

◇ 研究报告 ◇

基于核的 k -最近邻在水下目标识别中的应用*

严良涛^{1†} 项晓丽²

(1 中国人民解放军 91388 部队 湛江 524022)

(2 广州杰赛科技股份有限公司 广州 510220)

摘要 针对水下目标特征类型多、非线性强的特点,该文将基于核的 k -最近邻应用于水下目标识别。该方法采用主成分分析对特征矩阵进行降维,利用核函数技巧将降维后的特征映射到高维空间进行 k -最近邻分类识别,并讨论了邻近点个数 k 对实验结果的影响。实际实验数据验证结果表明:与传统的 k -最近邻和 BP 神经网络分类器相比,基于核的 k -最近邻分类器的综合性能更优。

关键词 水下目标识别, k -最近邻, 主成分分析, 核函数

中图法分类号: TP391.4 文献标识码: A 文章编号: 1000-310X(2019)03-0448-04

DOI: 10.11684/j.issn.1000-310X.2019.03.023

Application of k -NN based on Kernel in underwater target recognition

YAN Liangtao¹ XIANG Xiaoli²

(1 Military Unit 91388 of PLA, Zhanjiang 524022, China)

(2 Gci Science & Technology Co., Ltd., Guangzhou 510220, China)

Abstract The targets underwater have many features and strong nonlinearity, this paper applies the k -nearest neighbor (k -NN) based on Kernel to underwater target recognition. This method uses principal components analysis (PCA) to reduce the dimension of the feature matrix. Then the Kernel technique is used to map the reduced dimension to the high-dimensional space for k -NN classification and recognition. The influence of the number k of adjacent points on the test results is discussed. The result of actual experimental data shows that the classifier has better overall performance than the traditional k -NN and BP neural network classifiers.

Key words Underwater target recognition, k -nearest neighbor, Principal components analysis, Kernel

0 引言

水下辐射声场和水声信道的复杂性是造成水下目标识别难度大的根本原因^[1]。这两方面因素

的影响使声呐接收的噪声信号都是相互耦合、调制甚至畸变的,因此研究者们提出了多种特征提取方法^[2-4],试图从不同角度得到噪声信号的特征,但水下环境的复杂性决定了这些特征必然呈现强非线性^[5]。在目标识别过程中,为保证识别的正确率

2018-10-14 收稿; 2018-12-29 定稿

*国家自然科学基金项目 (11774374)

作者简介: 严良涛 (1989-), 男, 江西南昌人, 硕士, 研究方向: 智能水下目标识别。

†通讯作者 E-mail: xxlylt@sina.cn

应将多种特征加以组合,但这会造成数据维数过高,识别速率下降。为此,本文提出了基于核(Kernel)的 k 近邻^[6] (k -nearest neighbor, k -NN) 水下目标识别方法。该方法利用主成分分析^[7] (Principal components analysis, PCA) 对高维的特征矩阵进行降维,解决目标识别速率低的问题;利用 Kernel 技巧将降维后的非线性特征映射到高维空间并在该空间进行 k -NN 分类识别,能够有效减小非线性特征在低维度空间距离度量误差,提高识别正确率。实际实验数据的验证结果表明:与 k -NN 相比,基于核的 k -NN 的目标识别速率略低,但目标的识别正确率得到较大提高;与 BP 神经网络分类器相比,基于核的 k -NN 的目标识别正确率略低,但目标的识别速率得到较大提高。

1 基于核的 k -NN 基本原理

1.1 空间映射及核函数

给定特征样本 \mathbf{x} , 将其从 n 维特征空间映射到 m 维特征空间:

$$\begin{aligned} \mathbf{x} &= (\mathbf{x}_1, \dots, \mathbf{x}_n) \xrightarrow{\text{特征映射}\psi} \psi(\mathbf{x}) \\ &= (\varphi_1(\mathbf{x}), \dots, \varphi_m(\mathbf{x})), \\ \mathbf{x} &\in \mathbf{S}_1, \psi(\mathbf{x}) \in \mathbf{S}_2, \end{aligned} \quad (1)$$

其中, \mathbf{S}_1 为原始 n 维特征空间, \mathbf{S}_2 为 m 维映射特征空间。 \mathbf{x} 为 \mathbf{S}_1 中的特征样本, $\psi(\mathbf{x})$ 为对应 \mathbf{S}_2 中的特征样本。 ψ 为将 \mathbf{S}_1 映射到 \mathbf{S}_2 的非线性映射, φ_i 为特征映射函数, $i = 1, \dots, m$ 。

