

在线压缩感知方法及其在漏磁检测中的应用*

张兰勇^{1,2}, 陈辉煌¹, 刘 胜¹, Christos Papavassiliou²

(1 哈尔滨工程大学自动化学院 哈尔滨 150001; 2 帝国理工学院 伦敦 SW7 2AZ)

摘要:以长距离油管的漏磁检测系统为研究对象,研究了漏磁检测数据的在线压缩算法。针对嵌入式在线工作环境下,传统的数据压缩方法难以应用的问题,引入压缩感知(CS)理论,提出了漏磁检测数据在线CS压缩方法。确定了小波基作为漏磁信号的最佳稀疏表示基,并推导了小波稀疏基矩阵的数学表达式;提出Welch界和PRP共轭梯度算法的测量矩阵优化算法;提出了漏磁检测数据的重要数据段筛选方法,极大地减少了数据存储量。仿真试验证明了所提出在线压缩算法极大地减少了在线环境压缩编码的运算复杂度,具有简单迅速、压缩比高、重构精度高等优点,符合漏磁检测数据在线压缩的实际要求。

关键词: 压缩感知;漏磁检测;在线压缩;数据筛选

中图分类号: TN98 TP23 TH17 **文献标识码:** A **国家标准学科分类代码:** 0811

On-line compressed sensing method and its application in magnetic flux leakage detection

Zhang Lanyong^{1,2}, Chen Huihuang¹, Liu Sheng¹, Christos Papavassiliou²

(1. School of Automation, Harbin Engineering University, Harbin 150001, China; 2. Imperial College London, London SW7 2AZ, UK)

Abstract: In this dissertation, taking the magnetic flux leakage (MFL) detection system for long-distance oil pipeline as study object, the online compression algorithm of magnetic flux leakage detection data is studied. Aiming at the problem that traditional data compression method is difficult to apply in the embedded online work environment, compressed sensing (CS) theory is introduced and an online CS compression method for MFL detection data is proposed. The wavelet base is determined as the best sparse representation base of the magnetic flux leakage signal, and the mathematical expression of the wavelet sparse base matrix is derived; A measurement matrix optimization algorithm based on Welch bound and PRP conjugate gradient algorithm is proposed; An important data segment screening method of the MFL detection data is proposed, which greatly reduces the data storage size. The simulation results show that the proposed online compression algorithm greatly reduces the computation complexity of compression encoding in online environment, has the advantages of simple and rapid operation, high compression ratio, high reconstruction precision and etc., and meets the actual requirements of MFL detection data online compression.

Keywords: compressed sensing; magnetic flux leakage detection; online compression; data screening

1 引言

由于钢制长输石油管道缺陷检测的特殊工作环境(电磁屏蔽、无拖缆),漏磁检测数据无法实时的传送至地面,需要存储在检测机器人携带的存储介质内。由于

信息量极其大,必须对检测数据进行在线压缩处理,以减少存储量。对采用的压缩方法提出以下要求:压缩速度快、压缩比大、硬件易于实现、消耗资源少、重构精度高。常用的漏磁检测信号压缩方法包括LZW(Lempel-Ziv-Welch)无损压缩算法、霍夫曼编码压缩、小波压缩、神经网络压缩等。传统的小波变换压缩编码的实现过程:原

收稿日期:2017-03 Received Date: 2017-03

* 基金项目:国家自然科学基金(51579047)、国家科技支撑计划课题(2013BAG25B01)、高等学校博士学科点专项科研基金(20132304120015)、黑龙江省博士后科研启动金(LBH-Q14040)、MPRD专项支持(IEP-0401)、东南大学毫米波国家重点实验室开放课题(K201707)、中央高校基本科研业务费(HEUCF160414)项目资助

始信号通过 Nyquist 采样,再对采样信号进行正变换、量化、编码才能储存。由 Unisys 提出 LZW 的无损压缩算法,压缩比较低,且对硬件有一定要求;由霍尔曼提出的霍夫曼编码压缩方法压缩量很低,压缩比例为 80% ~ 90%;神经网络压缩尽管压缩比例大,但计算量巨大且需要消耗巨大的存储,且编码速度慢。

现有的漏磁数据压缩方法,大多是在漏磁数据特性的基础上,通过一定的手段对漏磁数据进行去冗余处理以实现数据压缩。这样的压缩往往需要设计复杂的压缩编码算法,这在嵌入式环境下实现困难且十分耗时。而对于在线数据压缩来说,希望压缩过程越便捷越好,解压过程则可以离线的在计算机上完成,对解压速度的要求并不苛刻,也就是说,传统的压缩方法并不是非常适合数据的在线压缩处理。希望寻找一种新的算法,能够将复杂的运算过程从编码端剥离。压缩感知 (compressed sensing, CS) 理论的出现为解决上述问题提供了可能。所谓“压缩感知”便是试图通过尽量少地去采集信息,去尽量多地还原出原始信息。其实现方法为通过将检测信号线性投影为低维观测向量,从而允许对原始信号进行低速率(低于 Nyquist 频率)的采样,相当于信号的采样与压缩同步进行。这些较少的采样值包含了原始信号所有的重要信息,在接收端即可通过求解一个优化问题来重构原始数据。整个编解码过程,压缩易,解压略难,成功的将复杂运算从编码端转移到了解码段,正好是所希望的格局。因此,基于 CS 理论的数据压缩可以很好地匹配本文在线压缩、离线解压的实际应用背景。

根据 CS 理论对已通过 Nyquist 采样得到的信号序列,以测量矩阵进行降维观测,得到低维的观测值作为压缩数据,基于 CS 的降维观测压缩方法相较于传统的小波编码压缩方法在编码环节更简单,小波编码压缩需要历经小波变换、系数量化、系数编码等过程,而 CS 降维观测仅需完成一次矩阵相乘即可,节省硬件资源,易于硬件实现,具备更快的压缩速度。达到对检测数据在线快速压缩的目的^[1]。

对比基于小波变换编码和基于 CS 理论的降维观测的压缩方法可以发现基于 CS 的降维观测压缩方法相较于传统的小波编码压缩方法在编码环节更简单,小波编码压缩需要历经小波变换、系数量化、系数编码等过程,而 CS 降维观测仅需完成一次矩阵相乘即可,节省硬件资源,易于硬件实现,具备更快的压缩速度。

2 压缩感知及信号的稀疏表达

压缩感知理论允许人们以低采样频率对信号进行采样,实现对信号中信息的直接采样^[2-3]。其基本思想是:如果一个未知信号是稀疏的,或者其在某个变换域里面

可以进行稀疏的表示,那么就可以用一个与稀疏变换基不相关的测量矩阵将信号投影到一个低维空间上,然后通过求解一个优化问题就可以从这些低维的投影中以高概率重构出原信号^[4]。理论上,任何信号只要能够找到相应的稀疏基,就可以进行压缩采样^[5]。

