

基于改进k-means算法的数字图像聚类

高西, 胡子牧

引用本文:

高西, 胡子牧. 基于改进k-means算法的数字图像聚类[J]. 液晶与显示, 2020, 35(2): 173–179.

GAO Xi, HU Zi-mu. Digital image clustering based on improved k-means algorithm[J]. *Chinese Journal of Liquid Crystals and Displays*, 2020, 35(2): 173–179.

在线阅读 View online: <https://doi.org/10.3788/YJYXS20203502.0173>

您可能感兴趣的其他文章

Articles you may be interested in

基于分块颜色直方图和GWLBP的图像检索算法

Image retrieval algorithm based on block color histogram and GWLBP

液晶与显示. 2017, 32(9): 755–763 <https://doi.org/10.3788/YJYXS20173209.0755>

融合改进人工蜂群和K均值聚类的图像分割

Image segmentation algorithm based on improved artificial bee colony and K-mean clustering

液晶与显示. 2017, 32(9): 726–735 <https://doi.org/10.3788/YJYXS20173209.0726>

基于特征域聚类下Radon变换的火车票图像方向检测算法研究

Direction detection algorithm of train ticket images based on Radon transform with feature area clustering

液晶与显示. 2018, 33(12): 1033–1039 <https://doi.org/10.3788/YJYXS20183312.1033>

基于图论和FCM的图像分割算法

Image segmentation algorithm based on graph theory and FCM

液晶与显示. 2016, 31(1): 112–116 <https://doi.org/10.3788/YJYXS20163101.0112>

基于核模糊C-均值和EM混合聚类算法的遥感图像分割

Remote sensing image segmentation based on KFCM and EM hybrid clustering algorithm

液晶与显示. 2017, 32(12): 999–1005 <https://doi.org/10.3788/YJYXS20173212.0999>

文章编号:1007-2780(2020)02-0173-07

基于改进 k-means 算法的数字图像聚类

高 西, 胡子牧*

(重庆医科大学 附属大学城医院, 重庆 401331)

摘要:针对海量彩色图像聚类问题, 本文引入改进型 k-means 算法并将其应用于彩色图像聚类中。该算法由类内-类间距离加权 k-means 算法和基于近邻传播聚类算法的类数量上界确定方法组成。在实验中, 彩色图像的亮度分量的局部二值模式 (Local Binary Pattern, LBP) 图被重组成行向量, 然后构成样本集, 本文所提出的改进型 k-means 算法被用于对样本集进行聚类处理。实验结果显示, 在多个聚类方法常用的评价指标上, 本方法相比于传统方法达到了更高的聚类准确度。同时, 相比于传统方法, 本方法也更具有执行效率。

关键词:数字图像; k-means 聚类; LBP 特征

中图分类号:TP394.1; TH691.9 **文献标识码:**A **doi:**10.3788/YJYXS20203502.0173

Digital image clustering based on improved k-means algorithm

GAO Xi, HU Zi-mu*

(University-Town Hospital of Chongqing Medical University, Chongqing 401331, China)

Abstract: For the mass image clustering problem, the improved k-means algorithm is proposed and applied to the color image clustering. The algorithm consists of intraclass-interclass distance weighted k-means algorithm and nearest neighbor propagation clustering algorithm. In the experiment, the LBP map of the luminance component of the color image is reconstructed into a row vector and then constitutes a sample set. The improved k-means algorithm proposed in this paper is used to cluster the sample set. The experimental results show that the proposed method achieves higher clustering accuracy than the traditional methods in the evaluation indicators commonly used in multiple clustering methods. At the same time, the method is more efficient than traditional methods.

Key words: digital image; k-means clustering; LBP feature

1 引言

随着互联网、5G 等技术的飞速进步, 可收集的图片数据种类、数量越来越多, 数据特征的维度也越来越高。为了从海量图片中快速检索、

分类有用的图片, 许多研究者将聚类方法用于该领域^[1-5]。聚类是模式识别和数据挖掘中的一个重要方向, 是一类无监督学习算法, 它遵循相似规则将数据样本划分为不同的类, 在同一类中的对象之间相似性较高, 而在不同类中对象之间相似性较低。到目前为止, 很多研究者

收稿日期: 2019-07-22; 修订日期: 2019-10-21.

