

基于最小二乘支持向量机的扫描仪特征化

田东文^{1,2}, 白春燕², 肖颖¹

(1.上海出版印刷高等专科学校, 上海 200093; 2.上海理工大学, 上海 200093)

摘要:目的 基于最小二乘支持向量机回归(LSSVR), 研究扫描仪图像输入设备的特征化方法。方法 以 ColorChecker SG 标准色卡为目标, 通过最小二乘支持向量机建立 RGB 三通道值到 CIE Lab 色度值的非线性映射模型, 采用基于交叉验证的网格搜索确定模型最优参数, 优化 LSSVR 模型, 实现彩色扫描仪的色度特征化。结果 所建模型的训练集 R-squared 为 0.996, 验证集 R-squared 为 0.998, 训练集与验证集的 CIEDE2000 平均色差分别为 1.1463, 1.2754。结论 LSSVR 模型能够较好地实现彩色扫描仪色度特征化, 泛化能力较强, 此模型可有效地提高彩色扫描仪特征化的精度且计算处理速度更快。

关键词: 扫描仪; 最小二乘支持向量机; 扫描仪特征化; 色彩映射

中图分类号: TS803 文献标识码: A 文章编号: 1001-3563(2020)09-0222-04

DOI: 10.19554/j.cnki.1001-3563.2020.09.034

Scanner Characterization Based on Least Squares Support Vector Machine

TIAN Dong-wen^{1,2}, BAI Chun-yan², XIAO Ying¹

(1.Shanghai Publishing and Printing College, Shanghai 200093, China;

2.University of Shanghai for Science and Technology, Shanghai 200093, China)

ABSTRACT: The work aims to study the characterization method of scanner image input device based on the least squares support vector machine regression (LSSVR). With the ColorChecker SG standard color card as the target, a non-linear mapping model of RGB three-channel value to CIE Lab value was established with the least squares support vector machine. The cross-validation grid search was used to determine the optimal parameters of the model and the LSSVR model was optimized to achieve the chromaticity characterization of color scanner. The R-squared of the model's training set was 0.996, the R-squared of the validation set was 0.998, and the average color differences of CIEDE2000 of the training set and the validation set were 1.1463 and 1.2754, respectively. LSSVR model can better realize the chromaticity characterization of color scanners, and has strong generalization ability. It also can effectively improve the characterization accuracy and has a faster calculation processing speed.

KEY WORDS: scanner; least squares support vector machine; scanner characterization; color mapping

扫描仪作为印刷行业中非常重要的图像输入设备, 原稿获取的重要来源, 其色彩结果的精准度对于高质量、高品质的印刷图像色彩复制至关重要。目前, 彩色扫描仪特征化多采用色度特征化或光谱特征化的方法, 其中色度特征化应用较多, 即通过特定的模

型、算法得出 R, G, B 三通道值与对应的 CIE Lab 值之间的非线性映射关系。

由于 RGB 值与 CIE Lab 色度值具有较高的非线性关系, 可采用非线性拟合^[1]或者人工神经网络^[2-3]等其他算法来实现色空间的色度转换。Henry R.Kang

收稿日期: 2019-05-27

基金项目: 国家新闻出版总署“柔版印刷绿色制版与标准化实验室”项目(ZBKT201706)

作者简介: 田东文(1983—), 男, 在读博士, 讲师, 主要研究方向颜色科学、图像技术和光电检测技术。

和 Peter G.Anderson^[2]分别利用前馈型神经网络、级联相关神经网络进行了 RGB 色空间到 CIEXYZ 色空间的转换研究，但是实验结果无法正确的反应色差，实验结果与 CIE1976Lab 色空间的色差存在较大差异，同时也显现出了前馈型神经网络无法快速确定适当网络隐含层的弊端。尽管级联神经网络可以确定隐含层数，但是，需要的样本集更多，训练时间也 longer。徐艳芳等^[3]采用 BP 神经网络由 RGB 模式到 CIEXYZ 模式以及 CIELab 模式的非线性转换，通过 ΔE^*_{ab} 进行色差计算与评价，结论表明人工神经网络精度优于多项式回归，使用包含 6 个最佳隐含层的人工神经网络结构，得出的 CIELab 平均色差值在 1.4~2.6，色差最大值在 6~8；但是 BP 神经网络无法自动选择最佳隐层数，需要根据优化结果不断尝试得出最佳隐含层，并且训练、计算时间也较长，结果也不太理想。后来，李斌^[4-5]等通过支持向量机 (SVM) 对彩色扫描仪进行特征化，实验结果表明：平均色差为 2.31，最大色差为 5.79，最小色差为 0.51，特征化效果相比之前有了很大的改善。在最小二乘支持向量机算法中，所有的训练点均为支持向量，而误差就是优化目标之一，这是最小二乘支持向量机 (LSSVM) 与支持向量机 (SVM) 重要的不同点，并且 LSSVM 通过求解线性方程组得出最优解，速度也更快^[6]。故文中采用最小二乘支持向量机回归 (LSSVR) 实现彩色扫描仪的特征化。

