

# 计算和存储空间受限下的数据稀疏核分析方法

谢晓丹<sup>1</sup>, 李伯虎<sup>1</sup>, 柴旭东<sup>2</sup>

(1. 北京航空航天大学, 北京 100191; 2. 北京仿真中心, 北京 100854)

**摘 要:** 针对核主成分分析算法广泛面临的训练样本数量大而带来的计算和存储空间的问题, 提出了基于 1 类支持向量理论的稀疏核主成分分析算法, 该方法适合于计算和存储空间受限下的应用场合, 如小型硬件平台下的图像检索系统、医学辅助诊断系统等. 通过求解最优方程找到能够代表原始样本空间的少量典型样本, 这些样本作为计算核数据矩阵, 大大节省了核矩阵计算的时间和存储空间成本, 在有限的训练样本集上最大限度在硬件平台下图像处理领域有效提高识别率和计算效率.

**关键词:** 主成分分析; 核方法; 稀疏学习

**中图分类号:** TP309

**文献标识码:** A

**文章编号:** 0372-2112 (2017)06-1362-05

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2017.06.012

## Computation and Store Space Constrained-Based Sparse Kernel Data Analysis

XIE Xiao-dan<sup>1</sup>, LI Bo-hu<sup>1</sup>, CHAI Xu-dong<sup>2</sup>

(1. College of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China;

2. Beijing Simulation Center, Beijing 100854, China)

**Abstract:** In order to solve the computation and storage space problems of kernel principal component analysis, which come from the large number of the training samples, this paper presents one-class support vector based sparse kernel principal component analysis (SKPCA). This method can be used in the computation-constrained and space-constrained applications, for example, a small scale hardware platform based image retrieval system, medical assistant diagnosis system, and so on. The method uses the constrained optimization equation to seek the few representative samples, and the few representative samples are used to compute the kernel matrix. The method decreases the computing time and decreases the storage space. So under conditions of the limited training samples, the method is to improve the performance of accuracy and efficiency for hardware computing platform-based image processing.

**Key words:** principal component analysis; kernel method; sparse learning

### 1 引言

核学习算法已经广泛应用于数据非线性处理中, 取得了良好的效果<sup>[1-3]</sup>, 如图像识别<sup>[4,5]</sup>、图像分类<sup>[6]</sup>, 面部表情分析<sup>[7]</sup>, 语音识别<sup>[8]</sup>, 元器件质量识别<sup>[9]</sup>, 文本分类<sup>[10]</sup>等. 在过去的研究中已经有很多许多特征提取方法, 如主成分分析 (PCA, Principal Component Analysis) 和线性判别分析 (LDA, Linear Discriminant Analysis). PCA 目的是最大限度地减少均方差准则, 已被广泛用于人脸识别和字符识别等领域. 在大多数应用中表现出良好的性能, 随后核学习方法用来解决 PCA 线性问题, 1998 年学者 Scholkopf 提出核主成分分析 (KP-

CA, Kernel Principal Component Analysis) 并引起广泛关注<sup>[1]</sup>, 在各个领域获得良好的效果. 在随后的研究工作中, Yang 等人将 KPCA 算法应用于人脸图像的特征提取, 提出了 Combined Fisherface 算法<sup>[11]</sup>, 其主要思想是分别利用 PCA 和 KPCA 提取同一个对象的两类不同特征, 认为这两类特征对于图像识别是互补的, 融合这两个特征进行图像识别工作. Liu<sup>[12]</sup> 将多项式核函数扩展到为分数次幂多项式模型, 并结合 KPCA 与 Gabor 小波用于人脸识别中. 此外, 核学习方法在医学图像中也有广泛应用<sup>[13]</sup>, 在高光谱图像中有广泛应用<sup>[14]</sup>. 包括 KPCA 在内的所有核学习算法在使用过程中需保存所

