

基于脑电信号特征提取的睡眠分期方法研究

李 斐,马千里

(南京邮电大学 通信与信息工程学院,江苏 南京 210003)

摘 要:睡眠分期是研究睡眠及其相关疾病的基础,是完成睡眠质量评估的前提,具有重要的意义。主要提出了一种新的脑电信号特征提取方法,能够有效提高睡眠分期的准确率。传统的自动睡眠分期方法都是以一个睡眠时期的时间片为单位进行特征参数提取,文中的睡眠分期按每30 s进行一次睡眠时期判断,将特征提取的时间片分为30 s、90 s、150 s以及210 s,研究不同时间片提取的特征参数对睡眠分期准确率的影响。采用Weka工具中的随机森林分类器对睡眠状态进行判别。实验结果表明,将210 s时间片得到的小波包系数、30 s时间片得到的排列熵以及90 s时间片得到的Petrosian分形维数作为自动睡眠分期的参数,可以得到85%的准确率;而采用30 s时间片得到的以上三类参数只能达到65%的准确率。

关键词:睡眠分期;脑电信号;小波包系数;排列熵;Petrosian分形维数

中图分类号:TP301

文献标识码:A

文章编号:1673-629X(2017)01-0177-05

doi:10.3969/j.issn.1673-629X.2017.01.040

Research on Sleep Staging Method Based on Feature Extraction of EEG

LI Fei, MA Qian-li

(College of Telecommunications & Information Engineering, Nanjing University of
Posts and Telecommunications, Nanjing 210003, China)

Abstract: Researches on sleep staging is not only the basis of diagnosing sleep related diseases, but also the precondition of sleep quality evaluation, which has vital significance. A new method to extract EEG features is proposed which effectively improves the accuracy of sleep staging. Different from traditional automatic sleep staging method, sleep stage is classified every 30 seconds and time slice for feature extraction is respectively divided into 30 seconds, 90 seconds, 150 seconds and 210 seconds to study characteristic parameters of difference time slices on the accuracy of sleep stage. Besides, a random forest classifier in Weka tools is adopted to identify sleep state. The result shows that putting wavelet packet coefficients obtained by the 210 s time slice, the permutation entropy from the 30 s time slice and the Petrosian fractal dimension from 90 s time slice as the parameters of the automatic sleep staging, it can get accuracy of 85%, while three kinds of parameters in 30 s time slice above can only reach accuracy of 65%.

Key words: sleep stage; EEG; wavelet packet coefficient; permutation entropy; Petrosian fractal dimension

0 引言

近年来,睡眠质量成为影响人类健康的隐形杀手,越来越多的人受到失眠等睡眠障碍的困扰。睡眠质量评估以及睡眠类疾病诊断成为研究热点。人体生理学表明,一个健康的深睡眠阶段可以加速物理疗养^[1-2]。此外,健康的快速眼动(REM)阶段能够提高学习能力和记忆力。睡眠评分结果是所有睡眠问题识别中所必需的。睡眠评分,即为在多导睡眠图记录(PSG)中得出的睡眠分期。数据库中已经有部分病人的PSG样本,这其中就包括脑电图(EEG)、眼电图(EOG)和肌

电图(EMG)数据^[3]。1968年,专家遵循 Rechtschaffen & Kales(R&K)规则,确定了评估PSG记录得出睡眠分期的规则。依据R&K准则,每个时期(30 s的数据)被分为清醒(W)、非快速眼动(N-REM S1, N-REM S2, N-REM S3和N-REM S4:从浅睡眠到深睡眠)和快速眼动(REM)。

目前,已经提出了许多用于睡眠阶段分类的模型^[4]。下面列出了在文献中常用于从脑电图数据提取的特征参数,如标准偏差^[5-6]、中位数^[6-7]、算术平均值^[7-8]、偏度^[9-10]、峭度^[9-10]、零交叉值^[7,11]、方差

收稿日期:2016-02-24

修回日期:2016-06-23

网络出版时间:2016-11-22

基金项目:国家自然科学基金资助项目(61201029)

作者简介:李 斐(1991-),女,硕士研究生,研究方向为无线通信与信号处理技术;马千里,副教授,研究生导师,研究方向为嵌入式系统软硬件设计、信号检测与处理、图像处理、生物医学电子学等。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20161122.1227.030.html>

