

一种采用 CCPSO-SVM 的煤与瓦斯突出预测方法

黄为勇 邵晓根 陈奎

(徐州工程学院信电工程学院 徐州 221111)

摘要 为了有效地对矿井煤与瓦斯突出进行预测,提出了一种基于完全混沌粒子群优化(CCPSO)与支持向量机(SVM)的矿井煤与瓦斯突出预测方法。该方法将矿井工作面前方煤体瓦斯涌出量动态变化时间序列的多重分维谱作为特征指标,应用支持向量(SVM)构建预测模型,模型的参数向量由改进的完全混沌粒子群优化算法和测试集样本集分类错误率最小准则选择和优化。实验结果证明,该方法是有用的,它为煤与瓦斯突出预测提供了一种新途径。

关键词 煤与瓦斯突出,预测,支持向量机,完全混沌粒子群优化,多重分维谱

中图分类号 IP181,TD713 **文献标识码** A

Coal-and-Gas Outburst Forecast Using CCPSO and SVM

HUANG Wei-yong SHAO Xiao-gen CHEN Kui

(School of Information and Electrical Engineering, Xuzhou Institute of Technology, Xuzhou 221111, China)

Abstract In order to forecast effectively coal-and-gas outburst in coal-mine, a new method for coal-and-gas outburst forecast based on CCPSO (complete chaotic particle swarm optimization) and SVM (support vector machine) was presented. With multi-fractal dimension spectrum of gas emission amount dynamic time series in the front of work-face in coal-mine being feature index, the forecasting model was constructed by using SVM. The parameters vector of the proposed model was selected and optimized by CCPSO and the criteria of CERM (classification error rate minimization) and TSSM (test sample set minimization). The experimental results show that the proposed method is effective and provides a new approach for forecasting coal-and-gas outburst in coal-mine.

Keywords Coal-and-gas outburst, Forecast, Support vector machine, Complete chaotic particle swarm optimization, Multi-fractal dimension spectrum

1 引言

煤与瓦斯突出是严重威胁煤矿安全生产的自然灾害之一。突出危险性的准确预测是有效防治突出灾害的重要技术基础,在我国“四位一体”的综合防突措施中,突出预测已成为防止煤与瓦斯突出发生的第一道防线,研究有效的煤与瓦斯预测方法具有重要意义^[1]。

影响突出的因素众多,发生的原因复杂,在不同的工作面各种因素对煤与瓦斯突出的影响不一,迄今为止,人们还没有对各种地质、开采条件下突出发生的规律完全掌握,也难以从理论上确定预测突出的敏感指标,目前预测指标的确定在很大程度上还是基于人们的经验和统计规律^[2]。从系统的观点来看,突出是含瓦斯煤岩系统在采掘活动扰动下发生的动力灾害现象,从突出孕育到激发以至发展的过程中,系统内部各要素之间及其与外部系统的相互作用具有明显的非线性特征。突出的发生是一个复杂的非线性动力系统在时空演化过程中的灾变行为,作为这一过程的物理-力学响应,突出动态前兆时间序列(Q序列)必然依其数据序列和数据大小蕴含着

有关系统动态演化过程的特征信息。采掘工作面前方煤体瓦斯涌出量的动态变化与煤体的突出危险性相一致,无论瓦斯涌出量上升或上下起伏,都是突出危险的前兆信息。

工作面 Q 序列具有明显的混沌-分形特性,但工作面在由无突出危险状态转为有突出危险状态时, Q 序列的非线性指标(如关联维数 D2、二阶 Renyi 熵 K2 以及 Lyapunov 指数等)与工作面突出的危险性之间没有明显的相关性,这给特征指标的选取带来了相当的困难。其原因是 Q 序列的产生是复杂的煤岩瓦斯动力系统内多种因素综合作用的结果,不同的子系统相互交迭影响,系统内不同的子集具有不同的标度指数和分维值,对这种概率分布不均匀的多重分形,仅用一种分维难以全面刻画其特性。研究表明,有突出危险时段与无突出危险时段相比, Q 序列的分形谱曲线表现出明显的异常,因此对于变化更为复杂的煤岩瓦斯动力学系统可以采用能够描述多重分形测度或维数连续谱来描述^[3],因此工作面 Q 序列的多重分形特征可望成为预测煤与瓦斯突出的新特征指标。

影响突出的众多因素与突出危险性之间存在高度复杂的非线性映射关系,处理这样一个非线性问题,传统的数理统

到稿日期:2012-03-01 返修日期:2012-06-02 本文受国家自然科学基金(50534050),江苏省高校自然科学基金项目(06KJD460174)资助。

黄为勇(1963-),男,博士,副教授,CCF 会员,主要研究方向为计算机测控与智能信息处理技术, E-mail: hwy@xzit.edu.cn;邵晓根(1963-),男,教授,主要研究方向为智能控制与信息处理技术;陈奎(1971-),男,博士,讲师,主要研究方向为无线传感器网络与智能信息处理技术。