有样本来进行核矩阵的计算,使算法的执行时间和存储空间大大提升,不能适用于一些计算资源和存储资源都受限的情况下,例如,卫星平台上的最流行高光谱成像,由于光谱和空间分辨率的不断提升带来了巨大的数据量,在实际应用中产生了两个问题:通信通道带宽限制了全波段数据的传输,这些数据用于地面的进一步处理与分析;在一些应用中的实时图像处理的需求.数据压缩能够在一定程度上解决传输问题,但不能实现实时分析.基于机器学习的数据分析技术实现根据目标光谱数据实现每个像素谱线的分类,从而从多个波段高光谱图像产生一副图像,并且该系统在卫星平台上实现.高光谱数据采集后,基于光谱数据库,每个像素被分类成不同的目标.数据库中的光谱数据是事先采集的,所以采集的光谱与数据中的光谱有不一致性.这种不一致性可认为是非线性变化,目标之间的光谱曲线关系也是典型的非线性关系.因此,该分类问题为典型的非线性复杂数据分类问题.传统的分类方法不能适用于高光谱遥感数据,在各种机器学习方法中,核学习是可行的有效的适用于高光谱遥感数据的非线性分类方法.然而,由于卫星平台计算资源和存储资源都受限,因此在该应用上如何提升有限计算和存储空间下的数据处理技术是必须要解决的问题.尤其是核主成分分析(KPCA)在实际应用中需要用所有样本计算核矩阵,并占用存储空间存储所有训练样本.在数据量大的情况下,需要耗费大量计算时间和存储空间,不适合用于计算和存储资源受限的硬件平台计算.为此,本文在研究基于稀疏最小二乘支持向量机理论的基础上,提出了一个新颖的稀疏主成分分析算法,在有限的训练样本集上最大限度在硬件平台下图像处理领域有效提高识别率和计算效率.该方法在大量的样本中选择少量的有代表性的样本,这些有代表性的样本参与核矩阵的计算,全体样本中只有少部分样本被选出作为代表样本,因此我们称为稀疏技术.在计算核矩阵过程中,只采用小部分样本参与计算,相比全部样本参与计算来说要节省大量的计算时间.此外,核学习机需要保存全部训练样本,在应用中,对于输入的测试样本,需要与所有样本计算得到核矩阵,采用稀疏技术只采用少量样本来计算,节省了大量的保存样本的空间.因此,稀疏技术可以提高计算效率节省样本空间.

## 2 稀疏核主成分分析算法

核主成分分析(KPCA)的主要思路为利用核方法扩展主成分分析(PCA),从而利用非线性映射将数据从原始空间映射到另一空间.如果内核函数是正定的内核,那么存在一个映射到一个点的样本空间.空间具有一种所谓的再生核希尔伯特空间(RKHS, Reproducing

Kernel Hilbert Space)结构.在特征空间内的样本可以不进行明确的非线性映射函数计算,使得计算样本是在非常高维情况下进行的.常用的此类正定核函数为多项式核和高斯内核,这意味着他们每个样本在不同的映射.基于PCA特征提取需要存储的系数矩阵.虽然基于特征提取的KPCA需要存储原始样本资料,计算核矩阵导致巨大的存储和高计算耗时.为了解决这个问题,首先用最小二乘支持向量机建立稀疏核主成分分析(SKPCA).其次,核函数及其参数的选择严重影响算法的性能.在核映射空间数据的几何结构是由核函数完全确定的,若核函数选择不当,特征空间的数据点分布可能变得不利于分类.目前的方法是从一个离散数值集选择核参数,该方法不会改变在核映射空间数据的几何结构.采用数据依赖核可以通过改变其参数改变核的结构,从而改善SKPCA的性能是可行的.

首先,采用最小二乘1类支持向量机原理对传统KPCA进行建模,其主要思想为实现1类目标函数的优化问题.其次,引入稀疏核主成分分析,其中输入数据的结构自适应改变关于输入数据的分布数据相关的内核.然后,目标函数可描述为

$$\max_w \sum_{i=1}^N [0 - \mathbf{w}^T(\phi(\mathbf{x}_i) - \mathbf{u}^\phi)]^2 \quad (1)$$