值^[7,12]、最大值和最小值^[7,11]、平均能量^[11,13-14]、平均 teager 能量^[13]、彼得罗辛分形维数^[14]、莱利熵^[11,14]、频谱熵^[11,14-15]、排列熵^[16]、近似熵^[17]、维格纳威乐系数^[11-12]、小波变换^[9,14,18-19]、平均曲线长度^[13-14]、Hurst 指数^[17]和 Hjorth 参数^[14,18]等。以上文献的特征参数提取时都按照一个睡眠时期(30 s 的数据)进行计算,但在实际人工进行睡眠时期判断时,前后时间片的数据也会在专家的考虑范围内。

文中提出一种新的提取特征参数的方式,即将前后时间片(每 30 s)也作为当前睡眠时期特征参数的提取依据。以脑电信号为睡眠分期原始信号,分别取 30 s,90 s,150 s,210 s 时间片的小波包系数、排列熵(PEn)、彼得罗辛分形维数(Petrosian 分形维数),从中提取特征参数作为中间 30 s 睡眠时期判断的依据。所提取的小波包系数、PEn、Petrosian 分形维数作为睡眠各期特征参数组合,具有较高的分期准确率^[20]。

1 数据来源

文中使用的数据集是由圣文森特大学医院和都柏林大学^[21]提供,对数据库中全部 25 个人的数据进行研究。该数据的人口学特征如下:受试者 25 例,年龄:50±10 岁,范围 28 ~ 68 岁;BMI:31.6±4.0 kg/m²,范围 25.1 ~ 42.5 kg/m²;AHI:24.1±20.3,范围 1.7 ~ 90.9。多导睡眠记录是通过 Jaeger-Toennies 系统获得。Jaeger-Toennies 系统通过使用 10 ~ 20 个电极位置获得多导睡眠记录,其中包括了 2 个 EEG 通道(C₃-A₂和 C₄-A₁),2 个 EOG 通道和 1 个 EMG 通道,平均记录时间为 6.9 h。文中研究只采用单个脑电通道(C₃-A₂),采样率为 128 Hz。EEG 信号主要集中在 0 ~ 30 Hz 处,且采用的脑电数据在 50 Hz 处具有工频干扰,通过 5 阶 IIR 巴特沃斯低通滤波器对 EEG 信号进行预处理,获得 0 ~ 35 Hz 的 EEG 信号。然后,对脑电图信号进行分割,分为 30 s 一个时期,每个时期对应于单个睡眠阶段。

表 1 显示了睡眠专家进行睡眠状态分类的 25 个受试者睡眠时期的分布,其中 N-REM S1 和 N-REM S2 期分别用 N₁、N₂ 表示,且合并 N-REM S3 和 N-REM S4 期为 N₃ 期(即依据 AASM 准则分类)。

表 1 睡眠状态各期分布

睡眠状态	样本数
Wake	4 732
N ₁	3 402
N ₂	6 985
N ₃	2 663
REM	3 016
万方数据	20 799

2 特征提取与分类方法

2.1 离散小波变换(DWT)

小波变换克服了傅里叶变换的缺陷^[22],并且该方法对于噪声不敏感,适用于非平稳信号的分析。连续小波变换的系数具有相当大的冗余量,为了在不丢失原始信号信息的情况下,尽量减小小波变换系数的冗余度^[23],提高压缩率^[24],引入了离散小波变换。定义如下:

$$DWT(j,k)=\frac{1}{\sqrt{|2^j|}}\int_{-\infty}^{\infty}x(t)\varphi(\frac{t-2^jk}{2^j})dt\tag{1}$$

其中, $x(t)$ 表示原信号; φ 表示小波基。

DWT 经常被用于分析 EEG 信号,主要问题是小波基以及分解层数的选择,其中小波分解的层数由原信号频率决定。分解层数的选择依据为使得被保留的小波系数与原信号不同睡眠状态的频率的相关性良好。脑电信号主要集中在 0 ~ 30 Hz,因此分解层数设置为 4。在分解层数低于 4 层的情况下,会丢失低频段的信息。没有必要选择大于 4 的分解层,4 层分解已经可以提取到所有 EEG 信号的有效频带。因此,信号被分解得到具有细节信息的 D₁-D₄和含有低频信息的 A₄。