1 扫描仪色度特征化原理

在扫描仪色度特征化之前，需要对扫描仪进行校正，扫描仪的校正通过扫描仪白平衡来实现，白平衡校正的作用是调整扫描仪三原色通道光学器件的最大输出工作电压，保证三通道信号混合中性色时达到均衡^[7-9]。

在彩色扫描仪色度特征化时，首先扫描特定标准的色靶 (Color target) 图像，如 ColorChecker Digital SG, ANSI IT8.7/2 标准色卡等，获取扫描后相应色块的 RGB 值；使用分光光度计 (X-Rite eXact) 测量相对应的色块，得到色块的 CIE Lab 值。然后，根据扫描仪获取的图像 RGB 值与分光光度计测量出的色靶的 CIE Lab 值，建立变换模型。最后，通过模型得出的计算值与实际值之间的色差评价模型的精度。

$$Y_i = M \cdot X_i \quad (i=1,2,\dots,n) \tag{1}$$

式中 X_i 为扫描仪扫描得到的 RGB 值得列向量，作为输入值； Y_i 为模型中对应 CIE Lab 色空间的 Lab 值得列向量，作为输出值； M 为 X, Y 之间对应的转换关系； i 为颜色样本。

通过寻找相应映射关系 M ，使模型预测值 Y_i 无限接近分光光度计实际测量值便是彩色扫描仪特征化的关键所在。

2 最小二乘支持向量机 (LSSVM) 原理

由扫描仪获取的图像三通道 RGB 值与对应的 Lab 存在非线性映射关系，而 LSSVM 可较好地解决小样本非线性映射问题，因此，文中采用 LSSVM 实现 CIE Lab 色度值的预测。

在回归模型中， m 个样本点的训练集 $D = \{(x_i, y_i), i=1, 2, \dots, m\}$ 有 n 维输入 t 维输出，通过非线性关系转换到高维特征空间^[10-13]，即：

$$f(x_i)_j = \omega_j^T \varphi(x_i) + b_j \quad (i=1, 2, \dots, m; j=1, 2, \dots, t) \tag{2}$$

由结构风险最小化原则，结合正则化损失函数，式 (2) 可等价于：

$$\begin{cases} \min J(\omega_j, e_{ij}) = \frac{1}{2} \left(\omega_j^T \omega_j + \gamma \sum_{i=1}^m \sum_{j=1}^t e_{ij}^2 \right) \\ \text{条件 } y_{ij} = \omega_j^T \varphi(x_i) + e_{ij} + b_j \quad (i=1, \dots, t) \end{cases} \tag{3}$$

式中： γ 为惩罚因子； e_{ij} 为预测误差； $J(\omega_j, e_{ij})$ 为结构风险函数。

为求解上述优化问题，根据 Lagrange 函数等价于：

$$\begin{aligned} L(\omega_j, b_j, e_{ij}, \alpha_{ij}, \gamma) = \\ \frac{1}{2} \omega_j^T \omega_j + \frac{1}{2} \gamma \sum_{i=1}^m e_{ij}^2 - \sum_{i=1}^m \alpha_{ij} (\omega_j^T \varphi(x_i) + e_{ij} + b_j - y_{ij}) \end{aligned} \tag{4}$$

式中： α_{ij} 为 Lagrange 乘子。

对式 (4) 中 $(\omega_j, b_j, e_{ij}, \alpha_{ij})$ 分别求偏导数，转化为式 (5) 所示的方程：

$$\frac{\partial L}{\partial \omega_j} = 0 \Rightarrow \omega_j = \sum_{i=1}^m \alpha_{ij} \varphi(x_i)$$

$$\frac{\partial L}{\partial b_j} = 0 \Rightarrow \sum_{i=1}^m \alpha_{ij} = 0 \tag{5}$$

$$\frac{\partial L}{\partial e_{ij}} = 0 \Rightarrow \alpha_{ij} = \gamma e_{ij}$$

$$\frac{\partial L}{\partial \alpha} = 0 \Rightarrow \omega_j^T \varphi(x_i) + b_i + e_{ij} - y_{ij} = 0$$