其中  $\mathbf{u}^\phi = \frac{1}{N} \sum_{i=1}^N \phi(\mathbf{x}_i)$ . 直接稀疏核学习方法对KPCA进行理论推导.用膨胀系数(expansion coefficients)和膨胀向量(expansion vectors)进行有关的有关描述.假定矩阵  $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_{N_z}]$ ,  $\mathbf{Z} \in \mathbf{R}^{N \times N_z}$ , 由  $N_z$  个膨胀向量组成,  $\beta_i (i = 1, 2, \dots, N_z)$  ( $N_z < N$ ) 为膨胀系数,那么可将上述优化问题可转化为:

$$\begin{aligned} \max_{w, e} J(w, e) &= -\frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \\ \text{subject to } e_i &= \mathbf{w}^T(\phi(\mathbf{x}_i) - \mathbf{u}^\phi), i = 1, 2, \dots, N \\ \mathbf{w} &= \sum_{i=1}^{N_z} \phi(\mathbf{z}_i) \beta_i \end{aligned} \quad (2)$$

其中  $\phi(\mathbf{Z}) = [\phi(\mathbf{z}_1), \phi(\mathbf{z}_2), \dots, \phi(\mathbf{z}_{N_z})]$ ,  $\gamma$  为表征误差权值的常数.可以将上述优化问题转化为如下两步:第一,求解找到可以代表最优的膨胀向量和系数;第二,求解最优映射矩阵.给定任意  $\mathbf{Z}$ , 上述优化问题转化为

$$W(\mathbf{Z}) := \max_{\beta, e} -\frac{1}{2} \beta^T \mathbf{K} \beta + \frac{\gamma}{2} \sum_{i=1}^N e_i^2$$

$$\text{subject to } e_i = \beta^T g(\mathbf{x}_i), i = 1, 2, \dots, N \quad (3)$$

其中

$$g(\mathbf{x}_i) = \left[ k(\mathbf{z}_1, \mathbf{x}_i) - \frac{1}{N} \sum_{q=1}^N k(\mathbf{z}_1, \mathbf{x}_q) \dots k(\mathbf{z}_{N_z}, \mathbf{x}_i) - \frac{1}{N} \sum_{q=1}^N k(\mathbf{z}_{N_z}, \mathbf{x}_q) \right]^T,$$

$\boldsymbol{\beta} = [\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_N]^T, \mathbf{K}_z = [k(\mathbf{z}_i, \mathbf{z}_j)]$ . 上述优化问题的解可用拉格朗日方法进行求解. 拉格朗日方程为

$$L(\boldsymbol{\beta}, \mathbf{e}, \boldsymbol{\alpha}) = -\frac{1}{2} \boldsymbol{\beta}^T \mathbf{K}_z \boldsymbol{\beta} + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 - \sum_{i=1}^N \alpha_i (\mathbf{e}_i - \boldsymbol{\beta}^T \mathbf{g}(\mathbf{x}_i)) \quad (4)$$

其中参数  $\alpha_i, i = 1, 2, \dots, N$  为组合系数, 用梯度下降法求解使函数  $L(\boldsymbol{\beta}, \mathbf{e}, \boldsymbol{\alpha})$  最大.

$$\begin{cases} \frac{\partial L}{\partial \boldsymbol{\beta}} = 0 \rightarrow \mathbf{K}_z \boldsymbol{\beta} = \sum_{i=1}^N \alpha_i \mathbf{g}(\mathbf{x}_i) \\ \frac{\partial L}{\partial \mathbf{e}_i} = 0 \rightarrow \alpha_i = \gamma \mathbf{e}_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \mathbf{e}_i - \boldsymbol{\beta}^T \mathbf{g}(\mathbf{x}_i) = 0 \end{cases} \quad (5)$$

令  $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_N]^T (\boldsymbol{\alpha}_{N \times 1}), \mathbf{G} = [\mathbf{g}(\mathbf{x}_1), \mathbf{g}(\mathbf{x}_2), \dots, \mathbf{g}(\mathbf{x}_N)] (\mathbf{G}_{N \times N}), \mathbf{E} = [e_1, e_2, \dots, e_N]^T (\mathbf{E}_{N \times 1})$ , 那么

$$\begin{cases} \mathbf{K}_z \boldsymbol{\beta} = \mathbf{G} \boldsymbol{\alpha} \\ \boldsymbol{\alpha} = \gamma \mathbf{E} \\ \mathbf{E} = \mathbf{G}^T \boldsymbol{\beta} \end{cases} \quad (6)$$