对于稀疏信号 \mathbf{x} ,考虑一个一般的观测过程,即利用测量矩阵 $\Phi \in \mathbb{R}^{m \times n}$ 对 \mathbf{x} 进行降维投影,其数学描述为:

$$\mathbf{y} = \Phi \mathbf{x} = \Phi \Psi \mathbf{s} \quad (1)$$

式中: $\mathbf{y} = [y_1, y_2, \dots, y_m]^T \in \mathbb{R}^m$ 是观测向量, $\{\boldsymbol{\varphi}_j\}_{j=1}^m$ 为 Φ 的行向量。这里,每一个 $\boldsymbol{\varphi}_j \in \mathbb{R}^{1 \times n}$ 可以看作一个传感器,它们分别获取了信号的一部分信息。根据得到的这 m 个观测值 \mathbf{y} 和测量矩阵 Φ ,就可以近乎完美的重构原始信号^[6]。

文献[7]证明在 Φ 和 Ψ 非相关的情况下,二者的解相同,而最小 L_1 范数优化问题是一个凸优化问题,可以方便的进行求解,相当于简化运算^[8]。

至此,可以总结,压缩感知理论研究的核心问题有 3 个:信号的稀疏表达、观测矩阵的构造以及重构算法的设计。信号的稀疏表达,即寻找或设计合适的稀疏基或者稀疏冗余字典 Ψ ,使得信号的稀疏变换系数的非零元个数尽量少;观测矩阵的构造,即设计测量矩阵 Φ ,使 Φ 和 Ψ 尽可能地不相关,从而以尽可能少地观测值,包含 \mathbf{x} 中尽可能多的信息,有助于提升信号的精确重构概率;信号重构算法的设计优化,即找寻能够高概率而精确地重构原始信号的算法,同时追求算法的快速性和稳定性。本文主要研究了前两个核心问题。

压缩感知理论要求信号必须是本身稀疏的或者其在某变换域中存在稀疏的表达形式。通常一个信号的稀疏表示基并不唯一,对于一维时变非平稳信号来说,小波是目前效果最好、应用最广泛的分析工具。从信号的稀疏表达的角度来看,小波分解相当于对信号进行小波域变换,小波分解系数相当于信号的小波变换域系数,其稀疏程度随着分解层数的增大而增大。因此本文对于漏磁检测信号的稀疏表达选用小波基作为稀疏表示基。

根据小波变换的 Mallat 算法来推导小波稀疏基矩阵的显性公式。

设小波稀疏表示基为 $\Psi_{level} \in \mathbb{R}^{n \times n}$,其中 $level$ 为小波分解的层数,则有 $\mathbf{x} = \Psi_{level} \cdot \mathbf{w}$,其中 $\mathbf{w} \in \mathbb{R}^n$ 为小波分解系数。小波稀疏基矩阵无法通过一个简单的公式来表示。我们通常是按照小波分解的算法步骤一步步的对信号进行若干操作来得到分解系数,而希望只通过一个简单的矩阵相乘操作即可得到分解系数,即 $\mathbf{w} = \mathbf{W}_{level} \cdot \mathbf{x}$,其中, $\mathbf{W}_{level} \in \mathbb{R}^{n \times n}$ 为小波分解的等效变换矩阵。而知道 \mathbf{W}_{level} 便可以通过求逆得到 Ψ_{level} ,即 $\Psi_{level} = \mathbf{W}_{level}^{-1}$ 。由于对于算法的运算速度的要求并不严格,选择了形式更简洁的 Mallat 构造算法。

本文利用对称延拓方案以尽量保证小波分解系数的稀疏性。双正交小波的等效滤波器组具有线性相位的,假设低通滤波器 h 的长度为 m ,高通滤波器 g 的长度为 l ,则 m, l 一定是奇数,且滤波器系数是中心对称的,即:

$$\begin{aligned} h &= \{h_0 \ h_1 \ \cdots \ h_{(m-1)/2} \ \cdots \ h_{m-2} \ h_{m-1}\} = \\ &= \{h_0 \ h_1 \ \cdots \ h_{(m-1)/2} \ \cdots \ h_1 \ h_0\} \\ g &= \{g_0 \ g_1 \ \cdots \ g_{l-1/2} \ \cdots \ g_{l-2} \ g_{l-1}\} = \\ &= \{g_0 \ g_1 \ \cdots \ g_{l-1/2} \ \cdots \ g_1 \ g_0\} \end{aligned} \quad (2)$$

以低通滤波器 h 对长为 n 的信号 \mathbf{x} 滤波得到 \mathbf{H}_1 为例,求取对称延拓滤波的等效矩阵 $\mathbf{W}_{H_1} \in \mathbb{R}^{n \times n}$,使得下式成立:

$$\mathbf{H}_1 = \mathbf{W}_{H_1} \cdot \mathbf{x} \quad (3)$$

首先考虑不进行延拓的情况。不延拓其实相当于零延拓,对于 m 长滤波器 h ,卷积过程中需延拓 $m - 1$ 个零点,故滤波后系数长度为 $n + m - 1$ 。而周期延拓和对称延拓的本质,就是将这 $m - 1$ 个延拓点用相应的周期点或对称点填充,以使可以从 $n + m - 1$ 个滤波系数保留 n 个即可。对称延拓时,求取 \mathbf{H}_1 的公式表达如下:

$$\begin{aligned} \mathbf{H}_1 &= \mathbf{W}_{\text{sym}} \cdot \mathbf{x}_{\text{sym}} = \\ &= \begin{bmatrix} h_{m-1} & h_{m-2} & \cdots & 0 & \cdots & 0 & 0 \\ 0 & h_{m-1} & \cdots & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & \ddots & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & h_{m-1} & \cdots & h_0 & 0 \\ 0 & 0 & \cdots & 0 & h_{m-1} & \cdots & h_0 \end{bmatrix} \\ &= \begin{bmatrix} x_{\frac{n+1}{2}} & \cdots & x_0 & \cdots & x_{n-1} & \cdots & x_{n-\frac{n+1}{2}} \end{bmatrix}^T_{1 \times (n+m-1)} \end{aligned} \quad (4)$$

式中: \mathbf{x}_{sym} 为 \mathbf{x} 对称延拓后的 $n + m - 1$ 个滤波系数, \mathbf{W}_{sym} 为滤波器等效矩阵。这里 \mathbf{W}_{sym} 为 $n \times (n + m - 1)$ 维,并不是所要求的 $n \times n$ 维的 \mathbf{W}_{H_1} , 需要根据滤波器系数的对称性,对式进行分段处理。利用公式转换可得 \mathbf{W}_{H_1} 。

$$\mathbf{W}_{H_1} = \begin{bmatrix} [\mathbf{W}_{H_{\text{low}}}]_{\frac{n+1}{2} \times n} \\ [\mathbf{W}_{H_{\text{mid}}}]_{(n-m+1) \times n} \\ [\mathbf{W}_{H_{\text{high}}}]_{\frac{n+1}{2} \times n} \end{bmatrix}_{n \times n} \quad (5)$$

