

基于卡尔曼滤波参数自学习的大坝变形预测

占鹏飞 吕 鑫 毛莺池 徐淑芳 王龙宝 马鸿旭

(河海大学计算机与信息学院 南京 210098)

摘 要 卡尔曼滤波模型被广泛运用于大坝的变形预测,然而其参数的识别,尤其是状态和观测噪音协方差矩阵的识别,主要来源于工程经验和领域专家知识。因此提出一种自学习的参数识别方法,该方法基于历史数据,结合 Monte Carlo 和拒绝采样算法获取卡尔曼滤波参数。具体地,从训练样本中挑选出与真实值最接近的实测值对状态噪音进行估计,并通过计算它与总体误差的差值来确定观测噪音。实验表明,相比已有的同类方法,该方法的准确性更高,更适用于大坝变形预测。

关键词 Monte Carlo, 拒绝采样, 卡尔曼滤波, 参数自学习, 大坝变形预测

中图法分类号 TP311 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.05.048

Parameter Self-learning Method Based on Kalman Filter for Dam Deformation Prediction

ZHAN Peng-fei LV Xin MAO Ying-chi XU Shu-fang WANG Long-bao MA Hong-xu

(College of Computer and Information, Hohai University, Nanjing 210098, China)

Abstract Kalman filter is widely applied to dam deformation prediction. However, the identification of parameters to the model, especially the state and observation noise covariance matrices, is derived mostly from the experience of engineering or expert knowledge. Therefore, a self-learning method was proposed for parameter identifying, in which the parameters of Kalman filter are determined by the combination of Monte Carlo and rejection sampling algorithm from history data. More precisely, the state noise sorted out from training ones is evaluated by samples, whose observations approximate actual value completely, and the observation noise is determined by calculating the difference of the aforementioned noise and overall error. The experiment result shows that the proposed method is more accurate than other congener ones, and it's more applicable to dam deformation prediction.

Keywords Monte Carlo, Rejection sampling, Kalman filter, Parameter self-learning, Dam deformation prediction

1 引言

大坝的安全不仅影响到大坝工程效益的发挥,而且在保障人民生命财产安全方面起到举足轻重的作用。因此,学者和工程专家投入了大量的时间和精力来分析大坝的安全监测数据建模,以发现大坝运行的规律。传统的建模方法^[1]以工程力学为基础来发掘规律,然而建立的模型预测结果与实际的观测结果往往相差甚远。因此,学者们试图将一些智能算法与物理模型相结合来改进预测的结果。比如,王伟等^[2]将遗传算法、自适应粒子群算法应用到大坝的安全预警中,有效地提高了统计模型的预测精度;Kose E 等^[3]深入讨论了灰度理论在大坝预测中的应用,并与简单的指数平滑进行了对比,得出了该方法具有更高精准度的结论;徐洪钟等^[4]利用神经网络方法来确定大坝效应量分量的比例,并用工程实例验证

了其有效性。此外,Jiang C 等^[5]提出了一种可变滑动窗口的方法来估计坝基的径向位移,极大地提高了预测的准确性。然而,这些方法都有一个明显的不足,即预测阶段计算量大,不适用于实时性要求高的场合。为解决这个问题,一些学者将卡尔曼滤波模型应用到大坝的变形预测中^[6-8],但同时也带来了一些新问题。比如,当存在大量的监测测点时,使用人工方式识别参数是不可取的;如果所有的测点都使用相同的参数,会造成预测结果的可信性问题等。正如 Welch G 和 Bishop G^[9]指出的,当观测误差接近于 0 时,卡尔曼滤波模型可以获得任意预测精度。所以说,如果卡尔曼滤波模型的参数估计不合理,那么结论的可靠性就存在严重的挑战。对此,本文提出了一种基于蒙特卡罗-拒绝采样的方法,旨在解决基于卡尔曼滤波的大坝变形预测模型参数学习问题,进而更好地应用卡尔曼滤波模型来预测大坝变形。

