

改进型 RBF 神经网络的多标签算法研究

李书玲 刘 蓉 刘 红

(华中师范大学物理科学与技术学院 武汉 430079)

摘要 针对已有的 RBF 神经网络多标签算法未充分考虑多个样本标签之间的关联性,从而导致泛化性能受到一定影响的问题,研究分析了一种改进型 RBF 神经网络的多标签算法。该算法首先优化隐含层 RBF 神经网络基函数中心求取算法—— k 均值聚类。采用 AP 聚类自动寻找 k 值以获得隐含层节点数目,并构造 Huffman 树来选取初始聚类中心以防 k -均值聚类结果陷入局部最优。然后构造体现标签类之间信息的标签计数向量 C ,并将其与由优化 k -均值聚类得到的聚类中心进行线性叠乘,进而改进 RBF 神经网络基函数中心,建立 RBF 神经网络。在公共多标签数据集 emotion 上的实验表明了该算法能够有效地进行多标签分类。

关键词 多标签学习, RBF 神经网络, k -均值聚类, AP 聚类

中图分类号 TP18 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.4.065

Multi-label Learning for Improved RBF Neural Networks

LI Shu-ling LIU Rong LIU Hong

(College of Physical Science and Technology, Central China Normal University, Wuhan 430079, China)

Abstract A modified multi-label radial basis function (RBF) neural network algorithm that can fully consider the relationship between numbers of sample labels was presented. This improved algorithm is based on the fact that ignoring the relevance between sample labels may cause potential performance loss. The modified algorithm first optimizes the RBF basis function center calculation algorithm in hidden layer, i. e. k -means clustering. AP clustering is used to automatically find k values to obtain the node number of hidden layer and a Huffman tree is constructed to select the initial cluster centers to prevent the k -means clustering results falling into local optimal. Then a label counting vector C that reflects the correlation between the labels is constructed, and it is linearly multiplied with the clustering centers which are obtained through k -means clustering optimization to optimize the RBF basis function center and establish RBF neural network. Experiments using the public multi-label emotion data sets demonstrate the effectiveness of the proposed algorithm.

Keywords Multi-label learning, RBF neural networks, k -means clustering, AP clustering

1 引言

随着科技的发展,智能人机交互技术逐步进入人们的生活。人脸识别、语音识别、身份识别等识别技术在智能人机交互技术中都有一定的应用,而这些技术归根结底是模式识别中的分类问题。在分类问题中,多标签分类^[1]比较常见,它是用一个实例(描述对象的实物)代表每个样本,但每个样本可以同时属于多个类别标签。此种分类方式符合人们事物情感认知观念,在实际生活中有重要的研究价值,现已逐渐成为国际机器学习学术界一个新的研究热点^[2,4]。

多标签研究中,早期的研究主要集中于多标签文本分类。研究者主要从多标签处理、性能评价指标以及改进传统机器学习算法 3 方面进行研究。近十年来,随着信息技术的提高以及信息多元化的发展,多标签分类技术已广泛用在多媒体内容的自动标注^[5]、生物学基因功能组信息^[6]、娱乐(音乐、电影等分类)、信息检索^[7,8]等较多领域。在此领域内,多标签

研究多数是在原有分类算法基础上的改进与优化。例如 Crammer 和 Singer^[9]改进感知机算法进行多标签文本学习。Youngmoo E. Kim 和 Erik M. Schmidt^[10]等研究基于音乐情感分类的多标签学习。而 Barutcuoglu 等人^[11]提出了基于贝叶斯学习框架方法,更好地预测基因功能。文献^[12]是对多标签研究的总结,总结了多标签的一些基本概念、评价指标,并比较了几种代表性的多标签学习算法。如何充分挖掘并运用标签之间的关联性是深入研究多标签的关键。文献^[13]中 ML-KNN 懒惰学习算法将多标签问题转化成多个独立的两类分类问题来解决。此种学习算法忽略了标签之间的关联性,分类效果不佳。针对文献^[13]存在的问题,文献^[14]做了两大改进。首先,逐一确定与每个类对应的样本构成的训练集中测试样本的近邻,以充分利用训练集蕴含的数据信息;其次,在标签类的预测中,通过线性分类器将标签计数向量中所有标签类的信息综合起来加权到每个预测样本上,充分利用标签之间的相关性;最后,在实验数据集上验证,得到了很

