

基于 GEP 算法的压缩感知语音观测序列建模

郭海亮

(陕西师范大学 计算机科学学院, 陕西 西安 710062)

摘要: 为了进一步减少压缩感知中语音信号观测序列的数据传输量, 文中采用基因表达式编程 (Gene Expression Programming, GEP) 算法对语音信号的观测序列进行建模与预测, 同时引入观测序列建模预测后的压缩感知理论框架来解决该问题。首先, 分析了压缩感知中语音信号观测序列的相关特性, 然后利用 GEP 算法对语音信号观测序列建立了精确的非线性模型结构, 最终实现原始语音信号的重构。实验结果表明, 该算法在保证重构语音的性能的前提下, 可以进一步减少语音信号观测序列的传输量, 最终实现语音信号的二次压缩。

关键词: 压缩感知; 语音观测序列; 基因表达式编程; 二次压缩

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2015)05-0046-06

doi: 10.3969/j.issn.1673-629X.2015.05.012

Speech Signals Measurements Sequence Modeling in Compressed Sensing Based on GEP

GUO Hai-liang

(School of Computer Science, Shaanxi Normal University, Xi'an 710062, China)

Abstract: In order to reduce the amount of data transmission of speech signals measurements sequence in compressed sensing, use GEP algorithm to model and predict for the measurements sequence of speech signal, and a CS theoretical framework is proposed after predicting and modeling the measurements sequence to fix this question. First, analyze the relevant characteristics of the measurements sequence of speech signal in compressed sensing. Then using GEP algorithm, build an accurate nonlinearity model structure for speech signals measurements sequence. Finally, achieve the goal of rebuilding original signals. Showed by experiment, this algorithm can further reduce the amount of measurements sequence, while ensuring the performance of reconstructed speech signals, to achieve the purpose of secondary compression of speech signals.

Key words: CS; speech measurements sequence; GEP; secondary compression

0 引言

近年来, 由 Donoho^[1] (美国科学院院士) 以及 Candes^[2] 等于 2004 年提出了一种全新的信息获取理论, 称之为压缩感知 (Compressed Sensing, CS) 理论^[3]。压缩感知理论是一种边采样边压缩的新型采样定理, 它把本来采样和压缩的两个过程合在了一起。压缩感知对信号进行处理后获得的是观测序列, 观测序列的长度远远小于奈奎斯特采样获得的信号长度, 这样就使得采集高分辨率的信号成为了可能。这也正符合当下人们对高清信号的需求。CS 理论指出, 只要信号满足稀疏特性, 就可以通过一个观测矩阵乘以原始信号得到信号的观测序列, 该观测序列包含有原始

信号所有的信息。这样不仅减轻了数据采集设备的负担, 而且节约了采样和传输资源, 最后达到了压缩的目的。压缩感知理论一经提出就引起了极大的关注, 国内外专家高度重视, 为研究信号处理开辟了一个新领域。同时压缩感知在 2007 年还获得了美国十大科技进展奖。

语音信号是一种非平稳的、多变的、非常复杂的信号。目前把压缩感知运用于语音信号处理的研究还比较少, 各种研究方法还不是很成熟。但是如果能够把压缩感知理论成功运用于语音信号系统中, 意义将是很重大的。语音系统是个很庞大的系统, 文中研究只是针对其中的很小一部分。由于人体发生器官的构造

特性,发生器官肌肉运动相对比较慢,这就决定了人发出的声音在 10 ~ 30 ms 内可以近似地看成是平稳的,这就便于语音信号的短时处理操作。基于压缩感知的语音信号处理系统,会把一段语音进行分帧处理,这一段一段的语音在短时间内是平稳的。接着再逐帧进行压缩采样,采样后就每帧都会得到少量的观测序列。根据这些观测序列再在接收端重构出原始的语音信号。

