

# 基于数据挖掘和CAPSO-SNN的电力作业风险态势感知

陈碧云,李弘斌,李 滨

(广西大学 广西电力系统最优化与节能技术重点实验室,广西 南宁 530004)

**摘要:**随着电力作业安全监控技术的不断发展,电力作业全过程在线信息采集成为可能。以电力作业数据为基础,提出一种基于数据挖掘和云自适应粒子群优化脉冲神经网络(CAPSO-SNN)的电力作业风险态势感知方法。该方法首先从电力作业事故事件数据库中提炼出所有作业风险影响因素以构建风险影响因素体系,然后通过主成分分析法从中挖掘出作业过程中应重点关注的风险关键要素,再以风险关键要素作为输入参数,通过云自适应粒子群优化脉冲神经网络进行作业风险态势感知的训练和预测。最后,以某电网公司的实际历史作业事故事件为样本,展示了所提方法的应用过程。算例结果表明,该方法不仅适用于分析电力作业的风险组成,还可以在作业过程中有效地感知风险状态信息,跟踪风险发展趋势,有助于实施电力作业风险的全过程精细化态势利导管控。

**关键词:**数据挖掘;态势感知;云自适应粒子群优化;脉冲神经网络;态势利导;电力作业

**中图分类号:**TM 734

**文献标志码:**A

**DOI:**10.16081/j.epae.201912027

## 0 引言

态势感知 SA(Situation Awareness)是指对某个时空范围内的环境因素进行感知、理解,并且对未来状态的发展趋势进行预测<sup>[1]</sup>。SA技术不仅在航空、军事、网络安全等领域的风险控制分析方面得到广泛应用<sup>[2]</sup>,也同样在电力领域中引起了高度关注<sup>[3]</sup>。近年来,不少学者对基于SA的电网调度运行架构<sup>[4-6]</sup>及其关键技术<sup>[7-9]</sup>展开讨论。有学者提出由大数据驱动的电力生产安全风险SA将是未来电力生产安全预警和控制决策的关键技术之一<sup>[10]</sup>。

目前国内外针对电力生产安全风险的SA研究主要关注于系统的运行风险。例如,文献[11]面向能源互联网提出了提高配电网拓扑安全SA能力的互联架构,为未来能源互联网环境的鲁棒配电网建设提供了理论参考与技术支撑。文献[12]综合考虑主动配电系统的供电能力、运行薄弱环节以及分布式电源等因素,构建主动配电系统的安全SA指标体系,并利用模糊层次分析法对系统进行安全态势预警等级评估。文献[13]在大数据分析以及人工智能算法的基础上,提出了智能电网网络安全的SA机制,并强调了智能算法与SA融合交互的重要性。

值得注意的是,除了系统运行风险之外,电力生产安全风险有相当一部分来源于电力生产作业过程,且与作业环境、气象因素、人员状态、设备状态以及管控机制等高维多源异构影响因素密切相关。这些风险影响因素涵盖了电力作业的风险信息,在作

业过程中经过诱发、转化、耦合而演化成具有时间关联性的作业事故场景。但是,目前针对电力作业过程的风险研究仍局限于风险因素分析与脱机量化评估<sup>[14-15]</sup>,且忽视了作业历史事故样本集中潜在的风险诱因大数据。而基于数据分析的传统风险评估方法中,统计方法仍处于数据的简易分析层面,无法对多维数据信息进行深度挖掘和汲取;层次分析法、专家系统法等为主观赋权的数据融合方式,风险评价结果难免存在一定的主观局限性<sup>[16]</sup>。文献[17]借鉴安全行为学、心理学和事故致因理论筛选人身安全风险因子,利用多元线性回归法对电力作业人身事故危害值进行预测,但其所用算法在面对大量电力作业数据时计算精度有限,且无法对作业过程中的风险趋势演化模式进行识别。随着各类智能传感设备和基于数据驱动的智能算法的发展,充分利用历史数据以及现场环境、人员和设备等实时状态监测信息,实现作业过程的风险动态评估和预警成为可能。为此,融合人工智能算法的SA架构为电力作业全过程风险智能化管控技术的研究提供了契机。

本文考虑未来电力作业现场实时安全监控技术的发展趋势,构建了一种数据驱动的电力作业风险SA基本框架。在该框架下,首先阐述了基于主成分分析PCA(Principal Component Analysis)法的电力作业风险关键要素挖掘流程;得益于第三代神经网络——脉冲神经网络SNN(Spiking Neural Networks)的数据挖掘与模式识别能力<sup>[18]</sup>,以作业过程中的风险关键要素作为研究对象,提出了基于云自适应粒子群优化脉冲神经网络CAPSO-SNN(Cloud Adaptive Particle Swarm Optimization-Spiking Neural Networks)的电力作业风险SA方法,以期为电力作业风险全过程精细化态势利导控制提供技术支撑。以某

收稿日期:2019-05-15;修回日期:2019-10-28

基金项目:国家自然科学基金资助项目(51767002)

Project supported by the National Natural Science Foundation of China(51767002)

电网公司的300起电力作业历史事故案例分析验证了所提模型方法的有效性。

## 1 电力作业风险SA基本框架

电力作业风险SA基本框架可分为关键要素挖掘、风险状态理解和风险趋势预测3个阶段,分别解决挖掘电力作业在线风险感知中需要重点关注的风险关键要素、理解电力作业风险状态与构成以及电力作业风险趋势预测和作业调整措施制定等问题。

(1)关键要素挖掘(excavation):这一阶段主要是从复杂无序、多种类、多层次的作业风险影响因素中剔除风险弱相关因素以及信息采集难度较大的因素,从中挖掘出风险关键要素并将其作为作业过程中需要感知的风险因素信息,达到降低信息采集成本、提高作业风险防控效率的目的。

(2)风险状态理解(comprehension):通过构建电力作业风险SA模型,实时分析感知到的风险关键要素状态,对当前电力作业过程进行风险态势评价,分析风险状态组成,为风险趋势预测提供风险状态信息。

(3)风险趋势预测(projection):根据对电力作业风险状态信息理解、分析的结果,跟踪风险发展趋势,预测风险等级。由此,可在作业风险发展至高风险阈值前提出风险态势利导控制决策辅助作业方式的调整,进而对作业风险进行闭环精准管控。包含3个阶段的电力作业风险SA基本框架如图1所示,图中 $X_1, X_2, \dots, X_m$ 为风险影响因素的各因素值。