计、模糊数学和神经网络等方法是有局限性的,有必要引入一种新的、适合处理复杂非线性系统问题的数学工具来构建矿井煤与瓦斯突出危险性预测模型^[3]。

支持向量机(support vector machine, SVM)是一种建立在 VC 维理论和结构风险最小化(SRM)原则基础上的一种小样本新型机器学习方法,其在最小化经验风险的同时,最小化置信区间的上界,从而获得更强的泛化能力,有效地解决传统的神经网络方法存在的过学习、鲁棒性差和泛化能力差等问题^[4,5]。因此本文采用多重分维谱为敏感指标,应用基于结构风险最小化准则的支持向量机提取出判识工作面突出危险性的定量准则,以此构建的敏感指标同煤与瓦斯突出类型之间存在的复杂的非线性函数模型更具优越性和合理性^[2]。

由于支持向量的多个参数之间存在一个最佳匹配,参数向量的选择恰当与否会直接影响其应用效果,为此本文提出了一种改进的完全混沌粒子群优化算法并将其应用到支持向量机参数向量的选择和优化中,以期构建煤与瓦斯突出预测模型,实现对突出危险性的智能分类识别和评估。实验结果验证了该方法的有效性,其达到了预期的效果。

2 混沌序列的多重分维谱

分形可分为两大类,一是几何相似或均匀分形,二是统计自相似或非均匀分形——多重分形、复分形。对于概率分布均匀的简单分形,只需要有一个指数和一个相应分维就可表述分形体的全部特征;但对于概率分布不均匀的多重分形,必须用分维谱 $D_q \sim q$ 来描述^[3]。

将 m 维相空间分形集 A 划分成尺度为 ϵ 的一个个的 m 维方盒,其 q 阶 Renyi 多重分维 D_q 定义为:

$$D_q = \begin{cases} \frac{1}{q-1} \lim_{\epsilon \rightarrow 0} \frac{\ln \sum_{i=1}^{N(\epsilon)} p_i^q(\epsilon)}{\ln \epsilon}, & q \neq 1 \\ - \lim_{\epsilon \rightarrow 0} \frac{\sum_{i=1}^{N(\epsilon)} p_i(\epsilon) \ln_i(\epsilon)}{\ln \epsilon}, & q = 1 \end{cases} \quad (1)$$

式中, $N(\epsilon)$ 为至少含有一个点的盒子, $p_i(\epsilon)$ 为分形集 A 落入第 i 个盒子的概率, q 可取任意实数。分析表明, D_q 是 q 的递减函数,且 D_q 对于 q 的谱是有界的,由不同 q 阶次的 D_q 构成的多重分维谱 $D_q \sim q$ 即可描述多重分形集的非均匀结构。

目前多重分维 D_q 的计算方法主要有数盒子法、固定半径法、推广 G-P 法、固定质量法以及最小生成树法等。由于固定质量法具有不易出现“平台”、不存在起点效应和尺度效应、对 $q \leq 0$ 仍具有较好的收敛性、易操作等优点,因此可采用固定质量法计算 D_q 。固定质量 M , 以 $R(M)$ 为包含质量的 M 的最小球半径,且 $\tau(q) = (q-1)D_q$, 经过推导可得当 $M \rightarrow 0$ 时的 D_q 值为:

$$D_q = - \frac{\lg M}{\lg [R(M)^{-\tau(q)}]^{1/\tau(q)}} \quad (2)$$

在计算时,每个点都作为基准点,给定 $\tau(q) \neq 0$, 取一定 M 值,分别计算每个基准的 $R_j(M)$, $j=1, 2, \dots, n$, 求 $R_j(M)$ 的 $\tau(q)$ 阶广义平均值:

$$\bar{R}_\tau(M) = \left[\frac{1}{n} \sum_{j=1}^n R_j(M)^{-\tau(q)} \right]^{-1/\tau(q)} \quad (3)$$

改变 M , 计算出一系列的 $\bar{R}_\tau(M)$, 在 $\lg M - \lg \bar{R}_\tau(M)$ 图上

找出无标度区,无标度区点的斜率即为 D_q 值,相应的 q 值由式(4)给出:

$$q = \frac{\tau(q)}{D_q} \quad (4)$$

3 支持向量机分类原理

支持向量机的基本思路是建立分类超平面,不仅使分类面对所有样本都能正确分类,而且要使分类的间距 $2/\|\omega\|$ 最大。设线性样本集 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ 为训练样本,其中输入训练向量 x_i 为特征向量(指标), x_i 属于两类中的一类,用 y_i 表示类别, $y_i \in \{-1, +1\}$ 。分类问题可转化为优化问题:

$$\min \frac{1}{2} \|\omega\| + C \sum_{i=1}^n \xi_i \quad (5)$$

其约束条件为:

$$y_i (\omega^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i=1, 2, \dots, n \quad (6)$$

式中, $C > 0$ 为惩罚因子, ξ_i 为松弛变量。利用 Lagrange 优化方法将上述最优问题转化为如下凸二次优化问题:

$$\begin{cases} \max \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j (x_i^T x_j) \\ \text{s. t. } a_i \geq 0, i=1, \dots, n \\ \sum_{i=1}^n a_i y_i = 0 \end{cases} \quad (7)$$