在得到 \mathbf{H}_1 之后还要进行下抽样,每两个点抽一个点,保留下标为偶数的样本点即可。设下抽样的等效矩阵为 $\mathbf{E}_{\downarrow 2} \in \mathbb{R}^{\frac{n}{2} \times n}$, 设其元素为 e_{ij} , 则:

$$\begin{aligned} e_{ij} &= \begin{cases} 1, & j = 2i - 1 \\ 0, & j \neq 2i - 1 \end{cases} \\ i &= 1, 2, \dots, \frac{n}{2}; \quad j = 1, 2, \dots, n \end{aligned} \quad (6)$$

设由 \mathbf{x} 通过低通滤波器 h 及下抽样得到 \mathbf{A}_1 的等效矩阵为 $\mathbf{W}_{A_1} \in \mathbb{R}^{(n/2) \times n}$, 则有:

$$\mathbf{A}_1 = \mathbf{E}_{\downarrow 2} \mathbf{H}_1 = \mathbf{E}_{\downarrow 2} \mathbf{W}_{H_1} \mathbf{x} = \mathbf{W}_{A_1} \mathbf{x} \quad (7)$$

即: $\mathbf{W}_{A_1} = \mathbf{E}_{\downarrow 2} \cdot \mathbf{W}_{H_1}$ 。

同理,可以按照相同的步骤求得 \mathbf{x} 通过高通滤波器 g 及下抽样得到 \mathbf{D}_1 的等效矩阵为 $\mathbf{W}_{D_1} \in \mathbb{R}^{\frac{n}{2} \times n}$, 则有 $\mathbf{W}_{D_1} = \mathbf{E}_{\downarrow 2} \cdot \mathbf{W}_{G_1}$ 。将 \mathbf{W}_{A_1} 和 \mathbf{W}_{D_1} 上下组合在一起就可以组成一个 $n \times n$ 的矩阵,这就是想要的第1层小波分解等效变换矩阵 $\mathbf{W}^{(1)} \in \mathbb{R}^{n \times n}$ 。

$$[\mathbf{W}^{(1)}]_{n \times n} = \begin{bmatrix} [\mathbf{W}_{A_1}]_{(n/2) \times n} \\ [\mathbf{W}_{D_1}]_{(n/2) \times n} \end{bmatrix}_{n \times n} \quad (9)$$

因此,第1层分解系数为:

$$\begin{bmatrix} [\mathbf{A}_1]_{(n/2) \times 1} \\ [\mathbf{D}_1]_{(n/2) \times 1} \end{bmatrix}_{n \times 1} = [\mathbf{W}^{(1)}]_{n \times n} \cdot [\mathbf{x}]_{n \times 1} \quad (10)$$

以后各层分解以此规律类推即可。最后,可以得出 $level$ 层分解的等效变换矩阵 $\mathbf{W}_{level} \in \mathbb{R}^{n \times n}$ 的公式表达,小波稀疏基 $\Psi_{level} = \mathbf{W}_{level}^{-1}$, 则:

$$\begin{aligned} \Psi_{level} &= \mathbf{W}_{level}^{-1} = \\ &= \left(\prod_{j=1}^{level} \begin{bmatrix} [\mathbf{W}^{(j)}]_{\frac{n}{2^j} \times \frac{n}{2^j}} & \mathbf{O}_{\frac{n}{2^j} \times (n-\frac{n}{2^j})} \\ \mathbf{O}_{(n-\frac{n}{2^j}) \times \frac{n}{2^j}} & \mathbf{I}_{(n-\frac{n}{2^j}) \times (n-\frac{n}{2^j})} \end{bmatrix}_{n \times n} \right)^{-1} \end{aligned} \quad (11)$$

式(11)便是要求的小波稀疏表示基 Ψ_{level} 的显性的矩阵表达式。

3 测量矩阵的优化

漏磁检测信号的观测过程表示如下:

$$\mathbf{y} = \Phi \mathbf{x} = \Phi \Psi_{level} \mathbf{w} = \Theta \mathbf{w} \quad (12)$$

式中: $\mathbf{y} \in \mathbb{R}^m$ 为观测值, $\Phi \in \mathbb{R}^{m \times n}$ 为观测矩阵, $\Psi_{level} \in \mathbb{R}^{n \times n}$ 为小波稀疏基矩阵, $\mathbf{w} \in \mathbb{R}^n$ 为稀疏的小波分解系数, $\Theta = \Phi \Psi_{level} \in \mathbb{R}^{m \times n}$ 为相应的传感矩阵。

由于无论正交基矩阵 Ψ 如何选取,传感矩阵 $\Theta = \Phi \cdot \Psi$ 都能满足受限等距性质^[9]。根据此性质,能够很高概率地重构原信号。

学者们提出了许多算法来提升测量矩阵的观测性能。Elad 提出了平均相关性的概念并通过阈值收缩方法减小 Φ 和 Ψ 的平均相关性,该算法的不足之处在于阈值参数 t 和收缩系数 γ 的选取并没有理论性的指导原则,通常采用经验试凑法来选取。Duarte-Carvajalino 则结合了特征值分解来实现对测量矩阵 Φ 的优化,该算法在优化效果上逊色于 Elad 方法。Abolghasemi V 关结合等角紧框架 (equiangular tight frame, ETF) 理论,通过梯度迭代来优化测量矩阵,该算法在理论上证明了测量矩阵的优化目标应该是 ETF,这一结论极具理论指导意义。本文受此启发在前人研究工作的基础上,结合实际应用背景,提出了一种基于 Welch 界和 PRP (Polak-Ribiere-Polyak) 共轭梯度算法的测量矩阵优化算法^[10-12]。