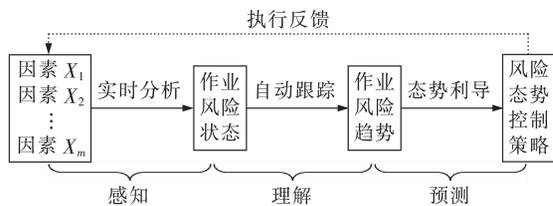


图1 电力作业风险SA基本框架

Fig.1 Basic framework of power operation risk SA

## 2 关键要素挖掘

根据事故致因理论,对某电网公司电力作业历史事故事件进行整理分析,将电力作业风险影响因素总结归类为人员属性类(A)、心理及行为类(B)、设备类(C)、作业管理类(D)、作业性质类(E)以及环境类(F)这6类一级因素,其中包含49类二级因素,涉及257个三级因素,建立的风险影响因素体系见附录中图A1。

为了保证用于分析计算的风险影响因素的关键性,需要对风险影响因素体系中的风险关键要素进行挖掘。本文利用PCA法剔除风险信息过度重叠的风险影响因素,以挖掘出相关性小且能反映电力作业全过程风险组成的风险关键要素,以便实现风

险数据降维,减少信息采集工作量,缩小安全薄弱环节评估范围<sup>[19]</sup>。实现流程如下。

(1)影响因素标准化。

由于风险影响因素的量纲不同,分布各异,需要对风险影响因素进行标准化处理。假设第 $i$ 个三级风险影响因素为 $Z_i$ ,按下式将风险影响因素的各因素值进行离差标准化处理:

$$X_i = \frac{Z_i - \bar{Z}_i}{\sqrt{D(Z_i)}} \quad (1)$$

其中, $\bar{Z}_i, D(Z_i)$ 分别为三级风险影响因素 $Z_i$ 的平均值与方差值; $X_i$ 为经离差标准化后的第 $i$ 个三级风险影响因素值。

(2)相关性矩阵建立与特征值计算。

以电网公司的电力作业事故事件数据库为数据样本,对不同事故数据信息进行抽象综合,建立符合样本集的风险影响因素体系,并利用Pearson相关系数来度量该体系中三级风险影响因素之间的相关性强弱。假设 $n$ 起作业历史事故的 $m$ 个三级风险影响因素构成的标准化风险影响因素矩阵为:

$$X = [X_1, X_2, \dots, X_i, \dots, X_m]_{n \times m} \quad (2)$$

其中, $X$ 为 $n \times m$ 阶标准化三级风险影响因素矩阵;第 $i$ 个三级风险影响因素向量 $X_i = [X_{i1}, X_{i2}, \dots, X_{im}]^T$ 。则进行相关性分析的三级风险影响因素向量 $X_i$ 和 $X_j$ 的Pearson相关系数表达式如下:

$$\rho_{ij} = \frac{\text{cov}(X_i, X_j)}{\sqrt{D(X_i)} \sqrt{D(X_j)}} \quad (3)$$

其中, $\text{cov}(X_i, X_j)$ 为向量 $X_i$ 和 $X_j$ 的协方差; $D(X_i)$ 和 $D(X_j)$ 分别为向量 $X_i$ 和 $X_j$ 的方差值。则可构建 $m$ 个三级风险影响因素的相关系数矩阵 $R$ 为:

$$R = \begin{bmatrix} \rho_{11} & \rho_{12} & \dots & \rho_{1m} \\ \rho_{21} & \rho_{22} & \dots & \rho_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{m1} & \rho_{m2} & \dots & \rho_{mm} \end{bmatrix} \quad (4)$$

对于构建的相关系数矩阵 $R$ ,可根据特征方程 $|\lambda E - R| = 0$ 求取其特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq \dots \geq \lambda_q (q \leq m)$ 以及相应的特征向量。

(3)主成分确定。

特征值 $\lambda_p$ 代表了主成分 $\gamma_p$ 的方差。第 $p$ 个主成分的方差贡献率 $\omega_p$ 可表示主成分 $\gamma_p$ 包含 $m$ 个风险影响因素信息的百分比,其表达式如下:

$$\omega_p = \lambda_p / \sum_{j=1}^q \lambda_j \quad (5)$$

主成分的方差贡献率与主成分的特征值大小成正比。当前 $o$ 个主成分的累积方差贡献率大于设定的累积方差贡献率阈值(一般取75%~95%)时,则认为前 $o$ 个主成分即可反映 $m$ 个风险影响因素的绝

大部分信息。前 $o$ 个主成分的累积方差贡献率表达式如下:

$$\mu_o = \sum_{p=1}^o \lambda_p / \sum_{j=1}^o \lambda_j \quad (6)$$

(4) 风险关键要素确定。

根据选取的 $o$ 个主成分,通过因子分析计算主成分因子载荷矩阵  $U = (u_1, \dots, u_p, \dots, u_o)_{m \times o}$ 。相关载荷列向量  $u_p$  中的元素  $u_{pi}$  对应第 $p$ 个主成分  $\gamma_p$  与原第 $i$ 个三级风险影响因素  $X_i$  间的相关载荷系数,取值区间为  $[-1, 1]$ 。相关载荷系数的正、负号分别代表正相关和负相关,其绝对值越大表明该因素与主成分的相关性越强。对于 $o$ 个主成分,分别选取  $u_p - u_o$  中最大值以及大于相关载荷系数设定阈值对应的风险影响因素作为作业全过程风险 SA 的风险关键要素。相关载荷系数阈值的设定决定了提炼出的风险关键要素所携带风险信息的有效性,过高的阈值导致风险关键要素过少,无法反映作业的绝大部分风险信息;反之,过低的阈值导致风险关键要素之间包含的风险信息重叠过多。因此,可结合部分事故样本进行交叉验证,设定验证误差最小的主成分个数与相关载荷系数阈值。需要说明的是,三级风险影响因素的取值方法、范围应结合电网公司实际情况,随着事故样本增加不断更新。

### 3 SNN 及其学习算法

#### 3.1 SNN

SNN 常用的简化模型为脉冲响应模型 SRM (Spiking Response Model),包含输入层、隐含层以及输出层 3 层神经元层。SNN 与常见的反向传播 BP (Back Propagation) 神经网络结构十分相似,其区别在于 SNN 结构的连续层中任意 2 个神经元  $e$  和  $f$  之间存在多个具有突触权值  $W_{ef}^a$  与可调节突触延时  $d^a$  的突触端,其连接结构如图 2 所示。