到稿日期:2016-06-24 返修日期:2016-09-29 本文受水利部公益性行业科研专项经费项目(201501007),NSFC-广东联合基金重点项目(U1301252),国家科技支撑计划(2013BAB06B04,HNKJ13-H17-04),国家自然科学基金面上项目(61272543)资助。

占鹏飞(1990—),男,硕士生,主要研究方向为数据挖掘与领域软件工程,E-mail: dethrive@hotmail.com;吕鑫(1983—),男,博士,讲师,主要研究方向为密码学、网络信息安全,E-mail: lvxin@hhu.edu.cn(通信作者);毛莺池(1976—),女,博士,副教授,主要研究方向为分布计算与并行处理、大规模数据处理技术、物联网,E-mail: yingchimao@hhu.edu.cn;徐淑芳(1981—),女,博士,讲师,主要研究方向为通信工程;王龙宝(1977—),男,博士,讲师,主要研究方向为机器学习、数据挖掘。

2 预备知识

2.1 卡尔曼滤波

卡尔曼滤波(KF)模型由 Kalman^[10]提出,现被广泛应用于导航追踪、经济时间序列预测和各种工程领域^[11]。其基本形式如下:

$$\begin{aligned} z_t &= A_t z_{t-1} + B_t u_t + \epsilon_t \\ y_t &= C_t z_t + \delta_t \end{aligned} \tag{1}$$

其中, z_t 是 t 时刻的隐状态; u_t 是外力因素; y_t 是 t 时刻的观测; ϵ_t 是 t 时刻的系统噪音,满足 $\epsilon_t \sim N(0, Q_t)$; δ_t 是 t 时刻的观测噪音,满足 $\delta_t \sim N(0, R_t)$; A_t 是状态转换矩阵; B_t 是输入信号矩阵; C_t 是测量模型矩阵(高斯噪音假设参考文献[12])。如果参数 $\theta_t=(A_t, B_t, C_t, Q_t, R_t)$ 已知,那么模型就是确定的,并且当参数 θ_t 与时间 t 无关时,它还是一个平稳模型。其求解过程可以分离为预测步和更新步,本文只给出其计算公式,具体推导参考文献[13]。

(1)预测步:已知 y_{t-1} ,可以给出 t 时刻的状态分布如下:

$$\begin{aligned} p(z_t | y_{1:t-1}, u_{1:t}) &= N(\mu_{t|t-1}, \Sigma_{t|t-1}) \\ \mu_{t|t-1} &\stackrel{\Delta}{=} A_t \mu_{t-1} + B_t u_t \\ \Sigma_{t|t-1} &\stackrel{\Delta}{=} A_t \Sigma_{t-1} A_t^T + Q_t \end{aligned} \tag{2}$$

(2)更新步:当观测到 t 时刻的观测值时,可以更新对 t 时刻的估计,即式(3):

$$\begin{aligned} p(z_t | y_{1:t}, u_{1:t}) &= N(z_t | \mu_{t|t}, \Sigma_{t|t}) \\ \mu_{t|t} &= \mu_{t|t-1} + K_t r_{t|t-1} \\ \Sigma_{t|t} &= (I - K_t C_t) \Sigma_{t|t-1} \\ r_{t|t-1} &\stackrel{\Delta}{=} y_t - C_t \mu_{t|t-1} \\ K_t &\stackrel{\Delta}{=} \Sigma_{t|t-1} C_t^T (C_t \Sigma_{t|t-1} C_t^T + R_t)^{-1} \end{aligned} \tag{3}$$

