

基于多模型融合的高光谱图像质量评价

徐冬宇¹, 厉小润^{1*}, 赵辽英², 舒锐³, 唐琪佳³

¹ 浙江大学电气工程学院, 浙江 杭州 310027;

² 杭州电子科技大学计算机应用技术研究所, 浙江 杭州 310018;

³ 上海卫星工程研究所, 上海 200240

摘要 针对单模型评价图像质量容易产生过拟合的问题, 提出基于多模型融合的高光谱图像质量评价算法。以图像噪声、模糊度和云含量为降质特征, 建立遥感图像主观评价库, 分别选用支持向量回归方法和集成决策树方法对带有评价值的训练集图像建立质量评价单模型。将两个单模型评价结果线性回归拟合, 得到模型融合的图像质量评价结果。同时, 以广义回归神经网络模型作为参照, 分别从均方误差、回归拟合指标、分类准确率、训练时间 4 个方面对几种模型进行对比。实验结果表明, 所提模型融合算法具有较高的拟合精度、较强的泛化能力, 并且所需的训练时间相对较少。

关键词 成像系统; 高光谱; 图像质量评价; 支持向量回归; 决策树; 模型融合

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP56.021101

Hyperspectral Image Quality Evaluation Based on Multi-Model Fusion

Xu Dongyu¹, Li Xiaorun^{1*}, Zhao Liaoying², Shu Rui³, Tang Qijia³

¹ College of Electrical Engineering, Zhejiang University, Hangzhou, Zhejiang 310027, China;

² Institute of Computer Application Technology, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

³ Shanghai Institute of Satellite Engineering, Shanghai 200240, China

Abstract In order to solve the problem that image quality is easily overfitted by a single model, a hyperspectral image quality evaluation algorithm is proposed based on multi-model fusion. Taking image noise, ambiguity and cloud content as the degraded features, a remote sensing image subjective evaluation database is established. The support vector regression method and the integrated decision tree method are respectively selected to establish a quality evaluation model for training set images with evaluation values. The image quality evaluation results based on model fusion are obtained via linear regression fitting of the two single model evaluation results. At the same time, the generalized regression neural network model is introduced as a reference, and several models are compared from four aspects of mean square error, regression fitting index, classification accuracy and training time. The experimental results show that the proposed model fusion algorithm has relatively high fitting accuracy, relatively strong generalization ability and relatively little training time.

Key words imaging system; hyperspectrum; image quality evaluation; support vector regression; decision tree; model fusion

OCIS codes 110.4234; 110.3000; 100.2960

1 引言

由于遥感图像成像过程中具有复杂性, 图像在形成、传输、接收过程中不可避免地会受到外部干扰和内部干扰, 因此图像会存在一定程度的噪声^[1-3]。

此外, 实际的传感器成像过程常会引起模糊^[4-5]。同时, 光学遥感数据中大量云的存在, 影响了遥感图像的质量, 从而降低了图像的数据利用率^[6-8]。这些噪声、模糊、云覆盖会使图像退化, 特征淹没, 给图像的理解和使用带来困难。因此, 选用合适的

收稿日期: 2018-07-01; 修回日期: 2018-07-06; 录用日期: 2018-07-26

基金项目: 国家自然科学基金(61671408)、教育部联合基金(6141A02022314)、上海航天科技创新基金(SAST2015041)

* E-mail: lxr@zju.edu.cn

图像质量评价方法、选择质量较好的遥感图像很有必要。

图像质量评价方法主要有两种。第1种是主观评价方法,由观测者进行目视评判,能反映人的真实直观感受。但由于人眼的分辨能力有限,这种评价方法主观性太强,观测者不同,评价可能有不同的结果,并且效率低;第2种是客观评价方法,主要用数学统计的方法对图像进行分析。客观评价方法根据是否有参考图像分为:全参考、无参考和半参考图像质量评价。全参考和部分参考评价需要已知全部或部分参考图像的特征和图像的失真信息,通过特定的算法对比待评价图像和参考图像之间的差异来获得图像质量的评价结果。无参考评价仅需要根据失真图像的自身特征估计图像的质量。由于在实际情况中难以获得参考图像,所以基于无参考遥感图像质量评价方法^[9-11]的应用最多。

无参考图像质量评价方法研究始于面向特定失真的评价,如仅针对模糊、噪声等单个特征进行评价。为排除不同失真类型的干扰,人们试图找到类似于人眼评价的统一评价机制,同时评价不同失真类型的图像,即面向非特定失真的无参考图像质量评价算法。非特定失真的无参考图像质量评价方法更接近人的评价方式,更具实用价值,因此,近几年涌现了大量的、各种各样的算法。

无参考图像质量评价的目标是模拟人眼对图像的评价,而人眼视觉系统的评价过程是一个复杂非线性过程,基于机器学习的方法可以很好地学习这一评价过程^[12]。无参考图像质量评价经历了早期针对某种特定失真、基于规则的方法后,逐渐朝着提取复杂特征、基于机器学习的方向发展。近期研究成果表明,图像质量评价的绝大多数方法都可以归为基于机器学习的方法,这些方法在现有的方法中取得了较好的估计效果,代表着当前无参考图像质量评价研究的发展方向^[12]。神经网络模型^[13]和支持向量机^[14-15]以其突出的性能在机器学习中受到很大的重视,在图像质量评价中应用广泛。这两类方法均是先提取图像特征,基于已知质量数据训练支持向量回归(SVR)分析模型或神经网络回归分析模型,由图像特征预测图像质量。Zhu等^[14]利用SVR模型将图像的失真类型分为3类,对每类进行单项评价,再通过加权得到遥感图像的总评分,取得了较传统统计回归模型更好的结果。Yin等^[13]采用广义回归神经网络(GRNN)估计图像质量,所采用的