到稿日期:2014-05-03 返修日期:2014-09-10 本文受国家自然科学基金:大众分类中标签间语义关系挖掘研究(12BTQ038)资助。

李书玲(1988-),女,硕士生,主要研究方向为智能信息处理与模式识别,E-mail:ls1880129@163.com;刘 蓉(1969-),女,硕士生导师,主要研究方向为智能信息处理、模式识别;刘 红(1988-),女,硕士生,主要研究方向为模式识别。

好的分类效果。又比如文献[15]是考虑了标签之间关联性的多标签贝叶斯网络算法,通过在数据集上进行实验,充分证明了算法的有效性。

文献[16]是基于 RBF 神经网络的多标签识别算法,它采用 k -均值聚类求取每一类样本的聚类中心,并将其作为 RBF 神经网络的基函数中心,构造 RBF 神经网络算法。在多标签数据集上进行实验,验证 ML-RBF 算法取得了满意的实验效果。但在文献[16]中,聚类中心是对每一类通过 k -均值聚类求得。虽然在输出层上聚类中心结合在一起进行预测,一定程度上考虑了标签之间的相关性,但其没有被充分考虑。本文改进 RBF 神经网络基函数中心的求解方法,具体做法是:首先优化隐含层基函数中心求取算法—— k -均值聚类。采用 AP 聚类^[17](Affinity Propagation)自动寻找 k 值,以获得隐含层节点数目;采用 Huffman 树选取初始聚类中心,以防止 k -均值聚类结果陷入局部最优。然后参考文献[14]构造能充分蕴含标签类之间关联性的标签计数向量,并将其线性加权到优化 k -均值聚类后求得的每一类基函数中心上。这种处理方法不但在输出层上将聚类中心结合在一起进行预测,考虑了标签关联性,而且在聚类中心求解阶段通过与标签计数向量线性叠乘,同样考虑了标签之间的关联性。因此,求得的基函数中心充分考虑了标签之间的关联性。最后,建立 RBF 神经网络分类模型,进行改进型 RBF 神经网络的多标签算法研究。

2 多标签的 RBF 神经网络算法

对多标签分类问题,RBF 神经网络的基本思想是:用径向基函数作为隐含层的节点激活函数,将输入层的低维线性不可分数据变换成输出层的高维数据,使其在高维空间中变得线性可分。隐含层节点激活函数以及隐含层到输出层的权重是训练 RBF 神经网络模型,进行多标签分类的关键。

图 1 示出多标签的 RBF 神经网络结构。在输入层,输入样本含有 d 维特征,记为 $x = (x_1, x_2, \dots, x_d)^T$ 。 L 代表总的标签类别, $l(l \in L)$ 表示其中的一类标签。在隐含层,把属于每一类的样本进行 k -均值聚类, k -均值聚类后,得到 k 个聚类中心,用 $\{c_1^l, c_2^l, \dots, c_k^l\}$ 表示,并将 c_j^l 作为径向基函数 $\phi_j^l(\cdot)$ 的中心。 w 表示隐含层到输出层之间的权重。 y 代表输出层。




图 1 多标签的 RBF 神经网络结构

多标签的 RBF 神经网络算法输出判别式为:

$$y_l(x_i) = \sum_{j=0}^k w_{jl} \exp\left(-\frac{\text{dist}(x_i, c_j^l)^2}{2\sigma_j^2}\right) \quad (1)$$

其中,权重 w 的维数为 $K+1$,表示隐含层节点的数目。 $K = \sum_{l=1}^L k_l$,加 1 是对偏置 bias 的处理:为其添加带有权重 w_{0l} 的偏