其中, K_t 为卡尔曼增益, $r_{t|t-1}$ 为测量创新误差。

2.2 拒绝采样

概率采样是指从一个概率密度函数为 $p(x)$ 的分布中抽取样本的过程,基本原则是使被抽取样本在分布函数中被抽取到的概率最大。拒绝采样是概率采样中的一种方法^[13],其思想是:1)构建一个概率密度函数 $q(x)$,使得对于某个常数 M ,满足 $Mq(x) \geq \tilde{p}(x)$,其中, $\tilde{p}(x)$ 是 $p(x)$ 的未归一化的形式(令 $Z_p = \int \tilde{p}(x) dx$,有 $p(x) = \tilde{p}(x)/Z_p$);2)从 $q(x)$ 的分布中抽取一个样本 x ,这对应于选择一个随机的 x 位置,然后从均匀分布 $U(0,1)$ 中抽取一个样本 u ,这对应于选择一个随机高度;3)如果满足 $u > \tilde{p}(x)/Mq(x)$,那么拒绝这个样本,否则接受该样本。

2.3 Monte Carlo 近似

一般来说,使用与随机变量相关的公式来计算关于它的一个函数的分布是比较困难的,但是可以采用一种简单却非常有效的近似计算方法——蒙特卡罗方法^[13]来替代。其过程是从这个函数的分布 $f(X)$ 中生成 N 个样本 $x_1, \dots, x_N$,然后利用这些样本,使用经验的分布 $\{f(x_n)\}_{n=1}^N$ 来近似地估计这个分布。其数学形式可以表示为:

$$E[f(X)] = \int f(x)p(x)dx \approx \frac{1}{N} \sum_{n=1}^N f(x_n) \tag{4}$$

其中, $x_n \sim p(X)$ 。从而,关于均值和方差的近似可以表示为:

$$\begin{aligned} \bar{x} &= \frac{1}{N} \sum_{n=1}^N x_n \rightarrow E[X] \\ \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2 &\rightarrow \text{var}[X] \end{aligned} \tag{5}$$

2.4 平均估计误差

定义平均估计误差 $AE = \sqrt{\sum_i (\hat{y}_i - y_i)^2 / N}$,其中 N

表示训练样本的个数, y_i 表示训练样本 i 的实际测量值, $\hat{y}_i$ 为训练样本 i 的估计值, $i=1, \dots, N$ 。一般来说, AE 的值越大,模型的准确性越低,反之则越高。

3 模型设计与参数学习

3.1 模型设计

本文以某拱坝坝基正垂监测项 A22-PL-01 测点的历史数据为例来分析水位变化量与位移变化量的关系,得到如图 1 所示的散点图。直观来看,顺河向位移变化量与水位变化量之间存在很强的线性关系,而横河向位移变化量与水位变化量之间基本无关。从而,可以假设位移变化量 Δz_t 与水位变化量 u_t 存在如下的关系模型:

$$\Delta z_t = b * u_t + c + \epsilon \tag{6}$$

其中, $\Delta z_t = z_t - z_{t-1}$, z_t 表示 t 时刻的位移值, b 表示水位变化量对位移变化量的影响因子, c 表示偏置量, ϵ 表示随机误差项。当横河向位移变化量与水位变化量无关时,只要令 $b=0$,上述模型就仍然成立。




图 1 水位变化量与位移变化量关系图

很显然,在拱坝变形分析的这个关系模型中,偏置项 $c=0$ 。

证明:由式(6)可得 $z_t - z_{t-1} = b * u_t + c + \epsilon$ (其中 $t=1, \dots, N$),从而 $z_t = z_0 + b \sum u_t + N_c + \sum \epsilon_t$ 。假设 $c \neq 0$,那么从上式可以知道序列 $\{z_t\}$ 是一个发散序列,这与大坝位移的实际运行呈现在一定的区间做周期性变化矛盾,从而 $c=0$ 。式(6)即可修正为:

$$z_t = z_{t-1} + b * u_t + \epsilon \tag{7}$$

到目前为止,这是很典型的回归模型。现在转向卡尔曼滤波模型,只需要将 z_t 看作是 t 时刻位移的隐状态值,那么式(7)也就意味着 t 时刻的隐状态 z_t 等于 $t-1$ 时刻的隐状态值 z_{t-1} 加上水位变动和状态随机误差对它的影响。不失一般性,可建立顺河向位移和横河向位移的状态转移方程:

$$\begin{aligned} z_{1,t} &= z_{1,t-1} + b_{1,t} u_t + \epsilon_{1,t} \\ z_{2,t} &= z_{2,t-1} + b_{2,t} u_t + \epsilon_{2,t} \end{aligned} \tag{8}$$