消去 ω 与 e_{ij} ，可得以下矩阵方程：

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + 1/\gamma & \dots & K(x_1, x_M) \\ \vdots & \vdots & \dots & \vdots \\ 1 & K(x_1, x_1) & \dots & K(x_1, x_M) + 1/\gamma \end{bmatrix} \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_m \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_m \end{bmatrix} \tag{6}$$

式中： K 为核函数，由 Mercer 条件可得：

$$K(x_i, x_j) = \varphi(x_i) \varphi(x_j) \quad (i=1, 2, \dots, m; j=1, 2, \dots, t) \tag{7}$$

由式 (6) 可得 LSSVM 函数模型为：

$$f(x_i)_j = \sum_{i=1}^m \sum_{j=1}^t \alpha_{ij} K(x_i, x_j) + b_j \tag{8}$$

式 (7) 中的核函数 $K(x_i, x_j)$ 为高维特征空间的

内积,由泛函的相关原理,核函数需要满足 Mercer 条件。文中的核函数选择径向基函数(RBF):

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (9)$$

由此,将归一化(Min-Max Normalization)后的红、绿、蓝三通道值作为模型的输入,CIE Lab 作为模型的输出,通过网格搜索及 5 折交叉验证确定模型最优参数 σ 和 γ ,模型的泛化能力由预测集来验证。

3 基于最小二乘支持向量回归(LSSVR)的扫描仪特征化模型

3.1 模型的建立

将红(R)、绿(G)、蓝(B)共3个特征量作为支持向量机模型的输入 $x_i = [R \ G \ B]_i$,色度值 CIE Lab 为模型的输出 $y_i = [L \ a \ b]_i$,因此 100 组训练样本集为 $\{(x_i, y_i), i = 1, 2 \dots n, n = 100\}$ 。支持向量机通过非线性映射 $\phi(x)$ 函数将输入空间的样本 x 映射到多维特征空间 H 中^[14-16],并在多维特征空间 H 中利用结构风险最小化原则建立线性回归函数。

通过最小二乘支持向量机回归实现扫描仪特征化,详细步骤如下所述。

1) 实验样本数据归一化。因为样本数据中三通道数值跨度较大,在建立回归模型之前将样本集数据归一化到[0, 1],归一化方法为:

$$x'_i = (x_i - x_{\min}) / (x_{\max} - x_{\min})$$

式中 x_i 为待归一化数据; x'_i 为归一化之后数据; x_{\min} 为最小值; x_{\max} 为最大值。

2) LSSVM 参数寻优。将 100 组训练样本数据作为输入,对应的 CIE Lab 作为模型输出,判断是否满足设定的终止条件,得出满足条件的最优参数 σ 和 γ 。

3) 建立 LSSVM 回归模型,并使用模型进行预测。由步骤 2) 得到最佳参数 σ, γ ,采用 RBF 核函数训练 LSSVR 回归建模,用训练后的模型对验证集样本回归预测。

4) 评价预测模型性能指标 RMSE, R 和 CIE DE2000^[17],若不符合要求则转至步骤 2),继续寻找最优参数。

5) 分别比较训练集真实值、预测值以及验证集真实值、预测值。得出模型的 RMSE, R-square。

6) 应用最小二乘法支持向量机模型预测,并对结果进行反归一化处理,分别得出预测集和训练集对应的 CIE DE2000 色差,并对模型进行评价。

3.2 实验验证与分析

实验中所用到的扫描仪为 Epson Perfection V370

Photo,扫描分辨率为 300 dpi(dot per inch),图像保存为 TIFF 格式,关闭扫描仪的色彩校正功能。选用 X-Rite ColorChecker Digital SG(共 140 色块)作为标准测试色卡。色卡中各色块的 CIE Lab 值用 X-Rite eXact Advanced Spectrophotometer 单点测量得到,其中,测量条件为 D50 光源、2°视场、M1 模式、T 状态响应、2 mm 测量孔径。对应光谱取值范围 400 ~ 700 nm,波长间隔为 10 nm。色卡扫描图像各色块的三通道 RGB 值通过 Matlab 图像处理工具箱中的 imread 函数批量读取,每个色块的 RGB 值取自各色块中心 50 像素×50 像素区域内的平均值。ColorChecker Digital SG 色卡扫描后图像见图 1。