置函数 $\phi_0(\cdot)$,并设置权值为 1。 w 通过最小化误差平方和函数^[16](least sum-of-squares error function)求解。 $\text{dist}(x_i, c_j)$ 计算 x_i 与 c_j 之间的欧氏距离。而基函数方差——平滑参数 σ ,通过计算每类之间基函数中心的平均距离来获得,如式(2)所示。

$$\sigma = \mu \left(\frac{\sum_{p=1}^{K-1} \sum_{q=p+1}^K \text{dist}(c_p, c_q)}{K(K-1)} \right) \quad (2)$$

其中, μ 为比例因子。

基于 RBF 神经网络的分类器模型工作方式是根据权重 w 将输入向量映射到输出空间。而在输入空间中,如何构造以多标签数据为基础的高斯函数形式的基函数中心,是 RBF 神经网络改进的重点。

3 基于多标签的 RBF 神经网络参数优化

改进型 RBF 神经网络的多标签算法整体流程如图 2 所示。




图 2 改进型 RBF 神经网络的多标签算法流程

在图 2 中,首先优化 k -均值聚类求取基函数中心 c 的过程。采用 AP 聚类优化 k -均值聚类的 k 值,利用 Huffman 树构造方法选取 k -均值聚类的初始聚类中心。然后统计每一类的标签计数向量,并与每一类的基函数中心线性叠乘,建立 RBF 神经网络模型,对多标签进行分类后输出结果 y 。

3.1 初始聚类中心的确定

RBF 神经网络算法的基函数中心采用 k -均值聚类进行求取,而 k -均值聚类在网络初始化阶段求取聚类中心时,传统做法是随机选取 k 个训练样本作为初始聚类中心。这种方法对聚类结果的影响有:

①选取的初始聚类中心不同,将使目标函数沿着不同的路径搜索最小值,容易陷入局部最优而不是全局最优。

②根据聚类结果的可理解性,可以反推出很多不同的初始聚类中心。因此随机选择聚类初始中心,会导致聚类结果的不稳定。

为了克服聚类算法选择初始聚类中心的不利问题,本文参考文献[18]采用基于 Huffman 树选取 k -均值聚类的初始聚类中心。Huffman 树的构造过程考虑了样本之间的相似性,使得找到的初始聚类中心在聚类结果中更准确。基于 Huffman 树的 k -均值聚类构造初始聚类中心的具体步骤如下:

Step1 首先采用欧氏距离计算数据样本之间的相似性,并将结果存成相异度矩阵形式。

Step2 找出相异度矩阵中非零最小值,并确定它是哪两个样本的相异度,再将两个样本的平均值作为中间结点加入到删除这两个样本后的样本数据中,组成新的数据集。

Step3 重复步骤 Step1 和 Step2,直到新的数据集中为

一个样本时终止。

Step4 假设需要将数据样本聚成 k 类, Huffman 树构造完毕后, 按构造结点的逆序顺序删掉 $k-1$ 个结点, 就得到了 Huffman 树的 k 个子树。其中 k 个子树的平均值就是 k -均值聚类的初始聚类中心。

3.2 k 值的确定

k -均值聚类方法因其简单且在实践中表现出色而被广泛使用。但此种方法在使用时需要事先给出 k 值。然而很多情况下, 对于给定的数据集并不知道分成几类最合适。

AP 聚类 (Affinity Propagation) 是一种无监督聚类算法, 它不需要给出聚类个数, 而是将所有的样本点都作为潜在的聚类中心。首先, 采用欧氏距离计算样本点的相似程度, 并将相似程度矩阵对角线上的数值作为聚类中心的参考度值 (preference), 该值越大, 最终获得的聚类中心个数越多; 该值越小, 最终获得的聚类中心个数越少。然后, 通过迭代方式不断更新每一数据点的吸引度值 (responsibility) 和归属度值 (availability)。最后, 根据设定的迭代次数或迭代多少次聚类中心不再发生变化来设置终止条件, 从而产生 m 个聚类中心, 并将其余数据分配到相应的聚类中^[17]。因此, 在进行 k -均值聚类之前首先采用 AP 聚类自动寻找合适的 k 值。