式中, a_i 为与每个样本对应的 Lagrange 因子。

式(7)是一个不等式约束下的二次函数机制问题,存在唯一最优解。若 a_i^* 为最优解,则

$$\omega^* = \sum_{i=1}^n a_i^* y_i x_i \quad (8)$$

式中, a_i^* 不为零的样本即为支持向量。

若样本在原始空间中线性不可分,则可以通过非线性变换 Φ 将输入空间变换到一个高维空间,然后在这个新空间中求取最优线性分类面,用核函数 $K(x_i, x_j)$ 代替最优分类平面中的点积 $x_i^T x_j$, 最后的决策函数为:

$$\begin{aligned} f(x) &= \text{sgn}[(\omega^*)^T \Phi(x) + b^*] \\ &= \text{sgn}(\sum_{i=1}^n a_i^* y_i K(x_i, x) + b^*) \end{aligned} \quad (9)$$

式中, b^* 为分类阈值,可用任意一个支持向量 x^* 求得。适当改变径向基核函数(RBF)的参数可以逼近其他形式的核函数,本文采用 RBF 核函数, RBF 核函数可表示为:

$$K(x_i, x) = \exp\{-\|x - x_i\|^2 / 2\sigma^2\} \quad (10)$$

因此,支持向量机预测模型的参数向量 θ 可表示为 $\theta = (C, \sigma)$ 。支持向量机的参数向量选择恰当与否对预测效果具有决定性的影响,本文采用改进的粒子群优化算法进行支持向量机参数向量 θ 的选择和优化。

4 改进的混沌粒子群优化算法

4.1 基本粒子群优化算法(BPSO)

假设在一个 d 维的目标搜索空间中, m 个代表潜在问题解的粒子组成的一个种群 $S = \{\vec{X}_1, \vec{X}_2, \dots, \vec{X}_m\}$, 记 $\vec{X}_i = \{x_{i1}, x_{i2}, \dots, x_{id}\} (i=1, 2, \dots, m)$ 表示第 i 个粒子在 d 维解空间的位置, $\vec{V}_i = \{v_{i1}, v_{i2}, \dots, v_{id}\} (i=1, 2, \dots, m)$ 表示第 i 个粒子的速度。在基本粒子群优化算法中通过两个极值进行速度和位置的更新,一个是第 i 个粒子自身搜索到适应值为最小的最

好点 $p_{best} = \{p_{i1}, p_{i2}, \dots, p_{id}\} (i=1, 2, \dots, m)$; 另一个是整个种群中的粒子的适应值为最小的最好点 $g_{best} = \{p_{g1}, p_{g2}, \dots, p_{gd}\}$ 。PSO 算法采用下面的公式对粒子的速度和位置进行更新:

$$\vec{V}_i^{k+1} = \omega \cdot \vec{V}_i^k + c_1 \cdot r_1 \cdot (\vec{P}_i^k - \vec{X}_i^k) + c_2 \cdot r_2 \cdot (\vec{P}_g^k - \vec{X}_i^k) \quad (11)$$

$$\vec{X}_i^{k+1} = \vec{X}_i^k + \vec{V}_i^{k+1} \quad (12)$$

式中, c_1 与 c_2 是加速常数, r_1 与 r_2 是 $[0, 1]$ 之间的随机数, ω 是惯性权重。

上述算法中所涉及的参数较少, 公式也比较简单, 可将此称为基本粒子群优化算法^[6,7]。

通过分析基本粒子群优化算法, 可以发现 BPSO 算法的搜索过程存在如下不足:

(1) 初始化过程是随机的, 随机过程虽然大多可以保证初始解群分布均匀, 但对个体的质量不能保证, 解群中有一部分远离最优解。如果初始解群较好, 将会有助于求解效率与解的质量。

(2) 由于式(11)中的 r_1, r_2 是均匀分布于 $[0, 1]$ 之间的两个随机数, 导致了粒进化过程的随机性, 使 p_{best} 和 g_{best} 的更新带有一定的盲目性, 影响了进化过程的收敛。

(3) 利用式(11)和式(12)更新自己的速度和位置, 其本质是利用本身信息、个体极值信息和全局极值 3 个信息来指导粒子下一步迭代位置, 当某些粒子的位置及其 p_{best} 接近群体的 g_{best} 时, 其速度更新由 $\omega \cdot \vec{V}_i^k$ 决定。 $\omega < 1$ 时, 粒子的运行速度越来越小, 接近于零, 粒子运行出现“惰性”。随着进化的进行, 其他粒子将很快聚集到这些惰性粒子的周围, 使进化过早地收敛到局部最优。

混沌运动具有遍历性、伪随机性和“规律性”的特点, 能在一定范围内按其自身“规律”不重复地遍历所有状态, 加之混沌信号产生机理简单, 具有内在并行性的优点, 采用混沌的搜索技术无疑会比其它随机搜索更具优越性。针对上述问题, 根据混沌优化的思想^[8,9], 本文提出了一种完全混沌粒子群方法。

4.2 完全混沌的粒子群优化算法(CCP SO)

产生混沌的数学模型有很多, 这里采用 Logistic 方程构造混沌序列:

$$x(t+1) = \mu x(t)(1-x(t)), t=0, 1, 2, \dots, n \quad (13)$$

式中, μ 是控制参数。

当 $0 < x(0) < 1, \mu = 4$ 时, Logistic 方程处于完全混沌状态, 此时 $x(t)$ 的轨迹是混沌轨迹且在 $(0, 1)$ 之间遍历。由任意初值 $x(0) \in [0, 1]$ 可迭代出一个确定的时间序列 $x(1), x(2), x(3), \dots, x(n+1)$ 。

