

引用格式:贾立丽,张升伟,何杰颖,等. 基于多任务联合稀疏表示的高光谱图像分类算法[J]. 微电子学与计算机, 2019, 36(10):15-20. [JIA L L, ZHANG S W, HE J Y, et al. Joint sparse representation and multitask learning for hyperspectral image classification[J]. Microeletronics & Computer, 2019, 36(10):15-20.]

基于多任务联合稀疏表示的高光谱图像分类算法

贾立丽^{1,2,3}, 张升伟^{1,2}, 何杰颖^{1,2}, 李 娜^{1,2,3}

(1 中国科学院 国家空间科学中心 微波遥感技术重点实验室, 北京 100190;
2 中国科学院 国家空间科学中心, 北京 100190; 3. 中国科学院大学, 北京 100149)

摘 要: 为了充分提取高光谱图像丰富的光谱信息, 尽可能降低光谱冗余, 同时保留较多有效判别信息. 基于高光谱图像单波段的谱间相似性, 提出了基于多任务学习和稀疏表示的分类算法. 该方法将光谱间的冗余特性转化为有效信息加以利用, 使用波段交叉分组策略构建子任务, 并引入稀疏表示模型将所有分类任务进行联合表示, 最终根据所有任务的累积残差确定测试样本的类别. 实验对比分析了多任务联合表示分类和单任务分类的准确率. 结果表明, 基于多任务联合稀疏表示模型的分类性能优于单任务模型.

关键词: 多任务学习; 稀疏表示; 高光谱图像; 图像分类

中图分类号: TP751.1

文献标识码: A

文章编号: 1000—7180(2019)10—0015—06

Joint sparse representation and multitask learning for hyperspectral Image clasifcation

JIA Li-li^{1,2,3}, ZHANG Sheng-wei^{1,2}, HE Jie-ying^{1,2}, LI Na^{1,2,3}

(1 Key Laboratory of Microwave Remote Sensing Technology, Chinese Academy of Science, Beijing 100190, China;
2 National Space Science Center, Chinese Academy of Sciences, Beijing 100190, China;
3 University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Hyperspectral images have abundant spectral information, and thus the adjacent single-band images usually contain similar and redundant information. To simultaneously reducing spectral redundancy and retaining more effective discriminant information, a novel classification algorithm based on multitask learning and sparse representation is proposed in this paper. In this method, the spectral redundancy is transformed into effective information and a band cross-grouping strategy is used to construct sub-tasks. Sparse representation model is introduced to jointly represent all classification tasks. Finally, the test samples are classified according to the cumulative residual of all tasks. An experiment is performed between multitask learning and the single task learning. The experimental results show that the classification performance of the former is better than the later.

Key words: multitask learning; sparse representation; hyperspectral images; image classification

1 引言

高光谱图像(Hyperspectral Images, HSIs)包含丰富的光谱信息,能够以较高的光谱信息对地物

目标进行精细化解析,增强对地物信息的提取能力^[1]. 目前高光谱图像已广泛应用于军事、农业、矿物探测等领域^[2-3]. 提高高光谱图像的分类性能,也成为研究的热点.

但是高光谱图像的谱分辨率非常高,相邻的单个频带图像之间呈现出很大的光谱相似性或冗余性.在这种情况下,相邻的单波段图像固地包含冗余和判别信息.目前的算法在处理光谱信息与数据冗余冲突的问题上,主要采用两种策略.第一种策略是均匀地利用光谱信息,忽略光谱的冗余性,如支持向量机(Support Vector Machines, SVM)、稀疏表示模型(Sparse Representation, SR)、协同表示模型(Collaborative Representation, CR).第二种策略则选择利用降维技术,实现光谱信息与频谱冗余之间的折中.通过降维操作可减少光谱的冗余,但同时可能会损失光谱的有效判别信息.如主成分分析(Principal Component Analysis, PCA)等.

而多任务学习(Multi Task Learning, MTL)的技术发展,为减少频谱冗余和保留有效光谱信息这两者的平衡提供了一个可行的思路.在遥感图像中,Chen等^[4]针对高分辨率遥感图像分类,结合低秩和稀疏结构,提出了一种鲁棒的多任务学习模型.Zhang等^[5]在高光谱图像检测领域,提出了多任务联合稀疏算法,使用交叉分组策略建立子任务,验证了多任务学习性能优于单任务性能.