此外,由于测量仪器误差、数据转换误差等不可避免,可建立如下的观测模型:

$$\begin{aligned} y_{1,t} &= z_{1,t} + \delta_{1,t} \\ y_{2,t} &= z_{2,t} + \delta_{2,t} \end{aligned} \quad (9)$$

其中, $z_{1,t}$, $z_{2,t}$ 分别表示 t 时刻的顺河向位移、横河向位移的实际状态; $y_{1,t}$, $y_{2,t}$ 分别表示 t 时刻的顺河向位移、横河向位移的观测值; $\epsilon_{1,t}$ 和 $\delta_{i,t}$ ($i=1,2$, 下文 i 的值与此处一致) 分别表示系统噪音和观测噪音。将其写成如式(1)的矩阵形式, 有 $A=I$, $B=(b_1, b_2)^T$, $Q=\text{diag}(q_1^2, q_2^2)$, $C=I$, $R=\text{diag}(r_1^2, r_2^2)$, 其中, diag 表示对角矩阵。下面将分别介绍如何估计状态模型和观测模型中的未知参数。

3.2 参数学习

(1) B 的确定

由于没有实际的隐状态值, 因此须借助于观测值来估计。首先, 可以对式(8)和式(9)进行变形, 得到:

$$\begin{aligned} \Delta z_{i,t} &= b_i * u_t + \epsilon_{i,t} \\ \Delta y_{i,t} &= \Delta z_{i,t} + \delta_{i,t} \end{aligned} \quad (10)$$

所以有 $\text{cov}(\Delta z_{i,t}, u_t) = \text{cov}(b_i u_t + \epsilon_{i,t}, u_t)$ 成立。由于随机误差互相独立, $\text{cov}(\epsilon_{i,t}, u_t) = 0$, 因此 $\text{cov}(\Delta z_{i,t}, u_t) = b_i \text{cov}(u_t, u_t)$ 成立, 通过相关系数法可以确定 b_i 的值。但是 $\Delta z_{i,t}$ 未知, 因此需要借助其观测值来估计 b_i 的值。又因 $\text{cov}(\Delta z_{i,t} + \delta_{i,t}, u_t) = b_i \text{cov}(u_t, u_t)$ 也成立, 从而有 $\text{cov}(\Delta y_{i,t}, u_t) = b_i \text{cov}(u_t, u_t)$, 即 $b_i = \text{cov}(\Delta y_{i,t}, u_t) / \text{cov}(u_t, u_t)$ 。

(2) Q 的确定

首先可以直接利用观测数据计算 $\Delta y_{i,t}$, 再采用极大似然估计方法求出其均值和方差, 如式(11)所示:

$$\begin{aligned} \hat{\mu}_{\Delta y_i} &= \frac{1}{N} \sum_{j=1}^N \Delta y_i^{(j)} \\ S_{\Delta y_i} &= \frac{1}{N} \sum_{j=1}^N (\Delta y_i^{(j)} - \hat{\mu}_{\Delta y_i})^2 \end{aligned} \quad (11)$$

