

# 基于神经网络的异构网络向量化表示方法

吴卫祖<sup>1</sup> 刘利群<sup>1</sup> 谢冬青<sup>2</sup>

(广东海洋大学信息学院 湛江 524088)<sup>1</sup> (广州大学计算机科学与教育软件学院 广州 510006)<sup>2</sup>

**摘要** 当网络中存在不同类型的对象时,对象与对象之间的关系会变得多种多样,网络的结构也会变得更为复杂。针对网络的异构化问题,提出了一种基于神经网络的异构网络向量化表示方法。针对具有图片和文本两种类型对象的异构网络,采用多层次的卷积网络将图片映射到一个潜在的特征空间,采用全连接的神经网络将文本对象也映射到相同的特征空间。在该特征空间内,图片与图片、文本与文本以及图片和文本之间的相似性采用相同的距离计算方法。在实验中,应用提出的方法进行异构网络的多种应用测试,结果表明提出的方法是有效的。

**关键词** 异构网络,神经网络,向量化表示,嵌入式向量

**中图分类号** TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.05.049

## Vectorized Representation of Heterogeneous Network Based on Neural Networks

WU Wei-zu<sup>1</sup> LIU Li-qun<sup>1</sup> XIE Dong-qing<sup>2</sup>

(School of Information, Guangdong Ocean University, Zhanjiang 524088, China)<sup>1</sup>

(School of Computer Science and Education Software, Guangzhou University, Guangzhou 510006, China)<sup>2</sup>

**Abstract** When there are different types of objects in the network, the relationships between objects would be various, and the structure of the network would become even more complex. To deal with the problem heterogeneity of networks, this paper proposed a neural network based vectorization representation method of the heterogeneous networks. For the heterogeneous network with two types of images and text, multi-hierarchical convolution neural network was adopted to map the original image into a latent feature space, and fully-connected neural network was adopted to map the text object into the same latent feature space. In the latent feature space, the similarities between images, texts, and even image and text can be calculated by the same distance computing method. In the experiment, the proposed method is applied to test a variety of applications in heterogeneous networks, and the results show that the proposed method is effective.

**Keywords** Heterogeneous networks, Neural network, Vectorized representation, Embedded vector

在数据挖掘等应用中,向量化表示方法将原始数据嵌入到多维空间中,通过计算映射后的数据在多维空间中的欧几里得距离来反映原始数据间的相似性<sup>[1]</sup>。在多维空间中,可以应用不同的相似性度量方法进行数据点的分类<sup>[2]</sup>、聚类<sup>[3]</sup>和检索<sup>[4]</sup>等应用。在 Web 检索和数据挖掘应用中,有效的嵌入式向量表示方法是基础的研究问题之一,其性能对上层应用的效果有着关键性影响,好的嵌入式向量表示方法往往能取得比复杂的应用模型更好的应用效果。通常 Web 上具有网络结构的数据资源是异构的,既包含图数据,也包含关系数据;既包含文本数据,也包含图片、音频和视频等多媒体数据<sup>[5]</sup>。在这种异构的网络中,很难将不同形式的数据用相同维度的向量表示。为了解决上述问题,目前采用的方法或者将数据预先定义为不同的特征向量,或者采用复杂的基于图论的算法。当图数据和关系数据并存时,将关系数据表示为图中节点或者边的属性值;在处理文本和图片等不同模式的数据时,针对某一特定模式采用相应的特征表示方法。

图或者网络数据的嵌入式向量表示最早应用于协同过滤

和链接预测等应用中。图通常用一个矩阵表示,矩阵中的每行和每列分别代表一个实体,实体间的关系通过矩阵来描述。在矩阵分解过程中,将一个矩阵分解为两个低维度的矩阵乘积,其中新生成的低维度表示潜在特征的维度。当网络中存在着多种模式的实体时,矩阵分解则扩展为张量分解<sup>[6]</sup>。采用张量分解进行多模式数据的嵌入式向量表示时,由于张量分解的问题在于多个模式数据之间参数的共享,因此很难有效地将其应用于大规模的异构网络中。