本文基于多任务联合稀疏表示模型,在高光谱图像谱间相似性的基础上,结合多任务方法的一致性和高光谱数据的特性,通过约束 $l_{2,1}$ 范数构建模型,使得多个子任务可共享稀疏表示,充分利用了高维原始高光谱图像的复杂光谱信息,保留了判别信息,有效避免每个分类任务中的冗余.多任务联合稀疏表示模型为高光谱图像分类提供了一种充分挖掘光谱信息的方法.

2 稀疏表示分类算法

稀疏模型假设属于同一地物类别的像元位于同一低维子空间.假设有 m 类训练样本,记 $D^i(i=1, 2, \dots, m)$ 为第 i 类训练样本,则所有训练样本构成的字典矩阵可表示为 $\mathbf{D} = [D^{(1)}, \dots, D^{(m)}]$.像元 x 可由这 m 个子字典的线性组合来表示:

$$x = D_1 w_1 + \dots + D_m w_m = \mathbf{D}w \quad (1)$$

式中, $x \in R^B$, $\mathbf{D} \in R^{B \times n}$, $w \in R^n$, n 为字典的训练样本总个数, B 为像元波段数. w 是一个由 m 个 n_i 维的子权重向量串联而成的 n 维的稀疏向量^[6],只有少量的非零元素.

稀疏算法通过重建公式(2)所示的优化问题,如正交匹配追踪法^[7](Orthogonal Matching Pursuit, OMP),获得字典 $\mathbf{D}$ 对应的权值向量 w .

$$\hat{w} = \arg \min \|Dw - x\|_2 \quad (2)$$

$$s. t. \|w\|_1 \leq \tau$$

τ 表示向量 w 中元素绝对值之和的上界.则待分类样本 x 对应的各分类类别的重构残差 $r_l(x)$ 为:

$$r_l(x) = \|w - D_l w_l\|_2, l = 1, \dots, m \quad (3)$$

待分类样本 x 的类别标签对应于产生残差最小的类别:

$$\text{class}(x) = \arg \min_l r_l(x) \quad (4)$$

3 多任务联合稀疏分类算法

3.1 多任务分组策略

多任务学习的一个关键任务是利用高光谱图像间的相似性,构建子任务.文中分析了公开数据集中Indian Pines谱间的相似性,谱间的相似性通过计算相关系数得到,相关系数矩阵图分析结果如图1.由图1可知,对角线位置(也就是相邻波段)之间的相关系数较高.

基于这种相似性,子任务的数据集采用交叉分组策略得到.根据原始图像的频带顺序,将多个相邻的单波段图像交叉分为不同组,以Indian Pines为例,分组情况为 $[1, 4, \dots, 193, 196, 199]$ 、 $[2, 5, \dots, 194, 197, 200]$ 、 $[3, 6, \dots, 195, 198]$,对应子任务1、子任务2和子任务3的数据集波段选取值,如图2所示.观察分组情况可知,子任务的数据集包含的波段数分别为67, 67, 66.也就是说通过交叉分组策略,子任务间包含的波谱数可能是不一样的,但是这并不影响权重向量的维度,具体分析见3.2节.

通过交叉分组,每个子数据集相同位置上对应的单波段图像是相互联系的.这种高相似性,保证了多任务学习中每个子任务的相关性.




图1 Indian Pines数据集光谱相似性




图2 Indian Pines 数据集交叉分组情况

3.2 多任务联合稀疏表示模型

假设多任务中有 K 个子任务,子任务字典集中波谱的相似性保证了多任务分类的相关性,多个任务之间可以共享稀疏表示^[8-11].

对于原始分类像元 $x \in R^B$,将其分解为 K 个相对应的子向量 $\{x^k \in R^{B^k}\}_{k=1}^K$. 即对于第 k 个子任务数据集,相对应的待分类像元 $x^k \in R^{B^k}$,训练样本字典 $\{d_i^k \in R^{B^k \times N}\}_{i=1}^N$,则待分类像元 x^k 由训练样本字典的稀疏线性组合表示如下:

$$x^k = w_1^k d_1^k + \cdots + w_N^k d_N^k = D^k w^k \quad (5)$$

式中, N 是训练样本数, $D^k \in R^{B^k \times N}$ 为训练样本字典, $w^k \in R^N$ 为第 k 个子任务的权重向量. 由于权重向量的维度可见,其只与样本数目有关,而与子任务样本的波谱数目无关. 也就是说,即使交叉分组后,子任务间波谱数目不同,并不会影响权重向量的维度.

