

基于多层反卷积网络的 SAR 图像分类

王云艳^{1,2} 何 楚^{1,3} 赵守能³ 陈 东⁴ 廖明生¹

1 武汉大学测绘遥感信息工程国家重点实验室,湖北 武汉,430079
2 湖北工业大学电气与电子工程学院,湖北 武汉,430068
3 武汉大学电子信息学院,湖北 武汉,430072
4 国防科技大学 ATR 重点实验室,湖南 长沙,410073

摘 要:针对传统特征提取方法不能提取目标高层结构特征的问题,提出了一种基于软概率的池化方法,结合多层反卷积网络,学习目标的高层结构特征,并将其用于合成孔径雷达(SAR)图像分类。首先对 SAR 图像进行子块划分,然后对每个子块进行基于多层反卷积网络的特征编码,学习出不同层次上的图像特征,最后将该特征用于支持向量机(SVM)分类器,实现 SAR 图像的分类。在国内首批 SAR 数据上的实验表明,该算法获得了较高的分类准确率。

关键词:合成孔径雷达;多层学习;反卷积网络;图像分类;软概率池化

中图法分类号:P237.3 **文献标志码:**A

合成孔径雷达(synthetic aperture radar, SAR)是一种主动式微波传感器,在目标识别、地物分类、水体监测等领域具有很大的应用潜力。随着 SAR 遥感系统的不断发展,研究如何有效地实现 SAR 图像的分类和识别具有重要意义^[1]。

提取图像特征进行分类与识别是 SAR 图像解译的重要方法。最基本的特征有灰度特征、栅格特征、纹理特征、形状特征、模板特征等,如吴晓红等提出了采用模板特征进行 SAR 图像目标识别^[2]。由于这些基本特征没有包含位置关系、场景等,使得其不能保留空间信息,因而出现了很多新的特征提取方法,如 Gabor、小波变换法等。万朋等^[3]结合小波变换和自适应维纳滤波提出了一种新的 SAR 图像目标综合检测方法;考虑到整个图像的信息较为复杂且难以处理,针对局部信息的特征提取方法,如子块划分等相继被提出,殷慧^[4]利用一种基于局部特征表达和最近邻分类器对高分辨率 SAR 图像的城区场景二级地物进行了分类;为了去除冗余特征和不相关特征,提高分类算法的执行效率,随后又出现了很多特征降维方法,包括特征选择^[5]、主成分分析^[6]、压缩感知^[7]等,如宦若虹等^[6]利用小波域主成分分析和

支持向量机(support vector machine, SVM)实现 SAR 图像特征的提取与目标识别。然而这些算法都只适用于获取图像的低层结构特征(如边缘梯度等),无法获取中层和高层的结构信息(如转角、节点等)。针对该问题, Hinton 等^[8]于 2006 年提出深度学习的概念,为解决与深层结构相关的优化难题带来了可能。深度学习能通过组合低层特征,形成更加抽象的高层表示,以发现数据的分布式特征。近年来,已经出现了很多经典的深度学习模型,如 DBN(deep belief net)^[9]、AutoEncoder^[10]、稀疏编码^[11]等。深度学习模型已被成功应用于语音识别^[9]、图像处理^[11]等领域。

本文引入深度学习的理论来解决 SAR 图像高层特征的提取问题,通过建立一个多层的反卷积网络(deconvolutional network, DN)^[12],实现高层结构特征的提取。本文的主要贡献在于池化(pooling)操作时引入了一个软概率的池化开关变量 s ,用于存放池化操作中特征值的位置。

1 多层反卷积网络

两层的反卷积网络如图 1 所示,每层反卷积

网络经过反卷积和池化运算进入下一层网络,多层反卷积网络就是单层反卷积网络的叠加。

反卷积网络模型的关键在于它是基于原始输入图像的重建。该模型采用分层的方式,每层由反卷积稀疏编码和池化组成,二者交替进行。在一个超完备集的稀疏限制下,模型每一层的重建都与原始输入图像的误差最小。第 l 层的代价函数 $C_l(y)$ 由两部分组成,第一项是重构项与原图像的误差项,第二项是具有稀疏 1 范数的关于特