现阶段,国内外对语音领域的压缩感知的研究还处在起步阶段。CS 理论在投入到实际的语音信号系统中时,发送端需要将观测序列进行压缩和编码,然后发送到接收端,接收端对收到的经过压缩后的观测序列进行解码,然后使用一定的重构算法恢复出原始的语音信号。当前,大部分已经使用 CS 理论的语音信号系统,很少会把观测序列编码部分重点研究,然而对于观测序列编码这部分内容的研究又是压缩感知将来必然会研究的内容。因此文中对这一部分的内容优先展开研究,与此同时考虑到发送端发送的观测序列越少,那么信道的利用率会越高,所以就必须要想办法把发送端传输的观测序列数尽可能减少,因此想到能否对语音信号的观测序列建立模型呢?这样的话就能极大地减少发送端传输的观测序列数了,如果这种想法真的能够实现,那么对于编码工作的研究将会有十分重大的意义。

文中尝试对语音信号的观测序列建模,在研究语音信号压缩感知的基础上,引入基因表达式编程 (Gene Expression Programming, GEP) 算法,用于建立观测序列的非线性模型,并通过模型分析提出一种规范化的非线性预测模型。求取观测序列的非线性预测系数等模型参数,那么在接收端再也不需要发送相对较长的观测序列,只需要发送一小部分观测序列和数量很少的模型参数,同样接收端只需要接收少量的观测序列和几个模型参数,然后通过重构算法,就能恢复出语音信号,从而达到二次压缩的目的。

1 语音信号压缩感知

1.1 压缩感知基本原理

压缩感知理论主要由三个约束条件组成,分别是:信号的稀疏表示、观测矩阵的选择和重构算法。信号的稀疏表示是压缩感知理论的前提条件,观测矩阵的选择决定了是否能够对信号进行很好的压缩,重构算法是恢复信号的关键环节。图 1 是基于压缩感知理论语音信号的重构过程图。

1.1.1 信号的稀疏表示

信号的稀疏表示是压缩感知的前提,只有信号可以稀疏表示了,那么才能对其使用压缩感知理论。对




图 1 基于压缩感知理论语音信号重构过程

于大多数信号而言,首先要做的工作就是对信号进行稀疏化处理,当然也有一些特例,比如信号本身就是稀疏的,这样的话就可以直接对语音信号使用压缩感知了。假设一维的离散信号用 $\mathbf{x} = [x(1), x(2), \dots, x(N)]^T$ 表示,同时假设变换矩阵 $\boldsymbol{\psi} = [\varphi_1, \varphi_2, \dots, \varphi_N]$, 它的列向量 $\{\varphi_i\}_{i=1}^N$ 要求是相互正交的,其中每个列向量可以用 $\varphi_i (i=1, 2, \dots, N)$ 来表示,那么信号 \mathbf{x} 就可以用下面的式子来表示:

$$\mathbf{x} = \boldsymbol{\psi} \boldsymbol{\alpha} = \sum_{i=1}^N \alpha_i \varphi_i \quad (1)$$

信号在 $0 < p < 2$ 且 $0 < R < N$, $\boldsymbol{\alpha}$ 满足时,有

$$\|\boldsymbol{\alpha}\|_p = \left(\sum_i |\alpha_i|^p \right)^{1/p} \leq R \quad (2)$$

其中, $\boldsymbol{\alpha}$ 是投影系数,就是认为信号满足稀疏条件,或者说信号是稀疏的,有时这种稀疏指的并不是严格意义上的稀疏,只要满足近似稀疏也是可以的。

1.1.2 CS 压缩模型

当确定信号可以稀疏化后,接下来就需要对信号进行压缩变换了,观测矩阵的选择条件是必须满足与稀疏基 $\boldsymbol{\psi}$ 不相关。假设选取一个观测矩阵为 $\boldsymbol{\varphi}: M \times N$, 该矩阵中 M 的维数远远小于 N 的维数,使用该观测矩阵对原始信号 \mathbf{x} 进行压缩变换后,会得到观测序列 \mathbf{y} , \mathbf{y} 是一个 $M \times 1$ 的向量。

$$\mathbf{y} = \boldsymbol{\varphi} \mathbf{x} \quad (3)$$

将式(1)代入到式(2),就会得到:

$$\mathbf{y} = \boldsymbol{\varphi} \mathbf{x} = \boldsymbol{\varphi} \boldsymbol{\psi} \boldsymbol{\alpha} \quad (4)$$