特征包括信息熵、能量、对比度、相关性和同质性等,预测得分与主观得分有较好的一致性,更加符合人类视觉的特性。除了上述常用方法外,其他一些机器学习方法也在图像质量评价中得到了应用,如多重线性回归(MLR)、随机森林回归分析等^[12]。

无参考图像质量评价作为一个典型的机器学习问题,其核心包括特征提取和回归方法两方面。从特征提取方面来看,噪声、模糊是影响图像质量的核心因素,由于高光谱遥感图像的特殊性,大量云的存在降低了图像数据的利用率^[6-8],因此云含量是遥感图像质量评价的核心特征。从识别方法上来看,典型的支持向量机和神经网络在这一领域取得了较好的效果^[12]。

本文选取EO-1卫星的Hyperion传感器拍摄的遥感图像,分别从特征提取和回归评价方法两个方面进行讨论。在特征提取部分,分别估计图像噪声、模糊度以及云含量,从而基于噪声、模糊度、云含量建立综合评价模型。在回归评价方法部分,介绍了GRNN和SVR模型^[12],并引入Bagging决策树模型^[16]。最后,提出基于多模型融合的高光谱图像质量评价方法,将SVR和Bagging决策树两个单模型训练的结果进行多重线性回归。在实验部分,分别从均方误差、回归拟合指标、分类准确率、训练时间4个方面对几种模型进行对比。实验结果表明,所提模型融合算法在训练集和测试集的3个拟合指标均优于被融合的两个单模型以及GRNN模型。

2 数据选取与预处理

图像评价数据库的建立,使研究人员可以使用固定统一的评价对象与标准对图像的质量进行评价,为图像质量评价算法构造训练集和测试集,从而为图像质量评价方法在学术领域的通用性、准确性奠定了基础^[17]。

选取EO-1卫星的Hyperion传感器拍摄的3幅遥感图像,裁剪出13个特征场景图像,其中只含云样本的有6个,只含云的特征场景图像如图1所示;只含海洋陆地样本的有4个含陆地和海洋的特征场景图像如图2所示,其中图2(g)、(h)、(i)以海洋为主,图2(j)以陆地为主;含海洋陆地和云的综合样本的有3个,含陆地海洋和云的特征场景图像如图3所示,图片大小为400 pixel×256 pixel。特征场景图像详细信息如表1所示。

表 1 特征场景图像详细信息

Table 1 Details of feature scene images

Sample	Imaging time	Location	Type
A	2017-02-03	Hong Kong, China	Cloud
B	2016-09-06	Japan Island	Cloud
C	2017-04-23	Caribbean Sea	Cloud
D	2017-02-03	Hong Kong, China	Cloud
E	2016-09-06	Japan Island	Cloud
F	2017-04-23	Caribbean Sea	Cloud
G	2017-02-03	Hong Kong, China	Sea (basis), land
H	2016-09-06	Japan Island	Sea (basis), land
I	2017-04-23	Caribbean Sea	Sea (basis), land
J	2017-02-03	Hong Kong, China	Sea, land (basis)
K	2016-09-06	Japan Island	Sea, land, cloud
L	2017-04-23	Caribbean Sea	Sea, land, cloud
M	2017-02-03	Hong Kong, China	Sea, land, cloud




图 1 只含云的特征场景图像。(a)样本 A;(b)样本 B;(c)样本 C;(d)样本 D;(e)样本 E;(f)样本 F

Fig. 1 Scene images with features of cloud-only. (a) Sample A; (b) sample B; (c) sample C;

(d) sample D; (e) sample E; (f) sample F




图 2 含陆地和海洋的特征场景图像。(a)样本 G;(b)样本 H;(c)样本 I;(d)样本 J

Fig. 2 Scene images with features of land and sea. (a) Sample G; (b) sample H; (c) sample I; (d) sample J




图 3 含陆地海洋和云的特征场景图像。

(a)样本 K;(b)样本 L;(c)样本 M

Fig. 3 Scene images with features of land, sea and cloud.

(a)Sample K; (b) sample L; (c) sample M

对上述 13 个真实图像分别加入 5 个不同大小的高斯噪声和 5 个不同程度的模糊,生成 $13 \times 5 \times 5 = 325$ 幅图像,其中,真实图像 13 幅,模拟图像 313 幅。高斯噪声类型为均值等于 0,方差分别为 0,0.000001,

0.00005,0.0001,0.00015,并按照从小到大的顺序添加。用于添加模糊的均匀滤波模板分别为 0,5,10,15,20。为了更好地观察添加图像之间的差异,将图像灰度范围拉伸到 0~255 之间。降质因素仿真图像如图 4 所示。