本文提出的完全混沌的粒子群优化算法的基本思想体现在如下 4 个方面:

(1) 由于混沌变量的遍历性, 使得采用混沌系列初始化粒子的位置和速度时, 既利用混沌提高了种群的多样性和粒子搜索的遍历性, 又不改变粒子群优化算法初始化时所具有的随机性本质。

(2) 为了能够有效地平衡全局和局部搜索, 改善算法寻优性能使得收敛速度进一步加快, 将混沌状态引入到惯性权重 ω 进行优化, 使粒子获得持续搜索的能力。这里采用下式

进行 ω 的混沌化, 再将惯性权值映射至 (α, β) 区间:

$$\omega(i+1) = 4.0\omega(i) \cdot (1-\omega(i)) \quad (14)$$

$$\omega(i) = \alpha + (\beta - \alpha) \cdot \omega(i) \quad (15)$$

式中, $i=1, 2, \dots, T_m, T_m$ 为最大迭代次数; 惯性权值范围取 $\alpha=0.4, \beta=0.9$ 。

(3) 为克服随机取值带来的效率低下的不足, 且提高收敛性, 将混沌引入到随机常数 r_1, r_2 中, 按 Logistic 映射动态更新:

$$r_i(t+1) = 4.0r_i(t) \cdot (1-r_i(t)) \quad (16)$$

式中, $r_i(t) \in (0, 1), i=1, 2$ 。

(4) 以当前整个粒子群迄今为止搜索到的最优位置为基础产生混沌序列, 把产生的混沌序列中的最优位置粒子替代当前粒子群中的一个粒子的位置。对于求解 d 维最优化问题, 可用 d 个独立的混沌变量序列来产生该空间中点的 d 个坐标分量。通过产生一组与优化变量相同数目的混沌变量, 用类似载波的方式将混沌引入优化变量使其呈现混沌状态, 同时把混沌运动的遍历范围放大到优化变量的取值范围, 然后直接利用混沌变量搜索, 以使跳出局部极值区间, 有利于提高搜索精度^[10]。

完全混沌粒子群优化算法的步骤如下:

Step1 初始化设置最大允许迭代次数或适应度误差限, 以及算法的学习因子 c_1 和 c_2 。

Step2 混沌初始化粒子位置和速度。

(1) 随机产生一个 d 维、每个分量数值在 $0 \sim 1$ 之间的向量, d 为目标函数中的变量个数, 根据式(13)得到 N 个向量。

(2) 将各个分量载波到对应变量的取值区间。

(3) 计算粒子群的适应值, 并从 N 个初始群体中选择性能较好的 M 个解作为初始解, 随机产生 M 个初始速度。

Step3 如果粒子适应度优于个体极值 p_{best} , 则将 p_{best} 设置为新位置。

Step4 如果粒子适应度优于全局极值 g_{best} , 则将 g_{best} 设置为新位置。

Step5 根据完全混沌后的式(11)和式(12)更新粒子的速度和位置。

Step6 对最优位置 $P_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ 进行混沌优化。

(1) 将 $P_{gi} (i=1, 2, \dots, d)$ 映射到 Logistic 式(3)的定义域 $[0, 1]$ 得:

$$z_i = (P_{gi} - a_i) / (b_i - a_i) (i=1, 2, \dots, d) \quad (17)$$

(2) 用 Logistic 方程进行迭代产生混沌变量序列 $z_i^m (m=1, 2, \dots)$ 。

(3) 把产生的混沌变量序列通过逆映射: $P_i^{(m)} = (P_i^{(m)}, P_2^{(m)}, \dots, P_d^{(m)}) (m=1, 2, \dots)$ 返回到原解空间, 得:

$$P_g^{(m)} = (P_{g1}^{(m)}, P_{g2}^{(m)}, \dots, P_{gd}^{(m)}) (m=1, 2, \dots) \quad (18)$$

Step7 在原解空间对混沌变量经历的每一个可行解 $P_g^{(m)}$ 计算其适应值, 得到性能最好的可行解 p^* , 用 p^* 取代当前群体中任意一个粒子的位置。

Step8 若满足停止条件, 则搜索停止, 输出全局最优位置, 否则返回步骤 Step3。

5 基于 CCP SO 与 SVM 的煤与瓦斯突出预测算法流程

矿井煤与瓦斯突出和特性指标之间存在十分复杂的非线性

性关系,而煤与瓦斯突出预测的实质在于利用已有测试数据寻找一个数学函数对特征指标和突出类型之间复杂的非线性函数关系进行拟合,从而实现对未来一段时间突出的可能性进行估测。因此煤与瓦斯预测问题可转化为对特征指标和突出类型之间存在的十分复杂的非线性关系的近似估计问题,可利用支持向量机来实现。