因此,  $\boldsymbol{\beta} = (\mathbf{K}_z)^{-1} \mathbf{G} \boldsymbol{\alpha}$ , 那么  $\mathbf{E} = \mathbf{G}^T (\mathbf{K}_z)^{-1} \mathbf{G} \boldsymbol{\alpha}$ . 最优解  $\boldsymbol{\alpha}^z$  为  $\mathbf{G}^T (\mathbf{K}_z)^{-1} \mathbf{G}$  的特征向量.  $\boldsymbol{\alpha}^z$  为  $\mathbf{G}^T (\mathbf{K}_z)^{-1} \mathbf{G}$  的特征值时  $W(\mathbf{Z})$  获得最大, 此时  $\boldsymbol{\beta}^z = (\mathbf{K}_z)^{-1} \mathbf{G} \boldsymbol{\alpha}^z$ . 此时, 需找到使得  $W(\mathbf{Z}) = -\frac{1}{2} (\boldsymbol{\beta}^z)^T \mathbf{K}_z (\boldsymbol{\beta}^z) + \frac{\gamma}{2} (\boldsymbol{\beta}^z)^T \mathbf{G} \mathbf{G}^T (\boldsymbol{\beta}^z)$  最大

所对应的  $\mathbf{Z}$ , 采用循环迭代的方法求解使上述方程达到最大的“具有代表性”的最优训练样本集  $\mathbf{Z}^*$ . 得到最优训练样本集后, 在该集合上执行主成分分析算法, 即为稀疏主成分分析 (SKPCA), 算法自适应地选择从训练样本集但对识别性能影响较小, 从而节省了计算时间和核矩阵计算的存储空间和计算时间的消耗. 因此, 在实际应用中, SKPCA 可以解决 KPCA 的在计算时间和存储空间限制, 在有效降低存储空间和时间消耗的前提下对 SKPCA 的特征提取能力影响有限. 从理论角度来看, SKPCA 是适应性与其严格要求而识别率不严格的应用场合.

### 3 仿真实验

利用仿真实验来验证和分析算法的性能, 重点分析 SKPCA 算法可行性. 仿真实验中, 首先利用机器学习领域国际上公开广泛应用的 UCI 数据集、ORL、YALE 数据库、威斯康星乳腺癌数据库上进行算法的性能测试.

第 1 组实验在 UCI 数据集上进行, 对于 KPCA 算法使用全部训练样本, 对于 SKPCA 使用训练样本最有代表性的样本, 这些样本是通过算法自适应选择得到. 实验中选择高斯核函数. 实验结果见表 1、表 2. 第 1 列为

6 个训练样本集的名称, 第 2 列为算法在相应数据集上的错误率, 第 3 列为该算法所使用的训练样本数量. 表 2 第 3 列数据括号内为与传统 KPCA 所采用的训练样本总数的百分比. 需要强调的是, 两种方法 SKPCA 和 KPCA 所采用的测试样本集的完全相同. 结果表明, 该算法实现了类似的识别性能, 但该算法只使用较少的训练集的大小. 例如, 只有采用全部样本 8% 的训练样本使用但错误率只有比普通方法高 2.8%. 算法只用少量的训练样本, 可节省存储空间并提升核主成分分析的计算效率. SKPCA 节省计算内核矩阵的时间并有效节省训练样本矩阵存储空间, 但获得与 KPCA 相近的识别准确率.

表 1 UCI 数据集上的 KPCA 识别性能

数据集	错误率 (%)	训练样本
Banana	13.6	400
Image	4.8	1300
F. Solar	31.4	666
Splice	8.6	1000
Thyroid	2.1	140
Titanic	22.8	150

表 2 UCI 数据集上的 SKPCA 的识别性能

数据集	错误率 (%)	训练样本
Banana	14.2	120
Image	5.4	180
F. Solar	34.2	50
Splice	9.4	280
Thyroid	2.2	30
Titanic	23.2	30