根据主观质量评价标准,组织 20 位具有遥感专业背景的专家采用差额平均期权评分(DMOS)评分法对图像进行评价^[18-19]。待评价图像包括 13 幅真实图像和 313 幅模拟图像在内的共计 325 幅遥感图像。所有的图像均有两组标签:评分分值标签(0~10 的浮点数),图像质量最好是 10 分,最差是 0 分;是否合格的分类标签中,对分值大于或等于 6 的图像标记为合格(标签值为 1),剩下的标记为不合格(标签值为 0)。




图4 降质因素仿真图像。(a)噪声仿真图像；(b)模糊仿真图像

Fig. 4 Simulation images of degraded factors. (a) Simulation image of noise; (b) simulation image of ambiguity

3 多模型融合评价遥感图像质量

3.1 遥感图像质量评价特征统计

遥感图像质量评价综合算法将选取3个特征量：噪声、模糊和云含量。

通常利用多元线性回归方法^[1]估计图像噪声。算法的基本思想是对图像分块，通过相邻波段多元线性回归拟合的方法结合均匀区域临近像元值拟合信号分离噪声，计算图像块噪声方差。

记某一子块中第 k 个波段第 i 行第 j 列的像素值为 $x_{i,j,k}$ ，多元线性回归拟合得到该像素信号估计值为

$$\hat{x}_{i,j,k} = a + bx_{i,j,k-1} + cx_{i,j,k+1} + dx_{i-1,j,k}, \quad (1)$$

式中： $x_{i,j,k-1}$ 、 $x_{i,j,k+1}$ 分别为第 $k-1$ 和 $k+1$ 个波段第 i 行第 j 列的像素值； a 、 b 、 c 、 d 为线性回归系数。

第 k 个波段图像块噪声估计图像块噪声估计值计算过程为

- 1) 输入第 $k-1$ 、 k 、 $k+1$ 个波段图像块；
- 2) 输出第 k 个波段图像块的噪声估计；
- 3) 根据(1)式估算第 k 个波段的信号；
- 4) 估算第 k 个波段图像块的残差 $r_{i,j,k}$ ，可表示为

$$r_{i,j,k} = x_{i,j,k} - \hat{x}_{i,j,k}; \quad (2)$$

5) 估算第 k 个波段图像块的噪声方差 σ_n^2 ，可表示为

$$\sigma_n^2 = \sum_i \sum_j r_{i,j,k}^2; \quad (3)$$

6) 将波段中所有子块的残差标准差的均值作为波段图像的最佳噪声估计值。

为了减少奇异地块的干扰，剔除上下各15%，

取中间70%的均值作为该波段图像的最佳噪声估计。

进行模糊度估计时，利用基于图像直方图的模糊度评价算法^[4]估计图像模糊度特征。根据遥感图像直方图上特殊均值附近像素点的分布情况，间接判断整幅图像的模糊程度。具体步骤如下：

1) 选择某个特定波段的遥感图像，得到灰度直方图，计算每个灰度的权值，可表示为

$$\omega(x_i) = \begin{cases} \frac{x_i}{x_{av}}, & x_i < x_{av} \\ \frac{255 - x_i}{255 - x_{av}}, & x_i \geq x_{av} \end{cases}, \quad (4)$$

式中： x_i 为图像第 i 级灰度级的灰度值； x_{av} 为图像灰度均值； $\omega(x_i)$ 为灰度值 x_i 的权值。

2) 计算遥感图像的模糊度评价价值

$$e = \sum_{x_i=0}^{255} p(x_i)\omega(x_i), \quad (5)$$

式中： $p(x_i)$ 为每个灰度值在图像中出现的频率。

利用基于反射率特性的高光谱遥感图像云检测方法^[6]估计云含量，根据各类地物在不同光谱下的反射率特征，从星载高光谱图像中选取3个特定波长的图像数据，再依照图像地物反射率及阈值判定法区分出高云区和中低云区，最后对二者合并，得到目标云区。高光谱遥感图像云含量检测流程如图5所示。

3.2 遥感图像质量评价算法

假设 x 与 y 分别为输入特征向量和输出变量。在图像质量评价问题中， $x^{(j)}$ ($j=1,2,3$)分别表示遥感图像的3个特征属性，即噪声、模糊度和云含量； y 表示章节2中介绍的研究人员对图像质量的评分值。给定已知训练数据集 $D = \{(x_1, y_1), (x_2,$

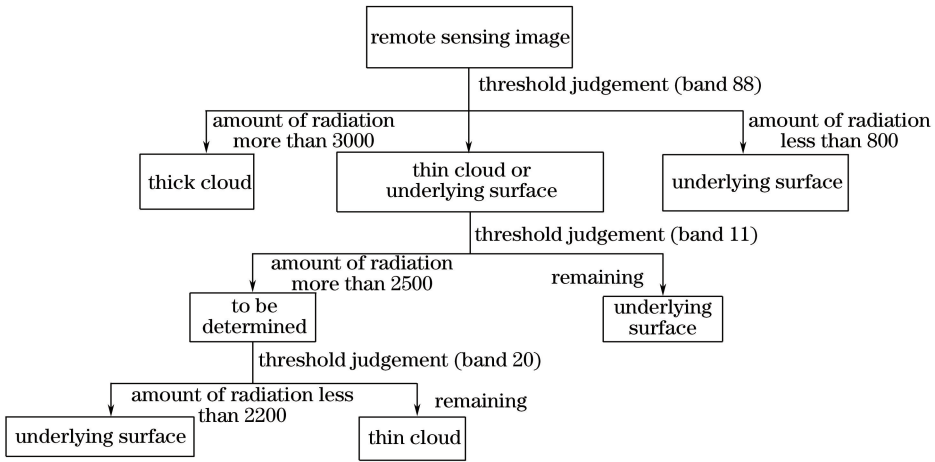


图5 高光谱遥感图像云含量检测流程图

Fig. 5 Flow chart of cloud content detection via hyperspectral remote sensing image