令 $\boldsymbol{\varphi} \boldsymbol{\psi} = \boldsymbol{\Theta}$, 那么 $\mathbf{y} = \boldsymbol{\Theta} \boldsymbol{\alpha}$ 。把 $\boldsymbol{\Theta}$ 称为压缩感知的信息算子,对于得到的观测序列 \mathbf{y} , 由于 \mathbf{y} 是一个 $M \times 1$ 的向量,而原始信号 \mathbf{x} 是一个 $N \times 1$ 的矩阵, M 的维数远远小于 N 的维数,此时就认为信号已经被压缩过了。观测矩阵的选择对信号的压缩程度和将来信号的重构都有很大的关系。

1.1.3 CS 重构模型

压缩感知重构的过程,其实就是通过公式(3),在已知观测序列 \mathbf{y} 和观测矩阵 $\boldsymbol{\varphi}$ 的前提下,求解 \mathbf{x} 的过程,但是由于方程 M 的个数远远小于原始信号的长度 N , 因此求解原始信号 \mathbf{x} , 就变成了一个病态问题,同时式(3) 也变成了一个欠定方程组。当观测矩阵 $\boldsymbol{\varphi}$ 满足 RIP 准则时,就可以对该问题进行无失真求解,因此可以通过在 $e(n) = s(n) - \hat{s}(n)$ 范数下求解。

$$\min \|\alpha\|_0 \text{ s. t. } \mathbf{y} = \Theta\alpha \quad (5)$$

式(5)的计算量非常巨大,很难求解。但是现在工程中可以用一些贪婪算法来不断地逼近方程的解,常用的贪婪算法有:基追踪法(Basic Pursuit, BP)^[4]、匹配追踪法(Matching Pursuit, MP)和正交匹配追踪法(Orthogonal Matching Pursuit, OMP)^[5]等。

1.2 语音观测序列的LPC预测

语音信号主要分为清音和浊音,清音部分能量和信息较少,所以研究重点是浊音部分。随机取一段语音信号,就会发现该语音信号的时间域内并不是稀疏的,因此就需要把DCT基运用到语音的稀疏变换中。孙林慧等^[6]通过实验发现,经过DCT基稀疏变换的语音信号,其大部分稀疏都是小系数,只有极个别的是大系数。相对于那些较大的系数,这些小系数是可以忽略不计的。这样的话,就可以把语音信号看成是近似稀疏的了。此外郭海燕等^[7]基于语音信号在KLT域的稀疏特性,验证了KLT域上语音信号的压缩感知性能。由此可见,说明语音信号是可以运用压缩感知理论对其进行压缩处理的。

由于经过CS变换的语音观测序列不再是原始的语音信号,但是它包含了大部分原始语音信号的重要信息,已有学者和专家论证过,证实语音的观测序列依然是时间序列,既然观测序列是时间序列,那么自然就想到,是否可以用处理时间序列的方法来处理观测序列呢?时间序列处理信号最经典也相对发展比较成熟的是线性预测模型,因此尝试对观测序列进行LPC建模,如果能够对观测序列建立精确的模型,以后在接收端就不用再接收一段较长的观测序列样点了,只需要接收LPC的系数和少量的观测序列即可,这就极大地降低了数据的传输量,同时也能达到二次压缩的目的。根据LPC理论的要求可知,如果一个信号符合LPC预测模型,那么该信号的预测误差的动态范围必须远远小于原始信号。

文中做了如下仿真:随机选取一帧含有120个样点,采样率为8 kps的语音信号,选用60×120的高斯随机矩阵作为观测矩阵,预测激励为前10个样点值,分别对该帧的原始语音信号和经CS变换后的观测序列进行线性预测恢复。