本文采用神经网络分别将不同类型的对象映射到相同的向量空间中,使得不同类型的对象之间可以相互计算相似性。此外,由于神经网络具有非线性特征,使得向量化后的特征空间可以更好地描述网络的结构特征。

## 1 异构网络的嵌入式向量表示

### 1.1 异构网络的定义

本文中的异构网络为具有下列结构的无向图  $G=(V, E)$ , 其中  $V=\{v_1, v_2, \dots, v_n\}$  为顶点的集合,  $E$  为边的集合。

到稿日期:2016-04-19 返修日期:2016-07-22 本文受广东省科技计划项目(2014A020218016), 国家 863 项目(2009AA012420)资助。

吴卫祖(1959—),男,副教授,主要研究方向为信息系统、网络安全、物联网、北斗通信及应用;刘利群(1972—),女,硕士,副教授,主要研究方向为软件工程、地理信息系统;谢冬青(1965—),男,博士,教授,博士生导师,主要研究方向为计算机网络安全等。

对于  $\forall i, j \in \{1, \dots, n\}$ ,  $e_{ij} \in E$  当且仅当顶点  $i$  和  $j$  之间存在一条无向的连接。此外,图  $G$  中有两个映射函数  $f_v: V \rightarrow O$  和  $f_e: E \rightarrow R$ , 其中  $f_v$  表示节点的类型映射函数,  $f_e$  表示边的类型映射函数。  $\forall v_i \in V, f_v(v_i) \in O$ , 并且  $\forall e_{ij} \in E, f_e(e_{ij}) \in R$ 。在上述的网络结构定义中,当  $|O|=|R|=1$  时,图  $G$  为同构网络;否则,图  $G$  为异构网络。

为了便于理论分析和后续的实验验证,本文以包含图片和文本的异构网络为例进行研究。在该异构网络中,  $O = \{I, T\}$ ,  $R = \{R_{II}, R_{IT}, R_{TT}\}$ 。

### 1.2 嵌入式向量表示

异构网络嵌入式向量表示的目标是学习多个映射函数分别将不同类型的模态数据映射到相同的特征空间,使得不同类型的对象的相似性在特征空间中可以直接计算得出。对于图片和文本对象,本文采用线性变换  $U \in \mathbb{R}^{d_I \times r}$  和  $V \in \mathbb{R}^{d_T \times r}$  分别将两种类型的对象映射到同一个潜在的向量空间中。对于图片  $x$  和文本  $z$ , 它们的映射过程为:

$$\tilde{x} = U^T x, \tilde{z} = V^T z \quad (1)$$

虽然图片向量  $x$  和文本向量  $z$  的维度 ( $d_I \neq d_T$ ) 可能不同,但是线性映射矩阵  $U \in \mathbb{R}^{d_I \times r}$  和  $V \in \mathbb{R}^{d_T \times r}$  将它们映射到相同维度(维度为  $r$ ) 的向量空间中。在该向量空间中,图片之间的相似性和文本之间的相似性为:

$$s(x_i, x_j) = \tilde{x}_i^T \tilde{x}_j = (U^T x_i)^T U^T x_j = x_i^T M_{II} x_j \quad (2)$$

$$s(z_i, z_j) = \tilde{z}_i^T \tilde{z}_j = (V^T z_i)^T V^T z_j = z_i^T M_{TT} z_j$$

同时,图片和文本之间的相似性也可以在该向量空间中计算得出:

$$s(x_i, z_j) = \tilde{x}_i^T \tilde{z}_j = (U^T x_i)^T V^T z_j = x_i^T M_{IT} z_j = s(z_i, x_j) = \tilde{z}_i^T \tilde{x}_j = (V^T z_i)^T U^T x_j = z_i^T M_{TI} x_j \quad (3)$$

当网络中的异构节点进行显示或者隐式的交互时,它们之间的连接也是异构的。当两个节点相互连接时,它们之间的相似性应该大于分开的两个节点之间的相似性。给定两个图片节点  $x_i$  和  $x_j$ , 它们之间的决策函数  $d(x_i, x_j)$  需要具有如下特征:

$$d(x_i, x_j) = s(x_i, x_j) - t_{II} \quad (4)$$

$$d(x_i, x_j) \begin{cases} > 0, & \text{if } A_{ij} = 1 \\ < 0, & \text{otherwise} \end{cases}$$