$y_2), \dots, (\mathbf{x}_N, y_N)\}$ 问题转化为构造一个函数模型 $f(\mathbf{x})$ 来拟合 \mathbf{x} 和 y 的关系, 即对于每一个训练样本 $(\mathbf{x}_i, y_i), i=1, 2, \dots, N$, 希望 $f(\mathbf{x})$ 能够无限接近 y 。这样便可以用训练好的函数模型 $f(\mathbf{x})$ 评价新的遥感图像质量^[20-21]。不同的质量评价算法对应不同的函数模型 $f(\mathbf{x})$ 。

为了能够将被融合的单模型和其他单模型分别与所提融合模型进行比较, 分别介绍在图像质量评价领域的经典算法——GRNN 和 SVR 模型^[12], 并尝试将另一机器学习模型——Bagging 决策树模型^[16]应用到图像质量评价中。最后提出基于多模型融合的高光谱图像质量评价方法, 将 SVR 和 Bagging 决策树两个单模型训练的结果进行多重线性回归, 由最小二乘法构造均方差损失函数, 利用梯度下降法求取回归参数。

3.2.1 广义回归神经网络

GRNN^[13]是一种建立在非参数估计基础上的非线性回归的径向基神经网络, 具有很强的非线性映射能力, 在图像质量评价领域应用广泛^[12]。

GRNN 由 4 层网络构成, 分别为输入层、模式层、求和层和输出层, GRNN 网络结构如图 6 所示。

输入层的神经元个数等于样本中输入向量的维数, 各神经元是简单的分布单元, 直接将输入变量传递给模式层。模式层神经元的个数等于样本个数 N , 各神经元对应不同的样本。模式层的每个节点连接到求和层中的两个节点, 输出层计算求和层的两个输出商数, 产生依赖于特征的预测值。

对于输入向量 \mathbf{x} , GRNN 的输出 \hat{y} 为

$$\hat{y}(\mathbf{x}) = \frac{\sum_{i=1}^N y_i \exp(-D_i^2/2\sigma^2)}{\sum_{i=1}^N \exp(-D_i^2/2\sigma^2)},$$




图6 GRNN 网络结构示意图

Fig. 6 Structural diagram of GRNN network

$$D_i^2 = (\mathbf{x} - \mathbf{x}_i)^T (\mathbf{x} - \mathbf{x}_i), \quad (6)$$

式中: N 为训练样本图像的数量; σ 为传递参数, σ 值越大, 函数逼近越光滑。

3.2.2 支持向量回归模型

SVR^[12]是支持向量在函数回归领域的应用, 其基本思想是求超平面, 使所有样本点到超平面的距离最小。

基于 SVR 评价遥感图像质量相当于求解函数模型 $f(\mathbf{x})$, 使得对于每一幅训练样本图像 $f(\mathbf{x}_i)$ 尽可能接近该图像已知的质量评分值 y_i 。求解函数模型 $f(\mathbf{x})$ 的过程即优化损失函数的过程, 用公式表达为

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*),$$

$$\text{s.t.} \begin{cases} y_i - f(\mathbf{x}_i) < \varepsilon + \xi_i \\ f(\mathbf{x}_i) - y_i < \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}, \quad (7)$$

式中: C 为惩罚系数; ε 为间隔带宽度的一半; ξ_i, ξ_i^* 为间隔带的上下松弛变量; \mathbf{w} 和后面关于 \mathbf{x} 的函数均为相同维数的列向量。其中关于 \mathbf{x} 的函数中选择高斯核, 核带宽系数为 g 。SVR 需要解决(7)式的优化问题。

根据拉格朗日乘子法求解(7)式优化问题。则对于任意遥感图像,其质量评价可表示为

$$f_{SVR}(\mathbf{x}_i) = \mathbf{w}^T \varphi(\mathbf{x}_i) + \mathbf{b}', \quad (8)$$

式中: \mathbf{b}' 为偏置项。

3.2.3 Bagging 决策树模型

Bagging 是一种典型的并行式集成学习方法。在本问题中,基学习器选用决策树^[14]中的 CART (Classification and Regression Tree)算法。

Bagging 决策树评价遥感图像质量的算法步骤如下:

1) 将输入空间划分为两个区域 $R_1(j, s)$ 和 $R_2(j, s)$,并在每个区域用常量值 \hat{c}_1 和 \hat{c}_2 来拟合图像的评价值 y 。

$$\begin{aligned} R_1(j, s) &= \{\mathbf{x} \mid x^{(j)} \leq s\}, \\ R_2(j, s) &= \{\mathbf{x} \mid x^{(j)} > s\}, \\ \hat{c}_m &= \frac{1}{N_m} \sum_{\mathbf{x}_i \in R_m(j, s)} y_i, \\ \mathbf{x} &\in R_m, m = 1, 2, \end{aligned} \quad (9)$$