征图 z 的正则项。如式(1)所示:

$$\min_{f,z} C_l(y) = \lambda_l \| \hat{y}_l - y \|_2^2 + \sum_{k=1}^{K_l} |z_{k,l}|_1 \quad (1)$$

式中, λ_l 作为权重可以权衡误差项和正则项的比重。从 $C_l(y)$ 可以看出,本文模型是最小化当前层重建 \hat{y}_l 与原始图像的误差,而不是与前一层的输出 \hat{y}_{l-1} 之间的误差。这样随着网络层数的增加,得到的特征图与原始输入图像的联系不会随之疏远,系统更加符合实际。




图 1 两层反卷积网络框图
Fig. 1 Framework of Two-layer Deconvolution Network

2 重建与学习过程及池化方法

2.1 多层反卷积网络的重建与学习过程

对于层数为 l 层的反卷积网络,定义重建算子为 R_l ,因此根据图 1 有:

$$\hat{y}_l = F_1 U_{s_1} F_2 U_{s_2} \cdots F_l z_l = R_l z_l \quad (2)$$

式中, F 为卷积运算; U_s 为反池化运算; z_l 为第 l 层的特征图。同样,也可以将原始输入传播到第 l 层,这样就可以学习到第 l 层的特征图 z_l :

$$z_l = F_l^T P_{s_{l-1}} F_{l-1}^T P_{s_{l-2}} \cdots P_{s_1} F_1^T y = R_l^T y \quad (3)$$

式中, F^T 为反卷积运算; P_s 为池化运算。

2.2 基于软概率的池化方法

传统的反卷积网络多采用硬概率池化方法,即在池化时只记录特征值,这样重建图像的反池化(unpooling)操作中就只能简单地把特征值放在中间位置。这种池化过于简单,重建的图像将会存在模糊和抖动。

本文提出的软概率池化(soft probability pooling, SPP)方法能同时记录特征值和池化特征值的位置,也就是在每层的反卷积结束后,引入一个软概率池化位置变量 s ,用于存放池化操作中特征值的位置,同样的, p 用于存放 SPP 池化后的特征值。反池化时,使特征值位于软概率计算出的位置,这样多层反卷积网络的重建图像与原图像最接近,避免了模糊或抖动的影响,鲁棒性更高。

具体二维的池化过程的示意图如图 2 所示,同样可延伸至三维甚至多维。假设需要池化的特征

图为 z ,则基于 SPP 的池化模型为: $[p, s] = P(z)$, 首先记录下池化区内排在前面的 n 个特征值(z_1, z_2, \dots, z_n)及其相应的位置(s_1, s_2, \dots, s_n),SPP 池化后的特征值 p 为这 n 个特征值的平均绝对值,即

$$p = \frac{|z_1| + |z_2| + \cdots + |z_n|}{n} \quad (4)$$

同样的, SPP 池化后的位置变量 s 也由这 n 个特征值的位置决定,特征值为相应的权值,即

$$s = \text{Round} \left(\frac{s_1 \cdot |z_1| + s_2 \cdot |z_2| + \cdots + s_n \cdot |z_n|}{s_1 + s_2 + \cdots + s_n}, 0 \right) \quad (5)$$

相应的,反池化模型为: $z = U(p, s)$,方法是把特征值 p 放在由 s 决定的相应的位置中,特征图中的其余位置均被设置为 0,如图 2 所示。




图 2 二维空间的 SPP 池化与反池化示意图
Fig. 2 Diagram of SPP Pooling and Unpooling in Two-dimensional Space

3 基于 SPP 池化的多层反卷积网络的 SAR 图像分类算法

本文提出了一种基于 SPP 池化的多层反卷

积网络(soft probability pooling deep deconvolutional network, SPP-DCN)的 SAR 特征提取算法,其原理框架图如图 3 所示。首先准备一个单极化 SAR 数据,取不同图像作为训练和测试图像,并做一定的预处理;然后,用该数据中的每类作物的数据训练出该类的滤波器参数模型;其次,将测试数据分别输入每个类别的滤波器网络,利用学习的特征和滤波器参数得到重建图像,通过重建图像与输入图像的误差优化,不断更新学习的特征,直到得到最优特征;再次,通过每个类别的滤波器网络都将得到一个特征,将所有特征串联起来得到最终的特征矢量;最后,将特征矢量导入分类器 SVM,并对分类结果进行估计和评测。