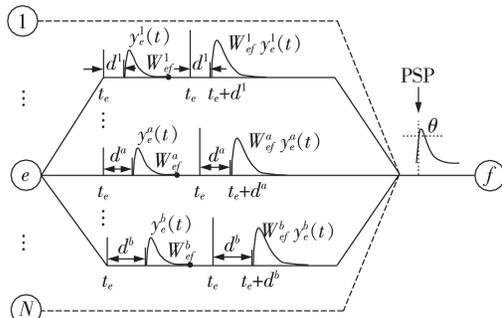


图2 SNN 连续层任意 2 个神经元间的连接结构

Fig.2 Connecting structure between any two neurons of SNN continuous layer

SRM 中的神经元状态仅由膜电位  $V(t)$  描述,且神经元的膜电位由上一层神经元的突触后电位 PSP (Post Synaptic Potential) 决定。当在  $t_f$  时刻神经元  $f$

接收一系列脉冲,使其膜电位值升高至预先设定的脉冲激发阈值  $\theta$  时,神经元  $f$  就发射一个脉冲信号,即 PSP。神经元  $f$  的膜电位值表达式如下:

$$V_f(t) = \sum_{e \in \Gamma^f} \sum_{a=1}^b W_{ef}^a y_e^a(t) \quad (7)$$

$$y_e^a(t) = \varepsilon(t - t_e - d^a) \quad (8)$$

其中,  $\Gamma^f$  为与神经元  $f$  直接相连的上一层神经元;  $b$  为神经元  $e$  和  $f$  之间连接的突触端数量;  $y_e^a(t)$  为神经元  $e$  的第  $a$  个突触端上未加权重的激励;  $t_e$  为神经元  $e$  的脉冲发射时间,单位为 ms;  $\varepsilon(t)$  为脉冲响应函数 SRF (Spike Response Function)。  $\varepsilon(t)$  可表示一个输入脉冲产生的 PSP,其表达式如下:

$$\varepsilon(t) = \begin{cases} \frac{t}{\tau} e^{1-\frac{t}{\tau}} & t > 0 \\ 0 & t \leq 0 \end{cases} \quad (9)$$

其中,  $\tau$  为 PSP 的衰减时间常数,单位为 ms。

#### 3.2 粒子群优化算法

粒子群优化 PSO (Particle Swarm Optimization) 算法思想基于迭代原理:假设  $l$  维空间中存在  $\kappa$  个飞行粒子,其中第  $r$  个粒子的位置表示为  $z_r = (z_{r1}, z_{r2}, \dots, z_{rl})$ ; 飞行速度表示为  $v_r = (v_{r1}, v_{r2}, \dots, v_{rl})$ ; 飞行过程中个体粒子经历的最优位置记为  $P_r = (p_{r1}, p_{r2}, \dots, p_{rl})$ ; 全局粒子经历的最优位置记为  $P_g = (p_{g1}, p_{g2}, \dots, p_{gl})$ ;  $r = 1, 2, \dots, \kappa$ 。算法首先初始化随机解,并构造适应度函数,通过随机解的适应度值进行迭代寻优,最终得到全局最优解。标准 PSO 算法的进化公式如下:

$$\begin{cases} v_{rs}^{k+1} = \omega v_{rs}^k + c_1 \mu_1 (p_{rs} - z_{rs}^k) + c_2 \mu_2 (p_{gs} - z_{rs}^k) \\ z_{rs}^{k+1} = z_{rs}^k + v_{rs}^{k+1} \end{cases} \quad (10)$$

其中,  $r = 1, 2, \dots, \kappa$ ;  $s = 1, 2, \dots, l$ ;  $\omega$  为惯性权重系数;  $c_1, c_2$  分别为认知和社会学习因子;  $\mu_1, \mu_2$  为 0~1 的随机数值;  $p_{rs}, p_{gs}$  分别为第  $r$  个粒子和全局粒子在第  $s$  维空间的最优解;  $v_{rs}^k, z_{rs}^k$  分别为第  $k$  次迭代中第  $r$  个粒子在第  $s$  维空间的速度与位置。由于标准 PSO 算法中粒子的学习因子与惯性权重的更新策略设置过于简单,导致算法寻优速度慢、精度低,容易在迭代中陷入局部最优和早熟收敛<sup>[20]</sup>。因此,需要改善惯性权重与学习因子的动态调整策略。

#### 3.3 CAPSO-SNN 学习算法

##### 3.3.1 惯性权重云自适应调整策略

在粒子群寻优过程的第  $k$  次迭代中,假设粒子适应度均值为  $\bar{f}^k$ , 优于和非优于  $\bar{f}^k$  的粒子适应度均值分别为  $\bar{f}_0^k$  和  $\bar{f}_1^k$ 。则第  $k$  次迭代中根据当前适应度值  $f_i^k$  的云自适应惯性权重  $\omega^k$  生成公式为:

$$\omega^k = \begin{cases} \omega_{\min} & f_i^k \leq \bar{f}_0^k \\ \omega_{\max} - 0.5u(f_i^k) & \bar{f}_0^k < f_i^k < \bar{f}_1^k \\ \omega_{\max} & f_i^k \geq \bar{f}_1^k \end{cases} \quad (11)$$

$$u(f_i^k) = e^{-\frac{(f_i^k - E_n^k)^2}{2(E_n^k)^2}} \quad (12)$$

其中,惯性权重云自适应调整范围为 $[\omega_{\min}, \omega_{\max}]$ ;第 $k$ 次迭代中云自适应惯性权重生成公式的期望 $E_n^k = \bar{f}^k$ ;熵 $E_n^k = (\bar{f}^k - f_{\min}^k)/\varphi_1$ ,超熵 $H_n^k = E_n^k/\varphi_2$ , $\varphi_1, \varphi_2$ 为调整系数;方差 $E_n^k = \text{normrnd}(E_n^k, H_n^k, 1, 1)$ , $\text{normrnd}(\cdot)$ 为生成正态分布随机数。

### 3.3.2 学习因子动态调整策略

$c_1, c_2$ 决定了粒子间信息交换的能力,对其进行动态调整可有效提高算法性能。寻优初期,需要所有粒子各自向着个体最优解 $P_r$ 快速寻优,同时保持粒子群多样性,此时令 $c_1 > c_2$ ;进化后期,全局粒子最优解已接近收敛值,需要各粒子在全局最优解 $P_g$ 附近寻优,此时令 $c_1 < c_2$ 。学习因子按以下公式进行动态调整:

$$c_1 = c_{1\max} - k(c_{1\max} - c_{1\min})/K \quad (13)$$

$$c_2 = c_{2\min} + k(c_{2\max} - c_{2\min})/K \quad (14)$$

其中, $[c_{1\min}, c_{1\max}]$ 和 $[c_{2\min}, c_{2\max}]$ 分别为 $c_1$ 和 $c_2$ 的取值范围; $k$ 和 $K$ 分别为当前迭代次数与迭代总次数。