互相关系数最小的矩阵是正交矩阵,其互相关系数为零,即不同列之间乘积皆为0。由于 Θ 不是一个方阵,

而是一个扁矩阵,因此 $\mu(\Theta)$ 不可能为0。对于一个列向量归一化的扁矩阵 $\tilde{\Theta} \in \mathbb{R}^{m \times n}$,其不同列向量的内积值中的最大值存在一个理论上的下界,称为 Welch 界,记为 μ_w 。

$$\mu_w = \sqrt{\frac{n-m}{m(n-1)}} \quad (13)$$

也就是说, $\mu(\tilde{\Theta}) \geq \mu_w$ 或者说对于 $G_{\tilde{\Theta}} = \tilde{\Theta}^T \tilde{\Theta}$ 来说, $\mu_{\max} = \max_{1 \leq i, j \leq n, i \neq j} |g_{ij}| \leq \mu_w$ 在极限情况下,即上式取“=”时,理想 Gram 矩阵 G_w 的所有非对角线元素满足下式: $\forall i, j, i \neq j \quad |g_{ij}| \leq \mu_w$ 由框架理论可知,当且仅当 $\tilde{\Theta}$ 是等角紧框架时,上式才能取等号。由于 ETF 是在给定 (m, n) 情况下,能够取得的互相关系数的最小情况,遗憾的是,对大多数整数对 (m, n) 来说并不存在 ETF,实数域 ETF 则更加稀少。为了找寻任意指定 (m, n) 下最优的感知矩阵,可以将 Welch 界作为优化目标(通常达不到),找寻一个列向量归一化矩阵 $\tilde{\Theta} \in \mathbb{R}^{m \times n}$,使得其 Gram 矩阵 $A = \tilde{\Theta}^T \tilde{\Theta} \in \mathbb{R}^{n \times n}$ 能够最大限度的逼近理想的 Gram 矩阵 G_w 。

为此,首先定义两个矩阵集合 \mathcal{A} 和 \mathcal{G}_w ,集合 A 包含了所有的 $A = \tilde{\Theta}^T \tilde{\Theta}$,

$$\mathcal{A} = \left\{ A \in \mathbb{R}^{n \times n} : A = A^T, \text{rank}(A) \leq m, \text{diag}(A) = e \right\} \quad (14)$$

式中: $\text{diag}(\cdot) = e$ 表示矩阵主对角线元素全为1。集合 \mathcal{G}_w 则包含了所有非对角线元素满足式所示的理想 Gram 矩阵 G_w 。

$$\mathcal{A}_w = \left\{ G_w \in \mathbb{R}^{n \times n} : \text{diag}(G_w) = e, |g_{ij}| \leq \mu_w (i \neq j) \right\} \quad (15)$$

注意到,这里 \mathcal{A} 是非凸集而 \mathcal{G}_w 是凸集。由于集合 \mathcal{A} 和 \mathcal{G}_w 在绝大多数情况下没有交集,那么矩阵 A 与矩阵 G_w 最佳逼近问题转化为:寻求集合 \mathcal{A} 内的一个元素 \hat{A} ,其到集合 \mathcal{G}_w 的距离最小(Frobenius 范数意义下)。用公式描述为:

$$\min \|A - G_w\|_F \quad \text{s.t. } A \in \mathcal{A}, G_w \in \mathcal{G}_w \quad (16)$$

式中: $\|\cdot\|_F$ 表示 Frobenius 范数。

对于这个优化问题的求解,可以将其分解为两个子问题,然后交替迭代求解这两个子问题来逼近最优解:

子问题 I 固定一个 $A \in \mathcal{A}$,求解 $\hat{G}_w = \underset{G_w \in \mathcal{G}_w}{\text{argmin}} \|G_w - A\|_F$ 。

子问题 II 固定一个 $G_w \in \mathcal{G}_w$,求解 $\hat{A} = \underset{A \in \mathcal{A}}{\text{argmin}} \|A - G_w\|_F$ 。

对于子问题 I:由于 \mathcal{A}_w 是凸集,因此这是一个非常简单的凸优化问题。可对优化问题作如下转化求解:

$$\begin{aligned} \min_{G_w \in \mathcal{G}_w} \|G_w - A\|_F &= \min_{G_w \in \mathcal{G}_w} \left(\sum_{i,j} (g_{ij} - a_{ij})^2 \right)^{1/2} \Leftrightarrow \\ \min_{|g_{ij}| \leq \mu_w, i, j, i \neq j} \sum |g_{ij} - a_{ij}| &= \sum_{i, j, i \neq j} \min_{|g_{ij}| \leq \mu_w} (|g_{ij} - a_{ij}|) \end{aligned} \quad (17)$$

其最优解 $\hat{G}_w = \{\hat{g}_{ij}\}_{n \times n}$ 满足:

$$\forall i, j, i \neq j \quad \hat{g}_{ij} = \begin{cases} a_{ij}, & |a_{ij}| \leq \mu_w \\ \mu_w \cdot \text{sign}(a_{ij}), & |a_{ij}| > \mu_w \end{cases} \quad (18)$$

其实子问题 I 相当于求一个凸集外的一个点(矩阵 A)到该凸集的最小距离。这一问题的解是唯一的,且最优解即是 A 在 \mathcal{G}_w 的投影点。

对于子问题 II:由于秩约束 $\text{rank}(A) \leq m$ 的存在,集合 \mathcal{A} 是非凸集,因此子问题 II 是一个带约束的多变量非线性非凸优化问题。本文提出的求解方法为:首先将子问题 II 转化为无约束优化问题,再采用 PRP 共轭梯度法来求解优化问题,进而获得子问题 II 的最优解。

子问题 II 的转化为:便于分析,将原优化问题转化为: $\min_{A \in \mathcal{A}} \frac{1}{2} \|A - G_w\|_F^2$, 令目标函数 $J(A) = \frac{1}{2} \|A - G_w\|_F^2$, 对 $J(A)$ 有如下推导过程:

$$\begin{aligned} J(A) &= \frac{1}{2} \|A - G_w\|_F^2 = \frac{1}{2} \text{tr} \{ (A - G_w)^T (A - G_w) \} = \\ &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (a_{ij} - g_{ij})^2 = \sum_{i=1}^{n-1} \sum_{j=i+1}^n (a_{ij} - g_{ij})^2 = \\ &= \sum_{i=1}^{n-1} \sum_{j=i+1}^n \left(\sum_{p=1}^{m-1} \sin \alpha_{pi} \sin \alpha_{pj} \prod_{k=1}^{p-1} \cos \alpha_{ki} \cos \alpha_{kj} + \right. \\ &\quad \left. \prod_{k=1}^{m-1} \cos \alpha_{ki} \cos \alpha_{kj} - g_{ij} \right)^2 \end{aligned} \quad (19)$$