由于 K 组子数据集之间具有较高的相似度,可能共享相同的稀疏表示. 单个子任务的稀疏表示可以扩展为多任务表示. 对于一个多任务分类任务,原始的分类像元 x 可由分解后的子向量表示:

$$\begin{aligned} x^1 &= w_1^1 d_1^1 + \cdots + w_N^1 d_N^1 = D^1 w^1 \\ &\vdots \\ x^K &= w_1^K d_1^K + \cdots + w_N^K d_N^K = D^K w^K \end{aligned} \quad (6)$$

合并子任务,多任务稀疏模型表示为:

$$\hat{W} = \arg \min_{w^k} \sum_{k=1}^K \|x^k - D^k w^k\|_2^2 + \rho \|W\|_{2,1} \quad (7)$$

式中,权重向量 $W \in R^{N \times K}$,为子权重向量 $w^k \in R^N$ 的集合.

$$W = \begin{bmatrix} w_1^1 & \cdots & w_1^K \\ \vdots & \ddots & \vdots \\ w_N^1 & \cdots & w_N^K \end{bmatrix} \quad (8)$$

$\|W\|_{2,1}$ 为正则项,用于约束任务间的相关性. ρ 为正则项的正则化参数. 对于 $\|W\|_{2,1}$,先求解 W 行 $\{w_i^*\}_{i=1}^N$ 的 l_2 范数,再求解向量 $b(w) = (\|w_1^*\|_2, \cdots, \|w_N^*\|_2)^T$ 的 l_1 范数. $l_{2,1}$ 范数求解将多个子任务结合,保证了任务优化求解的关联性和多任务间的稀疏性共享,约束了矩阵 W 每一列的稀疏性.

3.3 模型的优化算法

针对模型中的非凸优化问题,利用加速近端梯度法 (Accelerated Proximal Gradient Algorithm, APG) 对公式(7)进行优化求解,算法收敛速度为 $O(1/t^2)$. APG 算法的核心是交替更新系列矩阵 $\hat{W}^t = [w_i^{k,t}]$ 及聚合矩阵 $\hat{V}^t = [v_i^{k,t}]$. 当给定当前矩阵 $\hat{V}^t$,采用广义梯度映射更新矩阵 $\hat{W}^{t+1}$:

$$\hat{w}^{k,t+1} = \hat{v}^{k,t} - \eta^t \nabla^{k,t} \quad (9)$$

$$\hat{w}_i^{t+1} = [1 - \rho \eta^t / \|\hat{w}_i^{t+1}\|_2]_+ \hat{w}_i^{t+1} \quad (10)$$

式中, $t \geq 1, k = 1, 2, \cdots, K; i = 1, 2, \cdots, N$. $[\cdot]_+ = \max(\cdot, 0)$; $\nabla^{k,t} = -(D^k)^T x^k + (D^k)^T D^k \hat{v}^{k,t}$, $\eta^t = 1/2^t$, $\hat{V}^{t+1}$ 由 $\hat{W}^{t+1}$ 和 $\hat{W}^t$ 的线性组合迭代更新:

$$\hat{V}^{t+1} = (1 + \alpha^t) \hat{W}^{t+1} - \alpha^t \hat{W}^t \quad (11)$$

式中,序列 $\alpha^t = 2(t-1)/(1+(1+4t^2)^{1/2})$. 具体的优化算法流程如算法 3.1 所示.