### 3.3.3 SNN 训练步骤

根据上述 CAPSO 算法对 SNN 模型进行离线训练,以求取各突触端的最优权重,训练步骤如下。

(1) 筛选、整理事故样本数据,将样本数据初始化至区间 $[0, 1]$ 内,再进行脉冲发射时间编码。

(2) 对 SNN 的拓扑结构、参数进行设置,初始化突触权值以及粒子群,设当前迭代次数为 1。

(3) 选择适应度函数。本文将 SNN 的训练误差  $E$  作为适应度函数,其表达式为:

$$E = \frac{1}{2} \sum_{h=1}^J (t_h^A - t_h^D)^2 \quad (15)$$

其中, $t_h^A$ 和 $t_h^D$ 分别为输出层神经元 $h$ 的实际和期望输出脉冲发射时间,单位为 ms; $J$ 为输出层神经元数目。

(4) 对当前代各粒子计算的适应度值进行评价。将个体粒子的最优适应度值及位置存储在 $P_r$ 中;将全局粒子的最优适应度值及位置存储在 $P_g$ 中。

(5) 根据 3.3.1 节所述方法对惯性权重 $\omega$ 进行云自适应规则调整;根据 3.3.2 节所述方法对学习因子 $c_1, c_2$ 进行动态调整。

(6) 由调整后的参数重新计算粒子的速度和位置,生成新的粒子,并根据步骤(4)更新粒子适应度值的个体和全局最优值。若迭代次数未达到设定上限,则转到步骤(5);反之,输出网络突触端最优权值。

## 4 电力作业风险 SA 方法

电网公司电力作业事故事件数据库涵盖了带时

间戳的潜在风险影响因素信息,但其往往只提供了每起作业事故危害后果的综合评估结果,未能体现各个风险影响因素的不同状态对作业事故危害后果的耦合诱发关系以及各类风险影响因素在作业过程中的风险比重变化。

为此,本文利用 PCA 法挖掘出作业事故样本集的风险关键要素,对其因素状态进行精准时间编码后输入基于 CAPSO-SNN 的作业风险 SA 模型,对模型进行离线训练,以此深度汲取各个风险关键要素在不同状态下的事故危害后果贡献信息。训练后的模型可用于评估作业事故样本集的风险关键管控点,同时能够用于在线跟踪作业风险变化趋势,制定态势利导方向的风险管控措施。基于 CAPSO-SNN 的作业风险 SA 模型训练示意图如图 3 所示。

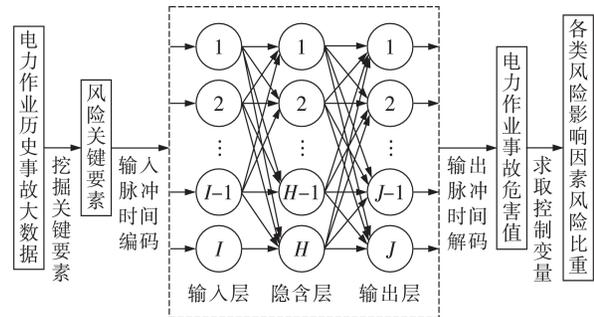


图 3 基于 CAPSO-SNN 的作业风险 SA 模型训练示意图

Fig.3 Diagram of training operation risk SA model based on CAPSO-SNN

### 4.1 输入输出变量选取

假设选取的电力作业事故样本集中有 $n$ 起电力作业事故,将电力作业事故危害评估值作为电力作业风险 SA 模型的输出变量。 $n$ 起电力作业事故危害评估值的向量表达式如下:

$$Y = [Y_1, Y_2, \dots, Y_n]^T \quad (16)$$

其中,作业事故危害评估值 $Y$ 根据 Q/CSG 210020—2014《中国南方电网有限责任公司电力事故事件调查规程》中的电力作业事故事件等级划分标准,综合评估作业事故造成的人身伤害、负荷损失与供电用户停电比例等内容对其进行标准量化。 $Y$ 属于无量纲值,其表示作业事故危害后果严重程度的一种度量。选取作业过程中的风险关键要素为模型输入变量, $n$ 起电力作业事故的 $m$ 个风险关键要素矩阵表达式如下:

$$X^* = [X_1^*, X_2^*, \dots, X_i^*, \dots, X_m^*]_{n \times m} \quad (17)$$

其中, $X_i^* = [X_{1i}^*, X_{2i}^*, \dots, X_{ni}^*]^T$ 为 $n$ 起作业事故事件的第 $i$ 个风险关键要素列向量。对于因素状态为连续量的关键要素,其取值为真实值;对于因素状态为逻辑量的关键要素,根据其状态是否存在以及程度大小对其进行赋值。上述风险关键要素值最终均标准化

至 $[0,1]$ 范围内,以便进行精准脉冲发射时间编码。

#### 4.2 参数设置

SNN输入、输出层神经元的数量 $I$ 、 $J$ 分别对应于模型的输入、输出变量的数量。本文输入层神经元数量 $I=122$ ,即122个风险关键要素;输出层神经元数量 $J=1$ ,即每起作业事故的危害评估值。除此之外,SNN的可调节参数有:隐含层的神经元数量 $H$ 、突触初始权值 $W$ 、突触数量 $b$ 、突触延迟 $d^a$ 的数值及其间隔以及衰减时间常数 $\tau$ 。

网络参数关乎模型的预测精度与计算速度,故本文将均方误差MSE(Mean Square Error)作为控制参数调整方向的指标。选取各参数变化范围为:隐含层神经元数量 $H \in [60, 100]$ ;初始权重 $W \in [0.001, 1]$ ;连接突触数量 $b \in [10, 20]$ ;突触延迟 $d^a \in [0.001, 0.03]$ ;衰减时间常数 $\tau \in [0.001, 0.01]$ 。确定某个参数的最优值时,保持其他参数不变,目标参数在所选领域内变化至突触权值变化的MSE最小时,即可输出最优参数。需要注意的是,为了避免参数寻优过程中SNN发生过拟合问题,需要在训练样本尺度内抽取出一个子集作为验证样本,当训练过程中验证误差逐渐增大时,表明SNN泛化能力下降,应停止训练。