根据式(10)以及随机高斯噪声假设 $E[\delta_{i,t}] = 0$, 那么易知 $E[\Delta y_{i,t}] = E[\Delta z_{i,t}] + E[\delta_{i,t}]$ 成立, 所以理论上 $\Delta y_{i,t}$ 和 $\Delta z_{i,t}$ 有相同的均值。由于 $\text{cov}[\Delta y_{i,t}] = \text{cov}[\Delta z_{i,t} + \delta_{i,t}] = \text{cov}[\Delta z_{i,t}] + \text{cov}[\delta_{i,t}]$, 因此 $\Delta y_{i,t}$ 的方差更大, 且两者之差是测量误差 R 。我们可以采用如图 2 的示意图来说明这两个高斯分布之间的关系。图 2 中的实线条代表 Δz 的分布, 钟形虚线代表 Δy (方差比 Δz 大), 而垂直的虚线代表它们具有相同均值。由于 Δy 的方差更大, 因此它的分布更宽, 峰值也就更小, 而 Δz 的分布更窄, 峰值更大。如果要从实际观测数据中选择样本来估计真实状态误差, 那么应该使得被选择的样本受到测量误差的影响越小越好。显然, 这倾向于从 Δy 的分布中选择最接近均值的那部分样本。一方面是因为这部分样本出现的概率更大, 所以被抽取到的可能性更大; 另一方面是因为对这部分样本计算出来的方差更小, 即受到测量误差的影响也更小。虽然在此过程中会忽略掉部分样本, 但是这部分样本是小概率样本, 在采样过程中应尽可能避免。此外, 为了避免由于偶然性因素导致两次计算状态噪音方差 Q 的结果差异较大, 本文采用 3.3 节介绍的蒙特卡罗方法来近似。由于蒙特卡罗的方法会进行多次采样并多次计算对应的 Q 值, 因此会导致计算复杂度增加, 但状态噪音参数的计算只需要用到已有的历史数据, 故可采用离线的方式计算, 而在之后的预测阶段不需要重复计算, 因此参数确定与模型预测可以分离。

而且, 针对准确性要求很高的需求, 在每次预测前可以重新计算参数; 对于一般性日常要求, 只需要定期维护参数值, 就可以在提高准确性的同时平衡时间开销。




图 2 同均值、不同方差时的正态分布概率密度图

根据 2.2 节的知识, 令 $q(x) = p_y(x)$, $p(x) = p_z(x)$, 那么要选择的样本集合 X 应该使得对于 $x \in X$, $p_y(x) \leq p_z(x)$ 成立。从而蒙特卡罗-拒绝采样的具体执行过程如下: 1) 从训练数据集中任意取一个样本 x 计算 $p_y(x)$, 同时任取一个随机数 $p_z(x) = u \in (0, 1)$, 如果 $u < p_y(x)$, 则拒绝这个样本, 否则接受所抽取的样本, 直到所采样本数为 N , 计算所采样本的方差; 2) 重复上述过程 K 次, 取它们的平均值作为 Q 的估计。算法的伪代码如下所示。

算法 1 calculate_Q

```
/* 利用蒙特卡罗拒绝采样求解状态方程的协方差矩阵 Q */
for (k=1; k<K; k++) { // K 表示重复次数
    while i<N { // N 表示每次抽取的样本数
        x(i) ~ q(x) and u ~ U(0,1)
        if u < M * q(x(i)) { accept x(i); i++; } // 接受样本, 计数器自增
        else { reject x(i); } // 拒绝该样本
    }
    calculate mean(x_k), var(x_k) // 计算一次采样后的方差
}
Q = sum(var_1, var_2, ..., var_K) // 计算 Q 的值
```

(3) R 的确定

只需要一步简单的计算。由前面的方法可以求解出近似的 Q 值, 再由式(11)可求解 $S_{\Delta y_i}$; 与此同时, 根据与式(10)有关系的 $S_{\Delta y_i} = q_i^2 + b_i^2 \sigma^2 + r_i^2$ 式成立, 可以很容易求解 $r_i^2 = S_{\Delta y_i} - q_i^2 - b_i^2 \sigma^2$ 。至此, 各个参数的确定已经完成, 之后的预测过程只需执行 3.1 节介绍的预测步和更新步即可。

