{ih} < D_0$ 时判定主成分特征 i 对应的风险指标组可能引发风

险事件 h , 否则主成分特征 i 对应的风险指标组不引发风险事件;

按数据类别和数据采集定位为第一风险事件贴标签。

[0009] 进一步的, 根据所述第一风险事件预测并发风险事件的方法, 包括:

构建FP-growth算法模块, 挖掘风险事件间的关联性, 通过已知风险事件确定并发风险事件, FP-growth算法模块的构建步骤为:

扫描历史数据统计项的频数, 设定最小支持度选出频繁项, 由频繁项和频数构建项头表;

根据项头表筛选和排序事务中的项, 由筛选结果构建FP-tree;

根据项头表确定频繁项的条件模式基和事务项集合, 根据条件模式基建立条件FP树, 采用历史数据训练FP-tree条件实例, 采用深挖和递归方法探索常见项集合, 输出FP-tree;

将第一风险事件输入FP-growth算法模块获得其并发风险事件, 按数据类别和数据采集定位为并发风险事件贴标签。

[0010] 进一步的, 据所述第一风险事件预测概率风险事件的方法, 包括:

定义第一风险事件对应风险指标的特征向量为 \mathbf{u} , 定义风险指标事件库目标风险事件对应风险指标阈值的特征向量为 \mathbf{v} , 计算第一风险事件特征向量和目标风险事件特征向量的综合相似度, 表达式为:

$$S(\mathbf{u}_f, \mathbf{v}_g) = \gamma \frac{I_{u_f} \cap I_{v_g}}{I_{u_f} \cup I_{v_g}} + \frac{1 - \gamma}{t \cdot K} \cdot \left(\sum_{x=1}^t \sqrt{\frac{n(\mathbf{u}_f)n(\mathbf{v}_g)}{n^2(s)}} \right) \cdot \left[\frac{e^{-|E_{u_f} - E_{v_g}| \cdot |\sigma_{u_f} - \sigma_{v_g}|}}{1 + e^{-|E_{u_f} - E_{v_g}| \cdot |\sigma_{u_f} - \sigma_{v_g}|}} \right],$$

$$\cdot \left(\sum_{k=1}^K \frac{|\min N_{u_f} - \min N_{v_g}| + \rho |\max N_{u_f} - \max N_{v_g}|}{|N_{u_f} - N_{v_g}| + \rho |\max N_{u_f} - \max N_{v_g}|} \right)$$

其中 $S(\mathbf{u}_f, \mathbf{v}_g)$ 为第 f 个第一风险事件特征向量 \mathbf{u}_f 与第 g 个目标风险事件特征向量 \mathbf{v}_g 的综合相似度, γ 为权重系数, I_{u_f} 为特征向量 \mathbf{u}_f 的风险指标集合, I_{v_g} 特征向量 \mathbf{v}_g 的风险指标阈值集合, t 为所有项目风险指标数量, $n(s)$ 为最大项目风险指标数量, $n(\mathbf{u}_f)$ 为特征向量 \mathbf{u}_f 的风险指标数量, $n(\mathbf{v}_g)$ 为特征向量 \mathbf{v}_g 的风险指标阈值数量, E_{u_f} 、 σ_{u_f} 为特征向量 \mathbf{u}_f 风险指标均值和方差, E_{v_g} 、 σ_{v_g} 为特征向量 \mathbf{v}_g 的风险指标阈值均值和方差, K 为向量维度, N_{u_f} 为特征向量 \mathbf{u}_f 的元素值, N_{v_g} 为特征向量 \mathbf{v}_g 的元素值, $\rho \in [0, 1]$ 为分辨系数;

设定综合相似度阈值, 根据综合相似度确定第一风险事件对应的概率风险事件, 按数据类别和数据采集定位为概率风险事件贴标签。

[0011] 进一步的, 获得所述城市安全风险评估结果的方法, 包括:

将第一风险事件、并发风险事件、概率风险事件、风险指标和风险事件权重组成安全风险数据集, 采用随机森林算法将安全风险集按照7:3划分成训练集和测试集;

构建城市安全风险评估模型, 所述城市安全风险评估模型包括贝叶斯网络、多模态预测模型和策略层;

贝叶斯网络根据已知的第一风险事件、并发风险事件和概率风险事件发生的历史数据来估计风险事件的概率关系, 计算每个风险事件在给定其它风险事件下的发生概率;

多模态预测模型用于学习训练集数据和风险事件发生概率进行安全风险评估,包括遗传-BP神经网络基模型、支持向量机回归基模型和随机森林基模型;

遗传-BP神经网络用于根据输入数据预测风险评分,采用均方误差损失函数评估预测值与实际值的差异,采用遗传算法优化网络结构和参数,采用Adam优化器调整学习率;

支持向量机回归通过输入数据找到超平面来区分不同风险等级的事件并进行风险评分预测,采用 ϵ -不敏感损失函数在 ϵ 范围内预测评分误差,采用SMO算法求解最优超平面;

随机森林通过构建决策树进行投票提高风险评分的准确性和稳定性,采用均方误差损失函数评估预测值与实际值差异,根据信息增益选择最佳分裂点;

策略层采用加权投票法整合基模型预测风险评分,输出层提取风险事件的类别和发生位置,最终输出安全风险评估结果,采用测试集评估城市安全风险评估模型;

将待评估城市安全风险监测数据和历史数据输入城市安全风险评估模型获得安全风险评估结果。

[0012] 第二方面,基于数字化标准的城市安全风险评估系统,包括:

数据采集模块:用于获取城市安全风险监测数据和历史数据,对所述监测数据和所述历史数据进行预处理;

数据处理模块:用于确定风险事件权重,用于对所述监测数据进行异常筛选和分类获得风险指标,用于匹配所述风险指标与风险指标事件库,用于预测不确定风险事件;

评估模型模块:根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果;

智能监管模块:用于储存、查看和管理所述监测数据和所述历史数据和所述城市安全风险评估结果,用于根据所述城市安全风险评估结果确定安全风险等级和向用户进行风险预警和建议,用于根据位置信息在安全风险地图上标注风险事件及其类别、安全风险等级和发生概率。

[0013] 本发明的有益效果是:

本发明是基于数字化标准的城市安全风险评估方法及系统,与现有技术相比,本发明具有以下技术效果:

本发明通过确定风险事件权重、监测数据的异常筛选和分类、数据匹配确定第一风险事件、预测不确定风险事件、构建模型步骤,可以在城市安全风险评估中提升数据预处理的能力和增强模型适应性,从而提高城市安全风险评估的效率与精度,将城市安全风险评估技术优化,可以大大节省资源,提高工作效率,可以实现对城市安全风险的评估,能够全面、客观、准确地获得城市区域的安全风险状况,为城市安全风险管控提供精准的科学指导,可以适应不同基于数字化标准的城市安全风险评估系统、不同用户的基于数字化标准的城市安全风险评估系统的终端评估需求,具有一定的普适性。

附图说明

[0014] 图1为本发明基于数字化标准的城市安全风险评估方法的步骤流程图。

具体实施方式

[0015] 下面通过具体实施例对本发明作进一步描述,在此发明的示意性实施例以及说明用来解释本发明,但并不作为对本发明的限定。

[0016] 本发明基于数字化标准的城市安全风险评估方法及系统包括以下步骤:

如图1所示,在本实施例中,包括以下步骤:

获取城市安全风险监测数据和历史数据,对所述监测数据和所述历史数据进行预处理;

根据所述历史数据构建风险指标事件库,确定风险事件权重;

对所述监测数据进行异常筛选和分类获得风险指标,将所述风险指标匹配所述风险指标事件库确定第一风险事件,根据所述第一风险事件预测不确定风险事件;所述不确定风险事件包括并发风险事件和概率风险事件;