设CAPSO算法的进化迭代次数 $K=300$ ,种群规模 $\kappa=100$ ;调整系数 $\varphi_1=0.5, \varphi_2=10$ ;惯性权重 $\omega \in [0.1, 0.9]$ ;  $c_1$ 和 $c_2$ 的取值范围均为 $[0.5, 2.5]$ 。

#### 4.3 脉冲发射时间编码

由于脉冲神经元对信息的编码与首次脉冲发射时刻有关,则在经归一化到区间 $[0,1]$ 内的风险关键要素中,最大值1对应的神经元将首先发射脉冲,记发射时间为0;最小值0对应的神经元最后发射脉冲,记发射时间为 $T_{\max}$ 。脉冲发射时间编码公式为:

$$T = T_{\max}(1 - T^*) \quad (18)$$

其中, $T_{\max}$ 为最大脉冲发射时间,单位为ms; $T^*$ 为经归一化后的风险关键要素值; $T$ 为经编码后神经元的脉冲发射时间,单位为ms。经过多次实验设置合适的输入、输出脉冲之间的时间延时 $\Delta t$ ,即可将输入变量 $X^*$ 编码成输入脉冲发射时间 $t_x \in [0, T_{\max}]$ ;对应的输出变量 $Y$ 编码成输出脉冲发射时间 $t_y \in [0 + \Delta t, T_{\max} + \Delta t]$ 。

#### 4.4 电力作业风险SA流程

综上所述,作业风险SA模型离线训练步骤以及电力作业全过程风险SA的实现流程如图4所示。电力作业在 $t$ 时刻的风险值 $R(t)$ 可由该次作业在 $t$ 时刻的事故危害评估值 $Y(t)$ 与事故发生概率 $P(t)$ 计算得到:

$$R(t) = Y(t)P(t) \quad (19)$$

其中,事故发生概率为风险关键要素条件概率值

$P(Y|X_i^*(t))$ 的累乘。条件概率值是指根据贝叶斯公式获得的当前风险关键要素状态下发生事故的概率。为便于计算,选取风险关键要素条件概率最小值作为基准值,将各个风险关键要素的条件概率值转换为标么值,并对作业事故发生概率值作如下处理:

$$P(t) = \lg \left( \prod_{i=1}^m P(Y|X_i^*(t)) \right) \quad (20)$$

其中, $i$ 为风险关键要素编号; $m$ 为风险关键要素数目。

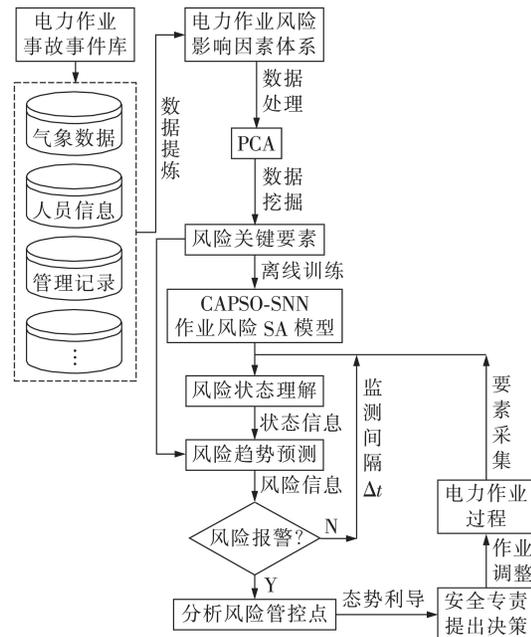


图4 电力作业风险SA流程

Fig.4 Process of power operation risk SA

风险阈值根据电网公司风险等级划分标准设置,如附录中图A2所示。当电力作业风险值达到预警风险等级时发出报警信息。安全专责可根据风险态势利导方向提供作业方式调整措施辅助风险精细化管控。

## 5 实例分析

### 5.1 模型准确性验证

以某电网公司的300起电力作业历史事故事件为例,构建作业事故训练样本集,另取30起事故事件作为测试样本,用于交叉验证主成分个数与相关载荷系数阈值的选择优度。利用上述PCA法从该作业事故训练样本集风险影响因素体系的257个三级因素中提取出73个主成分,主成分累计方差贡献率为92%,说明该73个主成分集中了全部因素的绝大部分风险信息。随后,通过因子载荷相关性分析,经交叉验证后设置相关载荷系数阈值为0.31,以此挖掘出122个风险关键要素(如附录中图A3所示)

用于仿真分析。应用 4.2 节方法设置 SNN 参数以及 CAPSO 算法参数,建立基于 BP 神经网络、SNN、PSO-SNN 以及 CAPSO-SNN 的作业风险 SA 模型。对 4 个风险 SA 模型输入带时间戳的风险关键要素信息,对模型的预测性能进行比较分析并验证所提模型的有效性与准确性。部分样本的风险预测值与真实值的对比结果如图 5 所示。

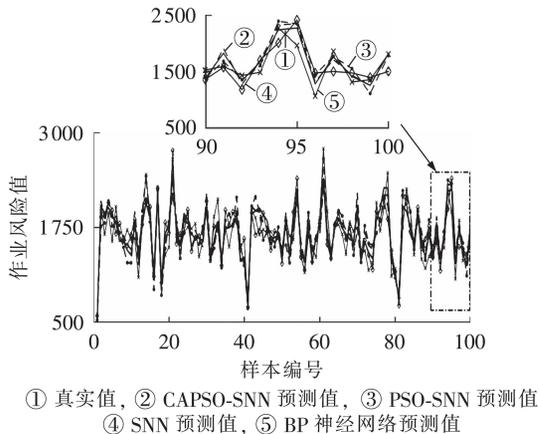


图 5 样本风险预测值与真实值对比

Fig.5 Comparison between risk predicted value and actual value of samples

每例样本的作业风险真实值为该次作业的事故危害评估值与根据该次作业风险关键要素状态计算出的事故发生概率的乘积。由图 5 可知,各模型计算结果与真实值具有较高的一致性,风险预测值与真实值的吻合度较好,且 CAPSO-SNN 的预测值更加贴近真实值。为了从数值上展现不同模型的整体预测性能情况,利用平均绝对百分比误差 MAPE (Mean Absolute Percent Error)、均方根误差 RMSE (Root Mean Square Error) 以及希尔不等系数 TIC (Theil Inequality Coefficient) 衡量各模型的预测精度,如表 1 所示。

