

基于语音卷积稀疏迁移学习和并行优选的帕金森病分类算法研究

张小恒^{①②} 李勇明^{*②} 王品^② 曾孝平^② 颜芳^② 张艳玲^③ 承欧梅^④

^①(重庆广播电视大学 重庆 400052)

^②(重庆大学通信工程学院 重庆 400030)

^③(陆军军医大学西南医院神经内科 重庆 400038)

^④(重庆医科大学附属第一医院神经内科 重庆 400016)

摘要: 基于语音数据分析的帕金森病(PD)诊断存在样本量小、训练与测试数据分布差异明显的问题。为了解决这些问题,需要从降维和样本扩充两个方面同时进行。因此,该文提出结合加噪加权卷积稀疏迁移学习和样本特征并行优选的PD分类算法。该算法可从源域的公共语音库中学习有利于表达PD语音特征的有效结构信息,同时完成降维和样本间接扩充。样本特征并行优选考虑到了样本和语音特征间的关系,从而有助于获取高质量的特征。首先,对公共语音库进行特征提取构造公共特征库;然后,以公共特征库对PD目标域的训练数据集及测试数据集进行稀疏编码,这里分别采用传统稀疏编码(SC)与卷积稀疏编码(CSC)两种稀疏编码方法;接着,对编码后的语音样本段和特征数据进行同时优选;最后,采用支撑向量机(SVM)进行分类。实验结果表明,该算法针对受试者的分类准确率最高值达到了95.0%,均值达到了86.0%,较相关被比较算法有较大提高。此外,研究还发现,相较于传统稀疏编码方法,卷积稀疏编码更有利于提取PD语音数据的高层特征;同样,迁移学习也有利于提高该算法性能。

关键词: 迁移学习; 帕金森病; 稀疏编码; 卷积稀疏编码; 语音样本特征并行优选

中图分类号: TP391.42; R749

文献标识码: A

文章编号: 1009-5896(2019)07-1641-09

DOI: 10.11999/JEIT180792

Classification Algorithm of Parkinson's Disease Based on Convolutional Sparse Transfer Learning and Sample/Feature Parallel Selection

ZHANG Xiaoheng^{①②} LI Yongming^② WANG Pin^② ZENG Xiaoping^②

YAN Fang^② ZHANG Yanling^③ CHENG Oumei^④

^①(Chongqing Radio & TV University, Chongqing 400052, China)

^②(College of Communication Engineering, Chongqing University, Chongqing 400030, China)

^③(Department of Neurology of Southwest Hospital, Army Medical University, Chongqing 400038, China)

^④(Department of Neurology, The First Affiliated Hospital, Chongqing Medical University,

Chongqing 400016, China)

Abstract: To solve the problems that there are few labeled data in speech data for diagnosis of Parkinson's Disease (PD), and the distributed condition of the training and the test data is different, the two aspects of dimension reduction and sample augment are considered. A novel transfer learning algorithm is proposed based on noise weighting sparse coding combined with speech sample / feature parallel selection. The algorithm can learn the structural information from the source domain and express the effective PD features, and achieves

收稿日期: 2018-08-09; 改回日期: 2019-01-28; 网络出版: 2019-02-23

*通信作者: 李勇明 yongmingli@cqu.edu.cn

基金项目: 国家自然科学基金(61771080, 61571069), 重庆市基础与前沿研究项目(cstc2018jcyjAX0779, cstc2016jcyjA0043, cstc2016jcyjA0064, cstc2016jcyjA0134), 重庆市教育委员会科学技术研究项目(KJ1603805), 西南医院联合孵化项目(SWH2016LHYS-11), 模式识别国家重点实验室开放课题基金(201800011)

Foundation Items: The National Natural Science Foundation of China (61771080, 61571069), The Chongqing Research Program of Basic Research and Frontier Technology(cstc2018jcyjAX0779, cstc2016jcyjA0043, cstc2016jcyjA0064, cstc2016jcyjA0134), The Chongqing Education Commission Science and Technology Research Program (KJ1603805), The Southwest Hospital Science and Technology Innovation Program (SWH2016LHYS-11), The Open Project Program of the National Laboratory of Pattern Recognition (201800011)

dimension reduction and sample augment simultaneously. Considering the relationship between the samples and features, the higher quality features can be extracted. Firstly, the features are extracted from the public data set and the feature data set is constructed as source domain. Then the training data and test data of the target domain are sparsely represented based on source domain. Spares representing includes traditional Sparse Coding(SC) and Convolutional Sparse Coding(CSC); Next, the sparse representing data are screened according to sample feature selection simultaneously, so as to improve the accuracy of the PD classification; Finally, the Support Vector Machine(SVM) classifier is adopted. Experiments show that it achieves the highest classification accuracy of 95.0% and the average classification accuracy of 86.0%, and obtains obvious improvement according to the subjects, compared with the relevant algorithms. Besides, compared with sparse coding, convolutional sparse coding can be beneficial to extracting high level features from PD data set; moreover, it is proved that transfer learning is effective.

Key words: Transfer learning; Parkinson's Disease (PD); Sparse Coding (SC); Convolutional Sparse Coding (CSC); Speech sample feature parallel selection

1 引言

帕金森病(Parkinson's Disease, PD)是一种退行性神经疾病, 随身监测、早期诊断、及时干预是提高PD诊疗质量的关键。基于语音的PD检测方法具有便利性、性价比高、非接触式、无创等优势, 因此对其进行深入研究提高其诊断性具有很大的科研价值和现实意义^[1-3]。

目前, PD语音特征参数提取的主要类型有基音周期、振幅微扰、基频微扰、谐波信噪比及基频标准差等多种类型^[4-8]。特征选择变换的方法有主成分分析^[9,10], 神经网络方法^[11,12], 串行搜索法、基于进化算法^[13]。分类器的方法主要有支持向量机^[5,6]、K最近邻网络、随机森林^[5]和决策树^[14]等。

上述研究均基于当前语音数据采用机器学习算法实现PD分类, 取得了较大进展^[15,16]。但是, 这些方法大都直接基于当前语音数据集本身进行。目前这些PD语音公共数据集规模较小, 难以采用深度学习方法进行处理, 样本和特征的同时优选有利于在小样本量情况下获得高质量的样本和特征, 提高分类准确性^[16]。尽管如此, 小样本量仍然限制了样本和特征的学习质量。稀疏编码(Sparse Coding, SC)^[17-20]可以有效压缩特征维度, 解决小样本量问题; 考虑到现已存在大量的公共语音库数据, 可考虑结合迁移学习, 对公共语音数据集进行稀疏迁移学习^[21], 从而弥补PD数据量很小且与测试数据特征分布不同的问题, 有效提升分类准确性。除传统稀疏编码外, 近年来在2维图像处理中流行的卷积稀疏编码^[22-24]具有较好的非监督稀疏学习能力。现有公共语音库主要都不带有标签, 因此可以考虑将该卷积稀疏学习用于从公共语音库中学习语音特征表达PD的更有效结构。此外, 为了进一步提升PD分类准确率, 本文还将样本特征同时优选的机制引入到稀疏编码的后续处理中, 提高分类准确性。