那么,图片节点  $x_i$  和  $x_j$  之间的损失函数可以形式化描述为:

$$L(x_i, x_j) = \log(1 + \exp(-A_{ij} d(x_i, x_j))) \quad (5)$$

式(5)所示的损失函数可以看作由网络连接指导得到的二值逻辑回归。将式(4)中的  $t_{II}$  替换为  $t_{IT}$  或者  $t_{TT}$ , 并且修改相应的相似性函数  $s(x_i, x_j)$ , 就可以得到不同模态数据之间的损失函数计算方法。于是,可以得到如下的目标函数:

$$\min_{U, V} \frac{1}{N_{II}} \sum_{x_i, x_j \in V_I} L(x_i, x_j) + \frac{\lambda_1}{N_{IT}} \sum_{x_i, z_j \in V_T} L(x_i, z_j) + \frac{\lambda_2}{N_{TT}} \sum_{z_i, z_j \in V_T} L(z_i, z_j) + \lambda_3 (\|U\|_2^2 + \|V\|_2^2) \quad (6)$$

其中,  $N_{II}$ ,  $N_{IT}$  和  $N_{TT}$  为这 3 种类型的连接在网络中对应的数量;  $\lambda_1$ ,  $\lambda_2$  和  $\lambda_3$  为均衡因子, 它们控制各个分量的比重。

在对式(6)所示的目标函数进行求解的过程中,采用坐标下降法。对于  $U$  和  $V$  两个参数,分别固定一个参数的取值,然后对另一个参数进行求解,该方法主要包含两步。

首先,固定参数  $V$  并对  $U$  求解。当  $V$  为固定值后,目标

函数式(6)可简化为:

$$\min_U \frac{1}{N_{II}} \sum_{x_i, x_j \in V_I} \log(1 + \exp(-A_{ij} x_i^T U U^T x_j)) + \frac{\lambda_2}{N_{IT}} \sum_{x_i \in V_I, z_j \in V_T} \log(1 + \exp(-A_{ij} x_i^T U V^T z_j)) + \lambda_3 \|U\|_2^2 \quad (7)$$

该目标函数相对于参数  $U$  的梯度为:

$$\frac{\partial}{\partial U} = \frac{1}{N_{II}} \sum_{x_i, x_j \in V_I} \frac{-A_{ij} (x_i x_i^T + x_j x_j^T) U}{1 + \exp(A_{ij} x_i^T U U^T x_j)} + \frac{\lambda_2}{N_{IT}} \sum_{x_i \in V_I, z_j \in V_T} \frac{-A_{ij} x_i z_j^T V}{1 + \exp(A_{ij} x_i^T U V^T z_j)} + 2\lambda_3 U \quad (8)$$

然后,固定参数  $U$  并对  $V$  求解。当  $U$  为固定值后,目标函数式(6)可简化为:

$$\min_V \frac{\lambda_1}{N_{IT}} \sum_{x_i, z_j \in V_T} \log(1 + \exp(-A_{ij} z_i^T U V^T z_j)) + \frac{\lambda_2}{N_{TT}} \sum_{z_i, z_j \in V_T} \log(1 + \exp(-A_{ij} z_i^T V V^T z_j)) + \lambda_3 \|V\|_2^2 \quad (9)$$

该目标函数相对于参数  $V$  的梯度为:

$$\frac{\partial}{\partial V} = \frac{\lambda_1}{N_{IT}} \sum_{x_i, z_j \in V_T} \frac{-A_{ij} (z_i z_i^T + z_j z_j^T) V}{1 + \exp(A_{ij} z_i^T V V^T z_j)} + \frac{\lambda_2}{N_{TT}} \sum_{z_i, z_j \in V_T} \frac{-A_{ij} z_i z_j^T U}{1 + \exp(A_{ij} z_i^T U V^T z_j)} + 2\lambda_3 V \quad (10)$$