表 1 模型预测误差评价指标对比

Table 1 Comparison of prediction error indexes

评价指标模型	MAPE / %	RMSE	TIC
BP 神经网络	9.25	184.17	0.053 1
SNN	7.23	146.84	0.042 1
PSO-SNN	6.18	131.20	0.037 9
CAPSO-SNN	4.16	82.91	0.023 9

由表 1 可知,CAPSO-SNN 模型的各个预测误差评价指标均优于其他模型,具有更好的样本学习和数值预测性能。同时,CAPSO-SNN 模型对该事故样本集的作业风险等级预测结果如附录中表 A1 所示。CAPSO-SNN 模型对该事故样本集的作业风险等级预测准确率为 91.7%,说明其具有较高的风险预测准确性,有效解决传统电力作业风险评估中人为设定风险影响因素权重导致风险预测准确性不高的

问题。

附录中图 A4 给出 CAPSO-SNN 模型对事故样本集中各风险等级作业事故的一级因素风险平均占比计算结果。由图可知,IV 级以及 III 级风险的事故中,人员属性类以及作业性质类因素的风险占比较高,说明低风险等级作业的风险水平主要取决于作业人员的专业素质、技能水平以及作业内容等因素;随着风险等级的提高,作业人员的心理状态、负荷程度、行为趋向以及作业管理情况逐渐占主导地位,因此高风险等级作业的风险管控点应重点关注这些风险关键要素。

## 5.2 电力作业过程风险趋势分析

为了分析所提方法在作业过程中的风险 SA 情况,选取事故样本集中某 35 kV 线路检修作业为例,取监测间隔  $\Delta t=5$  min。通过输入风险关键要素信息,对该次作业过程进行风险状态理解,计算中各类一级因素风险贡献值随时间变化情况如图 6 所示。

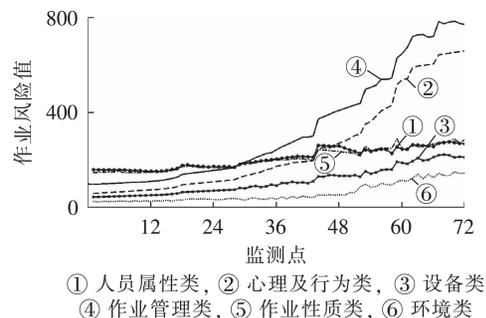


图 6 各类一级因素风险贡献值随时间变化情况  
Fig.6 Variation of risk contribution vs. time for all types of first-grade factors

图 6 反映了该次作业初始风险等级较低,风险主导要素为人员属性类和作业性质类要素;随着作业时长的增加,作业时间从白天变成晚上,天气状况变差,作业人员出现疲劳、工作情绪低落等现象;由于其他抢修作业抽调人员,该次作业人员配置只达到要求的 80%,只能进行交叉作业;最终有一作业人员在未受监管情况下,不按照作业表单指导步骤,独自抄录避雷器铭牌而误触避雷器带电部位导致事故发生。

该次作业过程的风险趋势预测曲线如图 7 所示。

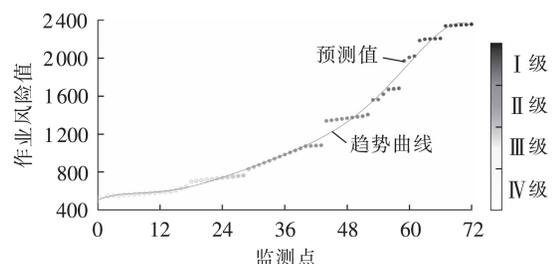


图 7 风险趋势预测曲线

Fig.7 Risk trend prediction curve

作业风险SA模型在每一监测点都提供了风险预测值,有效反映作业过程中的作业风险变化情况。最终风险预测等级为I级,与真实情况相符。若在监测点50—60的作业风险初始上升时间段内,根据风险态势利导方向提出针对作业管理类和心理及行为类风险关键要素的作业调整决策,即可有效降低该次作业的风险水平,避免事故的发生。

## 6 结论

本文针对电力作业传统风险评估方法未深度汲取电力作业事故事件数据库中的海量多维风险影响因素信息,评估分析过程主观性较强且难以在线应用的缺点,提出了一种电力作业风险SA方法。通过真实案例分析,得出结论如下:

(1)利用PCA的数据降维能力可有效挖掘电力作业风险关键要素,减少电力作业过程中的风险信息采集量,提高风险防控效率;

(2)利用CAPSO算法对SNN的突触权值进行全局寻优,提高了SNN的数据挖掘与学习映射能力;

(3)所提电力作业风险SA模型通过离线训练,能有效评估分析电力作业事故事件的事关键诱因与风险量组成,精准定位作业风险态势利导控制方向,同时避免传统作业风险评估中主观因素的不利影响;

(4)所提电力作业风险SA方法能准确理解作业过程中的风险状态,有效跟踪风险发展趋势,为电力作业全过程风险精细化态势利导控制决策的制定提供技术支撑,在线应用前景较大。