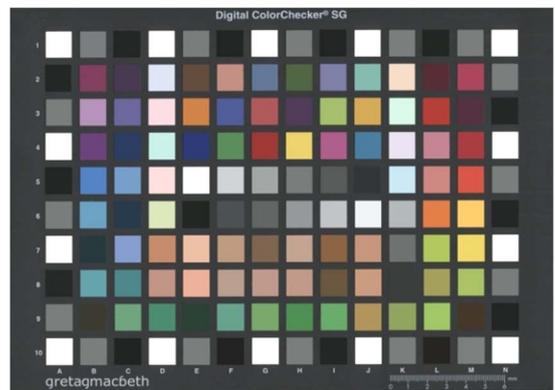


图 1 ColorChecker Digital SG 扫描图像
Fig.1 ColorChecker Digital SG scanned image

对实验所用到的 140 组数据样本随机选出 120 组作为训练集,剩余 20 组作为验证集。通过均方根误差 RMSE(Root Mean Squared Error)、相关系数 R-squared 以及 ΔE_{00}^* (CIEDE2000)等 3 个参数来分别评价训练集与验证集的预测值、测量值之间的差异。训练集、验证集的预测结果见表 1。

表 1 训练集、验证集的预测结果
Tab.1 Prediction results of training and validation sets

数据集	RMSE	R-squared	平均 ΔE_{00}^*	最小 ΔE_{00}^*	最大 ΔE_{00}^*
训练集	0.0098	0.9991	1.1463	0.1840	3.0102
验证集	0.0125	0.9988	1.2754	0.2482	2.8967

由表 1 可见训练集平均色差 ΔE_{00}^* 为 1.1463、最小色差 ΔE_{00}^* 为 0.184、最大色差 ΔE_{00}^* 为 3.0102。验证集平均色差 ΔE_{00}^* 为 1.2754、最小色差 ΔE_{00}^* 为 0.2482、最大色差 ΔE_{00}^* 为 2.8967,实验结果表明色差整体偏差值均小于文献[1,3,4]中的数值。其中,训练集与验证集的色差 95th 百分位数分别为:2.4583, 2.6101, 满足目前印刷工业对精细产品色彩复制的要求 ($\Delta E_{ab}^* < 3$)^[18]。

训练集与验证集 CIEDE2000 整体色差分布见图 2。

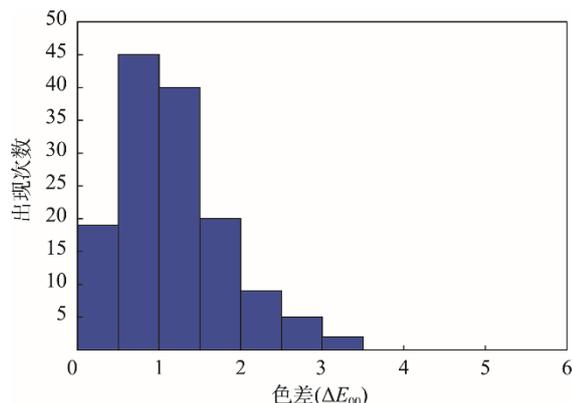


图 2 训练集与验证集 CIEDE00 色差分布直方图

Fig.2 Histogram of CIEDE00 color differences of training and validation sets

通过验证集数据可以看出 LSSVR 模型的泛化能力较好, 根据训练集样本训练后得出最佳模型参数, 然后对验证集样本进行预测, 得出对应的验证集的预测值, 此值与验证集真实值吻合很好。

通过 LSSVR 得出的非线性映射模型与传统神经网络结果相比, 无论在拟合的精度, 还是色差的分布上都有了极大的提高, 并且需要的训练样本数量更少。与传统的支持向量机 (SVM) 相比, 最小二乘支持向量机回归算法中, 所有的训练点均作为支持向量, 相比支持向量机求解凸二次规划的复杂计算, 最小二乘支持向量机回归转化为线性方程组求解问题, 并且误差作为重要的优化目标。对于小批量的样本集, LSSVR 的学习速度、求解速度也更佳。