从图2可见,用LPC预测系数可以很好地对原始语音信号进行恢复。从图3可见,使用LPC复原后的观测序列与原始的观测序列的误差非常大,已经远远超出了可以接受的范围。猜测其主要原因可能是由于语音观测序列是经过高斯随机矩阵变换而来的,随机高斯矩阵破坏了原始语音信号数据间的线性相关性,所以导致了用LPC复原后的观测序列误差极大,使得无法使用LPC方法对将来的观测序列进行预测。因

此得出结论:用LPC复原观测序列的方法行不通。




图2 原始语音信号LPC复原




图3 观测序列的LPC复原

既然LPC对观测序列建模的方法行不通,那接下来的重点工作就是赶快寻找其他的时间序列建模的方法。由于语音观测序列是原始语音序列与观测矩阵相乘后的结果,研究表明语音的观测序列样点值之间表现出来的更多的是非线性关系,因此,文中引入GEP算法尝试对观测序列进行建模与预测。

2 GEP算法应用于语音序列建模

2.1 GEP算法建模原理

基因表达式编程(Gene Expression Programming, GEP)是借鉴生物自然选择和遗传机制,结合遗传算法和遗传规划思想而发展起来的随机搜索和优化算^[8]法。通过将规划问题中的计算机程序编码为线性符号串,克服了GP中个体的树形结构带来的问题,并借鉴GA中的遗传算子简化了遗传操作,在很大程度上提高了发现特定计算机程序的能力和效率^[9]。

文中基于线性预测理论,旨在对观测序列建立有显式结构的语音信号非线性预测模型。为此,结合语音信号的非线性特征,引入GEP算法。对于含有 N 个样点值的一帧数据,设非线性预测模型为,

$$\hat{S}(n) = f(S(n-1), S(n-2), \dots, S(n-p)) \quad (6)$$

将采用语音信号的前 P 个真实值作为模型激励,即对于含有 N 个样点值的一帧数据,给定该帧数据的前 P 个样点值,对剩余的 $N-P$ 个数据值进行预测,其中 P 称为模型的阶数。在给定前 P 个值作为模型激励时,公式(6)所示的预测过程从第 $P+1$ 个值开始,可以实现 $N-P$ 步的预测。 f 为所要建立的非线性模型函数, $S(n)$ 与 $\hat{S}(n)$ 之差称为预测误差。

$$e(n) = S(n) - \hat{S}(n) \quad (7)$$

$$E = \sum_{n=1}^N [e(n)]^2 \quad (8)$$

其中, E 为均方误差。利用 GEP 算法求解非线性模型 f 时, 其评判标准是使得均方误差最小, 寻找预测值与原始语音值最为接近的非线性模型结构, 也就是使得 E 具有最小值。

GEP 非线性预测理论: 首先给出单帧的语音信号真实值序列, 通过种群中单个个体所描述的 f 函数获得预测序列值, 进而求解预测误差及均方误差值, 并作为当前个体在本次迭代中的适应度值。通过算法演化不断发现具有更小均方误差值的问题解, 最终得到的最优个体即为算法寻得的最优非线性模型。

个体结构: 文中采用传统 GEP 算法中的二叉树结构, 叶子节点除了包含某个输入的标识符, 还含有一个模型参数。重新定义函数集 $h = \{', '+', '\times', '\div', '\sin', '\cos'\}$, 终止符集 $t = \{-1, i(1 \leq i \leq p)\}$, h 中的函数通过组合可以实现复杂的非线性结构, 能够满足本研究中非线性预测模型的需求。叶子节点在终止符集中取值为 i 时对应公式(6)中的输入 $s(n-i)$, 取值为 -1 时表示该叶子节点仅作为模型参数。图4中列出了个体结构的示意图。




图4 个体结构示意图

在迭代过程中评价个体的适应度时, 将其所描述的非线性预测模型替换公式(6)中的 f 函数, 计算其对一帧数据的最小均方误差。对特定帧的数据, 个体适应度值越小, 表示其所描述的非线性预测模型效果越好。