通过实验得到 n 组多重分维谱 $D_q \sim q$ 敏感指标的数据对 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ 来构造支持向量机的学习样本与测试样本,并选取适当的核函数及参数向量;然后用学习样本来训练支持向量机,用测试样本对支持向量机进行测试。经过不断地学习及测试,在输入向量与实际值之间建立一种非线性映射 $f(\cdot)$,在达到较高的精度之后,该支持向量机就可以作为煤与瓦斯突出的预测模型:

$$\hat{y} = f_{svm}(x, \theta) \quad (19)$$

式中, $f_{svm}(x, \theta)$ 表示特征指标和突出类型的支持向量分类函数, θ 为支持向量机相应的参数向量, \hat{y} 为 x 所对应的预测值。

鉴于支持向量机的参数向量选择实际上是一个多维函数优化问题,粒子群算法采用实数编码,粒子可直接编码为 (C, σ) 。参数优化旨在测试样本集的分类错误率最小,故采用如下参数选择和优化的最优指标:

$$J = \frac{m_g}{M_g} \quad (20)$$

式中, m_g 为对训练后的模型进行测试时的分类失败的样本数目, M_g 为测试集的测试样本的总数。

基于粒子优化-支持向量机的煤与瓦斯突出预测算法流程描述如下。

Step 1 采集工作面瓦斯涌出动态时序数据 Q 序列,计算 Q 序列的多重分维谱,建立煤与瓦斯突出的学习样本集与测试样本集。

Step 2 初始化完全混沌粒子群算法的控制参数,并在变化范围内随机初始化支持向量机的参数初值。

Step 3 将每个粒子的位置向量依次作为支持向量机参数,根据学习样本构造煤与瓦斯突出预测模型,并计算适应值 J ,若 J 满足要求或算法达到最大进化代数,转 Step 5,否则转 Step 4。

Step 4 根据每个粒子的当前适应度值,由完全混沌的粒子群优化算法调整每个粒子的个体极值和全局极值,计算下一代支持向量机的参数向量,转 Step 3。

Step 5 得出最优的支持向量机参数向量,构建预测能力最强的支持向量分类机模型,并输出煤与瓦斯突出的预测结果进行预测误差分析。

6 应用实例

本文以文献[3]中的 Q 序列为数据源。该 Q 序列的测取选在焦作位村矿二 1 突出煤层掘进工作面进行。工作面瓦斯体积分数传感器布置在局部通风机风筒出口侧后方,距工作面煤壁约 10~15m。本文共利用矿井监测系统测取了 2003 年 9 月至 11 月 3 个月间的工作面瓦斯监测数据,每个班次的的数据为一个 Q 序列。实际获得的可用序列样本为 26 个,按各班次的日常突出预测结果,将其分为两类:有突出危险与无突出危险 Q 序列。

在对作为动力过程响应的时序序列进行分析时,首先对

动力系统相空间进行重构,并在此基础上计算 Lyapunov 指数 λ_1 , 二阶 Renyi 熵 K_2 和关联维 D_2 等 3 个非线性指标,然后应用相关判据来判断某一时间序列是否具有混沌-分形非线性特征。对所测取的 26 个 Q 序列进行计算后得到的混沌特征指标值如表 1 所列。

表 1 各 Q 序列混沌特征指标值

样本序号	(月-日-班次)	λ_1	k_2	D_2	突出危险性
1	09-01-22	0.000653	0.2892	6.4	有
2	09-02-06	0.000414	0.2775	3.4	有
3	09-17-22	0.000509	0.2456	5.8	无
4	10-04-14	0.000310	0.2582	7.1	无
5	10-05-14	0.000263	0.2704	6.9	有
6	10-10-06	0.000032	0.1956	5.1	有
7	10-11-06	0.000252	0.3257	7.5	无
8	10-12-22	0.000180	0.6134	9.6	无
9	10-14-14	0.000188	0.2436	3.2	有
10	10-16-14	0.002200	0.2118	3.1	无
11	10-25-14	0.001200	0.2719	3.7	无
12	10-26-14	0.000703	0.2682	10.3	无
13	10-27-06	0.000055	0.2546	7.4	有
14	10-27-14	0.000688	0.2800	3.6	有
15	10-28-22	0.000155	0.4579	4.4	无
16	10-29-14	0.000186	0.5155	7.9	有
17	10-29-22	0.000355	0.4327	8.1	无
18	11-01-22	0.000322	0.1924	9.3	无
19	11-02-06	0.000289	0.4200	9.7	无
20	11-10-22	0.000123	0.3200	7.5	无
21	11-16-06	0.000384	0.3122	4.8	有
22	11-19-22	0.000900	0.3126	5.5	无
23	11-24-06	0.000238	0.1993	5.1	有
24	11-28-06	0.000015	0.3442	8.9	无
25	11-28-14	0.000128	0.2907	3.6	有
26	11-30-14	0.001500	0.2870	10.2	有

由表 1 可以看出,工作面突出危险性与 Q 序列具有明显的混沌-分形特性,但 Q 序列的 λ_1, K_2 和 D_2 等各项混沌特征指标与工作面突出的危险性之间没有明显的相关性。应用第 2 节的固定质量法原理可计算出该时段所有 26 个呈混沌特征的 Q 序列的 $D_q(-5 \sim +5)$ 值,如表 2 所列。