该模型中重要的两个变量是特征图 z 和滤波器 f ,在训练滤波器模型中,需要得到不同类别的滤波器网络,在计算过程中也必须涉及到图像特征图。训练算法可分为两步:提取特征图和更新

滤波器。具体算法如下:

参数说明:训练集 X ,层数 L ,循环计算次数 E ,正则化参数 λ_l

```
for  $l=1:L$  %%循环层数
    初始化特征  $z$  和滤波器  $f$ ;
    for epoch= $1:E$  %%多次训练直至得到图像的最优特征和滤波器
        for  $i=1:N$  %%某类图片特征图推断
            for  $t=1:T$  %% 单张图片上的特征图推断
                重建输入并根据式(1)计算与原输入的误差;
                ISTA:梯度计算
                ISTA:收敛计算
                ISTA:根据式(4)和式(5)池化/反池化
            end for
        end for
        更新滤波器;
    end for
end for
输出:滤波器  $f$ ,特征图  $z$ ,开关变量  $s$ 
```

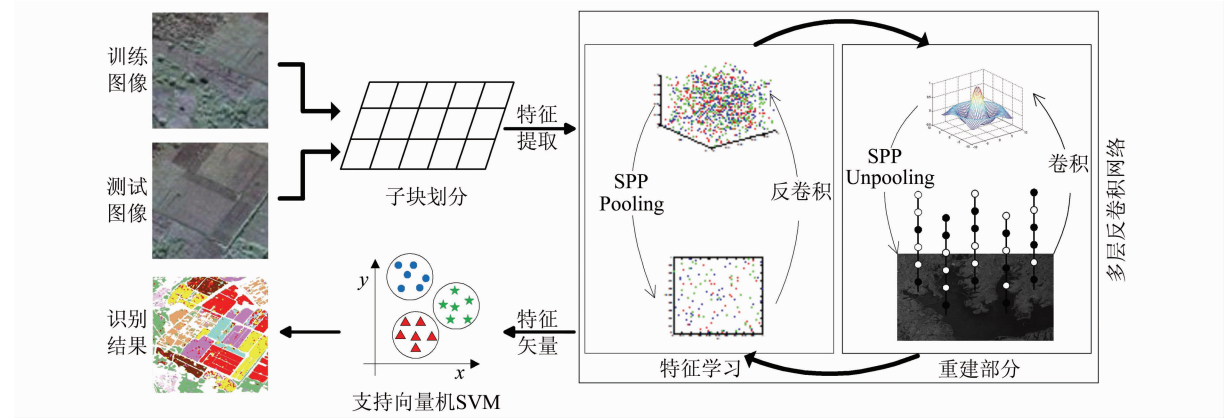


图 3 基于 SPP-DCN 的 SAR 图像分类算法框架图

Fig. 3 Framework of SAR Image Classification Algorithm Based on SPP-DCN

4 实验分析

4.1 实验数据

实验数据采用中国电子集团第 38 研究所获取的海南省陵水县的 1 个机载 X 波段单航迹极化 SAR 数据,图像大小为 2 200 像素 \times 2 400 像素,分辨率为 1 m \times 1 m,该图被分为芒果 1、芒果 2、芒果 3、槟榔果、龙眼、树林、建筑物、农田 1、农田 2、农田 3,共 10 类。图像的地面实况是实地考察后使用 ArcGIS 软件进行人工标注。原始图像和地面实况图像如图 4(a)和图 4(b)所示。

4.2 实验参数设置

实验中使用 4 层的反卷积网络模型,其中每层滤波器尺寸为 7 \times 7,在训练滤波器时,将根据层数分别进行多次迭代优化,最后选取第四层特

征用于分类。具体参数见表 1。

表 1 实验参数设置

Tab. 1 Parameter Settings of Experiment

参数名	参数值
Layers	4
Patch_size	32/16/8
Move_size	32/16/8
Filter_size	7 \times 7
Num_feature_maps	[15,50,100,150,250]
Epochs	[4,6,6,10]
Area	256/1 024
Num_train_img	50