第 2 组实验在 ORL 和 YALE 数据库上评估算法性能. 由英国剑桥大学 Olivetti 研究实验室开发的 ORL 脸数据库, 由 40 个人 400 幅灰度图像组成, 每个人 10 幅图像. 这些图像都反映着姿态、人脸表情的变化. 而来自耶鲁大学计算视觉与控制中心的 YALE 人脸数据库来自 15 个人 165 幅灰度图像, 这些图像也反映着光照、表情变化. 为了降低计算复杂度, 将原来图像  $112 \times 92$  重新剪裁为  $48 \times 48$ . 同样地, 将 YALE 数据库的图像剪裁为  $100 \times 100$  的图像. 算法性能如表 3 和表 4 所示, 三种算法在同样的实验条件下进行比较, SKPCA 和 KPCA 比较可以看出, 在 ORL 数据库上 SKPCA 仅用样本总数 60% 的样本获得相差 3% 的识别率, 而在 Yale 数据库上, 也可以得到类似的结果. 也就是说, 算法在牺牲 3% 左右的识别率的情况下, 可以节省 40% 的存储空间和

计算时间.

表 3 ORL 人脸数据库上性能比较

算法	错误率(%)	训练样本
最近邻分类器	19.2	75
Combined Fisherface	19.5	75
KPCA	15.3	200
SKPCA	18.4	120 (60%)

表 4 Yale 人脸数据库上性能比较

算法	错误率(%)	训练样本
最近邻分类器	20.6	75
Combined Fisherface	21.6	75
KPCA	17.8	75
SKPCA	20.4	45 (60%)

表 5 KPCA 和 SKPCA 性能比较

算法	错误率(%)	训练样本
KPCA	3.8 ± 0.4	300
SKPCA	5.4 ± 0.3	110 (37%)

通过以上 3 组仿真实验,可以得到如下结论:KPCA 具有一定的识别性能,但在训练过程时间消耗在实际模式识别领域应用中的优势.对于高维数据的 ORL 和 Yale 数据库识别中,计算效率是一个关键问题,KPCA 的特征值问题需要大量训练样本与所有训练样本全部计算核矩阵.因此,从大量的训练样本中找到最有意义的少量训练本来解决 SKPCA 的存储空间和时间消耗是可行的.

在实际应用中,计算效率是我们需要考虑的问题,尤其是在求解具有代表样本的过程中所耗的计算时间,一般来说,我们在实际应用中事先训练一个良好的特征提取器,而这个过程一般采用离线的方式进行.然后把具体的参数事先存在系统中,在线处理过程中,直接调用相关的样本,所以在实际应用系统中,实际上提升了系统的计算效率,并只存储有代表性的样本,节省了大量的存储空间,可以用于计算资源和存储资源受限的应用环境,这是本文提出的算法的优势所在.存在的问题在于,如何提高离线的训练效率,是未来工作需要解决的问题.

## 4 结论

核学习方法在图像分类、面部识别以及医学图像分类领域有重要应用,核主成分分析(KPCA)算法是核学习中重要算法之一.随着学习系统小型化的发展,在计算和存储资源受限的硬件平台上,提高实现 KPCA 算法性能具有重要意义.KPCA 在实际应用中需要用所有

样本计算核矩阵,并占用存储空间存储所有训练样本.在数据量大的情况下需要耗费大量计算时间和存储空间.本文提出了一种计算和存储空间受限下的稀疏核主成分分析算法,并在利用机器学习领域国际上公开广泛应用的 UCI 数据集、ORL、YALE 数据库、威斯康星乳腺癌数据库上进行算法的性能测试.在实际的人脸图像数据库上获得良好的算法性能,例如 ORL 数据库上仅用 60% 的样本获得相差 3% 的识别率,Yale 数据库上也可以得到类似的结果.也就是,在实际应用中,可以通过放弃的 3% 识别精度而获得 40% 的存储空间和计算时间.因此,提出的算法适合于计算和存储空间受限下的应用场合,尤其是资源受限的硬件计算平台上实现图像分类,面部识别,语音识别等领域.本文研究主要集中在算法理论研究,未来研究可围绕算法的硬件计算展开,从而提高机器学习算法的实际系统适应能力.