2) 在输入特征空间 \mathbf{x} 中,依次遍历每个特征 $x^{(j)} (j=1, 2, 3)$ 以及该特征的每个取值 $x^{(j)} = s$,计算每个切分点 (j, s) 的损失函数,选择损失函数最小的切分点,该过程可表示为

$$\begin{aligned} \min_{j, s} \left[\min_{c_1} \sum_{\mathbf{x}_i \in R_1(j, s)} (y_i - c_1)^2 + \right. \\ \left. \min_{c_2} \sum_{\mathbf{x}_i \in R_2(j, s)} (y_i - c_2)^2 \right], \end{aligned} \quad (10)$$

式中: c_1, c_2 为两个常量。

3) 继续对两个子区域递归的调用步骤 1) 和 2),直至切分结束。

4) 将输入空间划分为 M 个区域 R_1, R_2, \dots, R_M ,每个区域的输出值分别为 $\hat{c}_1, \hat{c}_2, \dots, \hat{c}_M$,生成决策树为

$$T(\mathbf{x}) = \sum_{m=1}^M \hat{c}_m \mathbf{I}, \mathbf{x} \in R_m, \quad (11)$$

式中: \mathbf{I} 表示单位矩阵,矩阵的维数表示叶子节点的个数。依据 Bagging 对回归问题的简单平均法,对于任意遥感图像,其质量评价可表示为

$$f_{\text{Bagging}}(\mathbf{x}_i) = \sum_{i=1}^K T_i(\mathbf{x}_i), \quad (12)$$

式中: K 为基学习器(即决策树)的个数。

3.2.4 模型融合

由于遥感图像成像复杂,降质因素众多,单模型评价图像质量容易产生过拟合,即在训练集图像中结果较好,但在测试集中效果很差。因此可以训练多个非线性模型,再将评价结果线性回归拟合,从而

取得 $1+1>2$ 的互补效果。

SVR 模型在解决小样本、非线性及高维模式识别问题中表现出许多特有的优势,但是却依赖输入的数据分布和对核函数的选择。决策树模型具有能够自动组合多个特征、不用关心特征之间是否相互依赖和不用担心异常值等优点,但是决策树模型容易过拟合。而将 SVR 模型和决策树模型相融合,令二者优势互补,能提高准确率,优化回归拟合效果。

依据模型融合,对于任意遥感图像,其质量评价可表示为

$$f_{\text{fusion}}(\mathbf{x}_i) = \alpha \cdot f_{SVR}(\mathbf{x}_i) + (1 - \alpha) \cdot f_{\text{Bagging}}(\mathbf{x}_i), \quad (13)$$

式中: $\alpha \in (0, 1)$,表示单模型权重。

多模型融合的关键即为求取回归参数 α 的过程。(13)式可以理解为多个单模型评价价值试图学得一个含参线性模型,以尽可能准确地预测主观评价价值 y ,而提高多模型融合结果的有效方法则是构造损失函数,使模型预测的结果尽可能接近真实的主观评价价值 y 。

在回归模型中最常用的损失函数则是利用最小二乘法构建平方损失,即

$$L(\alpha) = \frac{1}{2} \sum_{i=1}^N [y_i - f_{\text{fusion}}(\mathbf{x}_i)]^2. \quad (14)$$

则回归方程的最优参数 α^* 可表示为

$$\alpha^* = \arg \min_{\alpha} L(\alpha), \quad (15)$$

利用梯度下降法求取回归方程的最优参数 α^* ,回归参数 α 的计算中,输入第 i 幅图像的质量评价价值 $f_{\text{fusion}}(\mathbf{x}_i)$,第 i 幅图质量的主观评价价值为 y_i , $i=1, 2, \dots, N$,输出最优参数 α 。具体过程为:

1) 计算损失函数的导数

$$\begin{aligned} \frac{\partial L(\alpha)}{\partial \alpha} &= \sum_{i=1}^N [y_i - f_{\text{fusion}}(\mathbf{x}_i)] \cdot \\ &[f_{SVR}(\mathbf{x}_i) - f_{\text{Bagging}}(\mathbf{x}_i)]. \end{aligned} \quad (16)$$

2) 更新参数 α ,即

$$\alpha = \alpha - \eta \frac{\partial L(\alpha)}{\partial \alpha}, \quad (17)$$

式中: η 为学习速率,可设置为 0.1。

3) 重复步骤 1)、2),直至 $|\partial L(\alpha)/\partial \alpha| < \zeta$,其中 ζ 为无穷小数,可被设置为 10^{-5} 。

选取 EO-1 卫星的 Hyperion 传感器拍摄的高光谱遥感图像,分别选用 SVR 和集成决策树算法,基于噪声、模糊度、云含量 3 个指标建立多模型融合的综合质量评价模型,多模型融合的综合质量评价模型结构如图 7 所示。