对 $\mathbf{x}, \mathbf{y} \in \mathbf{S}_1$, 其核函数(Kernel)表示形式为

$$K(\mathbf{x}, \mathbf{y}) = \langle \psi(\mathbf{x}), \psi(\mathbf{y}) \rangle = (\psi(\mathbf{x}))^T \psi(\mathbf{y}), \quad (2)$$

式(2)中, $\langle \psi(\mathbf{x}), \psi(\mathbf{y}) \rangle$ 表示 $\psi(\mathbf{x})$ 和 $\psi(\mathbf{y})$ 的内积, $K(\mathbf{x}, \mathbf{y})$ 为 \mathbf{x} 和 \mathbf{y} 的函数。通过核函数 $K(\mathbf{x}, \mathbf{y})$ 直接计算高维特征空间的内积 $\langle \psi(\mathbf{x}), \psi(\mathbf{y}) \rangle$, 使其计算复杂度不受维度和映射 ψ 的影响。常用的 Kernel 有多项式核函数 $K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^p$ 、高斯核函数 $K(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2/C)$ 等。

1.2 k -NN 的核化

在 k -NN 中, 原始空间特征样本 \mathbf{x} 和 \mathbf{y} 之间的距离二范数为

$$d^2(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|^2. \quad (3)$$

假定将 \mathbf{x} 和 \mathbf{y} 映射至高维特征空间中, 那么此时高维空间特征样本 $\psi(\mathbf{x})$ 和 $\psi(\mathbf{y})$ 之间的距离二范数为

$$\begin{aligned} d^2(\psi(\mathbf{x}), \psi(\mathbf{y})) &= \|\psi(\mathbf{x}) - \psi(\mathbf{y})\|^2 \\ &= \langle (\psi(\mathbf{x}) - \psi(\mathbf{y})), (\psi(\mathbf{x}) - \psi(\mathbf{y})) \rangle. \end{aligned} \quad (4)$$

式(4)中存在内积项 $\langle (\psi(\mathbf{x}) - \psi(\mathbf{y})), (\psi(\mathbf{x}) - \psi(\mathbf{y})) \rangle$, 根据 1.1 节可知, 利用 Kernel 可实现对该内积的直接计算。此时:

$$\begin{aligned} d^2(\psi(\mathbf{x}), \psi(\mathbf{y})) \\ &= K(\mathbf{x}, \mathbf{x}) - 2K(\mathbf{x}, \mathbf{y}) + K(\mathbf{y}, \mathbf{y}). \end{aligned} \quad (5)$$

由式(5)可知, 高维特征空间样本 $\psi(\mathbf{x})$ 和 $\psi(\mathbf{y})$ 之间的距离可通过 Kernel 在原始空间中直接计算, 而不受维度和映射 ψ 的限制。

1.3 基于核的 k -NN 的算法实现

基于核的 k -NN 的实现过程如下: 给定一个用于训练的特征数据集, 将其映射到高维特征空间, 对新的输入实例, 利用 Kernel 计算其在高维特征空间中最邻近的 k 个实例, 若这 k 个实例的大多数属于某个类, 就把该新实例划分为这个类。本文选择高斯核函数进行运算, 具体过程如表 1 所示。

表 1 基于核的 k -NN 的算法实现过程

Table 1 The algorithm of k -NN based on Kernel

输入	(1) 训练数据集 $\mathbf{X} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$, $\mathbf{x}_i \in \mathbf{S}_1 \subseteq \mathbf{R}^n$ 为实例的特征向量, $y_i \in \mathbf{F} = \{c_1, c_2, \dots, c_\alpha\}$ 为实例的类别, $i = 1, 2, \dots, m$; (2) 待分类实例特征向量 \mathbf{x} 。
过程	(1) 选定 Kernel 及其参数 C ; (2) 选定合适的 k 值; (3) 根据 $d(\psi(\mathbf{x}), \psi(\mathbf{x}_i)) = \sqrt{K(\mathbf{x}, \mathbf{x}) - 2K(\mathbf{x}, \mathbf{x}_i) + K(\mathbf{x}_i, \mathbf{x}_i)}$ 找出在训练集中与 \mathbf{x} 最邻近的 k 个点, 涵盖这 k 个点的 \mathbf{x} 的邻域记为 $N_k(\mathbf{x})$; (4) 在 $N_k(\mathbf{x})$ 中根据多数表决原则决出 \mathbf{x} 的类别 y : $y = \arg \max_{c_j} \sum_{\mathbf{x}_i \in N_k(\mathbf{x})} I(y_i = c_j),$ $i = 1, 2, \dots, m; \quad j = 1, 2, \dots, \alpha,$ 其中, I 为指示函数, 当 $y_i = c_j$ 时 I 为 1, 否则 I 为 0。
输出	实例特征向量 \mathbf{x} 的类别 y 。