参数优化: 粒子群优化算法 (Particle Swarm Optimization, PSO) 是由 Eberhart 和 Kennedy 等于 1995 年提出的一种基于种群的并行全局优化算法。它源于对鸟群群体协作的捕食行为模拟, 通过种群间个体的协作, 引导整个群体向可能解的方向移动^[10-12], 从而获得最优解。传统 PSO 算法中, 由于快速的信息流动使得粒子容易聚集在一起, 导致群体多样性下降而陷入局部最优解。文中采用文献[13]提出的均匀搜索粒子群算法 (Uniform searching Particle Swarm Optimization, UPSO)。该算法对于单峰值以及多峰值函数, 尤其是极值非均匀分布的多峰值函数有很好的寻优能力。

2.2 观测序列的 GEP 建模的理论基础

由上节可知观测序列之间呈现出来的不再是线性关系, 而是很强的非线性关系。语音观测序列是经过 CS 变换后的语音信号, 它保留了原始语音信号的大部分信息, 因此它仍然是一种时间序列, 所以对时间序列进行分析和建模的方法对它依然适用, 而对时间序列的非线性预测和建模是 GEP 的经典应用领域, 也是对 GEP 性能进行评价的常用算例。

任哲坡等^[14] 基于 GP 算法在时间序列中的应用分析将其应用于对语音信号的建模和预测中。通过 GEP 在求解非线性模型中能够较好地获得具有最小误差的非线性拟合表达式的特点, 得到了具有良好泛化能力的模型结构, 并取得了良好的预测效果。

鉴于以上结果, 文中得到启发, 提出将 GEP 算法引入到对语音观测序列的建模和预测中, 目的是为了对语音观测序列建立显式的模型结构, 即使用 GEP 算法建立观测序列采样点之间最佳的非线性关系。同时把前面一小部分观测序列作为激励, 以后传输的参数是模型参数和激励参数, 不再是全部的观测序列。这样就可以实现对语音信号二次压缩的目的了。

对语音观测序列的建模是一个十分新颖且有极大挑战性的工作, 据笔者了解, 到现在为止, 国内外很少有能建立起高效的观测序列模型, 更不用说对观测序列建立显式的模型结构了。笔者建立观测序列的目的就是为了减少数据的传输, 从而达到二次压缩, 但是现在各个机构对观测序列的研究都还只是处于开始阶段, 研究的广度和深度都远远不够, 所以本实验是在忽略了信号传输过程中的量化误差和噪音误差的理想条件下进行的。

2.3 观测序列的 GEP 模型预测

基于压缩感知的语音观测序列建模, 可以概括为: 首先对一段语音信号进行分帧处理, 接着对每一帧信号经过 CS 变换, 得到 M 维的观测序列, 再利用 GEP 算法突出的非线性结构特点, 对经过每一帧的语音观测序列建立非线性预测模型, 根据最小均方误差原则得到一个对大多数观测序列都适合的模型, 使用优化算法优化该模型的参数。最后重构出原始信号。

用 GEP 模型对语音信号观测序列进行预测的实验步骤描述如下:

Step1: 为观测序列建模准备数据, 对经过压缩感知变换后得到的观测序列, 要对其进行分割, 分成两部分: 前一部分数据量小, 主要用于 GEP 建模时的模型激励; 后一部分数据量大。由于观测序列依然是时间序列, 所以应该考虑观测序列是时间序列的特性, 因此在分割的时候尽量按顺序分割, 这样才能保证观测序列的顺序性, 便于建模后准确地预测数据。

Step2:建立预测模型。预处理后,对每帧观测序列利用 GEP 算法建模,此时每帧观测序列均获得了一个具有最小均方误差的非线性预测模型。综合分析各模型间的相似性,通过整合与优化提取规范化的非线性模型结构。对得到的规范化的非线性模型采用 UPSO 算法来优化模型参数,从而得到更精确的模型结构,便于后面的数据预测。

Step3:实现预测恢复信号。在发送端对前一段数据量极小的观测序列和观测序列的 GEP 模型参数统一编码,发送到接收端,接收端根据收到的小段观测序列和 GEP 模型参数,预测出后面部分的观测序列,然后把两段观测序列整合起来,使用 OMP 算法重构出原始信号。