4 结语

文中基于最小二乘支持向量机回归建立扫描仪特征化模型, 采用交叉验证以及网格搜索方法得出模型最优参数, 可快速、准确得出扫描仪的 RGB 值与 CIE Lab 色度值之间的非线性映射关系, 可以很好地处理小样本、非线性映射的问题, 模型具有较好的泛化能力。实验结果表明, 提出的基于最小二乘支持向量回归模型预测精度较好, 与传统的支持向量机回归、多项式拟合、神经网络回归方法相比颜色色差优势明显, 可以作为扫描仪色度特征化的方法。

参考文献:

- [1] 王勇, 徐海松. 基于多项式回归模型的扫描仪色度特征化[J]. 光学学报, 2007(6): 1135—1138.
WANG Yong, XU Hai-song. Colorimetric Characterization for Scanner Based on Polynomial Regression Models[J]. Acta Optica Sinica, 2007(6): 1135—1138.
- [2] KANG H R, ANDERSON P G. Neural Network Application to the Color Scanner and Printer Calibrations[J]. Electronic Imaging, 1992, 1(2): 125—135.
- [3] 徐艳芳, 刘文耀, 左坤隆, 等. 彩色扫描仪的特征化[J]. 光学精密工程, 2004(1): 15—20.
XU Yan-fang, LIU Wen-yao, ZUO Kun-long, et al. Characterization of Color Scanners[J]. Optics and Precision Engineering, 2004, 12(1): 15—20.
- [4] 李斌, 张扬, 张逸新. 基于 SVM 的彩色扫描仪特征化[J]. 包装工程, 2011, 32(3): 81—83.
LI Bin, ZHANG Yang, ZHANG Yi-xin. Characterization of Color Scanner Based on SVM[J]. Packaging Engineering, 2011, 32(3): 81—83.
- [5] 李斌, 张逸新. CIE DE2000 在彩色扫描仪特征化色差评价中的应用[J]. 包装工程, 2011, 32(13): 82—85.
LI Bin, ZHANG Yi-xin. Application of CIE DE2000 in Characterization of Color Difference in Color Scanner[J]. Packaging Engineering, 2011, 32(13): 82—85.
- [6] WANG Hai-feng, HU De-jin. Comparison of SVM and LS-SVM for Regression[C]// 2005 International Conference on Neural Networks and Brain, 2005: 279—283.
- [7] HEALEY G, SHI M. Using Reflectance Models for Color Scanner Calibration[J]. Journal of the Optical Society of America A, 2002, 19(4): 645—656.
- [8] SHEN H L, XIN J H. Spectral Characterization of a Color Scanner by Adaptive Estimation[J]. JOSA A, 2004, 21(7): 1125—1130.
- [9] KHAN H A. Color Characterization Methods for a Multispectral Camera[J]. Electronic Imaging, 2018(16): 1—8.
- [10] SUYKENS J A K, VANDEWALLE J. Multiclass Least Squares Support Vector Machines[C]// International Joint Conference on Neural Networks, IEEE, 2008.
- [11] LIU L, HUANG W, WANG C. Hyperspectral Image Classification with Kernel-based Least-squares Support Vector Machines in Sum Space[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(4): 1144—1157.
- [12] SUYKENS J A K, BRABANTER J D, LUKAS L. et al. "Weighted Least Squares Support Vector Machines-robustness and Sparse Approximation"[J]. Neurocomputing, 2002(48): 85—105.
- [13] ZHANG W F, DAI D Q. Spectral Reflectance Estimation from Camera Responses by Support Vector Regression and a Composite Model[J]. Journal of the Optical Society of America A, 2008, 25(9): 2286—2296.
- [14] XU S, AN X, QIAO X, et al. Multi-Output Least-squares Support Vector Regression Machines[J]. Pattern Recognition Letters, 2013, 34(9): 1078—1084.
- [15] SENGUR A. Multiclass Least-Squares Support Vector Machines for Analog Modulation Classification[J]. Expert Systems with Applications, 2009, 36(3): 6681—6685.
- [16] NASIRI J A, CHARKARI N M, JALILI S. Least Squares Twin Multi-class Classification Support Vector Machine[J]. Pattern Recognition, 2015, 48(3): 984—992.
- [17] LUO M R, CUI G, RIGG B. The Development of the CIE2000 Colour-difference Formula: CIEDE2000[J]. Color Research & Application, 2001, 26(5): 340—350.
- [18] 胡成发. 印刷色彩与色度学[M]. 北京: 印刷工业出版社, 1993: 182—190.
HU Cheng-fa. Printing Color and Colorimetry[M]. Beijing: Printing Industry Press, 1993: 182—190.