3.3 标签计数向量的求解

本文采用文献[14]的多标签懒惰学习算法 (Multi-Label lazy learning approach, IMLLA) 思想, 对多标签 RBF 神经网络算法进行改进, 以充分挖掘和利用标签之间的关联性。

假设用 $X=R^d$ 表示样本空间, d 代表每个样本 x_i 有 d 维的属性值。 $Y=\{1, 2, \dots, Q\}$ 是所有可能标签组成的标签集合。对于样本 $x \in X$ 以及标签集合 $Y_i \subseteq Y$, 多标签数据集可用式(3)表示。

$$D = \{(x_1, Y_1), (x_2, Y_2) \dots (x_i, Y_i) \dots (x_m, Y_m), (x_i \in X, Y_i \subseteq Y, 1 \leq i \leq m)\} \quad (3)$$

其中, y_x 是与 x 对应的 Q 维类别向量, 当 $l \in Y$ 时, $y_x(l) = 1$; 当 $l \notin Y$ 时, $y_x(l) = -1$ 。另外, 设 $T_l = \{x_i | (x_i, Y_i) \in T, l \in Y_i\}$ 代表具有标签 l 的样本构成的集合。在每一类的 T_l 中找出 k 个近邻样本作为此类代表, 记做 N_x^l , 如式(4)所示。

$$N_x^l = \{z | z \text{ is among the } k \text{ nearest neighbor of } x \text{ in } T_l\} \quad (4)$$

其中, 寻找 k (本文 $k=10$) 近邻样本采用欧氏距离计算方法。

为综合运用标签集的其他类样本在每一类样本上蕴含的信息, 定义了 Q 维的标签计数向量 C_x (label counting vector)^[14]。首先统计每一类标签中等于 1 的样本, 然后对每一类样本 k -近邻, 并将 k -近邻后的每一类样本组合在一起。最后对新的标签集合中的每一类标签, 重新计算等于 1 的样本总个数, 如式(5)所示。

$$C_x(l) = \sum_{q \in Y} \sum_{\tau \in N_x^q} [|y_\tau(l) = 1|], l \in Y \quad (5)$$

最后将 $C_x(l)$ 与 k -均值聚类求得的每类基函数中心线性叠乘。此时基函数中心如式(6)所示。

$$C_{(l)} = c_{(l)} \cdot C_x(l), l \in Y \quad (6)$$

其中, $c_{(l)}$ 为 k -均值聚类求得的每一类 k 个聚类中心, 而 $C_{(l)}$ 就是线性加权后的每一类聚类中心。这样获得的 RBF 神经网络基函数中心考虑了整个标签向量在每一聚类中心上的综合权重信息, 充分体现了各个标签之间的相关性。

3.4 基函数中心的确定

RBF 神经网络采用的径向基函数通常是高斯函数, 而高斯函数的意义即典型代表每一类。本文采用改进型 k -均值聚类求取高斯函数中心。

标签计数向量 $C_x(l)$ 考虑了标签之间的关联性。将 $C_x(l)$ 与高斯中心线性叠乘, 相当于为每一类的典型代表添加了关联性权值, 可以理解为: 如果某一类样本属于多个标签, 属于的多个标签在多标签累计中出现的次数就会增加, 权重就会变大; 如果此样本属于单标签, 那么它仅在其中一类标签中出现一次, 而在其他类标签累计中出现的次数就会减少, 权重就会变小。