附录见本刊网络版(<http://www.epae.cn>)。

## 参考文献:

- [ 1 ] PANTELI M, CROSSLEY P A, KIRSCHEN D S, et al. Assessing the impact of insufficient situation awareness on power system operation[J]. IEEE Transactions on Power Systems, 2013, 28(3): 2967-2977.
- [ 2 ] ENDSLEY M R, BOLTE B, JONES D G. Designing for situation awareness: an approach to user-centered design[M]. Boca Raton, FL, USA: CRC Press, 2003.
- [ 3 ] PANTELI M, KIRSCHEN D S. Situation awareness in power systems: theory, challenges and applications[J]. Electric Power Systems Research, 2015, 122: 140-151.
- [ 4 ] CHEN Y, HUANG Z, ZHOU N. An advanced framework for improving situational awareness in electric power grid operation[C]//Proceedings of 18th World Congress of IFAC. Milano, Italy: IFAC, 2011: 13344-13352.
- [ 5 ] 杨胜春, 汤必强, 姚建国, 等. 基于态势感知的电网自动智能调度架构及关键技术[J]. 电网技术, 2014, 38(1): 33-39.  
YANG Shengchun, TANG Biqiang, YAO Jianguo, et al. Architecture and key technologies for situational awareness based automatic intelligent dispatching of power grid[J]. Power System Technology, 2014, 38(1): 33-39.
- [ 6 ] 周华锋, 胡荣, 李晓露, 等. 基于态势感知技术的电力系统运行驾驶舱设计[J]. 电力系统自动化, 2015, 39(7): 130-137.  
ZHOU Huafeng, HU Rong, LI Xiaolu, et al. Design of power system operation cockpit based on situation awareness technology[J]. Automation of Electric Power Systems, 2015, 39(7): 130-137.
- [ 7 ] 章坚民, 陈昊, 陈建, 等. 智能电网态势图建模及态势感知可视化的概念设计[J]. 电力系统自动化, 2014, 38(9): 168-176.  
ZHANG Jianmin, CHEN Hao, CHEN Jian, et al. Smart grid situation awareness diagram modeling and conceptual design of situation awareness visualization[J]. Automation of Electric Power Systems, 2014, 38(9): 168-176.
- [ 8 ] 黄蔓云, 卫志农, 孙国强, 等. 基于历史数据挖掘的配电网态势感知方法[J]. 电网技术, 2017, 41(4): 1139-1145.  
HUANG Manyun, WEI Zhinong, SUN Guoqiang, et al. A novel situation awareness approach based on historical data-mining model in distribution networks[J]. Power System Technology, 2017, 41(4): 1139-1145.
- [ 9 ] 王守相, 梁栋, 葛磊蛟. 智能配电网态势感知和态势利导关键技术[J]. 电力系统自动化, 2016, 40(12): 2-8.  
WANG Shouxiang, LIANG Dong, GE Leijiao. Key technologies of situation awareness and orientation for smart distribution systems[J]. Automation of Electric Power Systems, 2016, 40(12): 2-8.
- [ 10 ] 陈碧云, 丁晋, 陈绍南. 基于关联规则挖掘的电力生产安全事故事件关键诱因筛选[J]. 电力自动化设备, 2018, 38(4): 68-74.  
CHEN Biyun, DING Jin, CHEN Shaonan. Selection of key incentives for power production safety accidents based on association rule mining[J]. Electric Power Automation Equipment, 2018, 38(4): 68-74.
- [ 11 ] 徐成, 梁睿, 程真何, 等. 面向能源互联网的智能配电网安全态势感知[J]. 电力自动化设备, 2016, 36(6): 13-18.  
XU Cheng, LIANG Rui, CHENG Zhenhe, et al. Security situation awareness of smart distribution grid for future energy internet[J]. Electric Power Automation Equipment, 2016, 36(6): 13-18.
- [ 12 ] 黄伟, 刘琦, 杨舒文, 等. 基于主动配电系统供电能力的安全态势感知方法[J]. 电力自动化设备, 2017, 37(8): 71-80.  
HUANG Wei, LIU Qi, YANG Shuwen, et al. Security situation awareness based on power-supply ability model of active distribution system[J]. Electric Power Automation Equipment, 2017, 37(8): 71-80.
- [ 13 ] WU J, OTA K, DONG M, et al. Big data analysis-based security situational awareness for smart grid[J]. IEEE Transactions on Big Data, 2018, 4(3): 408-417.
- [ 14 ] 张良栋, 石辉, 张勇军. 电网事故原因分类浅析及其预防策略[J]. 电力系统保护与控制, 2010, 38(4): 130-133.  
ZHANG Liangdong, SHI Hui, ZHANG Yongjun. Analysis of causes and prevention methods for power network accidents[J]. Power System Protection and Control, 2010, 38(4): 130-133.
- [ 15 ] 李志会. 基于模糊故障树法的输电线路检修作业的风险评估与预控[D]. 北京: 北京交通大学, 2015.  
LI Zhihui. Risk assessment and pre-control in power transmission line filed maintenance work based on fuzzy fault tree analysis[D]. Beijing: Beijing Jiaotong University, 2015.
- [ 16 ] 谢从珍, 白剑锋, 王红斌, 等. 基于多维关联信息融合的架空输电线路雷害风险评估方法[J]. 中国电机工程学报, 2018, 38(21): 6233-6244.  
XIE Congzhen, BAI Jianfeng, WANG Hongbin, et al. Lightning risk assessment of transmission lines based on multidimensional related information fusion[J]. Proceedings of the CSEE, 2018, 38(21): 6233-6244.

- [17] 魏秀宁,杨悦群,王淦彪,等. 供电作业人身安全风险评估与控制[J]. 电力系统及其自动化学报,2016,28(8):105-110.  
WEI Xiuning, YANG Yuequn, WANG Ganbiao, et al. Human safety risk evaluation and control of power-supplying operation [J]. Proceedings of the CSU-EPSA, 2016, 28(8): 105-110.
- [18] MAASS W. Networks of spiking neurons: the third generation of neural network models [J]. Neural Networks, 1997, 10(9): 1659-1671.
- [19] 肖白,刘亚伟,施永刚,等. 基于主成分分析的中压配电网供电可靠性评估[J]. 电力自动化设备,2018,38(10):7-12.  
XIAO Bai, LIU Yawei, SHI Yonggang, et al. Power supply reliability assessment of mid-voltage distribution network based on principal component analysis [J]. Electric Power Automation Equipment, 2018, 38(10): 7-12.
- [20] 陈通,孙国强,卫志农,等. 基于相似日和CAPSO-SNN的光伏发电功率预测[J]. 电力自动化设备,2017,37(3):66-71.  
CHEN Tong, SUN Guoqiang, WEI Zhinong, et al. Photovoltaic

power generation forecasting based on similar day and CAPSO-SNN [J]. Electric Power Automation Equipment, 2017, 37(3):66-71.

#### 作者简介:



陈碧云

陈碧云(1978—),女,广西北海人,副教授,博士,主要研究方向为电力系统规划与可靠性分析(**E-mail**:chenbiyun@gxu.edu.cn);

李弘斌(1995—),男,广西南宁人,硕士研究生,主要研究方向为电力系统规划与可靠性分析(**E-mail**:248566369@qq.com);

李滨(1975—),女,广西南宁人,副教授,博士,主要研究方向为电力系统最优化(**E-mail**:lizhen@gxu.edu.cn)。

(编辑 王欣竹)

## Power operation risk situation awareness based on data mining and CAPSO-SNN

CHEN Biyun, LI Hongbin, LI Bin

(Guangxi Key Laboratory of Power System Optimization and Energy Technology,  
Guangxi University, Nanning 530004, China)

**Abstract:** With the continuous development of power operation security monitoring technology, online information collection in the whole process of power operation becomes possible. On the basis of power operation data, a power operation SA (Situation Awareness) method based on data mining and CAPSO-SNN (Cloud Adaptive Particle Swarm Optimization-Spiking Neural Networks) is proposed. Firstly, this method extracts all the operation risk influencing factors from the power operation accident events database to construct the risk influencing factors system, and then excavates the key risk factors which should be focused on in the process of operation through PCA (Principal Component Analysis) algorithm. Subsequently, the key risk factors are taken as input parameters to realize the training and prediction of operation risk SA via CAPSO-SNN. Finally, the application process of the proposed method is demonstrated based on a sample of actual historical operation accidents of a power grid company. The simulative results show that the proposed method is not only suitable for analyzing the risk composition of power operation, but also can effectively perceive the risk status information and track the risk development trend during the process of operation, which contributes to implementing the whole process delicacy situation orientation management and control of power operation risk.