2 基于语音卷积稀疏迁移学习和并行优选的PD分类算法(PD_CSC&S²_TL)

2.1 算法总体简述

本文算法主要流程如下。首先, 将公共语音库加噪扩展成一个更大的语音库, 并对扩展语音库进行特征提取形成语音特征库构造源领域数据集。然后, 对源领域数据集进行稀疏编码学习, 其中稀疏编码考虑传统稀疏编码和卷积稀疏编码两种方法处理, 传统稀疏编码训练学习得到稳定的稀疏字典 D , 卷积稀疏编码训练学习得到稳定的卷积核 D' 。基于稀疏字典, 卷积核对目标领域数据集即PD训练数据集编码计算稀疏表达系数, 并归一化形成稀疏表达系数矩阵 E 。为降低计算复杂度以提升其工程价值, 本文尝试分别用传统稀疏编码和卷积稀疏编码处理, 获取本文算法两个版本(基于语音传统稀疏迁移学习和并行优选的PD分类算法(classification algorithm of Parkinson's Disease based on speech Sparse Coding Transfer Learning and Simultaneous Selection, PD_SC&S²_TL)和基于语音卷积稀疏迁移学习和并行优选的PD分类算法(classification algorithm of Parkinson's Disease based on speech Convolutional Sparse Coding Transfer Learning and Simultaneous Selection, PD_CSC&S²_TL))。接着, 将稀疏表达特征矩阵进行特征扩展, 并采用交叉验证法将其划分为训练样本集和测试样本集。然后, 基于Relief算法^[25]计算训练样本集中混合特征的权重并进行特征优选生成训练测试样本特征集合 P ^[16], 其中优选方法及卷积稀疏编码的特征图选取方法满足训练样本类内距极小、类间距极大原则。最后, 设计支撑向量机(Support Vector Machine, SVM)分类器, 对重构后的训练集与测试集分别训练、测试, 得到分类结果。上述两种算法对应的非迁移学习版本分别记作PD_SC&S²

和PD_CSC&S², 可作为被比较算法, 从而显示稀疏迁移学习的有效性。

2.2 算法实现与分析

2.2.1 符号说明

目标领域数据集 $\mathbf{A}$, 样本总数为 H , 每个样本的特征数(向量分量数)为 N , 全体样本划分为 M 个受试者(subject), 即每个受试者包含的样本数为: $H_0 = H/M$; 公共数据集 $\mathbf{S}$ 通过加入不同信噪比不同类型噪声扩展为规模更大数据集 $\mathbf{S}'$, 并进行特征提取形成特征库

$$\begin{aligned} \mathbf{Y} &= \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_L \end{bmatrix} \\ &= \begin{bmatrix} \xi_1(\mathbf{S}'_1) & \xi_2(\mathbf{S}'_1) & \cdots & \xi_N(\mathbf{S}'_1) \\ \xi_1(\mathbf{S}'_2) & \xi_2(\mathbf{S}'_2) & \cdots & \xi_N(\mathbf{S}'_2) \\ \vdots & \vdots & \ddots & \vdots \\ \xi_1(\mathbf{S}'_L) & \xi_2(\mathbf{S}'_L) & \cdots & \xi_N(\mathbf{S}'_L) \end{bmatrix} \\ &= \begin{bmatrix} \tilde{\mathbf{Y}}_1 \\ \tilde{\mathbf{Y}}_2 \\ \vdots \\ \tilde{\mathbf{Y}}_L \end{bmatrix} \end{aligned} \quad (1)$$

作为源领域数据集, 其中 $\mathbf{Y}_i = [\xi_1(\mathbf{S}'_i), \xi_2(\mathbf{S}'_i), \dots, \xi_N(\mathbf{S}'_i)]$, $1 \leq i \leq L$, 采用文献[6]中特征提取方法提取信号 N 个不同特征, 特征样本总数为 L , $\tilde{\mathbf{Y}}_i$ 为 2 维 $H_0 \times N$ 块矩阵, 且 $\mathbf{Y}_i$ 为稀疏字典学习训练样本, $\tilde{\mathbf{Y}}_i$ 为卷积核稀疏学习训练样本。为方便对比分析, 非迁移学习版本PD_SC&S2和PD_CSC&S2的源领域数据集直接用目标领域数据集中的训练集, 其余算法流程与对应的迁移版本保持一致。

2.2.2 PD_SC&S2_TL的稀疏字典学习

在稀疏编码中, 给定 M 个训练样本 $\{\mathbf{x}_m\}_{m=1}^M$, 通过式(2)最小化目标函数学习稀疏字典 $\{\mathbf{d}_k\}_{k=1}^K$ 。

$$\begin{aligned} \arg \min_{\mathbf{a}, \mathbf{d}} \quad & \frac{1}{2} \sum_{m=1}^M \left\| \mathbf{x}_m - \sum_{k=1}^K \mathbf{a}_{m,k} \mathbf{d}_k \right\|_2^2 + \lambda \sum_{m=1}^M \sum_{k=1}^K \|\mathbf{a}_{m,k}\|_1, \\ \text{s.t.} \quad & \|\mathbf{d}_k\|_2^2 \leq c, \forall k = \{1, 2, \dots, K\} \end{aligned} \quad (2)$$

其中, $\mathbf{x}_m = \tilde{\mathbf{Y}}_m$ 为源域样本向量, $\mathbf{a}_{m,k}$ 是稀疏表达系数, 通过与相对应的稀疏字典 $\mathbf{d}_k$ 逼近向量 $\mathbf{x}_m$, λ 是大于0的正则化因子。

$$\begin{aligned} \min_{\mathbf{D}, \mathbf{a}} \quad & \frac{1}{2} \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_F^2 + \lambda \sum_{m,k} \|\mathbf{a}_{m,k}\|_1, \\ \text{s.t.} \quad & \sum_{m=1}^M d_{m,k}^2 \leq c, \forall k = \{1, 2, \dots, K\} \end{aligned} \quad (3)$$