经过以上步骤的处理后,新的语音观测序列 CS 理论框架如图 5 所示。




图 5 对观测序列 GEP 建模与预测后压缩感知理论框架

2.4 实验仿真

实验数据为取自语料库中的两个语音样本,经预处理后共有 36 帧数据,帧长取 40 ms,在 8 k 采样率下每帧数据含有 320 个样点值。将原始的语音信号进行分帧处理,对分帧后的每一帧信号进行压缩感知变换,压缩比 M/N 取为 0.5,稀疏基选用 DCT 基,观测矩阵使用常用的高斯随机矩阵,用 GEP 算法分别对 36 帧经 CS 变换后的观测序列建模,选取种群规模为 30,种群中个体数量为 50;预处理后,输入为每一帧语音信号经过变换后的观测序列,对观测序列利用 GEP 算法获得具有最小均方误差的非线性预测模型。共得到模型数 36 个,综合分析各模型间的相似性,通过整合与优化提取规范化的非线性模型结构。

文中提取规范化非线性预测模型如公式(9),其中模型阶数 $P = 20$, b_0 为常数。

$$\hat{s}(n) = a_0 * (\sum_{i=1}^{p/4} (a_i * s(n-i))) +$$
$$\cos(\sum_{j=(p/4)+1}^P (a_j * s(n-j))) + b_0 \quad (9)$$

为了验证模型的有效性,采用 UPSO 算法来优化模型参数进行数据预测。优化过程中的粒子数为 100,粒子更新公式中 $c = 1.3$, $w = 0.78$,UPSO 算法中的参数采用文献[13]中的默认值。

图 6 给出了一帧原始观测序列与 GEP 建模预测后观测序列的对比(略去了发送和接收的过程),其中

前 20 个数据是原始的观测序列,后 140 个样点是通过 GEP 模型建模预测出来。从图上可以看出,预测的效果还是比较理想的,预测精度也在可以接受的范围内,基本实现了对观测序列的准确预测,为下一步对观测序列使用重构算法恢复打好了基础。




图 6 原始观测序列与 GEP 建模预测后观测序列

图 7 显示的是原始语音信号与使用 GEP 模型预测后,再由 OMP 算法恢复出来的信号的对比图。从图中可以看出,恢复的信号和原始信号有些地方是有误差的,但总体还是不错的,特别是信噪比与不对观测序列建模时相差不大。




图 7 原始信号与观测序列建模预测后的重构信号

从表 1 可见,在相同的仿真环境下,预测激励的长度不一样对应的 MOS 和 SNR 值也是不一样的。表中给出了用三种预测情况的对比,第一种是无预测时 MOS 和 SNR 的取值情况,第二种是用前 1/8 观测序列来预测后 7/8 观测序列时 MOS 和 SNR 的取值情况,最

表 1 不同预测激励长度下预测信号的信噪比和 MOS 分

预测方法	MOS 分	SNR/dB
没有预测	3.742	21.348
1/8 预测 7/8	3.162	17.872
1/16 预测 15/16	2.374	15.294

后一种是用前 1/16 观测序列来预测后 15/16 观测序列时 MOS 和 SNR 的取值情况。

由此可见:采用 GEP 算法对语音观测序列建立显式的模型结构,然后使用前一部分观测序列预测后一部分观测序列,然后将两段观测序列整合,再利用重构算法恢复原始信号。在这一过程中,发现重构信号的精度和输入预测模型的激励的长度有很大关系。得出结论:当模型输入观测序列的长度减少时,MOS 分和 SNR 的值明显降低,说明预测的效果会变差。