在上述实现过程中选择的高斯核函数灵活度高, 不同的核参数 C 可以将原始空间映射到任意维空间。在对核参数 C 的优化过程中, C 值过大, 高次

特征上的权重衰减快,所映射出空间相当于原始空间的子空间; C 值过小,可将任意数据映射至线性可分的空间,但这很可能带来严重的过拟合问题^[8],因此 C 值的优化尤其重要。 k 值的确定采用在一定范围内^[9](样本量开平方 \sqrt{m} 附近)进行枚举计算确定。

2 基于核的 k -NN在水下目标识别中的应用

2.1 数据来源与预处理

将实测的166段水下目标噪声信号进行筛选、标记和梅尔频率倒谱系数(Mel frequency cepstrum coefficient, MFCC)特征提取^[10]后,得到120组特征数据,分属4类目标,每类30组,将其中 20×4 组作为训练样本集 $D_{(22 \times 80)}$,其余 10×4 组作为测试样本集 $T_{(22 \times 40)}$ 。利用PCA对训练样本集 D 进行降维,具体过程如表2所示。

表2 PCA的降维过程

Table 2 The algorithm of reducing dimensionality with PCA

输入	训练样本集 $D = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{80}\}$ 。
过程	(1) 对所有样本进行中心化和无量纲化处理: $D \rightarrow X$; (2) 计算样本的协方差矩阵 XX^T ; (3) 对协方差矩阵 XX^T 进行特征值分解; (4) 对协方差矩阵 XX^T 的特征值计算累计方差贡献率 $\sum_{i=1}^{d'} \lambda_i / \sum_{i=1}^d \lambda_i \geq t$; (5) 取最大的 d' 个特征值所对应的特征向量 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_{d'}$ 。
输出	投影矩阵 $W^* = \{\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_{d'}\}$ 。

这样就可以将一个特征样本 \mathbf{x} 映射到一个 d' 维特征子空间上去,此空间的维度小于原始的 d 维空间:

$$\begin{aligned} \mathbf{x} &= [x_1, x_2, \dots, x_d], \quad \mathbf{x} \in \mathbf{R}^d, \\ \downarrow \mathbf{x}W^*, \quad W^* &\in \mathbf{R}^{d \times d'}, \\ \mathbf{z} &= [z_1, z_2, \dots, z_{d'}], \quad \mathbf{z} \in \mathbf{R}^{d'}. \end{aligned} \quad (6)$$

本文取阈值 $t = 95\%$,根据计算确定 $d' = 16$,其方差贡献图如图1所示。

从图1可看出,第一主元占方差总和的22%左右,前16个主元占总体方差的95%左右。

训练样本集 $D_{(22 \times 80)}$ 经过PCA降维后就转换成低维数据集 $Z_{(16 \times 80)}$,接下来就可以在矩阵 Z 中利用1.3节中的基于核的 k -NN进行分类。




图1 PCA方差贡献图

Fig. 1 Variance contribution graph with PCA

2.2 训练过程及分析

选择高斯Kernel进行距离度量计算,不同核参数 C 值代表将数据集 $Z_{(16 \times 80)} = \{z_1, z_2, \dots, z_{80}\}$ 映射到不同的高维空间。在最优 C 值的高维空间内同一类别的样本最聚集,正确分类识别率最高。核参数 C 值的优化属于超参数优化问题^[11],本文采用sklearn.grid_search模块下的GridSearchCV对象对 C 值进行优化,其主要应用对象为小数据集,基本原理是对人工设置的超参数进行网格搜索得到最优值;若算法中存在多个超参数需优化,那么依次选取对模型影响最大的参数调优,直到所有的参数调整完毕。本文中只涉及核参数 C 值的优化,应用上述方法得到的最优值为45.62。

对 k 值在样本量开平方 $\sqrt{80}$ 附近进行枚举计算确定,得到在训练样本中不同 k 值与识别正确率之间的关系如图2所示。




图2 k 值与识别正确率之间的关系

Fig. 2 The relationship between k and recognition accuracy

从图2可看出, $k = 8$ 时识别正确率最高约为88%, 实际值为88.23%。

2.3 验证与比较

根据2.1节和2.2节得到的最优 d' 、 C 及 k 值, 将测试样本 $T_{(22 \times 40)}$ 进行分类并与各样本类别标签进行对比得出识别正确率, 同时计算每个测试样本识别过程的消耗时间 t 。与传统线性 k -NN 和 BP 神经网络分类器的比较如表3所示。