算法 3.1 APG 优化算法

输入:

1) 数据 $\{D^k, x^k\}_{k=1}^K$, 正则化参数 ρ

2) 初始化变量和参数:

$$\hat{w}^{k,0} = (D^k)^T x^k, \hat{v}^{k,0} = \hat{w}^{k,0}, \alpha^0 = -1, t := 0$$

迭代以下步骤:

$$1) \hat{w}^{k,t+1} = \hat{v}^{k,t} - \frac{1}{2^t} [-(D^k)^T x^k + (D^k)^T D^k \hat{v}^{k,t}]$$

$$2) \hat{w}_i^{t+1} = [1 - \rho \eta^t / \|\hat{w}_i^{t+1}\|_2]_+ \hat{w}_i^{t+1}$$

$$3) \alpha^t = 2(t-1)/(1 + \sqrt{1+4t^2})$$

$$4) \hat{v}^{t+1} = (1 + \alpha^t) \hat{w}^{t+1} - \alpha^t \hat{w}^t$$

$$5) t := t + 1$$

直到收敛

输出: 系数向量 $\{\hat{w}^k\}_{k=1}^K$

使用上述算法重建权重系数向量 $\hat{W}$, 得到每个子任务对应的子系数向量 $\{w^k\}_{k=1}^K$. 则待分类像元 x 对应的多任务重构残差, 为子分类像元 $\{x^k\}_{k=1}^K$ 与子字典 $\{D^k\}_{k=1}^K$ 和子系数向量 $\{w^k\}_{k=1}^K$ 重构 $\{\hat{x}^k\}_{k=1}^K$ 后的累积残差, 即:

$$r_l(x)=\sum_{k=1}^K\|x^k-D^k\hat{w}^k\|_2$$

(12)

待分类样本 x 的类别标签对应于残差最小的类别:

$$\text{class}(x)=\arg\min_l r_l(x)$$

(13)

4 实验分析

实验采用公开数据集中的 Indian Pines 和 Pavia University 两组数据集进行对比. 为了说明实验分类效果,进行了 5 组不同算法的对比实验,对比了包含全部波段的原始数据集、各个子任务及合并后多任务的分类效果. 其中原始数据集和各个子任务都使用稀疏表示模型进行测试. 多任务算法使用交叉分组策略,选取 $K=3$,即划分为 3 个子任务. 优化求解中正则化参数 $\rho=0.1$. 分类效果由总体分类精度 OA、平均分类精度 AA 及 Kappa 系数这三个指标评估.

4.1 Indian Pines 数据集实验

Indian Pines 数据集由机载成像光谱仪 AVIRIS 传感器在某农林采集的 Indian Pines 数据. 该数据集图像大小为 145×145 像素,波段范围为 $0.4\sim2.5\mu\text{m}$,空间分辨率 25 米. 滤除原图像中受水气影响较大,信噪比较低的 24 个波段,保留波段为 200 个. 实验使用的实际图像大小为 $145\times145\times200$,包含了 16 个地物类别.

实验中选取数据集中样本的 10%作为训练字典数,剩余的 90%作为测试样本. 三个子任务波段分别包含 67, 67, 66 个波段数,分组情况为 $[1,4,\cdots,193,196,199]$ 、 $[2,5,\cdots,194,197,200]$ 、 $[3,6,\cdots,195,198]$.

Indian Pines 实验样本数及算法对比结果如表 1 所示.

表 1 Indian Pines 数据集样本情况及分类结果对比

类别	样本数		不同任务的分类精度 /%				
	训练集	测试集	原数据集	子任务 1	子任务 2	子任务 3	多任务
Alfalfa	5	41	63.41	63.41	65.85	68.29	65.85
Corn-notill	143	1 285	67.39	67.39	67.70	67.94	67.08
Corn-mintill	83	747	62.38	62.38	62.92	63.19	65.19
Corn	24	213	57.28	57.28	58.22	58.69	58.22
Grass-pasture	49	434	78.34	78.34	79.49	79.95	76.04
Grass-trees	73	657	92.85	92.85	92.09	91.48	91.32
Grass-pasture-mowed	3	25	60.00	60.00	64.00	60.00	60.00
Hay-windrowed	48	430	99.77	99.77	99.30	99.07	99.07
Oats	2	18	55.56	55.56	55.56	55.56	50.00
Soybean-notill	97	875	70.86	70.86	70.97	72.00	70.63
Soybean-mintill	246	2 209	77.41	77.41	78.32	78.72	77.18
Soybean-clean	60	533	63.04	63.04	63.60	77.18	62.85
Wheat	21	184	93.48	93.48	94.02	95.11	92.93
Woods	127	1 138	79.96	79.96	80.40	80.14	80.05
Buildings-Grass-Trees-Drives	39	347	51.87	51.87	54.18	52.45	51.59
Stone-Steel-Towers	10	83	84.34	84.34	81.93	83.13	81.93
OA/%			74.65	74.65	75.15	75.08	74.49
AA/%			72.37	72.37	73.03	73.01	71.87
Kappa $\times100$			71.23	71.23	71.86	71.67	70.89