* 通信联系人, E-mail: huzimu0627@hotmail.com

提出了一些有效的聚类方法,例如 k-means^[6]、FCM^[7]、SOM 聚类^[8]、AP 算法^[9]、谱聚类算法^[10-13]。其中 k-means 算法以其对大型数据集的高处理效率而得到了最为广泛的应用。该算法的优点有很多,缺点主要在于:第一,只考虑类内距离,未考虑类间距离;第二,对包含海量样本的数据集的聚类数目上界的确定主要依靠经验,而人为设置的聚类数目上界往往偏大,导致了算法运行效率被降低。

有鉴于 k-means 算法的第一个缺陷,黄晓辉等^[14]提出了一种类内-类间距离加权的 k-means 算法,该算法的基本思路是,通过在子空间内最大化类中心与其他类内样本点的距离来融合类内和类间距离进行聚类。黄晓辉等在算法中设计了一个目标函数,然后通过求解目标函数来对算法参数进行迭代更新。在真实数据集上的表现证实了该算法相比于现有 k-means 类算法的优越性。针对传统 k-means 算法的第二个缺陷导致的聚类数目上界设置偏大,进而导致算法运行效率偏低的问题,周世兵等^[15]通过合理设置 AP 算法的初始参数确定了聚类数目的上界,该方法比传统的经验估计更为有效,大大提升了 k-means 算法的执行效率。本文提出了一种改进型的 k-means 算法,在该算法中,周世兵等提出的最小聚类上界确定方法与黄晓辉等提出的类内-类间距离加权 k-means 算法被合并使用。本文所提出的方法被用于一个标准聚类图像数据集的聚类中。实验结果显示,本文所提出的改进型 k-means 相比于传统 k-means 和另外几种 K-means 类算法,达到了更高的性能,同时执行效率也大为提升。

2 理 论

2.1 类内-类间距离加权 k-means 算法

与其他加权 k-means 算法类似,类内-类间距离加权 k-means 算法也包含 3 个计算步骤:更新分配矩阵 U 、更新类中心矩阵 Z 和更新特征权重矩阵 W 。

设有一包含 n 个 m 维样本的数据集 $X = \{X_1, X_2, \dots, X_n\}$ 。数据对象分配矩阵 $U \in R^{nk}$ 为一个只包含 0 和 1 的矩阵。 $Z = \{Z_1, Z_2, \dots, Z_k\}$ 为类中心矩阵,其中 $Z_p = \{z_{p1}, z_{p2}, \dots, z_{pm}\}$

为第 p 个类中心。 $W = \{W_1, W_2, \dots, W_k\}$ 为权重向量,其中 $W_p = \{w_{p1}, w_{p2}, \dots, w_{pm}\}$ 代表第 p 个类的特征权重, w_{pj} 为第 p 类中第 j 个特征的权重。该算法的目标函数如公式(1)所示。

$$P(W, U, Z) = \sum_{p=1}^k \sum_{i=1}^n u_{ip} \sum_{j=1}^m w_{pj} (x_{ij} - z_{pj})^2 - \eta \sum_{p=1}^k \sum_{i=1}^n (1 - u_{ip}) \sum_{j=1}^m w_{pj} (x_{ij} - z_{pj})^2 + \gamma \sum_{p=1}^k \sum_{i=1}^n w_{pj} \log w_{pj}, \quad (1)$$

其中: η 是类内-类间距离调整参数, γ 是权重分布控制参数。

固定权重矩阵 W 和类中心性能矩阵 Z , 式(1)在满足式(2)时可以最小化。

$$u_{ip} = \begin{cases} 1, & \sum_{j=1}^m w_{pj} (x_{ij} - z_{pj})^2 \geq \sum_{j=1}^m w_{p'j} (x_{ij} - z_{p'j})^2 \\ 0, & \sum_{j=1}^m w_{pj} (x_{ij} - z_{pj})^2 < \sum_{j=1}^m w_{p'j} (x_{ij} - z_{p'j})^2 \end{cases}, \quad (2)$$

固定数据对象分配矩阵 U 和特征权重矩阵 W , $P(W, U, Z)$ 可以最小化当且仅当:

$$z_{pj} = \frac{(1 + \eta) \sum_{i=1}^n u_{ip} x_{ij} - \eta \sum_{i=1}^n x_{ij}}{(1 + \eta) \sum_{i=1}^n u_{ip} - \eta n}, \quad (3)$$