总结求取 RBF 神经网络多标签算法基函数中心的求解方法, 步骤如表 1 所列。

表 1 改进型 RBF 神经网络的多标签算法伪代码

目标: 求取改进型 RBF 神经网络的多标签算法基函数中心
输入: 训练集 $D = \{(x_1, Y_1), (x_2, Y_2) \dots (x_i, Y_i) \dots (x_m, Y_m), (x_i \in X, Y_i \subseteq Y, 1 \leq i \leq m)\}$
过程: 1. AP 聚类寻找 k 值。
2. 每一类标签进行基于 Huffman 树方法求取初始聚类中心。
3. k -均值聚类, 得到每一类的 RBF 神经网络基函数中心 $c_{(l)}$ 。
4. 计算标签计数向量 $C_x(l)$ 。
for $l \in Y$ do
计算 N_x^l
end for
计算 $C_x(l)$
end
5. $C_{(l)} = c_{(l)} \cdot C_x(l), l \in Y$, 计算 RBF 神经网络基函数中心。

4 实验结果与分析

为验证改进型 RBF 神经网络的多标签算法的有效性, 在公共多标签数据集 emotion^[19] 上进行测试。数据集样本由 593 首音乐组成, 每首音乐都提取常用的节奏和音色两类特征。节奏类特征提取的是节拍柱形图的周期变化, 分别有: 每秒的节拍数 (BPMs)、BPMs 的高比率、BPMs 的低比率、最大峰、第二最大峰的幅度值以及由 40-90, 90-140, 140-250 节拍柱状图累加起来得到的 3 个特征; 提取的音色类特征有梅尔频率倒谱系数 (MFCC, 本文提取前 13 维的 MFCC)、短时傅里叶变换的谱质心、谱滚边、谱通量, 并为此音色特征计算了 4 个统计学变化参数, 包括均值、方差、平均标准差、标准差的标准差。这样共组成 72 维特征。根据特征和情感之间的关系, 专家对音乐进行标记, 共标记 6 种标签, 分别是惊讶的-惊奇的 (amazed-surprised)、高兴的-喜悦的 (happy-pleased)、放松的-镇静的 (relaxing-calm)、安静的-寂静的 (quiet-still)、悲伤的-孤独的 (sad-lonely)、生气的-恐惧的 (angry-fearful)。其中, 178 首音乐被标记为单标签, 315 首音乐被标记为双标签, 100 首音乐被标记为 3 个标签, 平均标签个数为 1.87。

评价多标签数据的分类结果, 需要选用多标签性能度量指标。本文采用了常用的 5 种多标签评价标准^[20], 分别是汉明损失 (hamming loss)、1 错误率 (one-error)、覆盖率 (coverage)、排序损失 (ranking loss) 以及平均准确度 (average precision)。

在实验中, 随机选择数据集的 2/3 作训练集, 1/3 作测试集进行实验, 每次都按此选择, 共进行 20 次实验。对于任何一种评价指标, 都是数据集进行多次实验结果的平均值。为

使结果清晰,对实验的最优结果进行加粗,并用符号“↑”、“↓”表示评价指标的好坏,“↑”表示数据越大越好,“↓”表示数据越小越好。另外,本文采用式(7)进行算法的5种多标签评价指标实验结果对比。

数据结果提高率=

$$\frac{|\text{本文算法平均数据结果}-\text{原算法平均数据结果}|}{\text{原算法平均数据结果}} \times 100\%$$

(7)

4.1 k-均值聚类初始聚类中心确定结果比较

本实验采用 Huffman 树方法确定初始聚类中心与随机选择初始聚类中心两种方法优化 k-均值聚类,并在多标签数据集 emotion 上进行基于 RBF 神经网络的多标签实验,结果如表 2 所列。

表 2 k-均值聚类中随机选择初始聚类中心与 Huffman 树选取初始聚类中心在 emotion 数据集上的实验结果比较(均值±标准差)

评价标准	两种方法		
	随机选初始聚类中心	Huffman 树选初始聚类中心	数据结果提高率/%
average precision ↑	0.7330±0.0150	0.7361±0.0168	0.42
coverage ↓	2.1468±0.1144	2.1303±0.1108	0.77
hamming loss ↓	0.6168±0.0092	0.6141±0.0095	0.44
one-error ↓	0.3682±0.0258	0.3627±0.0268	1.49
ranking loss ↓	0.2339±0.0194	0.2321±0.0212	0.77