在相关的 EEG 信号研究中发现,与 10 阶 Symmlet 小波(sym10)和 4 阶 Coiflet 小波(coif4)比较,Daubechies 小波具有更高的精度,并且注意到 4 阶 Daubechies 小波(db4)比 2 阶 Daubechies 小波(db2)略优^[8,25-26]。所以,采用 db4 小波对 EEG 信号进行 4 层分解,并统计 D₂-D₄与 A₄分量的绝对值的均值以及标准差。因为小波分解的特殊性,并不一开始就采用滑动窗进行小波分解计算 90 s,150 s 以及 210 s 的参数,而是先计算 30 s 时间片的小波系数,然后采用滑动窗以计算均值的方式得到 90 s,150 s 和 210 s 的参数。

通过对 EEG 信号进行 4 层 DWT 分解获得的子带频率范围如下:A₄分量包含 δ 频段(1 ~ 4 Hz),D₄分量包含 θ 频段(4 ~ 8 Hz),D₃分量包含 α 频段(8 ~ 13 Hz),D₂分量包含 β 频段(13 ~ 30 Hz)。D₁分量具有高于 30 Hz 的频率信息,这部分基本不含 EEG 信号的信息。因此,在这项研究中,使用 D₂-D₄细节分量和低频分量 A₄。

2.2 排列熵(PEn)

PEn 由 Bandt 和 Pompe^[27]提出。PEn 用比较相邻值的方式度量时间序列的复杂性。它具有简单、健壮和计算成本极低的优势^[28]。给定时间序列 $(x_t,t=1,2,\cdots,T)$,相空间重构向量为 $X_t=[x_t,x_{t+1},\cdots,x_{t+(n-1)l}]$,嵌入维数 n ,延迟时间 l (此处 $l=1$)^[29]。然后对每个重构分量 X_l 以升序排列,提取各个分量在原重构向量中的索引,可以得到不同的符号序列。 n 维相

空间映射 $n!$ 种不同的符号序列。设 $f(\pi)$ 为时间序列 π 出现的概率,其相对概率为 $p(\pi)=f(\pi)/(T-(n-1)l)$ 。排列熵定义为^[28]:

$$H_p=-\sum_{\pi=1}^{n!}p(\pi)\ln p(\pi)$$

(2)

文中按判断每个睡眠状态的 30 s EEG 信号数据计算 PEn,当计算 90 s、150 s、210 s 的参数时,采用滑动窗口提取 PEn,将当前睡眠状态的 30 s 前后的时间片加入到参数计算中。

2.3 Petrosian 分形维数 (PFD)

分形维数是用混沌方法计算信号的复杂性^[30]。PFD 便于分形维数的快速计算。PFD 将信号转化成二进制序列^[31]。PFD 可以由以下表达式计算:

$$PFD=\log_{10}k/(\log_{10}k+\log_{10}(k/(k+0.4N_s)))$$

(3)

其中, k 是信号的样本数; N_s 表示信号符号改变的次数。

PFD 与排列熵的计算采用相同的滑动窗获得 90 s、150 s、210 s 时间片的参数。

2.4 随机森林分类器

Breiman 于 2001 年提出一种新的组合分类算法——随机森林算法 (Random Forests, RF)^[32]。相比其他优秀的分类方法,如人工神经网络和支持向量机,它揭示了快速计算的优点,精度高、避免过拟合、抗噪能力好。因此,随机森林算法已经广泛应用于生物信息学的分类^[33-34]。

随机森林是通过自助法 (Bootstrap) 的重复采样技术,即从原始训练样本集 N 中有放回地重复且随机抽取 k 个样本生成新的训练样本集合,然后根据所抽取的 k 个样本生成 k 棵决策树组成随机森林。随机森林的实质是对决策树算法的改进,随机森林中的每一棵决策树都是由分类回归树 (CART) 算法所构建的未剪枝的决策树。森林中的每棵树的建立依赖一个独立抽取的样本,并且每棵树都具有相同的分布,分类的误差取决于每一棵决策树的分类能力以及它们之间的相关性。

随机森林的生成主要包括以下几个步骤:

(1) 采用 Bootstrap 方法在原始训练样本集 N 中抽取 k 个新的训练样本集,一般情况下要求每个新的训练集的样本容量与 N 一致。

(2) 对抽取的 k 个训练样本集进行学习,并以此生成 k 个决策树模型。在决策树的生成过程中,假设输入变量一共有 M 个,从这 M 个输入变量中随机抽取 F 个,每个内部节点均是选择这 F 个特征变量上最优的方式来分裂,且 F 的值在随机森林模型的形成过程中恒定。 万方数据

(3) 针对分类问题,将 k 个决策树的分类结果进行组合,形成最终的结果,组合方式是简单多数投票法。

3 实验结果

特征提取所得的各层小波系数的均值与方差 (D4-Mean-Std, D4MS)、排列熵、Petrosian 分形维数是从不同的角度取得的脑电信号的特征。其中 D4MS 与脑电信号 δ 频段 (1 ~ 4 Hz)、 θ 频段 (4 ~ 8 Hz)、 α 频段 (8 ~ 13 Hz)、 β 频段 (13 ~ 30 Hz) 具有良好的相关性,而 PEn 与 PFD 计算了脑电信号的复杂度,对 D4MS 中对 EEG 信号的特征具有补充作用,所以文中选择这三种参数作为睡眠分期的依据。

将特征提取所获得的 PFD、D4MS、PEn 一共 10 项特征参数以及人工睡眠状态分类结果作为分类器的输入。采用 Weka 工具包,并选择其中的随机森林对睡眠状态进行分类。

分类将随机选取每一睡眠状态 80% 的数据 (16 656 个样本) 作为训练集,剩下的 20% (4 158 个样本) 作为测试集。表 2 给出了单参数输入时随机森林分类的准确率。

表 2 单参数输入分类准确率

时间/s	D4MS/%	PEn/%	PFD/%
30	63.26	33.33	39.45
90	68.70	32.65	42.85
150	73.46	31.97	41.17
210	76.03	33.33	40.17

由表 2 可以看出,把对不同时间片提取的 PEn 作为分类器输入的分类准确率相近,在 32% 左右,而其他两种参数的分类准确率在不同时间片上差距较大。其中 PFD 的分类准确率在时间片为 90 s 时达到最高 (42.85%),各层小波系数的均值和标准差在时间片为 210 s 时的分类准确率达到最大 (76.03%)。以上结果为 10 次实验的结果的平均值,是在随机森林节点数为 25,且随机森林中每棵决策树都随机选择 60% 的训练样本作为分类依据时得出。

传统的每 30 s 提取的特征参数 D4MS、PEn、PFD 作为分类器输入得到的分类结果如图 1 所示。

		睡眠状态				
分类结果		Wake	N_1	N_2	N_3	REM
	Wake	781	170	69	2	38
	N_1	81	229	59	4	45
	N_2	67	190	1115	159	155
	N_3	0	2	65	365	12
	REM	17	84	89	2	353
准确率/s		82.56	33.68	79.81	68.61	58.54
总体准确率/%		68.37				

图 1 每 30 s 提取特征参数的分类结果

由图 1 可见, N_1 、 N_3 以及 REM 期的分类准确率较低,其中 N_1 期误判为觉醒期,分类准确率也最低,只有 33.68%。

采用单参数输入准确率最高的参数组合作为随机森林输入,各参数输入顺序为 D4MS、PEn、PFD,图 2 是测试样本的自动睡眠分期结果。

分类结果	睡眠状态					
		Wake	N_1	N_2	N_3	REM
	Wake	783	67	29	1	12
	N_1	86	489	42	3	10
	N_2	62	89	1284	76	89
	N_3	2	3	15	452	2
	REM	13	32	27	0	490
准确率/s		82.77	71.91	91.91	84.96	81.26
总体准确率/%	84.13					

图 2 优化参数提取的分类结果

比较图 1 与图 2 可知,新的参数提取方式可以达到更高的分类准确率,觉醒期的分类结果并无明显变化,其他各睡眠状态分类准确率都有所提高。其中对 N_2 期的分类达到了 91.91% 的准确率, N_1 、 N_2 以及 N_3 期的误判概率都减小了, N_1 期的分类准确率仍存在很大的提升空间。

图 3 给出了部分的随机森林分期结果与人工分期结果的比较。




图 3 部分分期结果比较

从图中可见,随机森林的分类结果大致与人工分期结果一致,其中 REM 期与 N_2 期, N_2 与 N_3 期之间存在的误判相对较多,觉醒期中有小部分误判成 N_1 、 N_2 期,结果基本与图 2 相符。

4 结束语

文中主要介绍了一种新的睡眠分期特征参数提取方式,在自动睡眠分期中引入了单个睡眠状态判断时期前后的 EEG 信号对睡眠分期结果的影响。研究结果表明,采用新的方式所提取的特征参数有效提高了自动睡眠分期准确率。

参考文献:

[1] Pan S T, Kuo C E, Zeng J H, et al. A transition constrained discrete hidden Markov model for automatic sleep staging[J]. BioMedical Engineering OnLine, 2012, 11: 52-71.