通过保持 $\mathbf{D}$ 和 $\mathbf{a}$ 中其中一个变量不变, 不断迭代优化可逼近最优稀疏字典 $\mathbf{D}$ 和系数 $\mathbf{a}$, 当保持字典 $\mathbf{D}$ 不变学习系数 $\mathbf{a}$ 时, 本文采用快速的特征符号搜索法(Feature-sign search)^[20]。当保持系数 $\mathbf{a}$ 不变学习 $\mathbf{D}$ 时, 可采用拉格朗日对偶法^[20]。式(3)可重新表达为 $\min \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_F^2, \text{ s.t. } \sum_{m=1}^M d_{m,k}^2 \leq c, \forall k = \{1, 2, \dots, K\}$ 。

转化为拉格朗日对偶式: $\varsigma(\mathbf{D}, \boldsymbol{\lambda}) = \text{trace}((\mathbf{D}\mathbf{a} - \mathbf{x})^T(\mathbf{D}\mathbf{a} - \mathbf{x}) + \sum_{k=1}^K \lambda_k \left(\sum_{m=1}^M d_{m,k}^2 - c \right))$, 最小化拉格朗日对偶 $\eta(\boldsymbol{\lambda}) = \min_{\mathbf{D}} \varsigma(\mathbf{D}, \boldsymbol{\lambda}) = \text{trace}(\mathbf{x}^T \mathbf{x} - \mathbf{x} \mathbf{a}^T (\mathbf{a} \mathbf{a}^T + \boldsymbol{\Lambda})^{-1} (\mathbf{x} \mathbf{a}^T)^T - c \boldsymbol{\Lambda})$, 其中, $\boldsymbol{\Lambda} = \text{diag}(\boldsymbol{\lambda})$, 则 $\eta(\boldsymbol{\lambda})$ 的梯度及海森矩阵计算为: $\partial \eta(\boldsymbol{\lambda}) / (\partial \lambda_i) = \left\| \mathbf{x} \mathbf{a}^T (\mathbf{a} \mathbf{a}^T + \boldsymbol{\Lambda})^{-1} \mathbf{e}_i \right\|^2 - c$, $\partial^2 \eta(\boldsymbol{\lambda}) / (\partial \lambda_i \partial \lambda_j) = -2((\mathbf{a} \mathbf{a}^T + \boldsymbol{\Lambda})^{-1} (\mathbf{x} \mathbf{a}^T)^T \mathbf{x} \mathbf{a}^T (\mathbf{a} \mathbf{a}^T + \boldsymbol{\Lambda})^{-1})_{i,j} ((\mathbf{a} \mathbf{a}^T + \boldsymbol{\Lambda})^{-1})_{i,i}$, 并通过式 $\mathbf{D}^T = (\mathbf{a} \mathbf{a}^T + \boldsymbol{\Lambda})^{-1} (\mathbf{x} \mathbf{a}^T)^T$ 得到一组最优稀疏字典 $[\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_K]$ 。

2.2.3 PD_CSC&S2_TL的卷积核稀疏学习

在卷积稀疏编码(CSC)中, 给定 M 个训练样本 $\{\mathbf{x}_m\}_{m=1}^M$, 通过式(4)最小化目标函数学习卷积核组 $\{\mathbf{d}_k\}_{k=1}^K$ 。

$$\begin{aligned} \arg \min_{\mathbf{a}, \mathbf{d}} \quad & \frac{1}{2} \sum_{m=1}^M \left\| \mathbf{x}_m - \sum_{k=1}^K \mathbf{d}_k * \mathbf{a}_{m,k} \right\|_2^2 \\ & + \lambda \sum_{m=1}^M \sum_{k=1}^K \|\mathbf{a}_{m,k}\|_1, \\ \text{s.t.} \quad & \|\mathbf{d}_k\|_2^2 \leq 1, \forall k = \{1, 2, \dots, K\} \end{aligned} \quad (4)$$

其中, $\mathbf{x}_m = \tilde{\mathbf{Y}}_m$ 为 $H_0 \times N$ 块矩阵, $\mathbf{a}_{m,k}$ 为 $H_0 \times N$ 特征图矩阵, 通过与相对应的卷积核 $\mathbf{d}_k$ 卷积逼近 $\mathbf{x}_m$, 符号 $*$ 表示2维卷积符号, λ 是大于0的正则化因子, 解决以上优化问题的方法都是基本经典框架交替方向乘子法(ADMM)^[26]。

式(4)可重新表达为

$$\arg \min_{\mathbf{a}} (1/2) \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_2^2 + \lambda \|\mathbf{a}\|_1 \quad (5)$$

其中, $\sum_{k=1}^K \mathbf{d}_k * \mathbf{a}_{m,k} = \mathbf{D}\mathbf{a}$, $\mathbf{D} = [\mathbf{D}_1 \mathbf{D}_2 \cdots \mathbf{D}_K]$ 为 $[\mathbf{d}_1 \mathbf{d}_2 \cdots \mathbf{d}_K]$ 所对应的向量化卷积运算符, $\mathbf{a} = [\mathbf{a}_1^T \mathbf{a}_2^T \cdots \mathbf{a}_K^T]^T$ 为向量化特征图。

进一步由式(5)表达为 $\arg \min_{\mathbf{a}, \mathbf{b}} (1/2) \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_2^2 + \lambda \|\mathbf{b}\|_1, \text{ s.t. } \mathbf{a} - \mathbf{b} = 0$ 。

可通过ADMM迭代求解, 并分为如下两个过程:

(1) 固定卷积核求特征图:

$$\begin{aligned} \mathbf{a}^{(j+1)} = \arg \min_a & \frac{1}{2} \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_2^2 \\ & + \frac{\rho}{2} \left\| \mathbf{a} - \mathbf{b}^{(j)} + \mathbf{u}^{(j)} \right\|_2^2 \end{aligned} \quad (6)$$

$$\mathbf{b}^{(j+1)} = \arg \min_b \lambda \|\mathbf{b}\|_1 + \frac{\rho}{2} \left\| \mathbf{a}^{(j+1)} - \mathbf{b} + \mathbf{u}^{(j)} \right\|_2^2 \quad (7)$$

$$\mathbf{u}^{(j+1)} = \mathbf{u}^{(j)} + \mathbf{a}^{(j+1)} - \mathbf{b}^{(j+1)} \quad (8)$$

(2) 固定稀疏表达系数求卷积核:

$$\begin{aligned} \mathbf{d}^{(j+1)} = \arg \min_d & \frac{1}{2} \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_2^2 \\ & + \frac{\rho}{2} \left\| \mathbf{d} - \mathbf{c}^{(j)} + \mathbf{v}^{(j)} \right\|_2^2 \end{aligned} \quad (9)$$

$$\mathbf{c}^{(j+1)} = \arg \min_c \lambda \|\mathbf{c}\|_1 + \frac{\rho}{2} \left\| \mathbf{d}^{(j+1)} - \mathbf{c} + \mathbf{v}^{(j)} \right\|_2^2 \quad (10)$$

$$\mathbf{v}^{(j+1)} = \mathbf{v}^{(j)} + \mathbf{d}^{(j+1)} - \mathbf{c}^{(j+1)} \quad (11)$$