由表 2 可看出,无突出危险时段 Q 序列 D_{-5} 均大于 5,而有突出危险时段 Q 序列的 D_{-5} 截止达到 20 以上(标号为 13 的样本)。这从另一个方面说明了煤层瓦斯动力系统是一个非常复杂的系统,至少需要 5 个甚至 20 个以上的实质性状态变量才能构建一个普通意义上的动力学模型,这也正是很难确定预测突出的敏感指标的根本原因。

上述典型的有突出危险和无突出危险时段 Q 序列的多重分维谱表明,工作面有突出危险状态与无突出危险状态相比,其瓦斯涌出量动态时序数据的多重分形特征具有显著差异。这里采用表 2 中 Q 序列 D_q 值作为本文进行煤与瓦斯突出预测研究的敏感特征指标。

为了提高训练的速度和精度,将 Q 序列的 $D_q(-5 \sim +5)$ 进行归一化处理,这里归一化采用式(21)进行:

$$z_{ij} = \frac{x_{ij}}{\max\{x_{ij}\}} \quad (21)$$

式中, x_{ij} 为第 i 个样本中第 j 个特征指标, z_{ij} 为 x_{ij} 规格化后的值。

这里把突出危险程度分类评价集定义为: $Y = \{\text{无突出危险}, \text{有突出危险}\}$ 。对于该二元评价集,作如下规定:有突出危险时,网络输出为 -1;无突出危险时,网络输出为 +1。

表2 混沌Q序列的 D_q 值($q=-5\sim 5$)

样本序号	时间 (月-日-班次)	q										突出 危险性	
		-5	-4	-3	-2	-1	0	1	2	3	4		5
1	09-01-22	14.99	14.87	14.65	14.19	12.86	8.75	6.31	5.61	5.34	5.20	5.12	Yes
2	09-02-06	10.15	10.07	9.98	9.91	9.84	9.33	4.13	3.48	3.26	3.11	3.00	Yes
3	09-17-22	8.35	8.32	8.26	8.07	7.13	5.23	4.65	4.49	4.44	4.41	4.38	No
4	10-04-14	11.08	10.97	10.77	10.43	9.81	8.96	8.34	7.89	7.48	7.16	6.91	No
5	10-05-14	13.89	12.44	10.38	8.50	7.43	7.08	6.89	6.17	6.09	6.08	6.09	Yes
6	10-10-06	8.41	8.35	8.20	7.90	7.25	6.09	5.48	5.15	4.91	4.71	4.54	Yes
7	10-11-06	11.17	11.09	10.92	10.56	9.51	7.74	6.81	6.38	6.15	6.00	5.90	No
8	10-12-22	13.94	13.84	13.73	13.61	13.50	13.42	11.74	10.98	10.57	10.26	10.02	No
9	10-14-14	12.11	11.91	11.68	11.46	11.50	10.87	4.87	3.65	3.19	2.98	2.87	Yes
10	10-16-14	5.25	5.11	4.60	2.66	2.23	2.12	2.07	2.06	2.04	2.03	2.02	No
11	10-25-14	5.27	5.11	4.85	4.56	4.33	4.17	4.04	3.94	3.86	3.81	3.77	No
12	10-26-14	10.73	10.67	10.56	10.39	10.15	9.90	9.67	9.48	9.32	9.21	9.13	No
13	10-27-06	20.21	20.01	19.76	19.40	18.70	16.37	10.52	7.72	6.64	6.10	5.79	Yes
14	10-27-14	17.83	17.48	17.05	16.53	15.94	15.00	6.76	4.96	4.38	4.13	3.99	Yes
15	10-28-22	5.42	5.16	4.85	4.54	4.32	4.20	4.14	4.10	4.07	4.01	3.95	No
16	10-29-14	18.23	18.00	17.63	16.97	15.67	13.47	8.19	6.78	6.48	6.27	6.12	Yes
17	10-29-22	16.13	16.09	16.01	15.85	15.53	14.51	11.30	9.86	8.90	8.21	7.73	No
18	11-01-22	14.58	14.54	14.44	14.20	13.36	10.96	9.84	9.58	9.47	9.41	9.37	No
19	11-02-06	14.51	14.35	14.11	13.70	12.94	11.66	10.77	10.32	9.93	9.62	9.40	No
20	11-10-22	12.82	12.60	12.31	11.85	10.91	9.02	7.57	6.93	6.55	6.29	6.09	No
21	11-16-06	14.83	14.81	14.78	14.74	14.67	13.72	5.28	5.30	5.25	5.20	5.15	Yes
22	11-19-22	12.52	11.35	9.45	7.92	6.96	5.78	5.13	4.89	4.75	4.64	4.55	No
23	11-24-06	15.77	15.71	15.64	15.59	15.58	15.32	5.73	4.71	4.48	4.35	4.25	Yes
24	11-28-06	9.32	9.24	9.11	8.90	8.62	8.35	8.11	7.89	7.70	7.54	7.41	No
25	11-28-14	6.82	6.76	6.66	6.38	4.14	2.77	2.54	2.52	2.49	2.49	2.49	Yes
26	11-30-14	16.36	16.36	16.36	16.36	16.15	11.13	10.23	9.89	9.58	9.36	9.23	Yes