**Key words:** data mining; situation awareness; cloud adaptive particle swarm optimization; spiking neural networks; situation orientation; power operation

# 附录

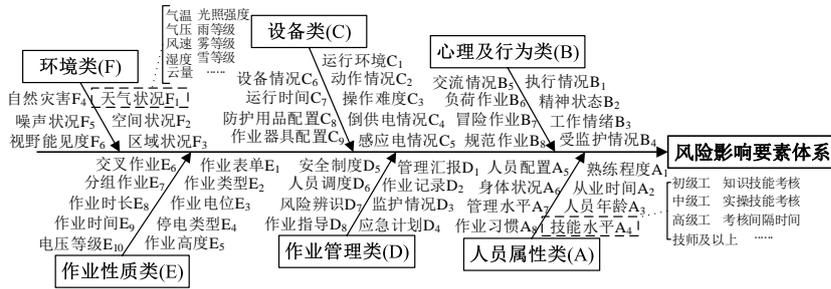


图 A1 电力作业风险影响因素体系

Fig.A1 System of power operation risk influencing factors

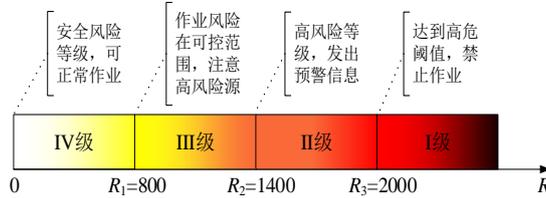


图 A2 电力作业风险等级划分

Fig.A2 Risk level classification of power operation

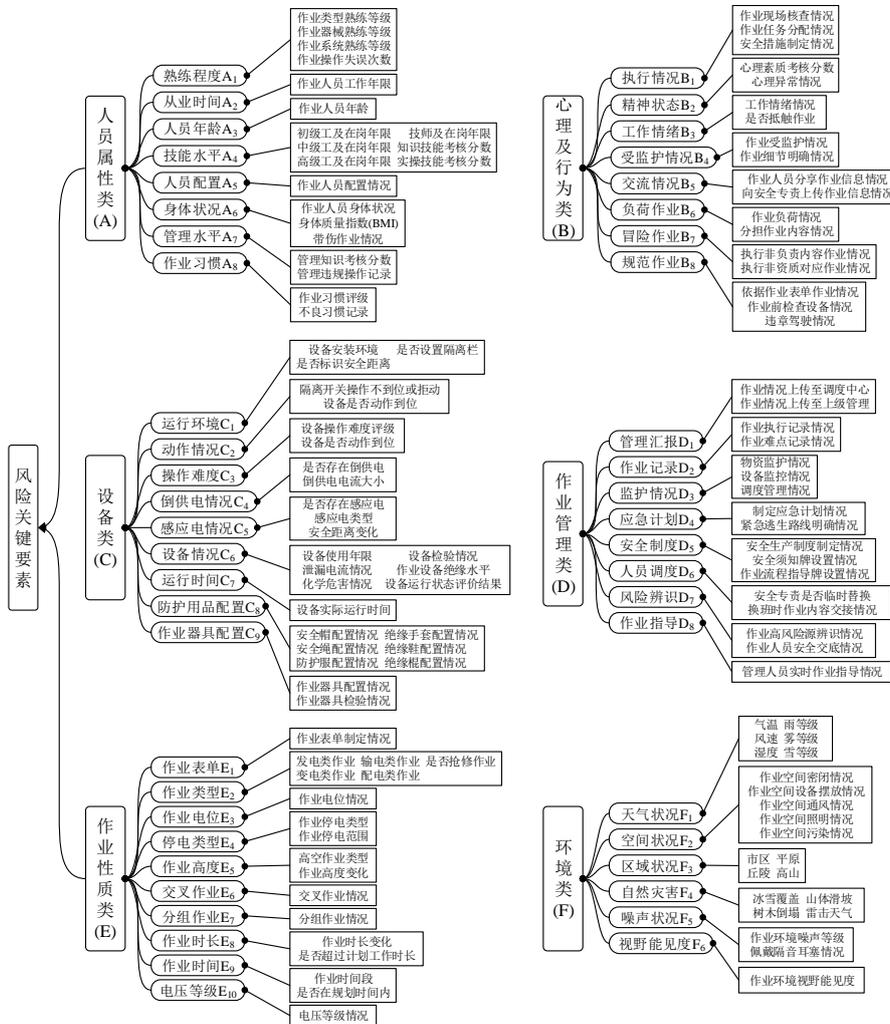


图 A3 本文所用风险关键要素

Fig.A3 Key risk factors used in this paper

表 A1 风险等级预测准确率  
**Tab.A1 Accuracy rate of risk level prediction**

风险等级	真实数量	预测数量	准确率
VI 级	2	3	
III 级	67	63	91.7%
II 级	177	179	
I 级	54	55	

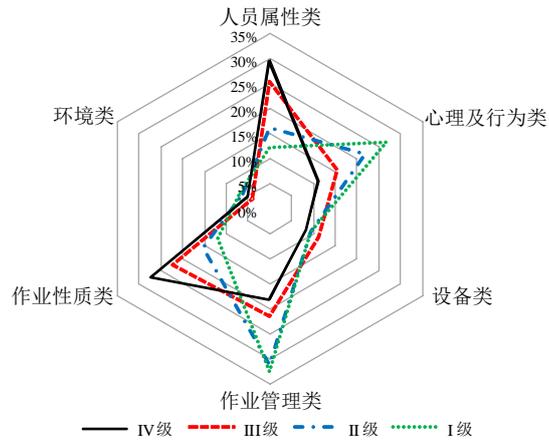


图 A4 各风险等级事故的一级因素风险占比

Fig.A4 Proportion of risks of first-grade factors for each risk level accident