固定数据对象分配矩阵 U 和类中心矩阵 Z , $P(W, U, Z)$ 可以最小化当且仅当:

$$w_{pt} = \frac{\exp(-\frac{D_{pt}}{\gamma})}{\sum_{j=1}^m \exp(-\frac{D_{pj}}{\gamma})}, \quad (4)$$

其中 $D_{pt} = (1 + \eta) \sum_{i=1}^n u_{ip} (x_{it} - z_{pt})^2 - \eta \sum_{i=1}^n (x_{it} - z_{pt})^2$ 。

类内-类间距离加权 k-means 算法的运行流程如下:

- 步骤 1: 输入数据集 X , 类数目 k , 参数 η 和 γ ;
- 步骤 2: 随机初始化类中心 Z 和特征权重 W ;
- 步骤 3: 固定 W 和 Z , 由式(2)求解 U ;
- 步骤 4: 固定 W 和 U , 由式(3)求解 Z ;
- 步骤 5: 固定 U 和 Z , 由式(4)求解 W ;
- 步骤 6: 重复步骤 3~5 直到目标函数(1)收敛或 U 不再改变。

2.2 基于近邻传播聚类算法的类数量上界确定方法

在运用 k-means 算法时,一般难以直接确定数据集的最佳聚类数目,因此一般的做法是根据经验确定聚类数目上限,在该数目上限之内,依次按照逐渐增大的聚类数目进行 k-means 聚类。由于经验估计往往导致聚类数目上限偏大,因此这种做法在实际应用中效率不高。文献[15]采用近邻传播算法(Affinity Propagation clustering, AP)来确定聚类数目上限,大大提高了效率。其详细的运行步骤如下:

步骤 1:将所有 AP 偏向参数 $p_i (i=1,2,\dots,n)$ 统一设定为吸引度中值 p_m ,然后通过 AP 算法确定聚类数目的搜索上界 k_{AP} ;

步骤 2:在聚类数目范围 $[2, k_{AP}]$ 内依次进行 k-means 算法,得到每个聚类数目下的聚类结果;

步骤 3:按照设定好的评价指标确定最优聚类数目。

3 图像聚类方案设计及实验

3.1 图像聚类方案设计

本文所提出的图像聚类算法的整体流程框图其详细运行流程如下:

步骤 1:将待聚类的彩色图片数据集中图片通过双线性插值法进行缩放,缩放后尺寸统一为 50×50 ;

步骤 2:将待聚类的彩色图片数据集中已缩放图片的亮度分量逐个进行局部二值模式(Local Binary Pattern, LBP)图生成;

步骤 3:将步骤 2 生成的所有 LBP 图由二维矩阵按行展开成一个一维行向量,每张 LBP 图像对应一个行向量。所有的行向量构成图片样本的聚类数据集;

步骤 4:将所有 AP 偏向参数 $p_i (i=1,2,\dots,n)$ 统一设定为吸引度中值 p_m ,然后通过 AP 算法确定聚类数目的搜索上界 k_{AP} ;

步骤 5:在聚类数目范围 $[2, k_{AP}]$ 内依次进行类内-类间距离加权 k-means 算法,得到每个聚类数目下的聚类结果;

步骤 6:按照平均 Silhouette 指标值确定最优聚类数目;

步骤 7:输出最优聚类数目下的聚类结果。

其中平均 Silhouette 指标值^[16]的定义如公式(5)所示。

$$K_{\text{AVG-Sil}} = \frac{1}{n} \sum_{i=1}^n \frac{b_i - a_i}{\max\{b_i, a_i\}}, \quad (5)$$

其中: b_i 为第 i 个样本到其他每个类中样本平均距离的最小值, a_i 为第 i 个样本与类内所有其他样本的平均距离。




图1 算法整体运行流程

Fig.1 Running process of proposed algorithm

3.2 实验

3.2.1 实验条件

本文中所涉及算法均使用 MATLAB R2019a




图2 本地图像数据集中部分样本

Fig.2 Partial samples of local image dataset




图3 GHIM10-K 图像数据集中部分样本

Fig.3 Partial samples of GHIM10-K image dataset

软件平台实现,实验所用计算机配置为:CPU 使用 AMD Ryzen 5 3600X 4 GHz,内存 64 GHz,显卡为 NVIDIA GeForce RTX 2070,系统为 Linux Ubuntu 系统。