### 1.3 神经网络结构

1.2 节所述的异构网络嵌入主要包含两个部分:1)人工构建特征表示;2)将不同的模态嵌入到相同的向量空间。下面通过神经网络模型将这两部分集成为一个统一的框架。

$$\min_{U, V, D_I, D_T} \frac{1}{N_{II}} \sum_{x_i, x_j \in V_I} L(p_{D_I}(x_i), p_{D_I}(x_j)) + \frac{\lambda_1}{N_{IT}} \sum_{x_i \in V_I, z_j \in V_T} L(p_{D_I}(x_i), p_{D_T}(z_j)) + \frac{\lambda_2}{N_{TT}} \sum_{z_i, z_j \in V_T} L(p_{D_I}(z_i), p_{D_T}(z_j)) + \lambda_3 (\|U\|_2^2 + \|V\|_2^2) \quad (11)$$

其中,  $p_{D_I}(\cdot)$  和  $p_{D_T}(\cdot)$  为两个非线性函数,它们对应的参数分别为  $D_I$  和  $D_T$ , 而  $D_I$  和  $D_T$  分别是图片和本文对应的参数集合。

在  $p_{D_I}(\cdot)$  的构建过程中,本文采用卷积神经网络提取图片的特征,采用全连接神经网络提取文本信息的特征。在图片模块中,图片特征的提取采用多层的卷积网络。对于第  $k$  层卷积网络,其特征映射函数可描述为:

$$h^k = \max(0, (W^k * M) + b^k) \quad (12)$$

其中,  $W^k$  和  $b^k$  为第  $k$  层卷积网络的权重和偏差,  $M$  为该层卷积网络的输入(当  $k=1$  时,  $M$  为原始图片),运算符  $*$  表示卷积操作,其定义如下:

$$o[m, n] = f[m, n] * g[m, n] = \sum_{u=-\infty}^{\infty} \sum_{v=-\infty}^{\infty} f[u, v] g[u-m, v-n] \quad (13)$$

在式(12)中,  $\max(0, \cdot)$  称为校正线性单元,它使得上述网络具有非线性特征。为了提取图片的整体特征,除了构建多层的卷积网络之外,通常在最后一个卷积网络后面加入一个或者多个全连接神经网络。

在  $p_{D_T}(\cdot)$  的构建过程中,首先应用 TF-IDF 方法将每个文本节点表示为向量,然后应用如下的特征变换:

$$p_{D_T}(z) = \max(0, W_T z + b_T) \quad (14)$$

式(14)是一个全连接神经网络,其中  $W_T \in \mathbb{R}^{r \times d_T}$ ,  $b_T \in \mathbb{R}$ ,

$r$  为该层中神经元的个数。

对于  $p_{D_I}(\cdot)$  和  $p_{D_T}(\cdot)$ , 仍然可以将它们嵌入到相同的特征空间。令  $D_I' = D_I \cup \{U\}$ ,  $D_T' = D_T \cup \{V\}$ , 得到如下的线性映射:

$$\tilde{p}_{D_I'}(z) = U^T p_{D_I}(x) \text{ 和 } \tilde{p}_{D_T'}(z) = V^T p_{D_T}(z) \quad (15)$$

于是, 式(11)所示的目标函数可转化为如下公式:

$$\min_{D_I', D_T'} \frac{1}{N_{II}} \sum_{v_i, v_j \in V_I} L'(\tilde{p}_{D_I'}(x_i), \tilde{p}_{D_I'}(x_j)) + \frac{\lambda_1}{N_{TT}} \sum_{v_i, v_j \in V_T} L(\tilde{p}_{D_T'}(z_i), \tilde{p}_{D_T'}(z_j)) + \frac{\lambda_2}{N_{IT}} \sum_{v_i \in V_I, v_j \in V_T} L(\tilde{p}_{D_I'}(x_i), \tilde{p}_{D_T'}(z_j)) \quad (16)$$

