

加权 K-NN 分类器及其应用

周伟

(杭州电子工业学院)

易丹波

(杭州通信广播技术研究所)

摘要

本文介绍了加权 K-NN 分类器的基本原理，并给出了相应的算法，着重对权函数的形式进行了讨论，提出了两种新的权函数定义公式。将加权 K-NN 分类器用在白血球自动分类系统中，分类精度比 K-NN 分类器有明显提高。

关键词：K-NN 分类器；权函数；加权 K-NN 分类器；白血球；二分树。

K-NN 分类器是较为常用的一种非参数分类器，在某些场合下应用时，能得到较为满意的结果^[1]。仔细考察 K-NN 分类器，可发现它有明显的缺陷：K-NN 分类器没有考虑待识样本与 K 个最近邻标准样本（训练集）的相似程度。显然，一个标准样本与待识样本越相似，这个标准样本应该在分类时起的作用也越大，反之亦然。为此，有人提出了加权 K-NN 分类器^[2]。

一、加权 K-NN 分类器

针对 K-NN 分类器存在的不足，人们提出了相应的改进措施，最常用的是距离加权 K-NN 分类器。

1. 加权 K-NN 分类器的基本原理及算法

假设：一训练样本空间 Ω ，共分为 M 类， $\Omega = \Omega_1 \cup \Omega_2 \cup \dots \cup \Omega_M$ ，已知它们的类别属性，训练样本集可表示为 $X = \{x^1, x^2, \dots, x^N\}$ ，其中 N 为训练样本总个数，可写成 $x^* = x_m^i \in \Omega_m$ ， $m = 1, 2, \dots, M$ ； $i = 1, 2, \dots, N_m$ ； $n = 1, 2, \dots, N$ ，且有 $\sum_{m=1}^M N_m = N$ ，待识样本为 $y \in \Omega$ 。

进一步假设：待识样本 Y 在训练样本空间 Ω 中的 K 个最近邻按其属性可表示为 x_m^ν ，其中 $\nu = 1, 2, \dots, K_m$ ； $m = 1, 2, \dots, M$ （排除 $K_m = 0$ 的情况），且有 $\sum K_m = K$ ，与 x_m^ν 相应的权为 W_m^ν 。

加权 K-NN 分类器的基本思想为, 赋予与待识样本 y 更接近的标准样本比较远的标准样本有更大的“权”, 也就是说, 在分类中起更大的作用。这个“权”函数随待识样本与标准样本之间距离的变化而变化, 更确切地讲, 定义权函数是距离度量 $d(y, x_m^i)$ 的减函数, 即有: $W_m^i = W[d(y, x_m^i)]$ 。

加权 K-NN 分类器的具体算法如下:

第一步 输入待识样本 y , 设置 K 值, $1 \leq K < N$;

第二步 设起始值 $n = 1$;

第三步 计算待识样本 y 与 x^n 之间的距离,

IF($n \leq K$) THEN 将 x^n 归入到 y 的 K 个最近邻中,

ELSE IF (x^n 比原先的 K 个最近邻更接近于 y), THEN 用 x^n 替换 K 个最近邻中的最远者, 置 $n = n + 1$;

第四步 IF($n \leq N$) THEN 转至第三步;

第五步 依据距离度量 $d(y, x_m^v)$ 确定权函数 W_m^v ;

第六步 计算判决函数 $C(Q_m/y) = \sum_{v=1}^{K_m} W_m^v$;

第七步 IF [$C(Q_m/y) > C(Q_\lambda/y)$ 对于所有 $\lambda \neq m$, $\lambda = 1, 2, \dots, M$ (排除 $K_\lambda = 0$ 的情况) 成立],

THEN 将 y 分类到 Q_m 中去;

第八步 IF [出现 $C(Q_m/y)$ 的最大值多于一个的情况下],

THEN 将 y 分类到首先找到的具有最大 $C(Q_m/y)$ 值的类别 Q_m 中去;

第九步 结束。

2. 几种权函数的定义式

上面给出了加权 K-NN 分类器的具体算法, 其中一个很关键的问题是如何根据距离度量 $d(y, x_m^v)$ 来确定权函数值 W_m^v 。文献[2]中介绍了三种权函数的定义式, 设 K 个最近邻中的最远点和最近点的距离分别为 d_{\max} , d_{\min} 。

第一种定义式为

$$W_m^v = \begin{cases} \frac{d_{\max} - d(y, x_m^v)}{d_{\max} - d_{\min}}, & 1 < K < N, \\ 1, & K = 1. \end{cases}$$