由表 2 可知,采用 Huffman 树选定初始聚类中心优化 k-均值聚类与随机选取初始聚类中心优化 k-均值聚类进行比较。在时间方面,虽然本文改进方法在运行 matlab 整体仿真代码所用时间 116.9695s 比随机选择初始聚类中心 matlab 整体仿真代码所用时间 7.4568s 长,但本文方法在 5 种多标签评价指标上得到了更好的评价结果,分别在 average precision 上数据提高了 0.42%,在 coverage 上数据提高了 0.77%,在 hamming loss 上数据提高了 0.44%,在 one-error 上数据提高了 1.49%,在 ranking loss 上数据提高了 0.77%。这充分表明了采用 Huffman 树选定初始聚类中心优化 k-均值聚类的适用性。

4.2 k 均值聚类 k 值选择结果比较

本实验采用 AP 聚类选取 k 值与样本比例选取 k 值(即每一类样本个数乘以相应比例,然后对数据取整得 k 值。本文相应比例 ratio=0.01)两种方法优化 k-均值聚类,并在多标签数据集 emotion 上进行基于 RBF 神经网络的多标签实验,结果如表 3 所列。

表 3 k-均值聚类中样本比例选取 k 值与 AP 聚类选取 k 值在 emotion 数据集上的实验结果比较(均值±标准差)

评价标准	两种方法		
	样本比例选取 k 值	AP 聚类选取 k 值	数据结果提高率/%
average precision ↑	0.7374±0.0168	0.7754±0.0139	5.15
coverage ↓	2.0933±0.0904	1.9403±0.0823	7.31
hamming loss ↓	0.6150±0.0110	0.5444±0.0142	11.48
one-error ↓	0.3620±0.0301	0.3105±0.0289	14.23
ranking loss ↓	0.2302±0.0170	0.1928±0.0135	16.25

从表 3 可知,采用 AP 聚类选取 k 值与采用样本比例选取 k 值对 k-均值聚类进行优化,在时间方面,虽然本文改进方法在运行 matlab 整体仿真代码所用时间 403.7774s 比样本比例选取 k 值 matlab 整体仿真代码所用时间 7.5816s 长,但

本文方法的数据在 5 种多标签评价指标上都得到了提高,分别在 average precision 上数据提高了 5.15%,在 coverage 上数据提高了 7.31%,在 hamming loss 上数据提高了 11.48%,在 one-error 上数据提高了 14.23%,在 ranking loss 上数据提高了 16.25%。这充分说明了采用 AP 聚类寻找 k 值优化 k-均值聚类的有效性。

4.3 多标签关联性实验结果比较

本实验将充分体现标签之间关联性的权重——标签计数向量与 RBF 神经网络基函数中心线性叠乘,在多标签数据集 emotion 上进行基于 RBF 神经网络的多标签实验,结果如表 4 所列。

表 4 不考虑标签关联性与考虑标签关联性在 emotion 数据集上的实验结果比较(均值±标准差)

评价标准	两种方法		
	不考虑标签关联性	考虑标签关联性	数据结果提高率/%
average precision ↑	0.7420±0.0206	0.7638±0.0122	2.94
coverage ↓	2.1097±0.1286	1.9670±0.0771	6.76
hamming loss ↓	0.6057±0.0121	0.5966±0.0127	1.50
one-error ↓	0.3515±0.0334	0.3283±0.0259	6.60
ranking loss ↓	0.2261±0.0218	0.2006±0.0115	11.28

表 4 列出了使用考虑标签之间关联性与不考虑多标签之间关联性两种方法进行多标签实验的结果。虽然在时间方面,本文考虑标签关联性在运行 matlab 整体仿真代码所用时间 7.9717s 比不考虑标签关联性运行 matlab 整体仿真代码所用时间 6.8796s 稍长,但本文方法在评价指标上都得到了不同程度的提高,分别在 average precision 上数据提高了 2.94%,在 coverage 上数据提高了 6.76%,在 hamming loss 上数据提高了 1.50%,在 one-error 上数据提高了 6.60%,在 ranking loss 上数据提高了 11.28%。这表明了进行多标签实验时充分考虑标签关联性的必要性。