最终交替迭代得到一组稀疏卷积核 $[\mathbf{d}'_1, \mathbf{d}'_2, \dots, \mathbf{d}'_k]$ 。

2.2.4 稀疏表达系数(特征图)的求解

传统稀疏编码的稀疏表达系数学习本文通过正交匹配跟踪算法(Orthogonal Matching Pursuit, OMP)^[27]完成, 基于稀疏字典 $[\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_k]$ 将目标领域特征向量 $\mathbf{A}_i$ 映射为稀疏表达系数 $\mathbf{E}_i$, 并生成新的

$$\text{特征集 } \mathbf{E} = \begin{bmatrix} \mathbf{E}_1 \\ \mathbf{E}_2 \\ \vdots \\ \mathbf{E}_H \end{bmatrix} = \begin{bmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1K} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{H1} & \beta_{H2} & \cdots & \beta_{HK} \end{bmatrix};$$

卷积稀疏编码的特征图学习可通过ADMM框架实现, 当卷积核 $[\mathbf{d}'_1, \mathbf{d}'_2, \dots, \mathbf{d}'_k]$ 固定, 本文采用快速卷积稀疏编码算法^[28], 其中式(6)、式(7)展开为

$$\begin{aligned} \mathbf{a}^{(j+1)} &= \arg \min_a \frac{1}{2} \|\mathbf{D}\mathbf{a} - \mathbf{x}\|_2^2 + \frac{1}{2} \left\| \mathbf{a} - \mathbf{b}^{(j)} + \mathbf{u}^{(j)} \right\|_2^2 \\ &= (\mathbf{D}^T \mathbf{D} + \mathbf{I})^{-1} (\mathbf{D}^T \mathbf{x} + \mathbf{b}^{(j)} - \mathbf{u}^{(j)}) \\ &= (\mathbf{I} - \mathbf{D}^T (\mathbf{I} + \mathbf{D} \mathbf{D}^T)^{-1} \mathbf{D}) \\ &\quad \cdot (\mathbf{D}^T \mathbf{x} + \mathbf{b}^{(j)} - \mathbf{u}^{(j)}) \end{aligned} \quad (12)$$

$$\begin{aligned} \mathbf{b}^{(j+1)} &= \arg \min_b \lambda \|\mathbf{b}\|_1 + \frac{1}{2} \left\| \mathbf{a}^{(j+1)} - \mathbf{b} + \mathbf{u}^{(j)} \right\|_2^2 \\ &= S_\lambda \left(\left\| \mathbf{a}^{(j+1)} + \mathbf{u}^{(j)} \right\| \right) \\ &= \begin{cases} \mathbf{a}^{(j+1)} + \mathbf{u}^{(j)} - \lambda, & \mathbf{a}^{(j+1)} + \mathbf{u}^{(j)} > \lambda \\ 0, & \left| \mathbf{a}^{(j+1)} + \mathbf{u}^{(j)} \right| \leq \lambda \\ \mathbf{a}^{(j+1)} + \mathbf{u}^{(j)} + \lambda, & \mathbf{a}^{(j+1)} + \mathbf{u}^{(j)} < -\lambda \end{cases} \end{aligned} \quad (13)$$

因卷积核已固定, 式(13)中 $(\mathbf{I} - \mathbf{D}^T (\mathbf{I} + \mathbf{D} \mathbf{D}^T)^{-1} \mathbf{D})$

可预先计算作固定参数极大简化算法复杂度, 式(13) $S_\lambda(\cdot)$ 为元素化操作的软阈值函数, 经过多次迭代得到稳定的特征图。目标领域特征矩阵 $\tilde{\mathbf{A}}_i$ 映射为特征图矩阵组 $\hat{\mathbf{a}} = [\mathbf{a}'_1 \mathbf{a}'_2 \cdots \mathbf{a}'_K]$, 选取其中 $\mathbf{a}'_k$ 作为特定映射 $\tilde{\mathbf{E}}_m$, 并构造新的特征集

$$\mathbf{E} = \begin{bmatrix} \tilde{\mathbf{E}}_1 \\ \tilde{\mathbf{E}}_2 \\ \vdots \\ \tilde{\mathbf{E}}_M \end{bmatrix}, \quad \mathbf{a}'_k \text{ 选取方法见2.2.5节。}$$

2.2.5 语音样本特征并行优选算法

特征扩展, 并构造

$$\begin{aligned} \mathbf{G} &= \begin{bmatrix} \mathbf{G}_1 \\ \mathbf{G}_2 \\ \vdots \\ \mathbf{G}_M \end{bmatrix} \\ &= \begin{bmatrix} \mathbf{E}_1 & \mathbf{E}_2 & \cdots & \mathbf{E}_{H_0} \\ \mathbf{E}_{H_0+1} & \mathbf{E}_{H_0+2} & \cdots & \mathbf{E}_{2*H_0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{E}_{(M-1)*H_0+1} & \mathbf{E}_{(M-1)*H_0+2} & \cdots & \mathbf{E}_{M*H_0} \end{bmatrix} \\ &= \begin{bmatrix} \mathbf{RS} \left(\begin{bmatrix} \tilde{\mathbf{E}}_1 & H_0 \times N & 1 \times N' \end{bmatrix} \right) \\ \mathbf{RS} \left(\begin{bmatrix} \tilde{\mathbf{E}}_2 & H_0 \times N & 1 \times N' \end{bmatrix} \right) \\ \vdots \\ \mathbf{RS} \left(\begin{bmatrix} \tilde{\mathbf{E}}_M & H_0 \times N & 1 \times N' \end{bmatrix} \right) \end{bmatrix}_{\text{CSC}} \\ &= \begin{bmatrix} \gamma_{11} & \gamma_{12} & \cdots & \gamma_{1N_0} \\ \gamma_{21} & \gamma_{22} & \cdots & \gamma_{2N_0} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{M1} & \gamma_{M2} & \cdots & \gamma_{MN_0} \end{bmatrix} \end{aligned} \quad (14)$$