关于二次压缩效果的情况:实验中是用前 1/8 语音观测序列作为预测激励来预测后 7/8 的语音观测序列,这样发送端需要传递到接收端的数据主要包括:作为模型激励的前 20 个观测序列值,非线性模型参数 22 个。总共的数据量合计为 42 个。原来的压缩感知理论,不对观测序列建立显式模型结构,需要往接收端传输 160 个数据。而建立模型后,只需传递模型参数和激励共 42 个数据量,此时发现数据的二次压缩比达到了 26.25%,也就是说经过建模后传输的数据量要比不建模时传输的数据量少 73.75%,数目可是相当可观的。同时从表 2 可以看出,同等仿真条件下,输入的预测观测序列长度越短,二次压缩比越小,那么二次压缩效果也就越明显,但是输入序列长度越短,重构语音的 SNR 和 MOS 分会明显降低,预测效果也会降低。

表 2 不同预测方法预测信号的二次压缩效果图

预测方法	需传数据量	二次压缩比/%
没有预测	160	100.00
1/8 预测 7/8	42	26.25
1/16 预测 15/16	22	13.75

3 结束语

文中基于语音信号的压缩感知理论,对经过稀疏变换的观测序列用 GEP 算法建立显式的模型结构,并通过模型分析提出了规范化的非线性模型结构,然后通过 UPSO 算法来优化模型参数。这样在接收端就只需要传递部分观测序列和模型参数,然后通过 OMP 算法重构出原始信号,避免了在接收端传递全部的观测序列,从而达到二次压缩的目的。实验结果表明,运用此方法,在不损失多信噪比的前提下,能够准确地预测

观测序列,最终还原出相对清晰、误差较小的语音信号。

参考文献:

[1] Donoho D. Compressed sensing[J]. IEEE Trans on Information Theory,2006,52(4):1289-1306.

[2] Candes E J,Romberg J,Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information[J]. IEEE Trans on Information Theory,2006,52(2):489-509.

[3] Baraniuk R. A lecture on compressed sensing[J]. IEEE Signal Processing Magazine,2007,24(4):118-124.

[4] Chen S S,Donoho D L,Saunders M A. Atomic decomposition by Basis pursuit[J]. SIAM Review,2001,43(1):129-159.

[5] Needell D,Vershynin R. Uniform uncertainty principle and signal recovery via regularized orthogonal matching pursuit[J]. Found Compute Math,2009,9(3):317-334.

[6] 孙林慧,杨震. 基于压缩感知的分布式语音压缩与重构[J]. 信号处理,2010,26(6):824-829.

[7] 郭海燕,杨震. 基于近似 KLT 域的语音信号压缩感知[J]. 电子与信息学报,2009,31(12):2948-2952.

[8] Ferreira C. Gene expression programming:a new adaptive algorithm for solving problems[J]. Complex Systems,2001,13(2):87-129.

[9] 钟义啸. 基因表达式编程的早熟抑制策略研究[D]. 成都:四川大学,2006.

[10] Kennedy J,Eberhart R C. Particle swarm optimization[C]//Proc of IEEE international conference on neural networks. USA:IEEE,1995:1942-1948.

[11] Eberhart R C,Kennedy J. A new optimizer using particle swarm theory[C]//Proc of sixth international symposium on micro machine and human science. Nagoya,Japan:[s. n.],1995:39-43.

[12] Eberhart R C,Simpson P K,Dobbins R W. Computational intelligence PC tools[M]. Boston,MA:Academic Press Professional,1996.

[13] 吴晓军,杨战中,赵明. 均匀搜索粒子群算法[J]. 电子学报,2011,39(6):1261-1266.

[14] 任哲坡,李志坚,吴晓军,等. 基于 GP 算法的语音信号非线性双向预测模型[C]//第三十二届中国控制会议论文集(E 卷). 出版地不详:出版者不详,2013.

基于GEP算法的压缩感知语音观测序列建模

作者：[郭海亮](#)，[GUO Hai-liang](#)
作者单位：[陕西师范大学 计算机科学学院, 陕西 西安, 710062](#)
刊名：[计算机技术与发展](#)[ISTIC](#)
英文刊名：[Computer Technology and Development](#)
年，卷(期)：2015(5)

引用本文格式：[郭海亮](#), [GUO Hai-liang](#) [基于GEP算法的压缩感知语音观测序列建模](#)[期刊论文]-[计算机技术与发展](#)
2015(5)