根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果。

[0017] 在本实施例中,根据所述历史数据构建风险指标事件库并确定所述风险事件权重的方法,包括:

采用聚类法确定历史数据中不同类别的风险事件,对风险事件进行特征提取获得对应风险指标,根据风险事件和对应风险指标构建风险指标库;

按照风险类别、风险事件和风险指标划分安全风险层次,结合层次分析法和专家咨询法确定各层次评估单元的权重;

在实际评估中,按照风险类别、风险事件和风险指标划分安全风险层次,得到一级指标风险类别及对应权重:自然灾害类-0.3(地震、暴雨、台风、高温天气);事故灾难类-0.25(化工事故、烟花爆竹事故、民用爆炸物品事故、工贸事故、交通运输事故、建筑施工事故);公共卫生类-0.2(传染病爆发、食品安全事件、职业病危害);公共安全类-0.15(犯罪活动、其他安全事件);基础设施类-0.1(老旧房屋坍塌、大客流、建筑火灾、城市电梯运行、交通运输、电力运行、燃气泄漏爆炸、桥梁运行、供排水管网故障)。

[0018] 在本实施例中,对所述监测数据进行异常筛选和分类获得风险指标的方法,包括:

按照区域风险评估标准确定安全风险项目,获取安全风险项目监测数据,标准化处理监测数据并代入模糊分簇聚类算法中,根据监测数据间相似度划分n个样本空间分簇,并确定分簇目标函数,表达式为:

$$Aim = \sum_{j=1}^n \sum_{i=1}^m \mu_{ij}^2(x_j A_i) \pm \sqrt{\frac{(x_j - A_i)^2}{(\bar{x}_j - A_i)^2}},$$

其中Aim为分簇目标函数,m为簇内样本的类别维度, x_j 为j簇监测数据样本, \bar{x}_j 为j簇监测数据均值, A_i 为样本在i维度的聚类中心, μ_{ij} 为监测数据样本 x_j 属于i维度的隶属度;

计算监测数据样本中数据对象的密度值,选取密度值最大的数据点作为第一个簇聚类中心点,并计算其余数据点的密度值,表达式为:

$$D_i = \mu_{ij} \sum_{j=1}^n \exp \left\{ -\frac{Aim}{x_j(0.5r_a)^2} \right\},$$

$$D'_i = D_i - D_0 \exp \left\{ -\frac{Aim}{x_j(0.5r_b)^2} \right\},$$

其中 D_i 为聚类中心点的密度值, D'_i 为聚类中心点以外数据点的密度值, r_a 为领域半径, r_b 为领域半径更新值, D_0 为初始最大聚类中心的密度值;

更新聚类中心和监测数据样本的隶属度,一直迭代直到最大迭代次数或满足目标函数时停止迭代,获得分为数据类别不同的 K 个簇;

进行多超球面学习,根据所有监测数据进行宏观超球面学习,根据监测数据分簇聚类结果对每个簇监测数据进行介观超球面学习,表达式为:

$$L^g = \frac{1}{|V^{train}|} \sum_{v_i \in V^{train}} \|z_i - c_0\|_2^2 + \lambda_2 \sum_{i=1}^{|V^{train}|} \|z_i\|_2^2,$$

$$L^l = \frac{1}{K|V^{train}|} \sum_{v_i \in V^{train}} \|z_i - c_{k_i^*}\|_2^2 + \lambda_2 \sum_{i=1}^{|V^{train}|} \|z_i\|_2^2,$$

$$L^c = -\frac{1}{K} \sum_{k=1}^K \log \left\{ \frac{\exp[\text{Sim}(q_k, q_k^+)]}{\sum_{k'}^K \exp[\text{Sim}(q_k, q_{k'}^+)]} \right\},$$