4 实验与分析

4.1 实验数据

实验数据来自某拱坝的坝基传感器变形监测数据, 时间跨度为 2012/06/01—2016/03/31, 其中, 2012/06/01—2014/12/31 的数据用于训练模型的参数, 其余则用作测试数据来验证所建立模型的有效性。实验所用数据只有在极端异常的情况下才置空。比如, 在 2012/08—2012/09 这段时间, A22-PL-01 测点的横河向位移都在 $-2 \sim 2$ 的区间范围内波动, 但是 2012/09/01 的数据值却达到 -16.7047 , 从而在数据处理过程中标记为空。当然, 如果变形监测数据在某个时点之后突然下移, 并且在后续的一段时间内都在这个值附近窄幅波动或者呈现规律性的趋势, 则不做任何处理。

4.2 实验结果分析

根据训练数据计算得到顺河向位移变化量与水位变化量

的相关系数约为 0.827,而横河向位移变化量与水位变化量的相关系数约为 0.012。为便于展示,本文仅选取两段测试数据来考查实验结果,其余情况可以依此进行。

本方法的预测结果和相对误差分别如图 3 和图 4 所示,为便于图 3 的图形绘制,这里仅出 2011/01/01—2016/03/31 时间段的预测结果。从图中可以看出,顺河向位移的形变值一般远大于横河向位移的形变值,且变化具有一定的趋势性;而横河向位移变化更接近于随机游走,但只是窄幅波动。从预测的结果来看,如果以相对误差来衡量预测结果,那么采用卡尔曼滤波可以很好地预测顺河向位移的形变值,但横河向位移则不然。这主要是因为水位波动对大坝顺河向位移的影响很大,而横河向位移的变化则基本与水位的波动无关(从相关系数也可以得知)。横河向位移变化受水位波动的影响较小,甚至可以忽略不计,下文不再讨论。




图 3 位移预测实际观测与预测值(注:上图为顺河向,下图为横河向)




图 4 预测的相对误差(注:左顺河向,右横河向)

当测试区间 2015/08/01—2015/10/31 存在局部调整时,为便于表示,图 5 中仅给出 2015/08/12—2015/09/25 的各个算法的预测值和实际值,可以发现 2015/09/07 这天原始数据曲线(raw)下折,以及图 6 中相对误差陡增,接近于 0.16。显然,预测存在一定的滞后性,从而导致了预测值和实际观测值之间存在较大的偏差。可以通过设定合理的阈值来捕获系统出现的异常情况,此时结合系统日志信息寻找其背后的原因,可以用于化解大坝运行过程中可能存在的隐患。

为进一步验证该改进方法的适应性,本文将该方法与基于可变滑动窗口的预测方法(CSW)和灰度模型的方法(GM)进行了比较。如图 5 和图 6 所示,相比于 CSW 方法,PS-KF 和 GM 的预测结果更为平滑,且对突跳的响应也更快,这在

图 5 和图 6 中分别表现为在对应的突跳之后这两种方法能够快速收敛到观测值的附近,误差迅速下降到较为合理的水平。一般来说,GM 和 PS-KF 方法都优于 CSW 方法,但是 GM 方法对缺失值较为敏感,这在图 6 中表现为误差曲线的最大值远大于其他两种。此外,在数据突变的情况下,相对于 GM 的调整过度以及 CSW 的调整不足,PS-KF 的调整幅度更为合理,这是因为卡尔曼滤波模型中增益矩阵 K 在每一步观察到新的测量值之后,都会重新计算误差的协方差矩阵和均值的估计(也称为后验估计值),从而能够更好地利用最新观测值来修正之前的预测结果。