4.4 改进型 RBF 神经网络的多标签实验结果比较

根据改进型 RBF 神经网络求取基函数中心的确定规则,将体现标签之间关联性的权重——标签计数向量与优化后的基函数中心线性叠乘,在多标签数据集 emotion 上进行多标签实验。表 5 比较了各多标签算法在 emotion 数据集上的实验结果。

表 5 5 种多标签算法在 emotion 数据集上的实验结果对比(均值)

评价标准	算法				
	本文	BR ^[21]	LP ^[22]	2BR ^[21]	ML-KNN ^[13]
average precision ↑	0.7902	0.7378	0.7632	0.7392	0.7104
coverage ↓	1.8783	2.4378	1.9300	2.4482	2.2715
hamming loss ↓	0.5389	0.1943	0.1964	0.1953	0.2616
one-error ↓	0.2833	0.3038	0.3389	0.2964	0.3894
ranking loss ↓	0.1784	0.2776	0.1867	0.2770	0.2603

由表 5 可以看出,本文算法结果除了评价指标 hamming-loss 外,在 average precision、coverage、one-error、ranking loss 4 个指标上都比 BR(Binary Relevance)算法、LP(Label Power set)算法、2BR(Twice Binary Relevance)算法、ML-KNN(Multi-label k-nearest neighbor)算法有所提高。但是,本文算法在本次实验进行中,运行 matlab 整体仿真代码所用时间为 749.8125s,运行时间较长。

为了综合评价各算法在 5 种评价指标上的表现情况,本

文采用了文献[14]两两算法比较并用得分机制来对算法进行比较的方法。例如假设有 A1 和 A2 两种算法,如果 $A1 > A2$,则 A1 得 1 分,A2 得 -1 分。按这种思想,本文对 5 种算法两两之间进行相互比较,最后每一算法的 5 种评价指标获得的得分加在一起,根据得分对算法总体排名,从而得知哪种算法最好。表 5 处理后的结果如表 6 所列。

表 6 5 种多标签算法在各性能上的整体评价

评价标准	5 种多标签算法	
	A1=本文, A2=BR, A3=LP, A4=2BR, A5=ML-KNN	
average precision ↑	A1>{A2, A3, A4, A5}, A2>A5, A3>{A2, A4, A5}, A4>{A2, A5}	
coverage ↓	A1>{A2, A3, A4, A5}, A2>A4, A3>{A2, A4, A5}, A5>{A2, A4}	
hamming loss ↓	A2>{A1, A3, A4, A5}, A3>{A1, A5}, A4>{A1, A3, A5}, A5>A1	
one-error ↓	A1>{A2, A3, A4, A5}, A2>{A3, A5}, A3>A5, A4>{A2, A3, A5}	
ranking loss ↓	A1>{A2, A3, A4, A5}, A3>{A2, A4, A5}, A4>A2, A5>{A2, A4}	

由表 6 可以得出,虽然 BR 算法就 hamming loss 指标在 5 种算法中是最优的,但整体来看,此算法却排在了第三位,而本文算法获得了最高分数 12 分,排在了第一位,从而证明了本文算法进行多标签实验的优越性。

结束语 本文设计了改进型 RBF 神经网络的多标签算法,在 emotion 数据集上进行多标签实验,并与参考文献的各类算法进行了评价比较。结果表明,本文将体现多标签之间关联性的标签计数向量与优化后的基函数中心线性叠乘,对 RBF 神经网络进行改进,可以得到较好的多标签评价结果。但此算法仍存在不足,如在采用 Huffman 树构造 k -均值聚类初始聚类中心时,虽得到了良好结果,但以牺牲计算速度为代价。如何在提高多标签评价结果的同时减少运行 matlab 整体仿真代码所用时间,有待进一步研究。另外,本文仅在 emotion 多标签数据集上进行了实验验证,多标签数据集单一,所以扩大多标签数据领域,进行充分的实验比较,使得到的结果更具有说服力,也是以后工作的方向。