其中, 传统稀疏编码的特征扩展是将同一个受试者的 H_0 个行向量 $\mathbf{E}_i$ 扩展为一个行向量, 卷积稀疏编码的特征扩展用 $\mathbf{RS}(\cdot)$ 函数将特征矩阵 $\tilde{\mathbf{E}}_m$ 重整为行向量, 即矩阵中 H_0 个 N 维行向量依次排列成一个 $H_0 \times N$ 维行向量, 归一化 $\mathbf{G}$ 得 $\mathbf{G}'$, 并分割 $\mathbf{G}' = \begin{bmatrix} \mathbf{G}_m \\ \mathbf{T}_m \end{bmatrix}$ 为训练集 $\mathbf{G}_m = [\mathbf{G}_1 \mathbf{G}_2 \cdots \mathbf{G}_{N_0}]$ 与测试集 $\mathbf{T}_m$ 。通过Relief算法计算权重并根据权重大小优选构造新的训练测试样本特征集合 $\mathbf{P}_{\mathbf{G}_m}^Q, \mathbf{P}_{\mathbf{T}_m}^Q$

$$\begin{aligned}
\mathbf{P} &= \begin{bmatrix} \mathbf{P}_{G_m}^Q \\ \mathbf{P}_{T_m}^Q \end{bmatrix} = \begin{bmatrix} \vec{\mathbf{P}}_1 \\ \vec{\mathbf{P}}_2 \\ \vdots \\ \vec{\mathbf{P}}_M \end{bmatrix} = \mathbf{G}_m \mathbf{C} \\
&= \begin{bmatrix} \gamma_{11} & \gamma_{12} & \cdots & \gamma_{1N_0} \\ \gamma_{21} & \gamma_{22} & \cdots & \gamma_{2N_0} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{M1} & \gamma_{M2} & \cdots & \gamma_{MN_0} \end{bmatrix} \\
&\quad \cdot \begin{bmatrix} c_{11} & c_{21} & \cdots & c_{Q1} \\ c_{12} & c_{22} & \cdots & c_{Q2} \\ \vdots & \vdots & \ddots & \vdots \\ c_{1N_0} & c_{2N_0} & \cdots & c_{QN_0} \end{bmatrix} \\
&= \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1Q} \\ p_{21} & p_{22} & \cdots & p_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ p_{M1} & p_{M2} & \cdots & p_{MQ} \end{bmatrix} \quad (15)
\end{aligned}$$

其中, $\mathbf{C}$ 为 $\mathbf{G}_m$ 优选矩阵, $c_{ij} = \begin{cases} 1, j = \text{ID}(w_i) \\ 0, \text{其他} \end{cases}$,

$1 < i < Q$ 。索引函数 $\text{ID}(w_i)$ 获取权重值 w_i 所对应特征向量标记, 基于Relief算法计算归一化特征向量 $[\mathbf{F}'_1 \ \mathbf{F}'_2 \ \cdots \ \mathbf{F}'_{N_0}]$ 的权重向量 $\mathbf{W} = [w_1 w_2 \cdots w_{N_0}]$, 其中 $\mathbf{F}'_j$ 的权重为

$$\begin{aligned}
w_j &= \sum_i^M \left(- \sum_r^R \left\| \gamma_{ij} - M_r(\gamma_{ij}) \right\|^2 \right. \\
&\quad \left. + \sum_r^R \left\| \gamma_{ij} - H_r(\gamma_{ij}) \right\|^2 \right) \quad (16)
\end{aligned}$$

其中, $M(\gamma_{ij})$ 为 γ_{ij} 的 R 个同类近邻集合, $H(\gamma_{ij})$ 为 γ_{ij} 的 R 个异类近邻集合, $M_r(\gamma_{ij}) \in M(\gamma_{ij})$, $H_r(\gamma_{ij}) \in H(\gamma_{ij})$ 。

且重排序 $w_1 \geq w_2 \geq \cdots \geq w_Q$ 优选前 Q 个权重值最大的特征向量, 并使得训练样本类内距极小, 类间距极大。

$$\begin{aligned}
Q &= \arg \left(\min \sum_i \left\| \mathbf{P}_{G_m(i)} - M_r(\mathbf{P}_{G_m(i)}) \right\|_2^2 \right. \\
&\quad \cdot \text{AND} \max \sum_i \left\| \mathbf{P}_{G_m(i)} - H_r(\mathbf{P}_{G_m(i)}) \right\|_2^2 \left. \right) \quad (17)
\end{aligned}$$

对卷积稀疏编码而言, 特征图是一组矩阵 $\hat{\mathbf{a}} = [a'_1 a'_2 \cdots a'_K]$, 选取方法采用遍历组内特征图并使得最终样本类内距极小, 类间距极大的原则选取。

$$k = \arg \left(\begin{aligned} &\min \sum_i \left\| \mathbf{RS}(a'_{ik} H_0 \times N \ 1 \times N')_{G_m(i)}^Q \right\|_2^2 \\ &- M_r \left(\mathbf{RS}(a'_{ik} H_0 \times N \ 1 \times N')_{G_m(i)}^Q \right) \left\|_2^2 \right. \\ &\max \sum_i \left\| \mathbf{RS}(a'_{ik} H_0 \times N \ 1 \times N')_{G_m(i)}^Q \right\|_2^2 \\ &- H_r \left(\mathbf{RS}(a'_{ik} H_0 \times N \ 1 \times N')_{G_m(i)}^Q \right) \left\|_2^2 \end{aligned} \right) \quad (18)$$

本文算法的两个版本流程类似, 主要区别是稀疏学习不同。这里以基于卷积核稀疏的版本(PD_CSC&S2_TL)进行算法步骤描述。该算法的伪代码描述如表1所示。

表 1 基于语音卷积稀疏迁移学习和并行优选的PD分类算法

输入: 公共数据集 $\mathbf{S}$, 目标领域数据集 $\mathbf{A}$, 样本总数 H , 每个样本的特征数 N , 受试者数 M
输出: 分类准确率, 灵敏度, 特异度
步骤:
(1)对公共数据集 $\mathbf{S}$ 叠加不同类型不同信噪比的噪声扩展其集合 $\mathbf{S}'$;
(2)根据式(1), 对集合 $\mathbf{S}'$ 的语音样本提取特征构造特征库即源领域数据集 $\mathbf{Y}$;
(3)根据2.2.2节及2.2.3节, 提取特征库 $\mathbf{Y}$ 的字典(稀疏编码), 卷积核(卷积稀疏编码);
(4)根据1.2.4节, 计算目标领域数据集 $\mathbf{A}$ 的稀疏表达系数矩阵 $\mathbf{E}$ (稀疏编码)或特征图矩阵 $\mathbf{E}$ (卷积稀疏编码);
(5)根据语音样本特征并行优选算法, 将特征矩阵 $\mathbf{E}$ 进行特征扩展为 $\mathbf{G}$ 并归一化为 $\mathbf{G}'$, 并进行样本特征同时优选得矩阵 $\mathbf{P}$;
(6)基于SVM分类器进行受试者留一法(LOSO)分类计算。