4.2 PaviaUniversity 数据集实验

Pavia University 数据集是由德国的机载成像光谱仪 ROSIS 传感器拍摄. 该数据集图像原始大小为 610×340 像素,空间分辨率为 1.3 米,包含 115 个波段数. 其中 12 个水吸收波段被移除后,剩下

103 个波段参与实验. 实验使用的实际图像大小为 $610\times340\times103$,包含了 9 类地物.

实验中选取数据集中样本的 1%作为训练字典数,剩余的 99%作为测试样本. 三个子任务波段分别包含 35、34、34 个波段数. 分组情况

[1,4,⋯,97,100,103]、[2,5,⋯,98,101]、[3,6,⋯,99,102].

PaviaUniversity 实验样本数及算法对比结果如表 2 所示.

表 2 Pavia University 数据集样本情况及分类结果对比

类别	样本数		不同任务的分类精度 /%				
	训练集	测试集	原数据集	子任务 1	子任务 2	子任务 3	多任务
Asphalt	66	6 565	74.46	74.64	74.79	74.76	87.74
Meadows	186	18 463	66.62	66.73	66.74	66.67	76.37
Gravel	21	2 078	69.78	70.36	70.50	70.40	84.99
Trees	31	3 033	87.37	87.70	87.77	87.90	98.52
Painted metal sheets	13	1 332	96.70	97.52	96.85	97.00	98.80
Bare Soil	50	4 979	84.35	85.12	85.08	84.96	90.38
Bitumen	13	1 317	83.52	84.36	84.51	84.74	88.53
Self-Blocking Bricks	37	3 645	82.30	82.74	82.80	82.58	92.35
Shadows	9	938	92.54	93.39	93.28	93.50	99.04
OA/%			74.96	75.28	75.30	75.26	84.75
AA/%			81.96	82.51	82.48	82.50	90.75
Kappa×100			70.09	70.12	70.16	70.19	80.17

4.3 结果分析

两组数据的仿真结果如表 1、表 2 所示,分析数据后可得:

(1)对比三个子数据集的实验结果.结果表明三者分类精度差异并不明显,三个数据集的 OA、AA、Kappa 以及各类别的精度指标 PA 都比较接近,从而验证了子数据集间的相似性.

本分析中,最大差值定义为三个数据集中最大值与最小值的差,最大差值比定义为最大差值与最小值的比值.Indian Pines 数据集,OA 最大差值为 0.66,最大差值比为 0.88%,AA 的最大差值比为 1.61%,Kappa 统计值的差值比为 1.37%.Pavia University 数据集中,OA 最大差值为 0.04,最大差值比为 0.053%,AA 最大差值比为 0.036%,Kappa 统计值的最大差值比在 0.01%.

(2)对比原始数据集与子数据集的实验结果,结果表明原始数据集和三个子数据集模型的分类效果十分相近.结果中 Indian Pines 两个子数据集的 OA 指标都优于原始数据,并且 Pavia University 三个子数据集的指标都优于原始数据.实验结果间接表明了高光谱图像的冗余特性以及较高的冗余性确实会影响分类结果.

本分析中,差值比定义为原始数据集与子数据集的差值与原始数据集的比值.Indian Pines 中原始数据集与三个子集 OA 的差值在 0.16~0.50,差值比在 0.21%~0.67%范围之内,AA 的差值比在

0.70%~1.01%范围内,Kappa 统计值的差值比在 0.48%~0.88%范围内.而 Pavia University 中原始数据集与三个子集 OA 的差值在 0.30~0.34,差值比在 0.40%~0.45%范围之内,AA 的差值比在 0.63%~0.67%范围内,Kappa 统计值的差值比在 0.042%~0.14%范围内.

(3)对比多任务与子数据集、原始数据集的实验结果.由于基于原始数据集,子数据集的单任务以及本文的多任务方法都是基于稀疏表示的,而本文提出的多任务算法的分类结果均明显高于各个子数据集和原始数据集,表明了多任务联合稀疏分类算法相比于传统的稀疏表示模型有了明显的改进,验证了本文算法的有效性.