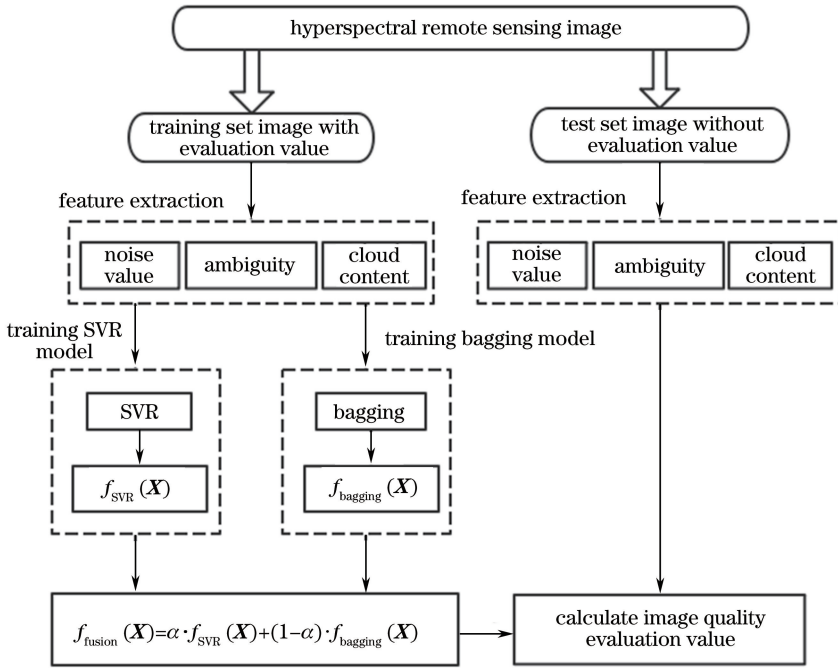


图 7 多模型融合的综合质量评价模型结构图

Fig. 7 Structural diagram of multi-model fusion integrated quality evaluation model

4 实验和结果分析

在评分值回归问题上,选择 R^2 作为评价指标^[22]

$$R^2 = 1 - \frac{\sum_{i=1}^N (f_i - y_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (18)$$

式中: f_i 为由模型计算的图像质量评分值; y_i 为由主观评价库得到的真实的图像质量评分值; \bar{y} 为真实评

分值的均值; N 为样本总数。评分回归评价指标 R^2 值在 0~1 之间,越接近 1 表示拟合效果越好。

为验证模型结果,随机选择样本集中的 460 幅作为训练样本,75 幅作为测试样本。在训练样本中训练模型参数,再将模型应用到测试样本中。分别计算模型在训练样本和测试样本中的拟合指标。

回归算法结果比较如表 2 所示。回归算法拟合结果如图 8 所示,其中,红色的星线表示真实的图像质量评价得分,蓝色的点线表示由算法拟合的图像质量评价得分。

表 2 回归算法结果比较

Table 2 Comparison of results by regression algorithms

Method	Training time /s	Training set			Testing set		
		Mean square error	Fitting indicator R^2	Classification accuracy /%	Mean square error	Fitting indicator R^2	Classification accuracy /%
GRNN	14.356	0.0207	0.9936	98.157	0.5896	0.8679	95.333
SVR	3.583	0.3148	0.9402	96.813	0.7855	0.8209	94.667
Bagging	1.497	0.1880	0.9643	95.817	0.6627	0.8542	94.667
Model fusion	5.019	0.0287	0.9945	98.016	0.2796	0.9590	96.333

Note: Three hyperparameters of SVR: $C=4.641$, $g=12.915$, $\epsilon=0.077$, number of bases for Bagging is 250.

表 2 中,均方差表示真实值和预测值的误差平方和,数值越接近 0 表示拟合效果越好。拟合指标 R^2 由(18)式求得,越接近 1 表示拟合效果越好。分类准确率是在算法拟合预测值的基础上得到的,当预测得分值大于或等于 6,判定为合格,小于 6 判定为不合格。将这种分类预测的结果再与实际分类值

比较,从而得到分类准确率。

由表 2 可以看出,4 种方法均实现了遥感图像质量评价,可以得到相对准确的质量评分,同时分类准确率均在 94% 以上。从均方误差、回归拟合指标、分类准确率 3 个方面将所提融合模型与被融合的两个单模型(SVR 模型和 Bagging 决策树模型)