3 实验结果与分析

3.1 实验条件

本文实验硬件实验平台CPU为intel i7-7700k, 内存64G。PD_SC&S2_TL的训练部分使用软件平台linux matlab R2015a, 参数是: 训练迭代次数取100, 稀疏惩罚因子取0.4, 基向量数取30~140, 代价函数取L1范数。PD_SC&S2_TL的编码、语音特征并行优选部分及PD_CSC&S2_TL的软件平台为win7 matlab R2016a, PD_CSC&S2_TL算法中, 训练迭代次数取1000, 卷积核数量取2~8, 惩罚因子取0.3。

本文实验的源领域数据集为TIMIT标准语音库。训练集包含了40男40女, 每人3句话, 然后叠加噪声(NOISEX-92噪声库)扩展为原来的10倍, 并通过算法自动调用praat工具提取Jitter, Shimmer, AC, NTH, HTN等26个语音特征形成特征库。由于相同训练参数下重复训练产生的稀疏字典不一定一致, 因此在相同训练参数下重复10次实验。本文

选用Sakar等人^[6]于2014年创建的较新的PD数据集作为目标集。这个帕金森病语音公共数据集可从加州大学欧文分校(UCI)机器学习数据库网站获取,给出了该数据集的下载链接。目前国际上有代表性的帕金森语音公共数据集之一为国际PD语音学者Saker等人提供的数据集。该数据集包含40个受试者的信息,其中帕金森患者20人(14个男性,6个女性),正常人20人(10个男性,10个女性)。每个受试者有26个不同发音任务的语音样本,每个样本有26个特征。基于数据集中的40受试者进行受试者留一法(Leave-One-Subject-Out, LOSO)交叉验证。选择该交叉验证法的主要原因在于:目前样本数还不够高,该验证法能最大化训练样本数,从而更能体现算法的潜在能力,且所有样本都参与测试,测试准确率更能接近实际应用场景中的结果。与目前一些相关文献采用 m 阶和hold-out交叉验证法不同,在该验证法下,训练集和测试集中样本均来自于不同的受试者,从而保证分类准确率不会虚高,符合实际诊断情况。此外,本文算法的性能评估准则参见文献^[15]。


3.2 算法性能比较分析

图1显示本文算法采用迁移学习前后的准确率


比较图;其中图1(a)为PD_SC&S²_TL与PD_SC&S²的准确率分布比较图,横坐标为基向量数,纵坐标为分类准确率,图1(b)为PD_CSC&S²_TL与PD_CSC&S²准确率分布比较图,横坐标为卷积核数,纵坐标均为分类准确率。由图可见,使用迁移学习后的分类准确率比使用前显著提高:PD_SC&S²_TL的准确率集中分布在70%~92%,而PD_SC&S²准确率集中分布在50%~70%,两者差别明显;PD_CSC&S²_TL准确率集中分布在75%~95%,PD_CSC&S²准确率集中分布在60%~77%,两者差别明显。这结果说明,迁移学习能够有利于学习到更多有效信息,从而有助于提升测试准确率。

图2显示采用迁移学习前后的ROC曲线比较,横坐标为假阳性率(1-特异度),纵坐标为真阳性率(灵敏度)。图2(a)为PD_SC&S²_TL与PD_SC&S²在基向量数 $N=50$ 时的ROC曲线对比图,图2(b)为PD_CSC&S²_TL与PD_CSC&S²在卷积核 $K=7$ 时的ROC曲线对比图。

由图2可见,使用迁移学习后ROC曲线更靠近左上角,说明迁移学习更能有效提升PD诊断性能,其中图2(a)中PD_SC&S²_TL的最大youden指数




(a) PD_SC&S²_TL与PD_SC&S²的准确率分布比较图




(b) PD_CSC&S²_TL与PD_CSC&S²准确率分布比较图

图1 本文算法使用迁移学习前后的平均分类准确率比较



(a) PD_SC&S²_TL与PD_SC&S²的ROC曲线比较图



(b) PD_CSC&S²_TL与PD_CSC&S²的ROC曲线比较图

图2 本文算法使用迁移学习前后的ROC曲线比较

即最佳临界点A坐标为(0.15, 0.86), 图2(b)中PD_CSC&S²_TL的最佳临界点B坐标为(0.14, 0.86), 其所对应的系统参数能让灵敏度和特异度同时达到较高值, 即误诊率和漏诊率均较小。

表2中被比较算法为: 线性核函数SVM算法、径向基核函数SVM算法, DBN算法, CNN算法, autoencoder+SVM(TL), autoencoder+SVM, DBN+SVM(TL), DBN+SVM, PD_SC&S²和PD_CSC&S²。其中, autoencoder和DBN的迁移(记为“算法(TL)”)和非迁移版本, 分别记做autoencoder+SVM(TL), autoencoder+SVM, DBN+SVM(TL), DBN+SVM, 迁移版本主要流程为: 利用autoencoder和DBN对源数据集进行无监督学习, 然后用训练好的网络对目标数据集进行特征表示, 提取其中一层隐含层, 再对其进行SVM训练分类, 非迁移版本与迁移版本的不同之处在于, 非迁移版本对目标数据集进行无监督学习而不是源数据集。本文算法主要分为PD_SC&S², PD_SC&S²_TL, PD_CSC&S², PD_CSC&S²_TL。

如表2所示, PD_CSC&S²_TL的平均准确率达到了86.0%, 相较于径向基核函数SVM算法, 从67.5%提高到86.0%, 改进了18.5%; 在灵敏度上, 相较于径向基核函数SVM算法, 从80.0%提高到91.0%, 改进了11.0%; 在特异度上, PD_SC&S²_TL达到了82.5%, 相较于线性核函数SVM算法, 从65.0%提高到82.5%, 改进了17.5%。此外对比文献[6]算法, DBN算法及CNN算法, 本文算法改进效果更加明显。

比较PD_SC&S²_TL和PD_CSC&S²_TL发现, PD_CSC&S²_TL效果更好, 在平均准确率上, 后者从81.0%提高到86.0%, 说明PD_CSC&S²_TL中的卷积编码更能提取数据的有效特征。比较使用迁移学习和未使用迁移学习可以发现, PD_SC&S²_TL和PD_CSC&S²_TL能实现更好的分类准确率。这体现在: PD_SC&S²_TL较PD_SC&S²平均准确率从68.5%提高到81.0%, 改进了12.5%; 灵敏度从69.5%到79.5%, 改进了10.0%; 特异度从67.5%到82.5%, 改进了15%。PD_CSC&S²_TL较PD_CSC&S²平均准确率从70.0%提高到86.0%, 改进了16.0%; 灵敏度从73.0%到91.0%, 改进了18.0%; 特异度从67.0%到81.0%, 改进了14%。PD_CSC&S²_TL具有最大分类准确率, 最大灵敏度, PD_SC&S²_TL具有最大特异度。