其中 L^g 为宏观超球面学习损失函数, L^l 为介观超球面学习损失函数, L^c 为对比学习损失函数, v_i 为训练集的节点, V^{train} 为训练节点集合, $|V^{train}|$ 为训练节点数量, z_i 为节点 v_i 在空间的表征, c_0 为宏观超球体中心, $\|\cdot\|_2$ 为 L_2 范数, λ_2 为正则化参数, $c_{k_i^*}$ 为节点 v_i 所属超球体中心, k_i^* 为节点 v_i 所属簇索引, $\text{Sim}(\cdot)$ 为余弦相似度函数, q_k 为第 k 个样本的查询向量, q_k^+ 为第 k 个正样本增强向量, q_t^+ 为所有正样本增强向量集合;

根据宏观超球面学习损失函数、介观超球面学习损失函数和对比学习损失函数确定多球体学习目标,进行异常判定获得风险指标,表达式为:

$$L = L^g + \lambda_l \cdot L^l + \lambda_c \cdot L^c,$$

$$s(v_i) = \|z_i - c_0\|_2^2 + \lambda_l \cdot \|z_i - c_{k_i^*}\|_2^2,$$

其中 L 为多球体学习目标, λ_l 为介观超球面学习参数, λ_c 为对比学习参数, $s(v_i)$ 为节点 v_i 的异常评分;

按数据类别和数据采集定位为风险指标贴标签;

在实际评估中,对某城市安全风险监测数据进行异常筛选和分类获得风险指标:自然灾害类(日降雨量250mm、河床高度+6米、内涝区域数量15个、内涝水深0.3m、社交媒体关于暴雨的讨论数量10000条/小时);事故灾难类(工业区化学泄漏1起);公共安全类(公共交通故障2起、盗窃事件5起、斗殴事件1起);基础设施类(交通拥堵指数8.5、紧急服务电话数量1500次、电力故障报告40起、移动网络流量比平时增加50%、网络攻击比平时增加30%、公共设施破坏1起)。

[0019] 在本实施例中,确定所述第一风险事件的方法,包括:

定义多个风险指标有概率引发一起或多起风险事件,对风险指标进行主成分分析获得主成分特征,一个主成分特征对应一组风险指标,通过计算主成分特征与风险指标相关系数确定该主成分特征对应的风险指标组,表达式为:

$$r_{ij} = \frac{(x_i - \bar{x})(y_j - \bar{y}) + \alpha \cdot f(x_i, y_j)}{\sqrt{\sum_{i=1}^p (x_i - \bar{x})^2} \sqrt{\sum_{j=1}^q (y_j - \bar{y})^2}} - \beta \zeta,$$

$$r_i = \frac{1}{q} \sum_{j=1}^q |r_{ij}|,$$

其中 r_{ij} 为第 i 个主成分特征值 x_i 与第 j 个风险指标值 y_j 的相关系数, r_i 为第 i 个主成分特征值与所有风险指标值的相关系数绝对值均值, \bar{x} 为所有主成分特征值均值, \bar{y} 为所有风险指标值均值, p 为主成分特征数量, q 为风险指标数量, α 为非线性项权重, $f(x_i, y_j)$ 为非线性函数用于捕捉 x_i 与 y_j 非线性关系, β 为正则化系数, ζ 为正则化强度;

选择 $r_{ij} > r_i$ 的风险指标组成第 i 个主成分特征的风险指标组,定义主成分特征向量集合为 $A_i = \{\psi_i, i = 1, 2, \dots, p\}$, ψ_i 为特征向量元素,风险事件向量集合 $B_h = \{\psi_h, h = 1, 2, \dots, s\}$, ψ_h 为风险事件向量元素,由第 h 个风险事件对应的风险指标阈值构成, s 为风险指标事件库中风险事件的数量,计算多个风险指标组合与风险指标事件库中风险事件的相关性确定第一风险事件,表达式为:

$$D_{ih} = \frac{1}{4} (E_{A_i} - E_{B_h})^T (\Sigma_{A_i} - \Sigma_{B_h})^{-1} (E_{A_i} - E_{B_h}) + \frac{1}{2} \ln \left\{ \frac{\det[0.5(\Sigma_{A_i} + \Sigma_{B_h})]}{\sqrt{\det(\Sigma_{A_i}) \det(\Sigma_{B_h})}} \right\},$$

$$E_{A_i} = \frac{1}{p} \sum_{i=1}^p \psi_i, \Sigma_{A_i} = \frac{1}{p-1} (\psi_i - E_{A_i})(\psi_i - E_{A_i})^T,$$

$$E_{B_h} = \frac{1}{s} \sum_{h=1}^s \psi_h, \Sigma_{B_h} = \frac{1}{s-1} (\psi_h - E_{B_h})(\psi_h - E_{B_h})^T,$$

其中 D_{ih} 为主成分特征 i 与风险事件 h 的距离, E_{A_i} 为第 i 个主成分特征样本的均值向量, E_{B_h} 为第 h 个风险事件样本的均值向量, Σ_{A_i} 为第 i 个主成分特征样本的协方差矩阵, Σ_{B_h} 为第 h 个风险事件样本阈值的协方差矩阵, $\det(\cdot)$ 为矩阵行列式;

设定距离阈值 D_0 ,当 $D_{ih} < D_0$ 时判定主成分特征 i 对应的风险指标组可能引发风险事件 h ,否则主成分特征 i 对应的风险指标组不引发风险事件;

按数据类别和数据采集定位为第一风险事件贴标签;

在实际评估中,通过计算风险指标的相关性确定两组风险指标组(日降雨量、河床高度、内涝区域数量、内涝水深、社交媒体关于暴雨的讨论数量,相关性系数 $0.88 >$ 相关系数绝对值均值 0.62)、(内涝区域数量、公共交通故障、交通拥堵指数、电力故障报告、移动网络流量比平时增加,相关性系数 $0.75 >$ 相关系数绝对值均值 0.51);

按照相关性主成分特征与风险事件的距离(0.08、0.15,距离阈值0.2)确定第一风

险事件为暴雨极端天气和交通拥堵。

[0020] 在本实施例中,根据所述第一风险事件预测并发风险事件的方法,包括:

构建FP-growth算法模块,挖掘风险事件间的关联性,通过已知风险事件确定并发风险事件,FP-growth算法模块的构建步骤为:

扫描历史数据统计项的频数,设定最小支持度选出频繁项,由频繁项和频数构建项头表;

根据项头表筛选和排序事务中的项,由筛选结果构建FP-tree;

根据项头表确定频繁项的条件模式基和事务项集合,根据条件模式基建立条件FP树,采用历史数据训练FP-tree条件实例,采用深挖和递归方法探索常见项集合,输出FP-tree;

将第一风险事件输入FP-growth算法模块获得其并发风险事件,按数据类别和数据采集定位为并发风险事件贴标签;

在实际评估中,将暴雨极端天气和交通拥堵对应的风险指标输入FP-growth算法模块,确定并发风险事件为公共交通延误、排水系统障碍。

[0021] 在本实施例中,据所述第一风险事件预测概率风险事件的方法,包括:

定义第一风险事件对应风险指标的特征向量为 \mathbf{u} ,定义风险指标事件库目标风险事件对应风险指标阈值的特征向量为 \mathbf{v} ,计算第一风险事件特征向量和目标风险事件特征向量的综合相似度,表达式为:

$$S(\mathbf{u}_f, \mathbf{v}_g) = \gamma \frac{I_{u_f} \cap I_{v_g}}{I_{u_f} \cup I_{v_g}} + \frac{1 - \gamma}{t \cdot K} \cdot \left(\sum_{x=1}^t \sqrt{\frac{n(\mathbf{u}_f)n(\mathbf{v}_g)}{n^2(s)}} \right) \cdot \left[\frac{e^{-|E_{u_f} - E_{v_g}| \cdot |\sigma_{u_f} - \sigma_{v_g}|}}{1 + e^{-|E_{u_f} - E_{v_g}| \cdot |\sigma_{u_f} - \sigma_{v_g}|}} \right],$$

$$\cdot \left(\sum_{k=1}^K \frac{|\min N_{u_f} - \min N_{v_g}| + \rho |\max N_{u_f} - \max N_{v_g}|}{|N_{u_f} - N_{v_g}| + \rho |\max N_{u_f} - \max N_{v_g}|} \right)$$