[2] 王小丹, 高允锁, 郭敏. 大学生睡眠质量及其影响因素的综述[J]. 中国热带医学, 2006, 6(10): 1906-1907.

[3] 唐向东, 李廷利. 首次中德睡眠研究学术讨论会综述[J]. 中国科学基金, 2008, 22(5): 277-281.

[4] 谢松云, 张振中, 杨金孝, 等. 脑电信号的若干处理方法研究与评价[J]. 计算机仿真, 2007, 24(2): 326-330.

[5] Fathima T, Bedeuzzaman M, Farooq O, et al. Wavelet based features for epileptic seizure detection[J]. MES J of Technol and Manag, 2010, 2(1): 108-112.

[6] Yuen C T, San W S, Rizoni M, et al. Classification of human emotions from EEG signals using statistical features and neural network[J]. International Journal of Integrated Engineering, 2010, 1(3): 71-79.

[7] Albayrak M, Koklukaya E. The detection of an epileptiform activity on EEG signals by using data mining process[J]. e-Journal of New World Sci. Acad, 2009, 4(1): 1-12.

[8] Subasi A. EEG signal classification using wavelet feature extraction and a mixture of expert model[J]. Expert Systems with Applications, 2007, 32(4): 1084-1093.

[9] Ozsen S. Classification of sleep stages using class-dependent sequential feature selection and artificial neural network[J]. Neural Computing & Applications, 2013, 23(5): 1239-1250.

[10] Gandhi T K, Chakraborty P, Roy G G, et al. Discrete harmony search based expert model for epileptic seizure detection in electroencephalography[J]. Expert Systems with Applications, 2012, 39(4): 4055-4062.

[11] Sen B, Peker M. Novel approaches for automated epileptic diagnosis using FCBF feature selection and classification algorithms[J]. Turk. J. Electr. Eng. Comput. Sci., 2013, 21: 2092-2109.

[12] Mohseni H R, Maghsoudi A, Shamsollahi M B. Seizure detection in EEG signals: a comparison of different approaches[C]//Proceedings of the 28th IEEE EMBS annual international conference. New York, USA: IEEE, 2006: 6724-6727.

[13] Alessandro M D, Vachtsevanos G, Hinson A, et al. A genetic approach to selecting the optimal feature for epileptic seizure prediction[C]//Proceedings of the 23rd annual international conference on engineering in medicine and biology society. Istanbul, Turkey: IEEE, 2001: 1703-1706.

[14] Kannathal N, Choo M, Acharya U, et al. Entropies for detection of epilepsy in EEG[J]. Comput Methods Prog Biomed, 2005, 80: 187-194.

[15] Srinivasan V, Eswaran C, Sriraam N. Artificial neural network based epileptic detection using time domain and frequency domain features[J]. Journal of Medical Systems, 2005, 29(6): 647-660.

[16] Bruzzo A A, Gesierich B, Santi M, et al. Permutation entropy to

detect vigilance changes and preictal states from scalp EEG in epileptic patients—A preliminary study[J]. *Neurological Sciences*,2008,29(1):3–9.

[17] Geng S,Zhou W,Yuan Q,et al. EEG non-linear feature extraction using correlation dimension and Hurst exponent[J]. *Neurological Research*,2011,33(9):908–912.

[18] Bao F S,Lie D Y,Zhang Y. A new approach to automated epileptic diagnosis using EEG and probabilistic neural network [C]//*Proceedings of the 2008 20th IEEE international conference on tools with artificial intelligence*. Washington DC, USA:IEEE,2008:482–486.

[19] Sezer E,Isik H,Saracoglu E. Employment and comparison of different artificial neural networks for epilepsy diagnosis from EEG signals[J]. *Journal of Medical Systems*,2012,36(1):347–362.