式(19)表明,目标函数 $J(A)$ 是关于参数向量 α 的函数,不妨记为 $F(\alpha)$,则有 $J(A) = F(\alpha)$,至此,最终将子问题 II 转化为如下的非线性无约束优化问题:

$$\begin{aligned} \min_{\alpha \in R^{(n-1)(n-1)}} F(\alpha) \quad \text{其中,目标函数 } F(\alpha) \text{ 为:} \\ F(\alpha) &= \sum_{i=1}^{n-1} \sum_{j=i+1}^n \left(\sum_{p=1}^{m-1} \sin \alpha_{pi} \sin \alpha_{pj} \prod_{k=1}^{p-1} \cos \alpha_{ki} \cos \alpha_{kj} + \right. \\ &\quad \left. \prod_{k=1}^{m-1} \cos \alpha_{ki} \cos \alpha_{kj} - g_{ij} \right)^2 = \\ &= 2 \times \sum_{i=1, i \neq v}^n \left\{ \left(\sum_{p=1}^{m-1} \sin \alpha_{pi} \sin \alpha_{pv} \prod_{k=1}^{p-1} \cos \alpha_{ki} \cos \alpha_{kv} + \right. \right. \\ &\quad \left. \prod_{k=1}^{m-1} \cos \alpha_{ki} \cos \alpha_{kv} - g_{iv} \right) \times \left(\cos \alpha_{uv} \sin \alpha_{ui} \prod_{k=1}^{u-1} \cos \alpha_{ki} \cos \alpha_{kv} - \right. \\ &\quad \left. \sin \alpha_{uv} \cos \alpha_{ui} \sum_{p=u+1}^{m-1} \sin \alpha_{pi} \sin \alpha_{pv} \prod_{k=1, k \neq u}^{p-1} \cos \alpha_{ki} \cos \alpha_{kv} - \right. \\ &\quad \left. \left. \sin \alpha_{uv} \cos \alpha_{ui} \prod_{k=1, k \neq u}^{m-1} \cos \alpha_{ki} \cos \alpha_{kv} \right) \right\} \end{aligned} \quad (20)$$

接下来将用 PRP 共轭梯度算法来求解子问题 II 转化的无约束优化问题。

非线性共轭梯度算法的迭代公式为 $\alpha_{t+1} = \alpha_t + \lambda_t d_t$ 。其中, t 为当前迭代步数, α_t 为当前迭代的自变量, λ_t 是当前迭代的步长因子,可由线搜索策略确定。而 d_t 是搜

索方向,由下式确定:

$$d_i = \begin{cases} -g_0, & t = 0 \\ -g_i + \beta_i d_{i-1}, & t \geq 1 \end{cases} \quad (21)$$

式中: g_i 为当前迭代的梯度,参数 β_i 表征了搜索方向的更新规则,不同的更新规则对应了不同的非线性共轭梯度算法。最常用的是 FR 方法和 PRP 方法^[13]:

$$\beta_i^{FR} = \frac{g_{i+1}^T g_{i+1}}{g_i^T g_i} \quad (22)$$

$$\beta_i^{PRP} = \frac{g_{i+1}^T (g_{i+1} - g_i)}{g_i^T g_i} \quad (23)$$

式中:PRP 更新规则的优势在于当 λ_i 较小时, β_i^{PRP} 自动向当前负梯度方向靠拢,避免了 FR 方法可能连续产生小步长的缺点。此外,为了保证算法对非凸函数的全局收敛性,需要对 β_i^{PRP} 做一个非负限制,即:

$$\beta_i^{PRP} = \max\{0, \beta_i^{PRP}\}$$

梯度的求取:下面将应用 PRP 共轭梯度算法来解决与子问题 II 等价的关于 $F(\alpha)$ 的无约束优化问题式。为此,首先需要求取目标函数 $F(\alpha)$ 求一阶导数(梯度):

$$\nabla F(\alpha) = \frac{\partial F(\alpha)}{\partial \alpha} =$$

$$\begin{bmatrix} \frac{\partial F(\alpha)}{\partial \alpha_{11}} & \dots & \frac{\partial F(\alpha)}{\partial \alpha_{(m-1)1}} & \dots & \frac{\partial F(\alpha)}{\partial \alpha_{1n}} & \dots & \frac{\partial F(\alpha)}{\partial \alpha_{(m-1)n}} \end{bmatrix}_{[(m-1) \times n] \times 1}^T =$$

$$\begin{bmatrix} \frac{\partial \Gamma(\alpha_{11})}{\partial \alpha_{11}} & \dots & \frac{\partial \Gamma(\alpha_{(m-1)1})}{\partial \alpha_{(m-1)1}} & \dots & \frac{\partial \Gamma(\alpha_{1n})}{\partial \alpha_{1n}} & \dots & \frac{\partial \Gamma(\alpha_{(m-1)n})}{\partial \alpha_{(m-1)n}} \end{bmatrix}_{[(m-1) \times n] \times 1}^T \quad (24)$$

式中: $\Gamma(\alpha_{uv})$ 为 $F(\alpha)$ 中所有包含元素 α_{uv} 的项的总和,有

$$\Gamma(\alpha_{uv}) = \sum_{i=1, i \neq v}^n (a_{iv} - g_{iv})^2 =$$

$$\sum_{i=1, i \neq v}^n \left(\sum_{p=1}^{m-1} \sin \alpha_{pi} \sin \alpha_{pv} \prod_{k=1}^{p-1} \cos \alpha_{ki} \cos \alpha_{kv} + \prod_{k=1}^{m-1} \cos \alpha_{ki} \cos \alpha_{kv} - g_{iv} \right)^2 \quad (25)$$

所以 $F(\alpha)$ 针对每一个可变参数 α_{uv} 的偏导数为:

$$\frac{\partial F(\alpha)}{\partial \alpha_{uv}} = \frac{\partial \Gamma(\alpha_{uv})}{\partial \alpha_{uv}} =$$

$$\frac{\partial}{\partial \alpha_{uv}} \sum_{i=1, i \neq v}^n \left(\sum_{p=1}^{m-1} \sin \alpha_{pi} \sin \alpha_{pv} \prod_{k=1}^{p-1} \cos \alpha_{ki} \cos \alpha_{kv} + \prod_{k=1}^{m-1} \cos \alpha_{ki} \cos \alpha_{kv} - g_{iv} \right)^2 \quad (26)$$

式中: $u = 1, 2, \dots, (m-1); v = 1, 2, \dots, n$ 。

根据式(24)~(26)得到了目标函数 $F(\alpha)$ 的一阶梯度 $\nabla F(\alpha)$ 的表达式,记为 $g_i = \nabla F(\alpha_i)$ 。有了一阶梯度,便可以应用 PRP 共轭梯度算法来求解子问题II。

PRP 共轭梯度算法求解子问题 II 的实现步骤如下。

1) 初始化:参数向量 $\alpha_0 \in \mathbb{R}^{[(m-1) \times n] \times 1}$,理想 Gram

矩阵 $G_w \in \mathcal{G}_w$,收敛阈值 $\varepsilon \geq 0$,迭代次数 $t = 0$;

2) 计算梯度 $g_t = \nabla F(\alpha_t)$;

3) 计算搜索方向 d_t ;

$$\beta_t^{PRP} = \max\left\{0, \frac{g_{t+1}^T (g_{t+1} - g_t)}{g_t^T g_t}\right\} \quad (27)$$

$$d_t = \begin{cases} -g_0, & t = 0 \\ -g_t + \beta_t d_{t-1}, & t \geq 1 \end{cases} \quad (28)$$