为了验证该算法的有效性,本文在这个 SAR 数据上进行了三组对比实验。

对比实验 1 基于复 Wishart 分布的 SAR 图像分类。作为经典的 SAR 图像分类方法,该方法利用最大似然估计对地物进行分类。最大似然

分类器认为每类地物都能够服从某个特定参数的 Wishart 分布,通过寻找 Wishart 距离最小的点,进而实现图像分类。

对比实验 2 基于纹理特征(Texture)+SVM 的 SAR 图像分类。提取的纹理特征是灰度共生矩阵(gray level co-occurrence matrix, GLCM)特征。

对比实验 3 基于 Decomposition + SPM (spatial pyramid model)的 SAR 图像分类。首先对极化 SAR 数据进行极化分解,得到 31 维极化特征^[13],然后在特征空间建立 3 层金字塔表达,用于 SVM 分类。

4.3 实验结果

本文利用 SPP-DCN 算法及三个对比实验在实验数据上进行了分类实验,各类地物的分类准确率如表 2、图 4 和图 5 所示。可以看出,Wishart 的分类准确率最低,而 Texture + SVM 方法和 Decomposition + SPM 方法的准确率比较接近, SPP-DCN 算法的分类准确率最高。从图 5 可以看出,SPP-DCN 算法在芒果 1、芒果 2 等地物上取得了较高的分类准确率,且平均加权分类准确率最高。

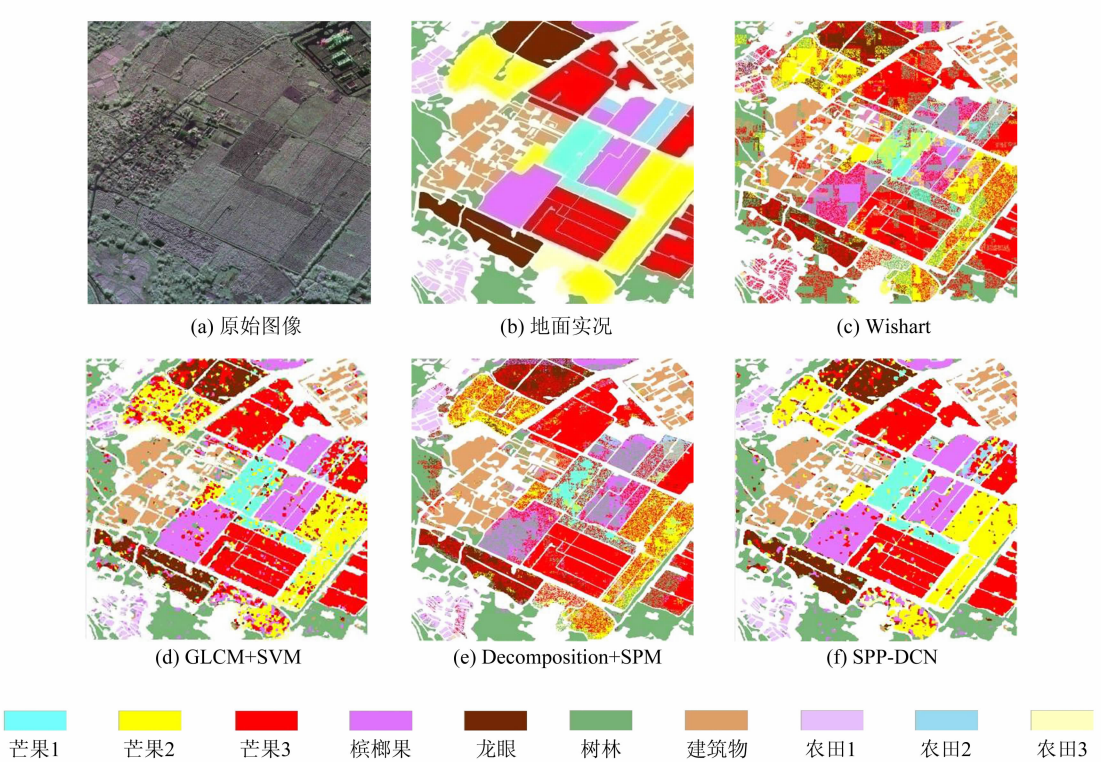


图 4 实验分类结果
Fig. 4 Classification Results of Experiment

表 2 分类准确率/%
Tab. 2 Classification Accuracy Rate/%

类别	Wishart	GLCM+ SVM	Decomposition+ SPM	SPP- DCN
芒果 1	54.58	78.39	61.33	79.27
芒果 2	62.50	64.56	55.83	80.76
芒果 3	76.83	82.13	86.64	86.58
槟榔果	54.16	80.01	58.00	84.59
龙眼	57.24	65.34	59.00	73.91
树林	71.35	82.39	88.47	86.96
建筑物	75.04	71.27	84.60	77.98
农田 1	47.49	58.35	81.47	67.16
农田 2	50.11	23.14	51.29	30.59
农田 3	49.30	15.98	49.27	30.07
平均	65.20	71.56	72.37	79.54