为了进行对比研究,实验时首先将数据源中的样本数据分为两组。第一组为测试样本,由标号为3、9、13、18和21的5个样本数据构成,用于检验该模型的检测效果。第二组为学习样本,由除第一组以外的21个样本所组成,用来建立学习模型。根据第2—5节描述的相关原理,整个算法在MATLAB6.5环境下进行编程实现,程序运行经过42次进化后目标函数收敛,得到支持向量机最佳参数向量 $\theta=(C, \sigma)=(721.8309, 0.5340)$ 。根据参数向量 θ 和学习样本求得支持向量机的支持向量数为13, $Margin=0.0196$,从而构建了煤与瓦斯突出的支持向量机预测模型。

建立模型后,将预测样本数据输入到构建的支持向量机预测模型中,其输出结果如表3所列。为了便于对比,表3中同时列出了支持向量机模型的非Sgn输出结果和神经网络预测方法(ANN)的预测结果数据^[1]。

表3 预测样本的预测结果

编号	时间	期望输出	SVM 预测		ANN 预测
			正常输出	非 Sgn 输出	
3	9-17-22	1	1	0.2887	1.0519
9	10-14-14	-1	-1	-1.0000	-1.5161
13	10-27-06	-1	-1	-1.0000	-0.6498
18	11-01-22	1	1	1.0000	1.0624
21	11-16-06	-1	-1	-1.0000	-1.0693

由表3可看出,采用支持向量机可以达到100%的预测正确率,较好地解决了小样本学习的问题,达到了非常理想的预测效果。

为进一步说明两种方法的本质特征,将第二组21个学习样本分别输入到SVM预测模型和神经网络预测模型,可以发现神经网络拟合的正确率为100%,而支持向量机拟合正确率为80.95%(其中编号为5、6、15和26的4个学习样本发生错误)。由此可见,对学习样本而言,神经网络输出结果比支持向量机输出更接近期望输出,说明神经网络比支持向量机具有更强的非线性拟合能力,这正是由于神经网络所具有的过拟合特性所致。根据表3的支持向量机模型的非Sgn输

出结果和神经网络预测方法的预测结果,计算出两种预测模型对测试样本的预测误差,如表4所列。

表4 误差分析

	支持向量机方法	神经网络方法
平均相对误差/%	14.2260	20.9980
平均绝对误差	0.1423	0.2100

由表4可以看出,对测试样本而言,支持向量机方法的平均相对误差和平均绝对误差均优于神经网络方法。这说明虽然神经网络方法具有优秀的非线性特性拟合能力,但支持向量机却具有更强的泛化能力,更适合应用到矿井煤与瓦斯预测中。

特别需要指出的是,采用神经网络预测方法不仅在理论上是有缺陷的,在实际应用过程中模型结构的选择也是困难的,其输出结果也不稳定;而支持向量机方法是建立在坚实理论基础之上,模型结构由样本本身所决定的,其输出结果是稳定的,这也说明了本文提出的支持向量机矿井煤与瓦斯的预测方法的优越性。

结束语 本文采用煤矿井下掘进工作面前方媒体瓦斯涌出量动态变化时间序列的多重分维谱作为预测煤与瓦斯突出的特征指标,应用具有强大非线性逼近能力与优秀泛化能力的支持向量机对特征指标与突出危险性类别之间的高度非线性关系进行拟合,构建矿井煤与瓦斯突出预测模型,模型的参数向量由完全混沌粒子群优化算法及测试集样本集分类错误率最小准则进行选择与优化。应用实例验证了所提方法的有效性,其达到了非常理想的预测效果,为矿井煤与瓦斯突出预测提供了一种新方法。

参考文献

[1] 孙燕,杨胜强,王彬,等.用灰关联分析和神经网络方法预测煤与瓦斯突出[J].中国安全生产科学技术,2008,4(3):14-17

②通过搜索 P_x 结点的 Token,找出所有 $t \in T$,满足 $t \in p_j(x) * \wedge p_j(x) \in P_x$,计算它们的输入强度 $S(t)$,并与其启动阈值 $\eta(t)$ 相比较,此处 $\eta(t)$ 可由定义 8 设定适当函数计算得到。如 $S(t) > \eta(t)$,则启动对应变换结点 T 。

③由式(12)和函数 N 计算所有 t 的后置集 V ,对每一 p_i , $p_i \in V$,输出 p_k 的标记数(即由转化程度函数得到的属性的质特征值)。如无这样的 p_k 存在,表明 x 不具有属性 $s_i(x)$ 。

以上识别操作的粒逻辑推理过程可表示在 AGLP 中,如图 1 所示。




图 1 识别操作的粒逻辑 AGLP 表示

结束语 在哲学观点上,属性不仅表现着它要表现的质特征,而且还拥有需要它界定和规范的量特征。本文讨论不确定性问题中的粒逻辑模型,揭示知识不确定性随知识粒度的变化关系,进一步挖掘知识不确定性与确定性之间的本质联系。在揭示模糊不确定性判据可变的时,构建了粒逻辑基本概念,最后用 Petri 网对其推理部分进行形式化描述,检验了其合理性。然而,得到这样的粒逻辑系统是简单的,其内容有待下一步进行丰富,完善后还将就粒逻辑的完备性及其归结式进行详细的探讨。