## 参考文献

- [1] LI J B, CHU S C, PAN J S. Kernel Learning Algorithms for Face Recognition [M]. USA: Springer, 2013.
- [2] 李君宝, 乔家庆, 尹洪涛, 刘大同. 模式识别中的核自适应方法及应用[M]. 北京: 电子工业出版社, 2013.
- [3] LI J B, WANG Y H, CHU S C, RODDICK J F. Kernel self-optimization learning for kernel-based feature extraction and recognition [J]. Information Sciences, 2014, 257(2): 70 - 80.
- [4] 亓晓振, 王庆. 一种基于稀疏编码的多核学习图像分类方法[J]. 电子学报, 2012, 40(4): 773 - 779.  
Qi Xiao-zhen, Wang Qing. An image classification approach based on sparse coding and multiple kernel learning [J]. Acta Electronica Sinica, 2012, 40(4): 773 - 779. (in Chinese)
- [5] 郭立君, 赵杰煜, 史忠植. 生成模型与判别方法相融合的图像分类方法[J]. 电子学报, 2010, 38(5): 1141 - 1145.  
Guo Li-jun, Zhao Jie-yu, Shi Zhong. Image categorization of integrated generative models and discriminative methods [J]. Acta Electronica Sinica, 2010, 38(5): 1141 - 1145. (in Chinese)
- [6] 罗会兰, 郭敏杰, 孔繁胜. 一种基于多级空间视觉词典集体的图像分类方法[J]. 电子学报, 2015, 43(4): 684 - 693.  
Luo Hui-lan, Guo Min-jie, Kong Fan-sheng. An image classification method based on multiple level spatial visual dictionary ensemble [J]. Acta Electronica Sinica, 2015, 43(4): 684 - 693. (in Chinese)
- [7] KRINIDIS S, PITAS I. Statistical analysis of human facial expressions [J]. Journal of Information Hiding and Multimedia Signal Processing, 2010, 1(3): 241 - 260.

- [8] SAYOUD H, OUAMOUR S. Speaker clustering of stereo audio documents based on sequential gathering process [J]. *Journal of Information Hiding and Multimedia Signal Processing*, 2010, 1(4): 344 – 360.
- [9] LIN H D, CHIU Y S. RBF network and EPC method applied to automated process regulations for passive components dicing [J]. *International Journal of Innovative Computing, Information and Control*, 2010, 6 (12): 5077 – 5091.
- [10] TANG H, WU J, LIN Z, LU M. An enhanced adaboost algorithm with naive Bayesian text categorization based on a novel re-weighting strategy [J]. *International Journal of Innovative Computing, Information and Control*, 2010, 6 (11): 5299 – 5310.
- [11] YANG J, YANG J Y. Combined fisherfaces framework [J]. *Image and Vision Computing*, 2003, 21(12): 1037 – 1044.
- [12] LIU C. Gabor-based kernel PCA with fractional power polynomial models for face recognition [J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2004, 26 (5): 572 – 581.
- [13] LI J B, PENG Y, LIU D T. Quasiconformal kernel common locality discriminant analysis with application to breast cancer diagnosis [J]. *Information Sciences*, 2013, 223: 256 – 269.
- [14] 湛德荣, 孙波, 陶鹏, 官久路. 基于核光谱角余弦的高光谱图像空间邻域聚类方法 [J]. *电子学报*, 2008, 36 (10): 1992 – 1995.
- Chen De-rong, Sun Bo, Tao Peng, Gong Jiu-lu. Spatial neighboring clustering method for hyperspectral imagery based on kernel spectral angel cosine [J]. *Acta Electronica Sinica*, 2008, 36(10): 1992 – 1995. (in Chinese)

## 作者简介



谢晓丹 女, 1976 年出生, 高级工程师, 博士生, 主要从事图像处理、高光谱信息处理、智能数据分析等领域的研究工作。

E-mail: xiexiaodanbeijing@126.com



李伯虎 男, 1938 年出生于上海市, 中国工程院院士, 博导, 研究方向为分布仿真、虚拟样机、并行工程、网络化设计, 制造系统。



柴旭东 男, 1969 年出生, 男, 山西人, 博士, 研究员, 博士后, 研究方向为分布交互仿真技术, 虚拟样机技术, 复杂系统高层建模与协同仿真技术。