对于 Indian Pines 数据集,其中 OA 提升范围为 7.16~7.82,提升比例为 9.53%~10.50%;AA 提升范围为 7.4~8.60,提升比例为 10.19%~11.97%;Kappa 统计值提升范围为 8.02~8.99,提升比例为 11.17%~12.68%.

对于 Pavia University 数据集,其中 OA 提升范围为 9.45~9.79,提升比例为 12.55%~13.06%;AA 提升范围为 8.24~8.79,提升比例为 9.99%~11.53%;Kappa 统计值提升范围为 9.98~10.08,提升比例为 14.22%~14.38%.

5 结束语

本文提出了基于多任务联合稀疏的分类算法,

涉及分组策略和联合表示两个关键问题. 前者利用交叉分组的策略实现, 将光谱之间的强相关性转化为各个子波段之间的相关性, 为后续实现联合表示奠定理论基础; 后者借助稀疏表示模型, 通过约束 $l_{2,1}$ 范数, 实现多任务之间的共享稀疏表示, 并采用加速近端梯度优化算法求解各个任务的权重系数. 文中采用真实的高光谱图像公开数据设计实验, 实验结果表明, 多任务联合稀疏表示算法的分类性能优于单任务模型, 验证了本文算法的有效性. 下一步工作, 将设计更详尽的实验, 对模型中的关键参数进行分析, 并计划进行模型的进一步优化, 进一步提升分类效果.

参考文献:

- [1] CHEN YI. Research on spatial-spectral resolution enhancement of hyperspectral image [D]. Xi'an: Northwestern Polytechnical University, 2016.
- [2] 赵春晖, 李晓慧, 王玉磊, 等. 高光谱图像异常目标检测研究进展[J]. 电子测量与仪器学报, 2014, 28(8): 803-811.
- [3] 余乐, 吴超, 吴静珠, 等. 结合高光谱与 CNN 的小麦不完善粒识别方法[J]. 电子测量与仪器学报, 2017, 31(8): 1297-1303.
- [4] CHEN J, ZHOU J, YE J, et al. Integrating Low-rank and Group-sparse Structures for Robust Multi-task Learning[C] // International Conference on Knowledge Discovery and Data Mining. San Diego, USA, 2011: 281-288.
- [5] ZHANG Y, DU B, ZHANG L, et al. Joint Sparse Representation and Multitask Learning for Hyperspectral Target Detection[J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(2): 894-906.
- [6] 薛晓琴, 基于协同表示的高光谱图像亚像元制图技术研究[D]. 西安: 西北工业大学, 2017.
- [7] LI W, TRAMEL E W, PRASAD S, et al. Nearest regularized subspace for hyperspectral classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 477-489.
- [8] HUANG Z, SHI Z, QIN Z, et al. A dimension reduction model for sparse hyperspectral target detection with weighted l_1 -minimization[C] // IEEE 5th Int. Congr. Image Signal Process. Chongqing, China, 2012: 972-976.
- [9] HUANG Z, SHI Z, YANG S, et al. Nonlocal similarity regularized sparsity model for hyperspectral target detection[J]. IEEE Geosci. Remote Sens. 2013, 10(6): 1532-1536.
- [10] CHEN Y, NASRABADI N M, TRAN T D, et al. Sparse representation for target detection in hyperspectral imagery. IEEE J. Sel. Topics Signal Process, 2011, 5(3): 629-640.
- [11] ZHANG Y, DU B, ZHANG L, et al. A sparse representation based binary hypothesis model for target detection in hyperspectral images[J]. IEEE Trans. Geosci. Remote Sens, 2015, 53(3): 1346-1354.

作者简介:

贾立丽 女, (1993-), 硕士研究生. 研究方向为数据处理、高光谱图像分类方法研究. E-mail: jialili9311@163.com.

张升伟 男, (1963-), 研究员. 研究方向为陆基、机载及星载微波传感器设计与研制.

何杰颖 女, (1984-), 研究员. 研究方向为星载微波辐射计定标和数据处理.

李娜 女, (1989-), 博士研究生. 研究方向为星载微波载荷的物理参数反演及资料同化研究.