4) 采用线搜索策略计算步长 λ_t ,更新 α_{t+1} :

$$\alpha_{t+1} = \alpha_t + \lambda_t d_t \quad (29)$$

5) 若 $\|g_{t+1}\| = \|\nabla F(\alpha_{t+1})\| < \varepsilon$ 或 $|\lambda_t - \lambda_{t-1}| < \varepsilon$ 成立,算法停止,转步骤 6),否则, $t = t + 1$,转步骤 2);

6) 记最优参数向量为 $\hat{\alpha}$,并根据式计算对应的优化矩阵 $\hat{A} \in \mathcal{A}$,输出。

测量矩阵优化算法的实现步骤如下。

Welch 界和 PRP 共轭梯度算法的测量矩阵优化算法的具体实现步骤总结如下:

1) 初始化:稀疏基 $\Psi_{level} \in \mathbb{R}^{n \times n}$,观测量维数 m ,最大迭代次数 $Iter$,初始参数向量 $\alpha^{(0)} \in \mathbb{R}^{[(m-1) \times n] \times 1}$ (高斯随机向量),迭代次数 $k = 0$,收敛阈值 $\varepsilon \geq 0$,计算 Welch 界 μ_w ,根据式计算 $\alpha^{(0)}$ 对应的矩阵 $A^{(0)}$ 。

2) 求解子问题 I : $A^{(k)}$ 已知,根据式求出子问题 I 的解 $G_w^{(k)}$ 。

3) 求解子问题 II :采用 PRP 共轭梯度算法的子问题 II 优化算法求出子问题 II 的最优解 $\alpha^{(k+1)}$ 并计算 $A^{(k+1)}$ 。

4) 若 $k = Iter$ 或 $|F(\alpha_{k+1}) - F(\alpha_k)| < \varepsilon$,算法停止,转步骤 5);否则, $k = k + 1$,转步骤 2)。

5) 记 α 的最优解为 $\hat{\alpha}$,根据式计算最优感知矩阵 $\hat{\Theta} = \tilde{\Theta}(\hat{\alpha})$,则优化后的测量矩阵 $\hat{\Phi} = \hat{\Theta}(\Psi_{level})^{-1} = \hat{\Theta} W_{level}$,输出 $\hat{\Phi} \in \mathbb{R}^{m \times n}$ 。

设计相关的数值试验,验证了本文提出的相关算法的优越性。试验通过 MATLAB 平台实现。下面用上述不同优化算法优化的测量矩阵进行 CS 压缩和重构试验,以验证测量矩阵的性能。试验中,固定整数对为不变,稀疏信号序列长度为,稀疏度为,即有个元素不为 0。对于的每一个取值,都进行 1 000 次的重复试验,且个非零元素的位置是随机变动的,记录 1 000 次试验中符合精确重构要求(一般取残差小于)的次数即可计算出当前稀疏度下的 CS 精确重构概率。依此方法,依次获取时对应的 CS 精确重构概率,便可绘制固定时,不同稀疏度信号的精确重构概率曲线。

关于 CS 重构算法,通常采用正交匹配追踪(orthogonal matching pursuit, OMP)算法为了更好的重构效果,本文采用广义正交匹配追踪(generalized OMP, gOMP)算法来实现 CS 重构,这是由 Wang J 提出的一种 OMP 算法的改进算法。

gOMP 算法下精确重构概率如图 1 所示,测量矩阵能够达到精确重构概率为 100% (高概率) 的最大允许稀疏度 K_{\max} 如表 1 所示。




图 1 gOMP 重构算法下的精确重构概率对比

Fig. 1 Comparison of accurate reconstruction probability for gOMP algorithm

表 1 $m = 64$ 时能够 100% 精确重构的最大允许稀疏度 K_{\max}

Table 1 Maximum allowable sparsity K_{\max} for 100% accurate reconstruction when $m = 64$

gOMP 重构	随机	Elad 方法		Vahid-1	Vahid-2	本文方法
	高斯法	$\gamma = 0.6$	$\gamma = 0.8$	方法	方法	
	14	20	19	1	18	22

分析以上图表有结论如下:

1) 随机高斯矩阵在 gOMP 算法下可以实现 $K \leq 14$ 的稀疏信号的高概率精确重构。

2) Vahid-1 方法仅能实现 $K = 1$ 时的高概率精确重构,性能不及随机高斯矩阵,这证明了以单位阵为优化目标的测量矩阵优化算法是存在局限性的。其会造成 A 矩阵中大于 0.5 的元素过多,甚至多于随机高斯矩阵,造成重构失真严重,因此其优化效果远逊于其余算法。事实上,此处已经证伪了 Vahid-1 方法,相信这也是 Vahid 在其后又提出 Vahid-2 算法的原因。

3) Vahid-2 方法、Elad 方法的重构概率曲线比较接近,在 gOMP 算法下可以高概率的实现 $K \approx 19$ 的稀疏信号的精确重构,较随机设计了相关的数值试验,从多个角度验证本文提出的相关算法的优越性。试验通过 MATLAB 平台实现。高斯矩阵的性能有较大的提升。

4) 本文采用的方法,性能较 Vahid-2 方法、Elad 方法有了进一步的提升,可以高概率的实现 $K \leq 22$ 的稀疏信号的精确重构。至此,通过仿真试验从不同角度证实了本文提出的测量矩阵优化算法的可行性和优越性。应用

本文算法优化的测量矩阵实施漏磁检测数据的在线压缩, m 的取值可以更小,有利于提高漏磁检测数据的压缩比。

4 漏磁检测数据筛选

在管道缺陷检测过程中,能够引起漏磁场起伏变化的是管壁缺陷和管道附件,而绝大多数的数据则是无用数据。因此,在对检测数据进行压缩处理之前,有必要对数据进行初步的筛选,降低压缩环节的工作量,从而进一步降低数据存储量。图 2 所示为截取自一段真实的管道缺陷漏磁检测曲线。图 2 中横坐标数值表示距探测器出发点的距离,纵坐标数值标示了不同传感器通道在管道周向的位置,曲线的起伏反映了漏磁场强度的变化^[15-16]。由图 2 可知,漏磁检测曲线主要包含 3 种数据。

1) 管道缺陷数据。在管道缺陷处(如腐蚀、裂纹、沟槽等),检测曲线具有较高的幅值,如 4 中长圆形框标示的两处。

2) 管道附件数据。在管道的附件处(如法兰、焊缝、支管、阀门、套管等),检测曲线也会呈现起伏变化,但是这部分曲线有呈现固定的形式,可以轻易的将其与缺陷数据做出区分。