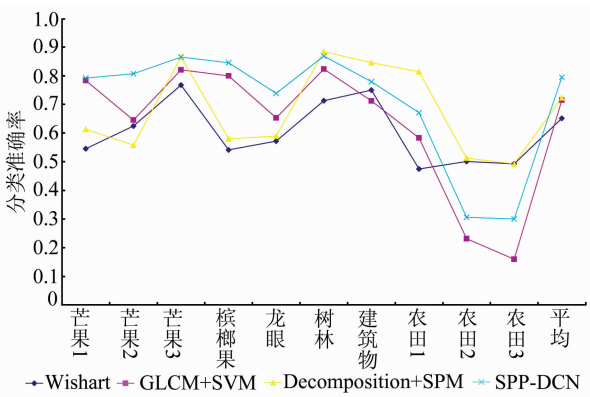


图 5 分类结果比较图
Fig. 5 Comparison of Experimental Results

5 结 语

本文提出的 SPP-DCN 算法在多层反卷积网络中引入了软概率池化位置变量,用于存放池化操作中特征值的位置,使得多层反卷积网络在重建图像过程中不会存在模糊和抖动,鲁棒性较高。该算法能提取 SAR 图像的高层次特征,将该特征用于国内首批 SAR 图像的分类,实验结果验证了该算法的有效性。

参 考 文 献

[1] Maitre H. Synthetic Aperture Radar Image Processing [M]. Sun Hong. Beijing: Publishing House of Electronics Industry, 2005 (Maitre H. 合成孔径雷达图像处理[M]. 孙洪. 北京: 电子工业出版社, 2005)

[2] Wu Xiaohong, Xie Ming, Gan Ke, et al. Feature Extraction and Target Recognition of SAR Images[J]. *Journal of Sichuan University (Natural Science Edition)*, 2007, 44(6): 1 275-1 280(吴晓红, 谢明, 干可, 等. SAR 图像的特征提取与目标识别[J]. 四川大学学报(自然科学版), 2007, 44(6): 1 275-1 280)

[3] Wan Peng, Wang Jianguo, Huang Shunji. A Synthesis Method for SAR Image Target Detection[J]. *Acta Electronica Sinica*, 2001, 29(3): 323-325(万朋, 王建国, 黄顺吉. SAR 图像目标综合检测方法[J]. 电子学报, 2001, 29(3): 323-325)

[4] Yin Hui. Research on Urban Scene Classification Method Using High Resolution Synthetic Aperture Radar Image Based on Local Feature Representation (殷慧. 基于局部特征表达的高分辨率 SAR 图像城区场景分类方法研究[D]. 武汉: 武汉大学, 2010)

[5] He Chu, Liu Ming, Xu Lianyu, et al. A Hierarchical Classification Method Based on Feature Selection and Adaptive Decision Tree for SAR Image[J]. *Geomatics and Information Science of Wuhan Univer-*

sity, 2012, 37(1): 46-49 (何楚, 刘明, 许连玉, 等. 利用特征选择自适应决策树的层次 SAR 图像分类[J]. 武汉大学学报·信息科学版, 2012, 37(1): 46-49)

[6] Huan Ruohong, Zhang Ping, Pan Yun. SAR Target Recognition Using PCA, ICA and Gabor Wavelet Decision Fusion[J]. *Journal of Remote Sensing*, 2012, 16(2): 262-274(宦若虹, 张平, 潘赞. ICA、PCA 和 Gabor 小波决策融合的 SAR 目标识别[J]. 遥感学报, 2012, 16(2): 262-274)