参 考 文 献

[1] Bucak S S, Jin R, Jain A K. Multi-label learning with incomplete class assignments[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Colorado Springs, CO, 2011: 2801-2808

[2] 张敏灵,周志华.多标签学习[M].北京:清华大学出版社,2011

[3] 李宇峰,黄圣君,周志华.一种基于正则化的半监督多标记学习方法[J].计算机研究与发展,2012,49(6):1272-1278

[4] 孔祥南,黎铭,姜远,等.一种针对弱标记的直推式多标记分类方法[J].计算机研究与发展,2010,47(8):1392-1399

[5] Sanden C, Zhang J Z. Enhancing multi-label music genre classification through ensemble techniques[C]//Proceedings of the 34th international ACM SIGIR conference on Research and Development in Information Retrieval. Beijing, China, 2011: 705-714

[6] Li Guo-zheng, You Ming-yu, Ge Le, et al. Feature selection for

semi-supervised multi-label learning with application to gene function analysis[C]//Proceedings of the First ACM International Conference on Bioinformatics and Computational Biology. Niagara Falls, New York, 2010: 354-357

[7] Gopal C, Yang Y. Multi-label classification with meta-level features[C]//Proceedings of the 33rd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. Geneva, Switzerland, 2010: 315-322

[8] 胡微微.基于语义分析的图像多标签标注算法研究[D].上海:华东理工大学,2013

[9] Crammer K, Singer Y. A new family of online algorithms for category ranking[C]//Proceedings of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, ACM, 2002: 151-158

[10] Kim Y E, Schmidt E M, Migneco R, et al. Music emotion recognition: A state of the art review[C]//11th International Society for Music Information Retrieval Conference. Utrecht, Netherlands, 2010: 255-266

[11] Barutcuoglu Z, Schapire R E, Troyanskaya O G. Hierarchical multi-label prediction of gene function [J]. Bioinformatics, 2006, 22(7): 830-836

[12] Zhang Min-ling, Zhou Zhi-hua. A review on multi-label learning algorithms[J]. IEEE Transactions on Knowledge and Data Engineering, 2014, 26(18): 1819-1837

[13] Zhang Min-ling, Zhou Zhi-hua. ML-kNN: A lazy learning approach to multi-label learning[J]. Pattern Recognition, 2007, 40(7): 2038-2048

[14] 张敏灵.一种新型多标记懒惰学习算法[J].计算机研究与发展, 2012, 49(11): 2271-2282

[15] Zhang Min-ling, Zhang Kun. Multi-label learning by exploiting label dependency[C]//Proceedings of the 16th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington, DC, USA, 2010: 999-1007

[16] Zhang Min-ling. ML-RBF: RBF neural networks for multi-label learning[J]. Natural Processing Letters, 2009, 29(2): 61-74

[17] 刘晓楠,尹美娟,李明涛,等.面向大规模数据的分层近邻传播聚类算法[J].计算机科学,2014,41(3):185-189

[18] 吴晓蓉. K-均值聚类算法初始中心选取相关问题的研究[D].长沙:湖南大学,2008

[19] Mulan 开源数据库 emotion 数据集[DB/OL]. [2014-3-4]. <http://source-forge.net/projects/mulan/files/datasets/emotions.rar/download> Mulan Open source database emotion Data set

[20] Zhou Zhi-hua, Zhang Min-ling, Huang Sheng-jun, et al. Multi-instance multi-label learning[J]. Artificial Intelligence, 2012, 176(1): 2291-2320

[21] Trohidis K, Tsoumakas G, Kalliris G, et al. Multi-label classification of music by emotion[J]. Journal on Audio, Speech, and Music Processing, Sep. 2011: 4

[22] Godbole S, Sarawagi S. Discriminative methods for multi-labeled classification[C]//Proceedings of the 8th Pacific-Asia Conference on Knowledge Discovery and Data Mining. Heidelberg, Berlin, 2004: 22-30