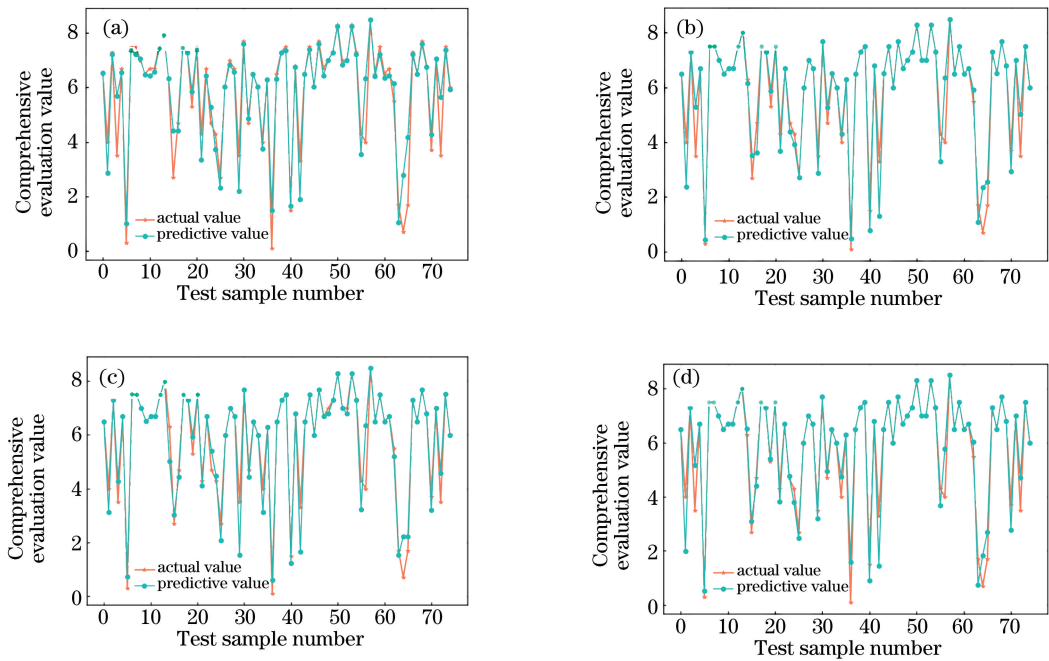


图 8 不同回归算法拟合结果。(a) SVR; (b) Bagging; (c) 模型融合; (d) GRNN

Fig. 8 Fitting results by various regression algorithms. (a) SVR; (b) Bagging; (c) model fusion; (d) GRNN

进行对比,融合模型在训练集和测试集上的 3 个指标均优于单模型。单模型在测试集上出现了严重的过拟合现象。以 SVR 模型为例,在训练集中的回归拟合指标 R^2 为 0.9402,而在测试集中 R^2 为 0.8209,均方误差也从 0.3148 升至 0.7855,说明 SVR 模型在训练集中实现了较好的训练结果,而在测试集中效果变差,表明模型的泛化能力较弱。而融合模型在训练集和测试集中 3 个指标的变化不大,且均优于单模型,表明融合模型的稳健性更强。将所提融合模型与 GRNN 模型进行对比,在训练集上两个模型相差不大,GRNN 模型略优于融合模型。但融合模型的训练时间远远小于 GRNN,而且 GRNN 模型同样存在测试集中过拟合的问题,泛化能力较弱。因此,所提融合模型优于应用广泛的 GRNN 模型。

5 结 论

以 EO-1 卫星 Hyperion 传感器的高光谱遥感图像为例,介绍了遥感图像质量评价的背景、主观评价库的建立以及数据的处理操作,分析了遥感图像噪声、模糊度、云含量 3 个降质因素,并以此建立了高光谱遥感图像质量综合评价模型。介绍了目前在图像质量评价领域中最典型的两种机器学习方法,即 GRNN 和 SVR 模型,并尝试将另一机器学习模型——Bagging 决策树模型应用到图像质量评价

中。提出了基于多模型融合的高光谱图像质量评价方法,将 SVR 和 Bagging 决策树两个单模型训练的结果进行多重线性回归,提出了多模型融合的高光谱遥感图像质量评价算法,分别从均方误差、回归拟合指标、分类准确率、训练时间 4 个方面对 4 种模型进行对比,实验结果表明,所提模型具有较高的拟合精度、较强的泛化能力,并且所需的训练时间相对较少。

参 考 文 献

- [1] Xu D. Hyperspectral remote sensing image denoising based on multiple linear regression and sparse representation [D]. Changsha: National University of Defense Technology, 2013.
徐冬. 基于多元线性回归和稀疏化表示的高光谱遥感图像去噪[D]. 长沙: 国防科学技术大学, 2013.
- [2] Tan Z G, Ou J P, Zhang J, *et al.* A laminar denoising algorithm for depth image[J]. Acta Optica Sinica, 2017, 37(5): 0510002.
谭志国, 欧建平, 张军, 等. 一种层析深度图像去噪算法[J]. 光学学报, 2017, 37(5): 0510002.
- [3] Zhang X, Jing X L. A method for image denoising based on normal inverse Gaussian model using Bayesian estimation[J]. Acta Optica Sinica, 2010, 30(1): 70-74.
张鑫, 井西利. 一种基于正态反高斯模型的贝叶斯图像去噪方法[J]. 光学学报, 2010, 30(1): 70-74.