由表2可以发现, 本文算法的分类准确率、敏感度和特异度均最高。SVM算法的分类准确率可达到67.5%, 但相比于本文算法来说, 差距较大。两种原始深度学习DBN和CNN的平均分类准确率

较低, autoencoder+SVM(TL)平均准确率为72.5%, DBN+SVM(TL)平均准确率为55.5%, 均高于其对应的非迁移版本。这表明, 迁移学习能够

表2 各种算法分类结果对比(%)

分类算法	基于受试者的留一法		
	准确率	灵敏度	特异度
SVM(线性核函数)			
平均	65.0	65.0	65.0
最好	65.0	65.0	65.0
SVM(径向基核函数)			
平均	67.5	80.0	55.0
最好	67.5	80.0	55.0
文献[6]算法			
平均	52.0	55.0	49.0
最好	85.0	85.0	90.0
DBN算法			
平均	54.6	52.4	56.8
最好	57.0	56.0	58.0
CNN算法			
平均	60.0	63.0	57.0
最好	65.0	61.0	69.0
autoencoder+SVM(TL)			
平均	72.5	75.0	70.0
最好	72.5	75.0	70.0
autoencoder+SVM			
平均	67.5	65.0	70.0
最好	67.5	65.0	70.0
DBN+SVM(TL)			
平均	55.5	60.0	51.0
最好	60.0	65.0	55.0
DBN+SVM			
平均	50.5	53.0	48.0
最好	57.5	65.0	50.0
PD_SC&S ²			
平均	68.5	69.5	67.5
最好	90.0	85.0	95.0
PD_SC&S ² _TL			
平均	81.0	79.5	82.5
最好	92.5	95.0	90.0
PD_CSC&S ²			
平均	70.0	73.0	67.0
最好	75.0	74.0	76.0
PD_CSC&S ² _TL			
平均	86.0	91.0	81.0
最好	95.0	100.0	90.0

在一定程度上提升分类准确率,但均比本文算法差。同时,通过比较本文算法没有迁移学习的两个版本可以发现,迁移学习确实起到了明显的提升效果,准确率、敏感度和特异度均有显著改善。

4 结束语

目前基于语音数据的PD诊断方法研究主要基于本地PD数据。但是由于PD的内在隐蔽性、非致命性等原因,采集PD样本难度较大,这就导致了小样本量与高准确率的矛盾问题。本文采用卷积稀疏学习算法降维,减小对样本量的需求;基于公共语音库进行稀疏迁移学习,从而有效扩大样本量;采用混合语音特征学习实现样本特征同时优选,提高分类准确性。基于以上方法,形成了本文的改进PD分类诊断算法。最后,采用了多个代表性算法进行性能验证比较。实验结果表明,本文算法中迁移学习和卷积稀疏编码是有效的。相比于被比较算法,本文算法在分类准确率、敏感度和特异度均取得了明显提升。由于PD诊断的训练数据集样本量小是一个始终存在的主要矛盾,下一步考虑基于本文成果,进一步研究扩展公共语音数据集的规模及类型。

参考文献

- [1] BENGE J F, ROBERTS R L, KEKECS Z, *et al.* Brief report: knowledge of, interest in, and willingness to try behavioral interventions in individuals with Parkinson's disease[J]. *Advances in Mind-Body Medicine*, 2018, 32(1): 8–12.
- [2] PLOUVIER A O A, OLDE HARTMAN T C, VAN LITSENBURG A, *et al.* Being in control of Parkinson's disease: a qualitative study of community-dwelling patients' coping with changes in care[J]. *European Journal of General Practice*, 2018, 24(1): 138–145. doi: [10.1080/13814788.2018.1447561](https://doi.org/10.1080/13814788.2018.1447561).
- [3] CHIU Y F and FORREST K. The impact of lexical characteristics and noise on intelligibility of Parkinsonian speech[J]. *Journal of Speech, Language, and Hearing Research*, 2018, 61(4): 837–846. doi: [10.1044/2017_JSLHR-S-17-0205](https://doi.org/10.1044/2017_JSLHR-S-17-0205).
- [4] LITTLE M A, MCSHARRY P E, HUNTER E J, *et al.* Suitability of dysphonia measurements for telemonitoring of Parkinson's disease[J]. *IEEE Transactions on Biomedical Engineering*, 2009, 56(4): 1015–1022. doi: [10.1109/TBME.2008.2005954](https://doi.org/10.1109/TBME.2008.2005954).
- [5] TSANAS A, LITTLE M A, MCSHARRY P E, *et al.* Novel speech signal processing algorithms for high-accuracy classification of Parkinson's disease[J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(5): 1264–1271. doi: [10.1109/TBME.2012.2183367](https://doi.org/10.1109/TBME.2012.2183367).
- [6] SAKAR B E, ISENKUL M E, SAKAR C O, *et al.* Collection and analysis of a Parkinson speech dataset with multiple types of sound recordings[J]. *IEEE Journal of Biomedical and Health Informatics*, 2013, 17(4): 828–834. doi: [10.1109/JBHI.2013.2245674](https://doi.org/10.1109/JBHI.2013.2245674).
- [7] GODINO-LLORENTE J I, SHATTUCK-HUFNAGEL S, CHOI J Y, *et al.* Towards the identification of idiopathic Parkinson's disease from the speech. New articulatory kinetic biomarkers[J]. *PLOS One*, 2017, 12(12): e0189583. doi: [10.1371/journal.pone.0189583](https://doi.org/10.1371/journal.pone.0189583).
- [8] KAYA M and BILGE H Ş. Classification of Parkinson speech data by metric learning[C]. Proceedings of the 2017 International Artificial Intelligence and Data Processing Symposium, Malatya, Turkey, 2017: 1–5. doi: [10.1109/IDAP.2017.8090285](https://doi.org/10.1109/IDAP.2017.8090285).
- [9] JI Wei and LI Yun. Stable dysphonia measures selection for Parkinson speech rehabilitation via diversity regularized ensemble[C]. International Conference on Acoustics, Speech and Signal Processing, Shanghai, China, 2016: 2264–2268. doi: [10.1109/ICASSP.2016.7472080](https://doi.org/10.1109/ICASSP.2016.7472080).
- [10] KIM J, NASIR M, GUPTA R, *et al.* Automatic estimation of Parkinson's disease severity from diverse speech tasks[C]. Proceedings of the 16th Annual Conference of the International Speech Communication Association, Dresden, Germany, 2015: 914–918.
- [11] SHAHBAKHTI M, TAHERIFAR D, and SOROURI A. Linear and non-linear speech features for detection of Parkinson's disease[C]. Proceedings of the 6th 2013 Biomedical Engineering International Conference, Amphur Muang, Thailand, 2013: 1–3. doi: [10.1109/BMEiCon.2013.6687667](https://doi.org/10.1109/BMEiCon.2013.6687667).
- [12] DUBEY H, GOLDBERG J C, ABTAHI M, *et al.* EchoWear: Smartwatch technology for voice and speech treatments of patients with Parkinson's disease[C]. Proceedings of the Conference on Wireless Health, Bethesda, USA, 2015: Article No.15. doi: [10.1145/2811780.2811957](https://doi.org/10.1145/2811780.2811957).
- [13] ARIAS-VERGARA T, VASQUEZ-CORREA J C, OROZCO-ARROYAVE J R, *et al.* Parkinson's disease progression assessment from speech using GMM-UBM[C]. Conference of the International Speech Communication Association, San Francisco, USA, 2016: 1933–1937. doi: [10.21437/Interspeech.2016-1122](https://doi.org/10.21437/Interspeech.2016-1122).
- [14] GEMAN O. Data processing for Parkinson's disease: Tremor, speech and gait signal analysis[C]. Proceedings of the 2011 E-Health and Bioengineering Conference, Iasi, Romania, 2011: 1–4.
- [15] 李勇明, 杨刘洋, 刘玉川, 等. 基于语音样本重复剪辑和随机森林的帕金森病诊断算法研究[J]. 生物医学工程学杂志, 2016,