图 5 不同算法的顺河向位移预测比较




图 6 不同算法的顺河向位移误差折线图

表 1 不同方法平均误差对比

	训练数据 2012/06—2014/12	测试数据 1 2015/08—2015/10	测试数据 2 2016/01—2016/03
PS-KF	0.541	0.219	0.031
CSW	0.394	0.387	0.041
GM	0.036	0.812	0.040

注:观测值缺失不参与计算。

表 1 的结果表明,无论数据平稳还是存在数据突跳或者数据缺失,基于参数自学习的卡尔曼滤波模型都是有效的。虽然该模型使用了蒙特卡罗方法和拒绝采样会增大计算开销,但是由于参数的学习是以离线形式计算的,而预测过程是利用卡尔曼滤波算法进行在线更新的,因此从整体上来说,该方法并不会导致预测过程中时间的剧增。在实际中,由于传感器数据相对稳定,因此也不需要每次预测之前都对参数进行更新,只需要定期修正即可,这使得该模型相对于以往的依靠人工干预率定参数的卡尔曼滤波模型具有更好的实用性。

结束语 本文主要解决了大坝变形预测中卡尔曼滤波模型参数自学习问题,避免了测点过多时对参数率的人工干预。但该方法要求模型的状态转换矩阵和测量模型矩阵都是单位矩阵,因此将该方法推广到任意形式的卡尔曼滤波模型有待于进一步的研究。此外,未来的研究可以考虑将温度和时效因子纳入到模型中以进一步提高模型的准确性。

(下转第 275 页)

- [3] SUN J G, LIU J, ZHAO L Y. Clustering Algorithms Research [J]. Journal of Software, 2008, 19(1): 48-61. (in Chinese)
孙吉贵, 刘杰, 赵连宇. 聚类算法研究[J]. 软件学报, 2008, 19(1): 48-61.
- [4] WANG J C, XIAO R, SUN Z X, et al. State of the Art of Information Retrieval on the Web[J]. Journal of Computer Research & Development, 2001, 38(2): 187-193. (in Chinese)
王继成, 萧嵘, 孙正兴, 等. Web 信息检索研究进展[J]. 计算机研究与发展, 2001, 38(2): 187-193.
- [5] YANG Z Z, HUANG H Y. WSD Method Based on Heterogeneous Relation Graph[J]. Journal of Computer Research and Development, 2013, 50(2): 437-444. (in Chinese)
杨防卓, 黄河燕. 基于异构关系网络图的词义消歧研究[J]. 计算机研究与发展, 2013, 50(2): 437-444.
- [6] LIAO Z F, LI L, LIU L M, et al. A Tripartite Decomposition of Tensor for Social Tagging[J]. Chinese Journal of Computers, 2012, 35(12): 2625-2632. (in Chinese)
廖志芳, 李玲, 刘丽敏, 等. 部图张量分解标签推荐算法[J]. 计算机学报, 2012, 35(12): 2625-2632.
- [7] CHUA T S, TANG J, HONG R, et al. NUS-WIDE: a real-world web image database from National University of Singapore[C]// Proceedings of the ACM International Conference on Image and Video Retrieval. ACM, 2009: 48.
- [8] TANG J, LIU H. Unsupervised feature selection for linked social media data[C]// Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2012: 904-912.
- [9] ZHU S, YU K, CHI Y, et al. Combining content and link for classification using matrix factorization[C]// Proceedings of the 30th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2007: 487-494.
- [10] KLAMI A, VIRTANEN S, KASKI S. Bayesian canonical correlation analysis[J]. The Journal of Machine Learning Research, 2013, 14(1): 965-1003.
- [11] QI G J, AGGARWAL C C, HUANG T S. Transfer Learning of Distance Metrics by Cross-Domain Metric Sampling across Heterogeneous Spaces[C]// SDM. 2012: 528-539.
- [12] TIAN F, GAO B, CUI Q, et al. Learning Deep Representations for Graph Clustering[C]// AAAI. 2014: 1293-1299.
- [13] TAO X M, HAO S Y, ZHANG D X, et al. Overview of classification algorithms for unbalanced data[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2013, 25(1): 101-110. (in Chinese).
陶新民, 郝思媛, 张冬雪, 等. 不平衡数据分类算法的综述[J]. 重庆邮电大学学报(自然科学版), 2013, 25(1): 101-110.