参考文献

[1] 李德毅,刘常昱,杜鹃,等. 不确定性人工智能[J]. 软件学报, 2004,15(11):1583-1594

[2] Zadeh L A. Fuzzy sets[J]. Information and Control,1965,8(3): 338-353

[3] Pawlak Z. Rough sets[J]. Int'l Journal of Computer and Information Sciences,1982,11(5):341-356

[4] Gau W L, Buehrer D J. Vague sets[J]. IEEE Trans on Systems, Man and Cybernetics,1993,23(2):610-614

[5] 陈守煜. 可变模糊集量变与质变判据模式及其应用[J]. 系统工程与电子技术,2008,30(10):1879-1882

[6] 蔡文,石勇. 可拓学的科学意义与未来发展[J]. 哈尔滨工业大学学报,2006,38(7):1079-1083

[7] 李德毅,孟海军,史雪梅. 隶属云和隶属云发生器[J]. 计算机研究与发展,1995,32(6):16-21

[8] Smarandache F. A Unifying field in logic: Neutrosophic logic,

Neutrosophic Probability and Statistics[M]. Xiquan Publishing Hours,2003

[9] 冯嘉礼. 思维、智能与属性论方法[J]. 广西师范大学学报:自然科学版,1997,15(3):1-6

[10] 王国胤,张清华,马希鹂,等. 知识不确定性问题的粒计算模型[J]. 软件学报,2011,22(4):676-694

[11] 解滨,李磊军,米据生. 基于知识粒度的粗糙集的不确定性度量[J]. 计算机科学,2010,37(9):225-228

[12] 张钊,张铃. 问题求解理论及应用[M]. 北京:清华大学出版社,1990

[13] Zadeh L A. Some reflections on information granulation and its certainty in granular computing, computing with words, the computational theory of perceptions and precipitated natural language[C]//Lin T Y, ed. Data Mining, Rough Sets and Granular Computing. Germany:Physica-Verlag GmbH Heidelberg,2002

[14] Zadeh L A. From computing with numbers to computing With words-from manipulation of measurements to manipulation of perceptions[J]. IEEE Transactions Circuits and Systems,1999, 45:105-119

[15] Zadeh L A. Outline of computational theory of perceptions based on computing with words [M]. New York: Academic Press, 2000:3-22

[16] 王飞跃. 词计算和语言动力学系统的计算理论框架[J]. 模式识别与人工智能,2001,14(4):377-384

[17] 王飞跃. 词计算和语言动力学系统的基本问题和研究[J]. 自动化学报,2005,31(6):844-852

[18] 苗夺谦,王国胤,刘清,等. 粒计算:过去、现在与展望[M]. 北京:科学出版社,2007

[19] 孙丽君,苗夺谦. 基于粒度计算的特征选择方法[J]. 计算机科学,2008(35):14-16

[20] 赵立权. 模糊集、粗糙集和商空间理论比较研究[J]. 计算机工程,2011,37(2):22-24

[21] 冯嘉礼. 从判断到识别的定性映射模型与模糊人工神经元[J]. 模式识别与人工智能,2006,19(1):35-66

[22] 潘谦红,王炬,史忠植. 基于属性论的文本相似度计算[J]. 计算机学报,1999,22(6):651-655

[23] 冯嘉礼,毕经迎. 基于属性论的肺癌细胞识别[J]. 广西师范大学学报:自然科学版,2011,29(3):183-186

[24] 许广林,冯嘉礼,刘永昌. 模式识别的属性计算网络模型[J]. 计算机研究与发展,2008,45(S):274-278

[25] Zhou Ru-qi, Lu Chun-he. Granular computing cognitive model based on criterion transformation [C] // Proceeding of 2011 IEEE International conference on Granular computing. 2011, 11:813-816

(上接第 220 页)

[2] 刘俊娥,曾凡雷,郭章林. 基于 RS-SVM 模型的煤与瓦斯突出多因素风险评价[J]. 中国安全科学学报,2011,21(7):21-25

[3] 王凯,俞启香. 煤与瓦斯突出的非线性特征及预测模型[M]. 徐州:中国矿业大学出版社,2005

[4] Cristianini N, Shawe-Taylor J. An introduction to support vector machine and other kernel-based learning methods [M]. Cambridge: Cambridge University Press,2000

[5] Vapnik V N. The nature of statistical learning theory [M]. New York: Springer verlag, 1995

[6] Coellc A, Pulido G T, Lechuga M S. Handling multiple objec-

tives with particle swarm optimization[J]. IEEE Trans on Evolutionary Computation,2004,8(3):256-279

[7] Kennedy J, Eberhart R C. Particle swarm optimization [C] // Proceedings of IEEE international conference on neural networks. Piscataway: IEEE Press,1995:1942-1948

[8] 张春概,李霄峰,邵惠鹤. 基于线性搜索的混沌优化及其在非线形约束优化问题中的应用[J]. 控制与决策,2001,16(1):120-124

[9] 孟红记,郑鹏,梅国晖,等. 基于混沌序列的粒子群优化算法[J]. 控制与决策,2006,21(3):262-266

[10] 朱红求,阳春华,桂卫华,等. 一种带混沌变异的粒子群优化算法[J]. 计算机科学,2010,37(3):215-217