- 33(6): 1053–1059.
- LI Yongming, YANG Liuyang, LIU Yuchuan, *et al.* Research on diagnosis algorithm of Parkinson's disease based on speech sample multi-edit and random forest[J]. *Journal of Biomedical Engineering*, 2016, 33(6): 1053–1059.
- [16] 张小恒, 王力锐, 曹垚, 等. 混合语音段特征双边式优选算法用于帕金森病分类研究[J]. *生物医学工程学杂志*, 2017, 34(6): 942–948. doi: [10.7507/1001-5515.201704061](https://doi.org/10.7507/1001-5515.201704061).
- ZHANG Xiaoheng, WANG Lirui, CAO Yao, *et al.* Combining speech sample and feature bilateral selection algorithm for classification of Parkinson's disease[J]. *Journal of Biomedical Engineering*, 2017, 34(6): 942–948. doi: [10.7507/1001-5515.201704061](https://doi.org/10.7507/1001-5515.201704061).
- [17] SHARMA P, ABROL V, DILEEP A D, *et al.* Sparse coding based features for speech units classification[J]. *Computer Speech & Language*, 2018, 47: 333–350. doi: [10.1016/j.csl.2017.08.004](https://doi.org/10.1016/j.csl.2017.08.004).
- [18] ZHOU Haotian, ZHUANG Yin, CHEN Liang, *et al.* Ship Detection in Optical Satellite Images Based on Sparse Representation[M]. Singapore: Springer, 2018: 164–171. doi: [10.1007/978-981-10-7521-6_20](https://doi.org/10.1007/978-981-10-7521-6_20).
- [19] LI Jinming. Sparse representation based single image super-resolution with low-rank constraint and nonlocal self-similarity[J]. *Multimedia Tools and Applications*, 2018, 77(2): 1693–1714. doi: [10.1007/s11042-017-4399-1](https://doi.org/10.1007/s11042-017-4399-1).
- [20] LEE H, BATTLE A, RAINA R, *et al.* Efficient sparse coding algorithms[C]. Proceedings of the 19th International Conference on Neural Information Processing Systems, Canada, 2006: 801–808.
- [21] CHANG Hang, HAN Ju, ZHONG Cheng, *et al.* Unsupervised transfer learning via multi-scale convolutional sparse coding for biomedical applications[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(5): 1182–1194. doi: [10.1109/TPAMI.2017.2656884](https://doi.org/10.1109/TPAMI.2017.2656884).
- [22] ZHANG He and PATEL V M. Convolutional sparse and low-rank coding-based image decomposition[J]. *IEEE Transactions on Image Processing*, 2018, 27(5): 2121–2133. doi: [10.1109/TIP.2017.2786469](https://doi.org/10.1109/TIP.2017.2786469).
- [23] HU Xuemei, HEIDE F, DAI Qionghai, *et al.* Convolutional sparse coding for RGB+NIR imaging[J]. *IEEE Transactions on Image Processing*, 2018, 27(4): 1611–1625. doi: [10.1109/TIP.2017.2781303](https://doi.org/10.1109/TIP.2017.2781303).
- [24] WOHLBERG B. Efficient algorithms for convolutional sparse representations[J]. *IEEE Transactions on Image Processing*, 2016, 25(1): 301–315. doi: [10.1109/TIP.2015.2495260](https://doi.org/10.1109/TIP.2015.2495260).
- [25] PERKINS S and THEILER J. Online feature selection using grafting[C]. Proceedings of the Twentieth International Conference on Machine Learning, Washington DC, USA, 2003: 592–599.
- [26] BOYD S, PARIKH N, CHU E, *et al.* Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. *Foundations and Trends® in Machine Learning*, 2011, 3(1): 1–122. doi: [10.1561/22000000016](https://doi.org/10.1561/22000000016).
- [27] EMADI M, MIANDJI E, and UNGER J. OMP-based DOA estimation performance analysis[J]. *Digital Signal Processing*, 2018, 79: 57–65. doi: [10.1016/j.dsp.2018.04.006](https://doi.org/10.1016/j.dsp.2018.04.006).
- [28] ŠOREL M and ŠROUBEK F. Fast convolutional sparse coding using matrix inversion lemma[J]. *Digital Signal Processing*, 2016, 55: 44–51. doi: [10.1016/j.dsp.2016.04.012](https://doi.org/10.1016/j.dsp.2016.04.012).
- 张小恒: 男, 1980年生, 副教授, 工程师, 研究方向为人工智能、生物医学信号与信息处理。
- 李勇明: 男, 1976年生, 教授, 博士生导师, 研究方向为人工智能、生物医学信号信息处理。
- 王 品: 女, 1979年生, 副教授, 硕士生导师, 研究方向为人工智能、生物医学信号信息处理。
- 曾孝平: 男, 1956年生, 教授, 博士生导师, 研究方向为人工智能、信号与信息处理。
- 颜 芳: 男, 1979年生, 副教授, 硕士生导师, 研究方向为生物医学信号信息处理。
- 张艳玲: 女, 1974年生, 教授, 硕士生导师, 研究方向为帕金森病诊疗、生物医学信号信息处理。
- 承欧梅: 女, 1968年生, 教授, 博士生导师, 研究方向为帕金森病诊疗、生物医学信号信息处理。