(上接第 271 页)

参 考 文 献

- [1] GU C S, WU Z R. Safety Monitoring of Dams and Dam Foundations—Theories & Methods and Their Application[M]. Nanjing: Hohai University Press, 2006. (in Chinese)
顾冲时, 吴中如. 大坝与坝基安全监控理论和方法及其应用[M]. 南京: 河海大学出版社, 2006.
- [2] WANG W, SHEN Z Z, LI T F. Safety Early Warning Evaluation Model for Dams Based on Coupled Method of Genetic Algorithm and Adapting Particle Swarm Optimization Algorithm [J]. Chinese Journal of Geotechnical Engineering, 2009, 31(8): 1242-1247. (in Chinese)
王伟, 沈振中, 李桃凡. 遗传算法与自适应粒子群算法耦合的大坝安全预警评价模型[J]. 岩土工程学报, 2009, 31(8): 1242-1247.
- [3] KOSE E, TASCI L. Prediction of the Vertical Displacement on the Crest of Keban Dam[J]. Journal of Grey System, 2015, 27(1): 12-20.
- [4] XU H Z, WU Z R, SHI B, et al. Neural Network Method for Determining the Component Proportion of Dam Effect Variable [J]. Journal of Hydraulic Engineering, 2003, 34(6): 111-114. (in Chinese)
徐洪钟, 吴中如, 施斌, 等. 确定大坝效应量分量比例的神经网络方法[J]. 水利学报, 2003, 34(6): 111-114.
- [5] JIANG C, XU F, LV X, et al. A Novel Changeable Sliding Window Method for Predicting Horizontal Displacement of Dam Foundation[C]// 2015 14th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES). IEEE, 2015(3): 497-500.
- [6] HE J, YANG G. Application of Cloud Model Based Kalman Filtering to Determination of Crack Opening Monitoring Index of Concrete Gravity Dam[J]. Water Resources and Power, 2015(3): 57-59. (in Chinese)
何军, 杨光. 基于卡尔曼滤波的云模型在某混凝土重力坝裂缝监控指标拟定中的应用[J]. 水电能源科学, 2015(3): 57-59.
- [7] SU G N, ZHENG D J, SUN B B. Application of Kalman Filtering Grey Model in Prediction of Dam Deformation [J]. Water Resources and Power, 2014(4): 37-40. (in Chinese)
苏观南, 郑东健, 孙斌斌. 卡尔曼滤波灰色模型在大坝变形预测中的应用[J]. 水电能源科学, 2014(4): 37-40.
- [8] ZHANG L M, LIU W D, QIN P. Deformation Analysis of RCC Arch Dam Vertical Displacement Based on Kalman Filter Method[J]. Hydropower Automation and Dam Monitoring, 2011, 35(6): 52-54. (in Chinese)
张黎明, 刘为东, 秦鹏. 基于卡尔曼滤波法的碾压混凝土拱坝垂直位移变形分析[J]. 水电自动化与大坝监测, 2011, 35(6): 52-54.
- [9] WELCH G, BISHOP G. An introduction to the kalman filter [J]. University of North Carolina at Chapel Hill, 2006, 8(7): 127-132.
- [10] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of basic Engineering, 1960, 82(1): 35-45.
- [11] FARAGHER R. Understanding the basis of the Kalman filter via a simple and intuitive derivation[J]. IEEE Signal processing magazine, 2012, 29(5): 128-132.
- [12] MAYBECK P S. Stochastic models, estimation, and control[M]. Academic Press, 1982.
- [13] MURPHY K P. Machine learning: a probabilistic perspective [M]. MIT Press, 2012.