## 2 实验结果与分析

实验采用公开的 NUS-WIDE 数据集<sup>[7]</sup>, 该数据集由新加坡国立大学媒体搜索小组收集整理。该数据集包含 269648 张图片和 5018 个文本标签, 每张图片都有若干个文本标签。在异构网络中, 如果图片和标签之间有关联, 那么它们之间存在着一个连接, 将图片看作标签文本的集合, 应用 TF-IDF 提取文本的特征, 用余弦相似性计算两幅图片的距离, 令相似性大于阈值的图片之间存在着连接; 对于某个文本标签节点, 如果该标签与另外一个标签同时出现的次数超过一定的比例, 则令这两个标签之间存在着连接。

首先, 实验采用非监督学习的方式观察算法的聚类准确性。在该组实验中, 分别利用数据集的内容(标签和图片)、链接(网络的边)、内容 & 链接实现了 3 种基本聚类算法, 并且将本文提出的方法与 LUFs<sup>[8]</sup> 和 LCMF<sup>[9]</sup> 两种方法进行了对比, 实验结果如图 1 所示。从图中可以看出, 本文提出的方法在对图片进行聚类分析时, 其聚类的准确率要高于其他方法。




图 1 聚类结果对比图

其次, 实验采用监督学习的方式对比了上述不同算法的分类准确率和 NMI, 实验结果分别如图 2 和图 3 所示。在图 2 中, 坐标横轴表示不同训练数据比例下的分类结果。从图 2 中可以看出, 当训练数据量不断加大时, 分类的准确率逐渐增加; 在不同算法的对比中, 本文方法的分类准确率明显高于其他几种方法。在图 3 所示的 NMI 对比结果中, 本文方法也优于其他几种方法。




图 2 分类结果对比图




图 3 NMI 结果对比图

最后, 为了充分验证本文提出的方法在异构网络上的性能, 分别采用 CCA<sup>[10]</sup>, DT<sup>[11]</sup> 和 LHNE<sup>[12]</sup> 3 种处理异构数据的方法作为基本算法来对比算法的 MAP 和  $p@k$ , 实验结果分别如图 4 和图 5 所示。在图 4 中, 实验采用图片、文本和图片+文本 3 种方式进行结果的预测, 其中图片+文本的方式具有最好的预测结果。在 4 种处理异构数据的算法中, 本文提出的方法仍然具有最高的 MAP 值。在图 5 中, 令  $p@k$  中的  $k$  分别取值为 1, 5, 10 和 20。随着  $k$  值的不断增大, 本文算法的  $p@k$  准确率呈现下降的趋势。在算法的性能对比中, 本文方法的  $p@k$  准确率依然高于相同环境下其他算法的  $p@k$  准确率。




图 4 算法的 MAP 对比图




图 5 算法的  $p@k$  对比图

**结束语** 随着网络应用的普及和发展, 网络中融入了不同类型的内容, 如文本、图片、音频和视频等, 这使得网络通常是异构的。当网络中存在异构对象时, 对象与对象之间的关系变得多种多样, 网络的结构也变得更为复杂。本文采用神经网络分别将不同类型的对象映射到相同的向量空间中, 使得不同类型的对象之间可以相互计算相似性。针对具有图片和文本两种类型对象的异构网络, 采用多层次的卷积网络将图片映射到一个潜在的特征空间, 采用全连接的神经网络将文本对象也映射到相同的特征空间。在该特征空间内, 图片与图片、文本与文本以及图片和文本之间的相似性采用相同的距离计算方法。在实验中, 应用提出的方法进行异构网络的多种应用测试, 结果表明提出的方法是有效的。

## 参考文献

[1] TAN Z H, WANG X W, CHENG W, et al. A Distributed Trust Model for Peer-to-Peer Networks Based on Multi-Dimension-History Vector[J]. Chinese Journal of Computers, 2010, 33(9): 1725-1735. (in Chinese)

谭振华, 王兴伟, 程维, 等. 基于多维历史向量的 P2P 分布式信任评价模型[J]. 计算机学报, 2010 33(9): 1725-1735.

[2] LIU H Y, CHEN J, CHEN G Q. Review of classification algorithms for data mining[J]. Journal of Tsinghua University(Science and Technology), 2002, 42(6): 727-730. (in Chinese)

刘红岩, 陈剑, 陈国青. 数据挖掘中的数据分类算法综述[J]. 清华大学学报(自然科学版), 2002, 42(6): 727-730.

- [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.