其中 $S(\mathbf{u}_f, \mathbf{v}_g)$ 为第 f 个第一风险事件特征向量 \mathbf{u}_f 与第 g 个目标风险事件特征向量 \mathbf{v}_g 的综合相似度, γ 为权重系数, I_{u_f} 为特征向量 \mathbf{u}_f 的风险指标集合, I_{v_g} 特征向量 \mathbf{v}_g 的风险指标阈值集合, t 为所有项目风险指标数量, $n(s)$ 为最大项目风险指标数量, $n(\mathbf{u}_f)$ 为特征向量 \mathbf{u}_f 的风险指标数量, $n(\mathbf{v}_g)$ 为特征向量 \mathbf{v}_g 的风险指标阈值数量, E_{u_f} 、 σ_{u_f} 为特征向量 \mathbf{u}_f 风险指标均值和方差, E_{v_g} 、 σ_{v_g} 为特征向量 \mathbf{v}_g 的风险指标阈值均值和方差, K 为向量维度, N_{u_f} 为特征向量 \mathbf{u}_f 的元素值, N_{v_g} 为特征向量 \mathbf{v}_g 的元素值, $\rho \in [0,1]$ 为分辨系数;

设定综合相似度阈值,根据综合相似度确定第一风险事件对应的概率风险事件,按数据类别和数据采集定位为概率风险事件贴标签;

在实际评估中,设定综合相似度阈值为0.6,计算第一风险事件对应风险指标的特征向量与风险指标事件库目标风险事件对应风险指标阈值的特征向量的综合相似度,根据综合相似度阈值确定概率风险事件:公共设备损害、房屋损害、地下设施积水、公共健康问题、公共活动取消、公共服务中断、网络通信受损、农业经济损失、供应链中断。

[0022] 在本实施例中,获得所述城市安全风险评估结果的方法,包括:

将第一风险事件、并发风险事件、概率风险事件、风险指标和风险事件权重组成安全风险数据集,采用随机森林算法将安全风险集按照7:3划分成训练集和测试集;

构建城市安全风险评估模型,所述城市安全风险评估模型包括贝叶斯网络、多模态预测模型和策略层;

贝叶斯网络根据已知的第一风险事件、并发风险事件和概率风险事件发生的历史数据来估计风险事件的概率关系,计算每个风险事件在给定其它风险事件下的发生概率;

多模态预测模型用于学习训练集数据和风险事件发生概率进行安全风险评估,包括遗传-BP神经网络基模型、支持向量机回归基模型和随机森林基模型;

遗传-BP神经网络用于根据输入数据预测风险评分,采用均方误差损失函数评估预测值与实际值的差异,采用遗传算法优化网络结构和参数,采用Adam优化器调整学习率;

支持向量机回归通过输入数据找到超平面来区分不同风险等级的事件并进行风险评分预测,采用 ϵ -不敏感损失函数在 ϵ 范围内预测评分误差,采用SMO算法求解最优超平面;

随机森林通过构建决策树进行投票提高风险评分的准确性和稳定性,采用均方误差损失函数评估预测值与实际值差异,根据信息增益选择最佳分裂点;

策略层采用加权投票法整合基模型预测风险评分,输出层提取风险事件的类别和发生位置,最终输出安全风险评估结果,采用测试集评估城市安全风险评估模型;所述安全风险评估结果包括整体风险评分、风险事件及其类别、发生概率和发生位置;所述风险事件包括主要风险事件和不确定风险事件;

将待评估城市安全风险监测数据和历史数据输入城市安全风险评估模型获得安全风险评估结果;