本文在实验中所使用的图片数据集共计两个。第一个为本地图片数据集,包含 4 200 张彩色图片,共分为 6 类:球类、景物类、建筑类、熊猫类、人脸类和汽车类。每类图片均包含 700 张,每张图片的大小均为 320×320 。本地图片数据集的部分样本数据如图 2 所示。第二个图片数据集

为 GHIM10-K 图片数据集。该数据集中包含共计 10 000 张彩色图片,分为烟花、日落、船、花、建筑、高山和昆虫等 20 个类,每类包含 500 张尺寸为 300×400 的图片。GHIM10-K 图片数据集中的部分图片样本如图 3 所示。

3.2.2 聚类效果评价指标

在实验中,调整兰德系数(Adjusted Rand Index, ARI)、宏 F1 度量(Marco-F1)和聚类时间用于进行算法聚类效果的评价指标。ARI 的计算公式如式(6)所示。

$$K_{ARI} = \frac{\sum_{ij} \binom{n_{ij}}{2} - [\sum_i \binom{a_i}{2} \sum_j \binom{b_j}{2}] / \binom{n}{2}}{\frac{1}{2} [\sum_i \binom{a_i}{2} + \sum_j \binom{b_j}{2}] - [\sum_i \binom{a_i}{2} \sum_j \binom{b_j}{2}] / \binom{n}{2}}, \quad (6)$$

宏 F1 度量的计算公式如式(7)所示。

$$K_{Macro-F1} = \frac{2K_{Macro-P} * K_{Macro-R}}{K_{Macro-P} + K_{Macro-R}}, \quad (7)$$

其中 $K_{Macro-P}$ 和 $K_{Macro-R}$ 分别为宏查准率和宏查全率。这两个指标的计算公式如式(8)所示。

$$\begin{cases} K_{Macro-P} = \frac{1}{n} \sum_{i=1}^n P_i \\ P_i = \frac{K_{TP_i}}{K_{TP_i} + K_{FP_i}} \\ K_{Macro-R} = \frac{1}{n} \sum_{i=1}^n R_i \\ R_i = \frac{K_{TP_i}}{K_{TP_i} + K_{FN_i}} \end{cases}, \quad (8)$$

其中 K_{TP_i} 为第 i 类样本被正确分类的数目, K_{FP_i} 为其他类样本被错误分类至第 i 类的数目, K_{FN_i} 为第 i 类样本被错误分类至其他类别的数目。

3.2.3 试验结果及分析

将待聚类的彩色图片数据集中图片通过双线性插值法进行缩放,缩放后尺寸统一为 50×50 ,然后将待聚类的彩色图片数据集中已缩放图片的亮度分量逐个进行 LBP 图生成。部分样本的 LBP 图如图 4 所示。

将所有的 LBP 图按行展开成一维行向量,每个向量作为一个样本,所有的样本构成聚类数据集,通过本文所提出的改进型 k-means 算法所确定的聚类数目搜索上界 k_{AP} 和经验估计确定的聚类数目搜索上界 k_e ,以及通过平均 Silhouette 指标值确定的最优聚类数目如表 1 所示。在范围




图 4 部分图片样本对应的 LBP 图

Fig.4 LBP images of partial sample images

$[2, k_{AP}]$ 内不同聚类数目对应的平均 Silhouette 指标值变化情况如图 5 所示。通过表 1 可以看出,相比于经验估计,AP 算法所确定的聚类数目上界更为准确,这将大大减少算法的执行时间,提高算法的执行效率。同时,也可以发现,通过平均 Silhouette 指标值确定的最优聚类数目达到了实际类数目的最优无偏估计。

为了证实本文所提出的图像聚类算法的优越性,将文献^[17-18]中的方法与本文方法进行比较。这 3 种算法各自将 3.2.1 小节中介绍的两个图像数据集进行 50 次聚类,50 次实验得到的平均 ARI、平均宏 F1 度量和平均执行时间列于表 2。通过表 2 可以看出,与两种参考算法相比,本文所提出的算法具有更高的执行效率,更具有实用性,这主要是因为本文方法将聚类数目搜索上界缩小所致。同时,相比于两种参考算法,更高的平均宏 F1 度量也证实了本文所提算法的优异聚类精确度。