第二种定义式为

$$W_m^v = \frac{1}{d(y, x_m^v)}, \quad \text{要求 } d(y, x_m^v) \neq 0.$$

第三种定义式为

$$W_m^v = K - i + 1.$$

式中 i ($1 \leq i \leq K$) 为 K 个最近邻按距离度量大小排队的序号, $i = 1$ 对应最近样本, $i = K$ 对应最远样本。

以上介绍的三种权函数定义式均可用在加权 K-NN 分类器中, 但都有不足之处, 三种定义式随距离增大而递减的速度是恒定的, 然而, 具有可调递减速度的权函数定义式使

用起来更方便。

下面给出两种更灵活合理的权函数定义式,假设同前。

第四种定义式为

$$W_m^v = \begin{cases} \exp\left\{\alpha\left[\frac{d_{\max} - d(y, x_m^v)}{d_{\max} - d_{\min}}\right]\right\}, & 1 < K < N, \\ 1, & K = 1. \end{cases}$$

式中 $\alpha(0 < \alpha < \infty)$ 用来调节权函数的递减速度。

第五种定义式为

$$W_m^v = \begin{cases} \exp\{-\alpha[d(y, x_m^v) - d_{\min}]\}, & 1 < K < N, \\ 1, & K = 1. \end{cases}$$

二、加权 K-NN 分类器的应用

文献 [1] 中介绍了一种在微机上实现白血球自动分类的方法,建立了细胞个数均为 97 的训练集和考试集各一个,自动分类系统采用 K-NN 分类器,定义距离度量 $d(y, x_m^i)$ 如下:

$$d(y, x_m^i) = (y - x_m^i)^T \Sigma^{-1} (y - x_m^i).$$

式中 Σ 为第 m 类标准样本的协方差矩阵。适中选择 $K = 5$, 分类结果较为满意, 如果采

表 1 不同分类器下的精度比较 ($K = 5$)

精度%		特征数					
条件		3	4	5	6	7	8
训练集	K-NN	78.35	79.38	80.41	83.50	85.57	85.57
	权函数一	85.57	86.60	88.66	88.66	90.72	90.72
	权函数二	79.38	80.41	81.44	83.51	85.57	87.63
	权函数三	78.35	78.35	82.47	84.54	86.60	87.63
	权函数四	86.60	88.66	91.75	92.78	92.78	93.81
	权函数五	85.57	86.66	89.69	91.75	93.81	93.81
考试集	K-NN	75.26	77.32	77.32	78.35	78.35	78.35
	权函数四	81.44	80.41	83.51	83.51	85.57	86.60
	权函数五	82.47	84.54	84.54	86.60	87.63	88.66

表 2 K 值对精度的影响(入选特征数为七)

K值		3	4	5	6	7	8	9	10	11	12
精度											
K-NN		79.38	79.38	80.41	80.41	81.44	81.44	80.41	78.35	77.32	77.32
加权 K-NN, 权函数四		89.69	89.69	91.75	91.75	92.78	92.78	93.81	93.81	93.81	93.81

用本文介绍的加权 K-NN 分类器,分类精度可望得到提高.

表 1 给出了利用加权 K-NN 分类器的分类结果. 为了便于比较, 同时还给出了利用 K-NN 分类器的结果. 可见, 加权 K-NN 分类器能改善分类精度. 本文提出的两种权函数定义式效果则更好, 考试集上的精度比训练集略低一些. 对应于第四、第五种定义式, 分别选择 $\alpha = 2$ 和 $\alpha = 0.2$. 表 2 给出了在训练集上 K-NN 分类器和加权 K-NN 分类器在不同 K 值下的分类精度. 可见, 对于 K-NN 分类器, 当 $K \geq 9$ 时, 分类精度反而下降, 而对于加权 K-NN 分类器, 分类精度是 K 值的不减函数, 故 K 值的选择较为方便.

本文介绍的加权 K-NN 分类器以极小量的速度下降换取了分类精度的可观提高, 这显然是可取的.

参 考 文 献

- [1] 周伟、王承训,白细胞自动分类问题的研究,杭州电子工业学院学报,2(1986),93—100.
- [2] Dudani, S. A., The Distance-Weighted K-Nearest-Neighbor Rule, *IEEE Trans., SMC-15* (1976), 325—327.

A WEIGHTED K-NN CLASSIFIER AND ITS APPLICATION

ZHOU WEI

(*Hangzhou Institute of Electronic Engineering*)

YI DANBO

(*Hangzhou Institute of Communication, Broadcasting and Television Technology*)

ABSTRACT

This paper introduces the basic principle of a weighted-K-NN classifier and presents the corresponding algorithm. The form of the weight function are discussed emphatically, and two new definition formulas of weighted function are produced. The weighted-K-NN Classifier has been applied to a system for the automated classification of white blood cells, and the classification accuracy is much higher than the K-NN Classifier.

Key words ——K-NN classifier; weighted function; weighted-K-NN classifier; white blood cells; binary tree.