3) 健康数据,大部分的数据都是起伏很小相对平坦的曲线,这部分健康数据即是代表健康的管壁。




图 2 典型的漏磁检测曲线

Fig. 2 Typical magnetic flux leakage detection curve

以上 3 类数据中,本文最关心的是缺陷数据,而管道附件数据可以用来辅助缺陷的定位,筛除冗余数据将极大地减少数据存储量。为了便于后文的叙述,将管壁有缺陷处、管道附件处采集到的漏磁检测数据称为“重要数据”;而无管道附件的完好区域采集的漏磁检测数据称为“非重要数据”。

为了尽量简化重要数据筛选的步骤,以等间隔的分段漏磁曲线为基本单元,进行关于数据段的重要性划分:非重要数据段(unnecessary data segment, UDS)和重要数据段(important data segment, IDS)。对于 UDS,仅存储该分段的位置信息编号,解压时该分段以幅值为 0 的直线代替;而 IDS,则送入压缩环节进行数据压缩处理后再存储^[17-18]。

在分段的漏磁检测数据上,可以用来区分 IDS 和

UDS 的信号特征包括:幅值动态范围 Δ , 幅值变化率 $diff$ 和信号能量 E 。IDS 通常具有较高的信号能量、较大的动态范围和幅值变化率,UDS 则相反。采用幅值动态范围 Δ 为主,信号能量 E 为辅的判据策略。定义如下:

$$\Delta(\mathbf{x}_n) = \max(\mathbf{x}_n) - \min(\mathbf{x}_n) \quad (30)$$

$$E(\mathbf{x}_n) = \sum_{i=1}^n x_i^2 \quad (31)$$

漏磁检测数据的重要数据段的筛选步骤如下。

1) 初始化:根据实际信号的特征,确定合适的数据分段长度 n , 动态范围阈值 λ_Δ 及能量阈值 λ_E 。

2) 读取数据分段 \mathbf{x}_n , 计算动态范围 $\Delta(\mathbf{x}_n)$ 。若 $\Delta(\mathbf{x}_n) \geq \lambda_\Delta$, 判定为 IDS, \mathbf{x}_n 送入压缩环节, 否则, 执行步骤 3)。

3) 计算信号能量 $E(\mathbf{x}_n)$ 。若 $E(\mathbf{x}_n) \geq \lambda_E$, 判定为 IDS, \mathbf{x}_n 送入压缩环节, 若 $E(\mathbf{x}_n) < \lambda_E$, 则判定为 UDS, 仅记录 \mathbf{x}_n 的位置和长度信息。

5 仿真与试验

试验首先针对图 2 所示的典型漏磁检测曲线, 该图是截取自真实的漏磁检测曲线图。该段数据包含了环焊缝和缺陷, 共 20 路漏磁检测曲线, 每一路包含 1 792 个采样数据, 数据总和为 35 840 个; 以 128 个采样数据为一个基本单元, 则每一路曲线可划分为 14 个基本单元, 全部共 280 个数据段基本单元。应用本文提出的重要数据段的筛选方法对这 280 个数据段进行重要数据段筛选。表 2 所示为所截区域 UDS 和 IDS 的占比。

表 2 UDS 和 IDS 的占比

Table 2 The proportion of UDS and IDS

	总数	UDS	IDS		
			$\Delta \geq \lambda_\Delta$	$\Delta < \lambda_\Delta$ 且 $E \geq \lambda_E$	IDS 相邻
段数	280	155	49	2	74
占比/%	-	55	18	1	26

真实的漏磁检测曲线如图 3 所示, 筛选出的重要数据段如图 4 所示。对比图 3、4 可以看到, IDS 区域完全的覆盖了环焊缝和两处缺陷部分, 没有发生漏判。这证明所提出的筛选办法是切实可行且十分有效的。IDS 包含 125 个数据段, 占所见区域数据段总量的一半以下, 极大地减少了后续压缩环节的工作量并有助于提升整体的数据压缩比例。

以上完成的是在线 CS 压缩过程, 存储设备在检测工作完成后取出, 离线环境下读取存储的数据。带有 UDS 标志的数据段由零线(磁传感器基准电平)在相应位置填充; 带有 IDS 的数据段则应用 gOMP 重构算法^[14-15]进行解码重构后填充到相应位置。如此, 完成了对漏磁检测信号的压缩、存储及解压还原工作。

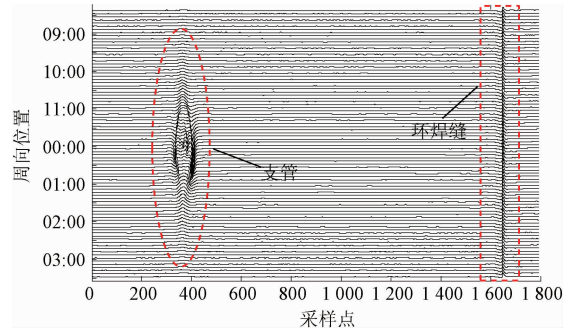


图 3 真实的漏磁检测曲线

Fig. 3 Real magnetic flux leakage detection curve




图 4 筛选出的重要数据段

Fig. 4 Schematic diagram of the screened important data segments

本节应用本文提出的在线压缩算法对图 3 和 4 的漏磁检测信号曲线进行 IDS 筛选和 CS 压缩编码, 应用 gOMP 算法对漏磁曲线进行解码重构并绘制重构的漏磁曲线图像。部分区域的重构结果对比, 如图 5 ~ 10 所示。




图 5 环焊缝及两个缺陷区域原始漏磁曲线

Fig. 5 Original magnetic flux leakage curve of a ring welding seam and two defective areas

通过以上漏磁曲线压缩重构前后对比可以证明, 本文提出的在线压缩算法可以很好地实现 CS 压缩编码并利用 CS 重构算法实现高精度的解码还原, 而不会破坏漏磁信号原有的特征, 保证了后续缺陷识别和缺陷轮廓重构工作的准确性。




图6 环焊缝及两个缺陷区域重构漏磁曲线

Fig. 6 Reconstructed magnetic flux leakage curve of a ring welding seam and two defective areas




图7 环焊缝区域原始漏磁曲线

Fig. 7 Original magnetic flux leakage curve of ring welding seam area




图8 环焊缝区域重构后漏磁曲线

Fig. 8 Reconstructed magnetic flux leakage curve of ring welding seam area




图9 支管区域原始漏磁曲线

Fig. 9 Original magnetic flux leakage curve of branch area




图10 支管区域重构后漏磁曲线

Fig. 10 Reconstructed magnetic flux leakage curve of branching area

本文提出的漏磁检测数据在线CS压缩算法,对于IDS数据段的压缩比达到40%,而IDS数据段占全部漏磁检测数据的不到20%,因此经过筛选并压缩后存储的数据总量仅为原数据的8%,扣除标志位及分段编号占用的空间,总共可以节省约90%的存储空间,效果十分可观。