表3 基于核的 k -NN、 k -NN 和 BP 神经网络分类器性能比较

Table 3 The performance comparison of k -NN based on Kernel, k -NN and BP neural network

分类器	正确率					
	A类	B类	C类	D类	平均正确率	平均耗时/s
基于核的 k -NN	85%	90%	80%	85%	85%	22.561
k -NN	80%	75%	70%	70%	73.75%	18.417
BP 神经网络	85%	85%	90%	90%	87.5%	52.325

由表3可知, 基于核的 k -NN 分类器的平均识别正确率为85%, 高于 k -NN 分类器11.25%, 低于 BP 神经网络分类器2.5%; 平均耗时为22.562 s, 高于 k -NN 分类器4.144 s, 低于 BP 神经网络分类器33.908 s。BP 神经网络分类器平均识别正确率虽略高于本文基于核的 k -NN 分类器, 但其平均耗时超出基于核的 k -NN 分类器一倍多; k -NN 分类器的平均耗时略小于基于核的 k -NN 分类器, 在可接受范围内, 但其平均识别正确率相对于基于核的 k -NN 分类器过低。所以得出结论: 相对于 k -NN 分类器和 BP 神经网络分类器, 基于核的 k -NN 分类器综合性能更优。

3 结论

本文利用 Kernel 技巧将原始空间数据映射至高维特征空间, 实现了原始空间的非线性耦合数据在高维特征空间的线性可分, 有效解决了水下目标特征数据非线性不可分的问题。并采用 PCA 对特

征数据矩阵进行降维, 利用 k -NN 进行分类识别, 形成了基于核的 k -NN 水下目标识别方法。通过与传统 k -NN 和 BP 神经网络分类器对比, 说明了基于核的 k -NN 分类器性能的优越性。

参 考 文 献

- [1] 葛青. 水下目标识别中的数据融合技术 [D]. 哈尔滨: 哈尔滨工程大学, 2008.
- [2] 郭戈, 王兴凯, 徐慧朴. 基于声呐图像的水下目标检测、识别与跟踪研究综述 [J]. 控制与决策, 2018, 33(5): 906-922.
Guo Ge, Wang Xingkai, Xu Huipu. Review on underwater target detection, recognition and tracking based on sonar image [J]. Control and Decision, 2018, 33(5): 906-922.
- [3] 王用, 张杰. 基于数据统计的雷达目标类型识别问题研究 [J]. 信息系统工程, 2018(5): 19.
- [4] 宋达. 基于深度学习的水下目标识别方法研究 [D]. 成都: 电子科技大学, 2018.
- [5] 胡光波, 梁红, 徐骞. 舰船辐射噪声混沌特征提取方法研究 [J]. 计算机仿真, 2011, 28(2): 22-24, 34.
Hu Guangbo, Liang Hong, Xu Qian. Research on chaotic feature extraction of ship radiated noise [J]. Computer Simulation, 2011, 28(2): 22-24, 34.
- [6] 刘松华, 张军英, 许进, 等. Kernel- k NN: 基于信息能度量的核 k -最近邻算法 [J]. 自动化学报, 2010, 36(12): 1681-1688.
Liu Songhua, Zhang Junying, Xu Jin, et al. Kernel- k NN: a new k NN algorithm based on informational energy metric [J]. Acta Automatica Sinica, 2010, 36(12): 1681-1688.
- [7] Schölkopf B. Kernel PCA and de-noising in feature spaces [J]. Advances in Neural Information Processing Systems, 1999, 11: 536-542.
- [8] Kung S Y. Kernel methods and machine learning [M]. Cambridge: Cambridge University Press, 2014.
- [9] 李振, 李伟光, 赵学智, 等. 基于主成分分析的特征频率提取算法及应用 [J]. 振动、测试与诊断, 2018, 38(4): 834-842, 879.
- [10] 李虹, 徐小力, 吴国新, 等. 基于 MFCC 的语音情感特征提取研究 [J]. 电子测量与仪器学报, 2017, 31(3): 448-453.
Li Hong, Xu Xiaoli, Wu Guoxin, et al. Research on speech emotion feature extraction based on MFCC [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(3): 448-453.
- [11] 武优西, 郭磊, 柴欣, 等. 基于优化算法的核函数参数选择的研究 [J]. 计算机应用与软件, 2010, 27(1): 137-140.
Wu Youxi, Guo Lei, Cai Xin, et al. On parameter selection of kernel function based on optimization algorithm [J]. Computer Applications and Software, 2010, 27(1): 137-140.