[7] He Chu, Liu Ming, Feng Qian, et al. PolInSAR Image Classification Based on Compressed Sensing and Multi-scale Pyramid[J]. *Acta Automatic Sinica*, 2011, 37(7): 820-827(何楚, 刘明, 冯倩, 等. 基于多尺度压缩感知金字塔的极化干涉 SAR 图像分类[J]. 自动化学报, 2011, 37(7): 820-827)

[8] Hinton G E, Salakhutdinov R. Reducing the Dimensionality of Data with Neural Networks [J]. *Science*, 2006, 313(5 786): 504-507

[9] Zhang Xiaolei, Wu Ji. Deep Belief Networks Based Voice Activity Detection[J]. *IEEE Transactions on Audio, Speech and Language Processing*, 2013, 21(4): 697-710

[10] Vincent P, Larochelle H, Lajoie I, et al. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion[J]. *Journal of Machine Learning Research*, 2010, 11: 3 371-3 408

[11] Yang J C, Yu K, Gong Y H, et al. Linear Spatial Pyramid Matching Using Sparse Coding for Image Classification[C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Miami, USA, 2009

[12] Zeiler M D, Taylor G W, Fergus R. Adaptive Deconvolutional Networks for Mid and High Level Feature Learning[C]. *IEEE International Conference on Computer Vision (ICCV)*, Barcelona, Spain, 2011

Classification of SAR Images Based on Deep Deconvolutional Network

WANG Yunyan^{1,2} HE Chu^{1,3} ZHAO Shouneng³ CHEN Dong⁴ LIAO Mingsheng¹

1 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China

2 School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China

3 Electronic and Information School, Wuhan University, Wuhan 430072, China

4 ATR Key Laboratory, National University of Defense Technology, Changsha 410073, China

Abstract: Aim at the problem that the traditional feature extraction methods cannot get the high level

structure features, this paper put forward a new soft probability pooling method, which is used in multilayer Deconvolutional Network, then high level structure features can be learned and be used for classification of SAR image. Firstly, the SAR image was divided into patches; then, the feature coding of each patch was obtained by means of multilayer Deconvolutional Networks, which can learn features suitable for image classification in different scale ; finally, the SAR image was classified through the features used in SVM classifier. Experimental results on the first batch domestic PolSAR images show that the classification accuracy rate of the proposed algorithm is superior.

Key words: synthetic aperture radar; multilayer learning; deconvolutional network; image classification; soft probability pooling

First author: WANG Yunyan, PhD, specializes in SAR imagery interpretation. E-mail: helen9224@126.com
Corresponding author: HE Chu, PhD, associate professor. E-mail: chuhe@whu.edu.cn
Foundation support: The National Key Basic Research and Development Program(973 Program) of China, No. 2013CB733404; the National Natural Science Foundation of China, Nos. 41371342, 61331016; the Natural Science Foundation of Hubei Province.

.....
(上接第 1370 页)

Accurate Determination of the Calibration Factor of iGrav-007 Superconducting Gravimeter

JIA Jiangang¹ LUAN Wei¹ SHEN Wenbin^{1,2}

1 School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China

2 Key Laboratory of Geospace Environment and Geodesy, Ministry of Education, Wuhan University, Wuhan 430079, China

Abstract: The iGrav superconducting gravimeter is the newest relative gravity meter with the highest accuracy and most portable measurements in the world. It provides the most stable relative gravity measurement. The calibration factor for the iGrav-007 superconducting gravimeter was accurately determined using site observations obtained with the FG5-112 absolute gravimeter and the iGrav-007 superconducting gravimeter at Wuhan Jiufeng station, based on Least Square method. The data processing results show that the calibration factor was $(-91.640\ 2 \pm 0.085\ 2) \times 10^{-8}\ \text{m} \cdot \text{s}^{-2} \cdot \text{V}^{-1}$ with a relative calibration accuracy of 0.092 9%, the accuracy of the calibration factor obtained by the absolute gravimeter for one day was better than 0.2%, the accuracy of the calibration factor obtained by absolute gravimeter for three days was better than 0.1%.

Key words: iGrav-007; FG5-112; superconducting gravimeter; calibration factor; accuracy analysis

First author: JIA Jiangang, PhD candidate, specializes in determination of earth gravity field. E-mail: jgjia@sgg.whu.edu.cn
Foundation support: The National 973 Program of China, No. 2013CB733305; the National Natural Science Foundation of China, No. 41210006.