6 结论

本文研究了漏磁检测数据的在线压缩算法。受制于嵌入式在线工作环境,传统的数据压缩方法难以应用与漏磁检测数据的压缩。本文独辟蹊径,引入压缩感知理论,提出了基于CS理论的漏磁检测数据在线压缩方法,极大地减少了在线环境压缩编码的运算复杂度。首先确定了小波基作为漏磁信号的稀疏表示基,并着重推导了小波稀疏基矩阵的显性表达公式;其后重点研究了测量矩阵的优化方法,提出基于Welch界和PRP共轭梯度算法的测量矩阵优化算法,并通过试验证明了算法的有效性和优越性;其后,提出了漏磁检测数据的重要数据段筛选方法,极大的减少了数据存储量;最后通过试验证明了该算法的确具有压缩算法简单迅速,压缩比高,重构精度高等优点,总共可以节省约90%的存储空间,非常契合本文漏磁检测数据在线压缩的实际要求。

参考文献

- [1] 王平. LZW无损压缩算法的实现与研究[J]. 计算机工程, 2002, 28(7):98-99.
WANG P. Realization and research of LZW lossless compression algorithm [J]. Computer Engineering, 2002, 28(7):98-99.
- [2] METZLER C A, MALEKI A, BARANIUK R G. From denoising to compressed sensing[J]. IEEE Transactions on Information Theory, 2016, 62(9):5117-5144.
- [3] RUSH C, GREIG A, VENKATARAMANAN R. Capacity-achieving sparse superposition codes via approximate message passing decoding [J]. IEEE

- Transactions on Information Theory, 2017, PP(99):1-1.
- [4] 邱立达, 刘天键, 傅平. 基于稀疏滤波的无线传感器网络数据融合[J]. 电子测量与仪器学报, 2015, 29(3):352-357.
QIU L D, LIU T J, FU P. Data fusion of wireless sensor networks based on sparse filtering [J]. Journal of Electronics Measurement and Instrumentation, 2015, 29(3): 352-357.
- [5] 杨真真, 杨震. 含噪语音压缩与重构的自适应共轭梯度投影算法[J]. 仪器仪表学报, 2012, 33(10): 2200-2207.
YANG ZH ZH, YANG ZH. Adaptive conjugate gradient projection algorithm for noise compression and reconstruction of noise suppression [J]. Journal of Instrumentation, 2012, 33(10): 2200-2207.
- [6] 李昌利. 欠定盲源分离的稀疏分量分析方法[J]. 广东海洋大学学报, 2009, 29(4): 70-74.
LI CH L. Spatial component analysis method for undetermined blind source separation [J]. Journal of Guangdong Ocean University, 2009, 29(4): 70-74.
- [7] CANDES E J, TAO T. Near-optimal signal recovery from random projections: Universal encoding strategies [J]. IEEE Transactions on Information Theory, 2006, 52(12): 5406-5425.
- [8] 田沛沛, 刘昱, 张淑芳. 一种基于 LDPC 矩阵的压缩感知测量矩阵的构造方法[J]. 电子测量技术, 2014, 37(3):43-46.
TIAN P P, LIU Y, ZHANG SH F. A construction method of compression sensing measurement matrix based on LDPC matrix [J]. Electronic Measurement Technology, 2014, 37(3): 43-46.
- [9] CANDES E J, ELDAR Y C, NEEDELL D, et al. Compressed sensing with coherent and redundant dictionaries[J]. Applied and Computational Harmonic Analysis, 2011, 31(1): 59-73.
- [10] ELAD M. Optimized projections for compressed sensing[J]. IEEE Transactions on Signal Processing, 2007, 55(12): 5695-5702.
- [11] ABOLGHAEMI V, FERDOWSI S, MAKKIABADI B, et al. On optimization of the measurement matrix for compressive sensing [C]. 18th Signal Processing Conference, 2010: 427-431.
- [12] ABOLGHAEMI V, JARCHI D, SANEI S. A robust approach for optimization of the measurement matrix in compressed sensing[C]. 2nd International Workshop on Cognitive Information Processing (CIP), 2010: 388-392.
- [13] 蔡正兰. 一种修正的 PRP 共轭梯度法的全局收敛性[J]. 重庆工商大学学报:自然科学版, 2015, 32(4): 20-22.
CAI ZH L. Global convergence of a modified PRP conjugate gradient method [J]. Journal of Chongqing Technology and Business University: Natural Science Edition, 2015, 32(4): 20-22.
- [14] WANG J, KWON S, SHIN B. Generalized orthogonal matching pursuit [J]. IEEE Transactions on Signal Processing, 2011, 60(12): 6202-6216.
- [15] WANG J, KWON S, SHIM B. Generalized orthogonal matching pursuit [J]. IEEE Transactions on Signal Processing, 2011, 60(12): 6202-6216.
- [16] 吴德会, 游德海, 柳振凉, 等. 交流漏磁检测法趋肤深度的机理与实验研究[J]. 仪器仪表学报, 2014, 35(2):327-336.
WU D H, YOU D H, LIU ZH L, et al. Mechanism and experimental study on skin depth of AC magnetic flux leakage [J]. Chinese Journal of Scientific Instrumentation, 2014, 35(2):327-336.
- [17] 王康, 叶伟, 劳国超, 等. 一种基于压缩感知的宽带 SAR 信号侦察方法[J]. 国外电子测量技术, 2014, 33(4):40-43.
WANG K, YE W, LAO G CH, et al. A detection method of broadband SAR signal based on compression sensing [J]. Foreign Electronic Measurement Technology, 2014, 33(4):40-43.
- [18] WANG X, TANG J, SHI L. Erratum: Induction heating of magnetic fluids for hyperthermia treatment[J]. IEEE Transactions on Magnetics, 2010, 46(4): 1043-1051.

作者简介



张兰勇(通讯作者), 2011 年于哈尔滨工程大学获得工学博士学位, 现为哈尔滨工程大学自动化学院硕士生导师, 主要研究方向为电磁信号处理与分析、先进控制理论等。

E-mail: zlyalf@sina.com

Zhang Lanyong (Corresponding author) received his Ph. D. degree in theory and control engineering from Harbin Engineering University in 2011. Now he is a supervisor for master student in School of Automation, Harbin Engineering University. His main research interest includes electromagnetic signal analysis and processing, and advanced control theory.



陈辉煌, 2016 于哈尔滨工程大学获得学士学位, 现为哈尔滨工程大学硕士研究生, 主要研究方向为电磁信号处理及物联网。

E-mail: 993988254@qq.com

Chen Huihuang received his B. Sc. degree from Harbin Engineering University in 2016. Now he is an M. Sc. candidate in Harbin Engineering University. His main research interest includes electromagnetic signal processing and Internet of Things.