表1 两种数据集的聚类数目搜索上界和最优聚类数目

Tab.1 Upper bound and optimal number of clusters for cluster number search of two data sets

	最优聚类数目	实际类数目	k_{AP}	k_e
本地数据集	6	6	8	30
GHIM10-K 数据集	20	20	23	50


图5 本地数据集(左)和 GHIM10-K 数据集(右)在范围 $[2, k_{AP}]$ 内的聚类数目-平均 Silhouette 值图Fig.5 Nmb of clusters-average Silhouette value image in the range $[2, k_{AP}]$

表2 3种算法的比较

Tab.2 Comparison of three algorithms

	方法	ARI	平均宏 F1 度量	平均执行时间/s
本地数据集	[17]	0.123 5	0.716 3	78.21
	[18]	0.176 8	0.582 0	99.36
	[19]	0.226 7	0.593 1	53.17
	[20]	0.310 5	0.621 7	51.18
	[21]	0.264 7	0.725 8	63.66
	本文方法	0.474 9	0.812 8	51.58
GHIM10-K 数据集	[17]	0.269 7	0.725 8	169.29
	[18]	0.303 8	0.663 0	214.07
	[19]	0.342 1	0.565 7	171.34
	[20]	0.230 9	0.597 3	101.43
	[21]	0.317 6	0.692 0	142.73
	本文方法	0.553 0	0.821 7	96.37

4 结 论

针对海量彩色图像高效精确聚类问题,本

文引入了一种改进型 k-means 算法并将其应用于彩色图像聚类中。该算法由类内-类间距离加权 k-means 算法和基于近邻传播聚类算法的聚类数量上界确定方法组成。在实验中,彩色图

像通过双线性插值缩放,缩放后尺寸统一为 50×50 。缩放后彩色图像的亮度分量的 LBP 图被重组为行向量然后构成样本特征数据集,本文所提出的改进型 k-means 算法被用于对样本集进行聚类处理。实验结果显示,在平均宏 F1

度量和 ARI 的测试中,本方法相比于传统方法达到了更高的水平,证实了本文所提方法优异的聚类准确度。同时,由于聚类数目上界的准确确定,相比于传统方法,本方法也更具有执行效率。

参 考 文 献:

- [1] LOWE D G. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [2] DIXIT R, NASKAR R. Region duplication detection in digital images based on centroid linkage clustering of key-points and graph similarity matching [J]. *Multimedia Tools and Applications*, 2019, 78(10): 13819-13840.
- [3] 孟晓燕, 段建民, 刘丹. 采用人体树图与混合粒子群聚类的行人检测 [J]. *光学精密工程*, 2018, 26(7): 1802-1812.
MENG X Y, DUAN J M, LIU D. Pedestrian detection based on tree-structured graphical model of the human body and hybrid particle swarm clustering [J]. *Optics and Precision Engineering*, 2018, 26(7): 1802-1812. (in Chinese)
- [4] 郑思凡, 王卫星, 吴永春. 基于光流拓扑稀疏加权的同步运动去混叠 [J]. *光学精密工程*, 2019, 27(5): 1188-1195. ZHENG S F, WANG W X, WU Y C. Synchronous motion de-aliasing based on optical flow topological sparse weighting [J]. *Optics and Precision Engineering*, 2019, 27(5): 1188-1195. (in Chinese)
- [5] 陈华伟, 袁小翠, 吴禄慎, 等. 基于曲率突变分析的点云特征线自动提取 [J]. *光学精密工程*, 2019, 27(5): 1218-1228.
CHEN H W, YUAN X C, WU L S, et al. Automatic point cloud feature-line extraction algorithm based on curvature-mutation analysis [J]. *Optics and Precision Engineering*, 2019, 27(5): 1218-1228. (in Chinese)
- [6] LU S Z, YU H L, WANG X H, et al. Clustering method of raw meal composition based on PCA and kmeans [C]//*Proceedings of the 37th Chinese Control Conference*. Wuhan, China: IEEE, 2018: 121-135.
- [7] YIH J M. FCM algorithm based on normalized mahalanobis distances in image clustering [C]//*Proceedings of 2010 International Conference on Machine Learning and Cybernetics*. Qingdao, China: IEEE, 2010: 2724-2729.
- [8] ZHANG Z Y, CHENG H M, ZHANG S G. Approach to SOM based correlation clustering [C]//*Proceedings of 2008 Chinese Control and Decision Conference*. Yantai, China: IEEE, 2008: 121-135.
- [9] FREY B J, DUECK D. Clustering by passing messages between data points [J]. *Science*, 2007, 315(5814): 972-976.
- [10] ESTER M, KRIEGEL H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise [C]//*Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining*. Portland, Oregon: ACM, 1996: 226-231.
- [11] SANDER J, ESTER M, KRIEGEL H P, et al. Density-based clustering in spatial databases: the algorithm GDB-SCAN and its applications [J]. *Data Mining and Knowledge Discovery*, 1998, 2(2): 169-194.
- [12] ANKERST M, BREUNIG M M, KRIEGEL H P, et al. OPTICS: ordering points to identify the clustering structure [C]//*Proceedings of 1999 ACM SIGMOD International Conference on Management of Data*. Philadelphia, Pennsylvania, USA: ACM, 1999: 49-60.
- [13] XU X W, JÄGER J, KRIEGEL H P. A fast parallel clustering algorithm for large spatial databases [J]. *Data Mining and Knowledge Discovery*, 1999, 3(3): 263-290.
- [14] 黄晓辉, 王成, 熊李艳, 等. 一种集成簇内和簇间距离的加权 k-means 聚类方法 [J]. *计算机学报*, 2019: 1-15.
HUANG X H, WANG C, XIONG L Y, et al. A weighting k-means clustering approach by integrating intra-cluster and inter-cluster distances [J]. *Chinese Journal of Computers*, 2019: 1-15. (in Chinese)
- [15] 周世兵, 徐振源, 唐旭清. 新的 K-均值算法最佳聚类数确定方法 [J]. *计算机工程与应用*, 2010, 46(16): 27-31.

- ZHOU S B, XU Z Y, TANG X Q. New method for determining optimal number of clusters in K-means clustering algorithm [J]. *Computer Engineering and Applications*, 2010, 46(16): 27-31. (in Chinese)
- [16] DUDOIT S, FRIDLAND J. A prediction-based resampling method for estimating the number of clusters in a dataset [J]. *Genome Biology*, 2002, 3(7): research0036.1.
- [17] QIAN P J, ZHOU J X, JIANG Y Z, *et al.* Multi-view maximum entropy clustering by jointly leveraging inter-view collaborations and intra-view-weighted attributes [J]. *IEEE Access*, 2018, 6: 28594-28610.
- [18] 陶性留, 俞璐, 王晓莹. 基于非负矩阵分解和模糊 C 均值的图像聚类方法 [J]. *信息技术与网络安全*, 2019, 38(3): 44-48.
- TAO X L, YU L, WANG X Y. One method based on non-negative matrix factorization and fuzzy C means for image clustering [J]. *Information Technology and Network Security*, 2019, 38(3): 44-48. (in Chinese)
- [19] JIA H J, DING S F, MENG L H, *et al.* A density-adaptive affinity propagation clustering algorithm based on spectral dimension reduction [J]. *Neural Computing and Applications*, 2014, 25(7/8): 1557-1567.
- [20] PAL N R, BEZDEK J C, HATHAWAY R J. Sequential competitive learning and the fuzzy *c*-means clustering algorithms [J]. *Neural Networks*, 1996, 9(5): 787-796.
- [21] JAIN A K. Data clustering: 50 years beyond K-means [J]. *Pattern Recognition Letters*, 2010, 31(8): 651-666.

作者简介:



高 西(1976—),女,四川内江人,学士,2009年于重庆医科大学获得学士学位,主要从事皮肤性病学暨医学美容、皮肤影像及图像处理方面的研究。
E-mail: gaoxi0627@hotmail.com



胡子牧(1973—),男,湖北沔阳人,学士,2004年于中央党校获得学士学位,主要从事医院管理、图像处理方面的研究。E-mail: huzimu0627@hotmail.com