在实际评估中,根据风险事件、风险指标和对应的类别权重采用贝叶斯网络计算得到风险事件发生的概率:(风险事件:暴雨极端天气90%、交通拥堵80%),(并发风险事件:公共交通延误70%、排水系统障碍60%),(不确定风险事件:公共设施损害30%、房屋损害20%、地下设施积水25%、公共健康问题15%、公共活动取消10%、公共服务中断5%、网络通信受损10%、农业经济损失20%、供应链中断15%);

将待评估城市安全风险监测数据和历史数据输入城市安全风险评估模型获得城市安全风险评估结果:城市安全风险评分为47分,是由极端暴雨天气事件引发的公共交通拥堵/延误事件,属于自然灾害类和事故灾难类风险事件,同时伴有事故灾难类、公共卫生类和基础设施类风险事件的发生。

[0023] 第二方面,基于数字化标准的城市安全风险评估系统,包括:

数据采集模块:用于获取城市安全风险监测数据和历史数据,对所述监测数据和所述历史数据进行预处理;

数据处理模块:用于确定风险事件权重,用于对所述监测数据进行异常筛选和分类获得风险指标,用于匹配所述风险指标与风险指标事件库,用于预测不确定风险事件;

评估模型模块:根据所述第一风险事件、所述不确定风险事件和所述风险事件权重构建城市安全风险评估模型,将待评估城市安全风险监测数据和历史数据输入所述城市安全风险评估模型获得城市安全风险评估结果;

智能监管模块:用于储存、查看和管理所述监测数据和所述历史数据和所述城市

安全风险评估结果,用于根据所述城市安全风险评估结果确定安全风险等级和向用户进行风险预警和建议,用于根据位置信息在安全风险地图上标注风险事件及其类别、安全风险等级和发生概率;

在实际评估中,通过监管模块导入城市安全风险评估结果,在安全风险地图中标记风险指标发生的位置,并标注对应的风险事件、风险事件类别、风险事件概率和城市安全风险评分,通过风险阈值判定城市安全风险评分为47分为中等风险,并向用户端发送预警信息和应对建议。

[0024] 以上所述仅为本发明的较佳实施例,并不用以限制本发明,凡在本发明的精神和原则之内,所作的任何修改、等同替换、改进等,均应包含在本发明的保护范围之内。

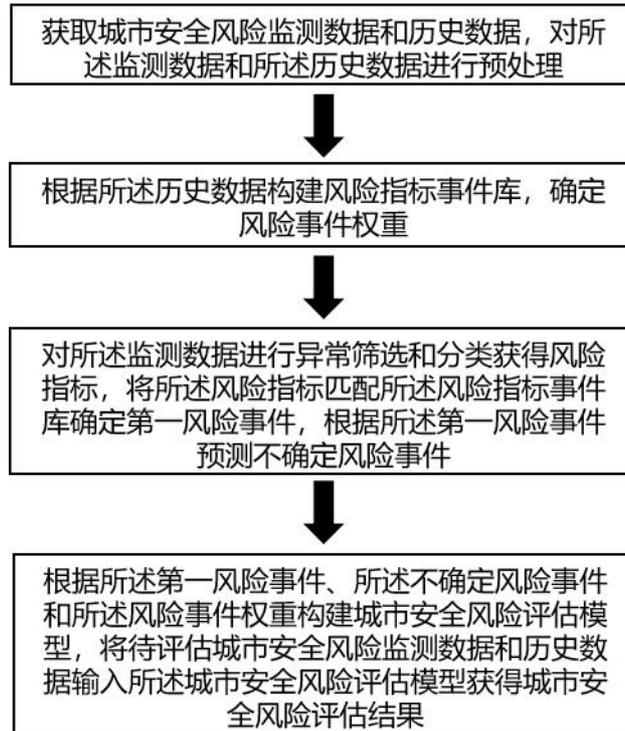


图 1