[20] Sen B,Peker M,Çavuşoğlu A,et al. A comparative study on classification of sleep stage based on EEG signals using feature selection and classification algorithms [J]. *Journal of Medical Systems*,2014,38(3):1–21.

[21] Goldberger A L,Amaral L A,Glass L,et al. PhysioBank,PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals[J]. *Circulation*,2000,101(23):215–220.

[22] Hasiloglu A. Rotation-invariant texture analysis and classification by artificial neural networks and wavelet transform[J]. *Turkish Journal of Engineering and Environmental Sciences*,2001(5):405–413.

[23] 曹怀信,赵建伟. 小波分析发展综述[J]. *咸阳师范学院学报*,2002,17(6):5–8.

[24] 成礼智,王红霞,罗永. 小波的理论与应用[M]. 北京:科学出版社,2004.

[25] Subasi A. Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction[J]. *Computers in Biology and Medicine*,2007,37:227–244.

[26] Mahajan K,Vargantwar M R,Rajput M S. Classification of EEG using PCA,ICA and neural network [J]. *International Journal of Engineering and Advance Technology*,2011(1):80–83.

[27] Bandt C,Pompe B. Permutation entropy;a natural complexity measure for time series[J]. *Physical Review Letters*,2002,88(17):174102.

[28] Liu X F,Wang Y. Fine-grained permutation entropy as a measure of natural complexity for time series [J]. *Chinese Phys B*,2009,18(7):2690–2695.

[29] 姚文坡,刘铁兵,戴加飞,等. 脑电信号的多尺度排列熵分析[J]. *物理学报*,2014,93(7):419–425.

[30] Petrosian A. Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns[C]//*Proceedings of the 26th IEEE international symposium on computer based medical systems*. Lubbock, Texas: IEEE,1995:212–217.

[31] 聂笃宪,曾文曲,文有为. 分形维数计算方法的研究[J]. *微机发展(现更名:计算机技术与发展)*,2004,14(9):17–19.

[32] Breiman L. Random forests [J]. *Machine Learning*,2001,45(1):5–32.

[33] Yuan M,Hu X Z. Predicting membrane protein types using the random forests algorithm[J]. *Acta Biophysica Sinica*,2009,25(5):349–355.

[34] Alan J,Bogunovic N. Random forest-based classification of heart rate variability signals by using combinations of linear and nonlinear features[J]. *IFMBE Proceedings*,2010,29(1):29–32.

+++++

(上接第176页)

[4] 白琳,李颖. 空间信号组合理论与关键技术[M]. 北京:人民邮电出版社,2013.

[5] MIMO 技术分类简介[M]. 出版地不详:摩尔实验室,2012.

[6] 文远保,张炫. 单调比率调度算法研究及改进[J]. *计算机工程与科学*,2006,28(10):68–70.

[7] 陈宇寒. 网格计算技术研究[J]. *计算机技术与发展*,2008,18(5):82–85.

[8] 白涛. 网络化控制系统的性能分析与调度优化[D]. 上海:上海交通大学,2005.

[9] 卢鹏. 计算机网络安全及其防护策略探析[J]. *硅谷*,2009(12):62–63.

[10] Riihonen T,Werner S,Wichman R. Spatial loop interference suppression in full-duplex MIMO relays [C]//*Forty-third Asilomar conference on signals, systems and computers*. [s. l.]:IEEE,2009:1508–1512.

[11] Lin K,Messierian R H,Wang Y. A digital leakage cancellation scheme for monostatic FMCW radar[C]//*IEEE international microwave symposium*. [s. l.]:IEEE,2004:747–750.

[12] Ma J,Li G Y,Zhang J,et al. A new coupling channel estimator for cross-talk cancellation at wireless relay stations [C]//*Global telecommunications conference*. [s. l.]:IEEE,2009:1–6.

[13] Riihonen T,Werner S,Wichman R,et al. On the feasibility of full-duplex relaying in the presence of loop interference [C]//*10th workshop on signal processing advances in wireless communications*. [s. l.]:IEEE,2009:275–279.

[14] Riihonen T,Werner S,Wichman R. Comparison of full-duplex and half-duplex modes with a fixed amplify-and-forward relay [C]//*Wireless communications and networking conference*. [s. l.]:IEEE,2009:1–5.