- [4] Pang S L. Research on image ambiguity evaluation [D]. Xi'an: Xidian University, 2010.
庞胜利. 图像模糊度评价研究[D]. 西安: 西安电子科技大学, 2010.
- [5] Lu H M, Xu M, Li X. Image deblurring with adaptive signal-noise ratio estimation for computational imaging system [J]. Acta Optica Sinica, 2014, 34(8): 0810002.
卢惠民, 徐明, 李迅. 用于计算成像系统的基于信噪比自适应估计的图像去模糊研究[J]. 光学学报, 2014, 34(8): 0810002.
- [6] Feng S Y, Zhang N, Shen J, *et al.* Method of cloud detection with hyperspectral remote sensing image based on the reflective characteristics [J]. China Optics, 2015, 8(2): 198-204.
冯书谊, 张宁, 沈霁, 等. 基于反射率特性的高光谱遥感图像云检测方法研究[J]. 中国光学, 2015, 8(2): 198-204.
- [7] Chen Y, Fan R S, Wang J X, *et al.* Cloud detection of ZY-3 satellite remote sensing images based on deep learning [J]. Acta Optica Sinica, 2018, 38(1): 0128005.
陈洋, 范荣双, 王竞雪, 等. 基于深度学习的资源三号卫星遥感影像云检测方法[J]. 光学学报, 2018, 38(1): 0128005.
- [8] Jiang X H, Wang X H, Ye H H, *et al.* Cloud contaminated satellite data processing method in CO₂ retrieving [J]. Acta Optica Sinica, 2015, 35(8): 0801001.
江新华, 王先华, 叶函函, 等. CO₂ 反演中卫星数据的云污染处理方法研究[J]. 光学学报, 2015, 35(8): 0801001.
- [9] Gao L L, Liu J J, Ren X, *et al.* Image quality evaluation of panoramic camera stereopair based on structural similarity [J]. Laser & Optoelectronics Progress, 2014, 51(7): 071004.
高露露, 刘建军, 任鑫, 等. 基于结构相似度的全景相机立体像对图像质量评价[J]. 激光与光电子学进展, 2014, 51(7): 071004.
- [10] Hou C P, Ma T T, Yue G H, *et al.* Multiply-distorted image quality assessment based on high-order phase congruency [J]. Laser & Optoelectronics Progress, 2017, 54(7): 071001.
侯春萍, 马彤彤, 岳广辉, 等. 基于高阶相位一致性的混合失真图像质量评价[J]. 激光与光电子学进展, 2017, 54(7): 071001.
- [11] Zhang F, Zhang N Y, Li Z Z. Image quality evaluation method based on symmetric phase consistency [J]. Laser & Optoelectronics Progress, 2017, 54(10): 101003.
张帆, 张偌雅, 李珍珍. 基于对称相位一致性的图像质量评价方法[J]. 激光与光电子学进展, 2017, 54(10): 101003.
- [12] Wang Z M. Review of no-reference image quality assessment [J]. Acta Automatica Sinica, 2015, 41(6): 1062-1079.
王志明. 无参考图像质量评价综述[J]. 自动化学报, 2015, 41(6): 1062-1079.
- [13] Yin Y. Non-reference blur image quality assessment based on general regression neural network [J]. Laser & Infrared, 2013, 43(4): 466-470.
殷莹. 基于广义回归神经网络无参考模糊图像质量评价[J]. 激光与红外, 2013, 43(4): 466-470.
- [14] Zhu X L, Xu M Z, Cong M. Assessment method for no-reference remote sensing image quality based on support vector machine [J]. Spacecraft Recovery & Remote Sensing, 2014, 35(6): 83-90.
朱晓玲, 许妙忠, 丛铭. 基于支持向量机的无参考遥感图像质量评价方法[J]. 航天返回与遥感, 2014, 35(6): 83-90.
- [15] Wu Y Q, Zhou Y, Long Y L. Small target detection in hyperspectral remote sensing image based on adaptive parameter SVM [J]. Acta Optica Sinica, 2015, 35(9): 0928001.
吴一全, 周杨, 龙云淋. 基于自适应参数支持向量机的高光谱遥感图像小目标检测[J]. 光学学报, 2015, 35(9): 0928001.
- [16] Fan C L. Hyperspectral remote sensing image classification algorithm based on decision tree [D]. Qinhuangdao: Yanshan University, 2014.
范成龙. 基于决策树的高光谱遥感图像分类算法研究[D]. 秦皇岛: 燕山大学, 2014.
- [17] Zhou Y J, Tian Q J. Image quality evaluation of EO-1 hyperion sensor [J]. Geo-Information Science, 2008, 10(5): 678-683.
周雨霁, 田庆久. EO-1 Hyperion 高光谱数据的质量评价[J]. 地球信息科学, 2008, 10(5): 678-683.
- [18] Yan L, Hu X B. Image quality assessment of IKONOS images based on contourlet-SIIM model [J]. Geomatics and Information Science of Wuhan University, 2014, 39(1): 12-16.
闫利, 胡晓斌. 利用 Contourlet-SSIM 视觉模型的 IKONOS 图像质量评价研究[J]. 武汉大学学报(信息科学版), 2014, 39(1): 12-16.
- [19] Zhang X L, Liu Z F, Dai J B, *et al.* Image quality assessment based on visual perception and gradient

- structural similarity [J]. *Application Research of Computers*, 2011, 28(6): 2348-2351.
- 张晓琳, 刘直芳, 代金波, 等. 基于视觉感知的梯度结构相似度图像质量评价 [J]. *计算机应用研究*, 2011, 28(6): 2348-2351.
- [20] Qian F, Sun T, Guo J, *et al.* Dynamic assessment of laser-dazzling effects based on the character of laser-spot and image feature [J]. *Chinese Journal of Lasers*, 2014, 41(6): 0609004.
- 钱方, 孙涛, 郭劲, 等. 基于光斑与图像特征的动态激光干扰效果评估 [J]. *中国激光*, 2014, 41(6): 0609004.
- [21] Wang F, Ni J P, Dong T, *et al.* No-reference image quality assessment method based on visual attention mechanism and sharpness metric approach [J]. *Journal of Applied Optics*, 2018, 39(1): 51-56.
- 王凡, 倪晋平, 董涛, 等. 结合视觉注意力机制和图像锐度的无参图像质量评价方法 [J]. *应用光学*, 2018, 39(1): 51-56.
- [22] Li S. Research on remote sensing image quality evaluation method based on statistical distribution [D]. Xi'an: Xidian University, 2017.
- 李帅. 基于统计分布的遥感图像质量评价方法研究 [D]. 西安: 西安电子科技大学, 2017.