

利用连续Hopfield网络(CHNN)实现低分辨

仪器的高分辨观测

潘琪, 杨帆, 姚佩阳

(空军工程大学电讯工程学院, 陕西西安 710077)

摘要: 结合直接解调技术, 重点推导论证了利用连续Hopfield网络实现低分辨仪器的高分辨观测, 并建立了相应的神经网络模型。经实验表明了该方法的实际可行性, 具有较好的推广能力。

关键词: 直接解调技术; 神经网络; 连续Hopfield网络; 优化计算

中图分类号: TP183 文献标识码: A 文章编号: 1009-3516(2005)03-0067-04

直接解调技术已应用于空间高能天体物理观测。应用直接解调技术于实验设计, 可以通过选择适当的调制方式, 在提高仪器灵敏度的同时改善结果的分辨能力, 即可用简单的观测装置取得高灵敏、高分辨的实验结果^[1]。本文利用连续Hopfield网络(CHNN), 对实现低分辨仪器的高分辨观测进行了研究。在推导论证了该网络可用于实现高分辨观测的基础上, 通过仿真实验证明了方法的可行性。

1 直接解调技术

由低分辨仪器观测 N 个物理量 f_i 得到 M 个数据 d_k , 其观测方程表示为矩阵形式:

$$\rho f = d \quad (\rho \text{ 为仪器的调制系数}) \quad (1)$$

用调制矩阵的转置阵 ρ^T 乘以方程两端可导出下列相关方程:

$$\rho f = c \quad (2)$$

其中 $c = \rho^T d$ 为对象经过某成像仪器调制后的像; $P = \rho^T \rho$ 为仪器的点分布函数矩阵。

传统的相关解调技术简单地用 c 代表对象分布, 完全丢弃了方程(2)中所包含的信息。而现在所发展的直接方法解调方法进一步由 c 推断对象 f , 更充分地利用了实验信息, 从而获得灵敏度和分辨率更高的重建结果^[1]。

利用高斯-赛德尔迭代公式的直接解调算法, 其迭代计算公式为

$$f_i^{(l+1)} = \frac{1}{P_{ii}} (c_i - \sum_{j \neq i} P_{ij} f_j^{(l)}) \quad (3)$$

约束条件 $f_i \geq b_i$ (b_i 为背景强度)。

2 利用连续Hopfield网络(CHNN)实现低分辨仪器的高分辨观测可行性分析

2.1 CHNN 的全局稳定性

CHNN 的输入和输出都是连续数值, 用 $N(\mathbf{W}, \mathbf{T})$ 表示一个 n 阶网络, 其中: \mathbf{W} 为 $n \times n$ 对称阵, $w_{ij} = w_{ji}$ 是单元 i 与 j 之间连接的权值; \mathbf{T} 为 n 维向量, T_i 是单元 i 的阈值; n_i 是第 i 个神经元的输入总和。CHNN 描述状态变化的方程式可表示为

收稿日期: 2004-10-27

作者简介: 潘琪(1981-), 女, 湖北武汉人, 硕士生, 主要从事信号与信息处理研究。

$$x_i(t+1) = F\left(\sum_{j \neq i}^n w_{ij}x_j(t) + T_i\right) \quad (4)$$

CHNN 与电子电路之间存在直接的对应关系,第 i 个输出神经元的模型如图 1 所示。利用电路实现其状态方程组为

$$\begin{cases} C \frac{du_i}{dt} = -\frac{u_i}{R} + \sum_{j=1}^r w_{ij}v_j + I_i \\ v_i = f_i(u_i) \end{cases} \quad i, j = 1, 2, \dots, r \quad (5)$$

当系统达到稳定时, Hopfield 能量函数定义为^[2]

$$E = -\frac{1}{2} \sum_{i=1}^r \sum_{j=1}^r w_{ij}v_i v_j - \sum_{i=1}^r v_i I_i + \sum_{i=1}^r \frac{1}{R} \int_0^{v_i} F^{-1}(\eta) d\eta \quad (6)$$

其中: $\frac{1}{R} = \frac{1}{r} + \sum_{j=1}^r w_{ij}$ (w_{ij} 为第 j 个输入与第 i 个输入之间的连接导纳, $w_{ij} = \frac{1}{R_{ij}}$; 函数 $F^{-1}(v_i)$ 为 u_i 的逆函数)。

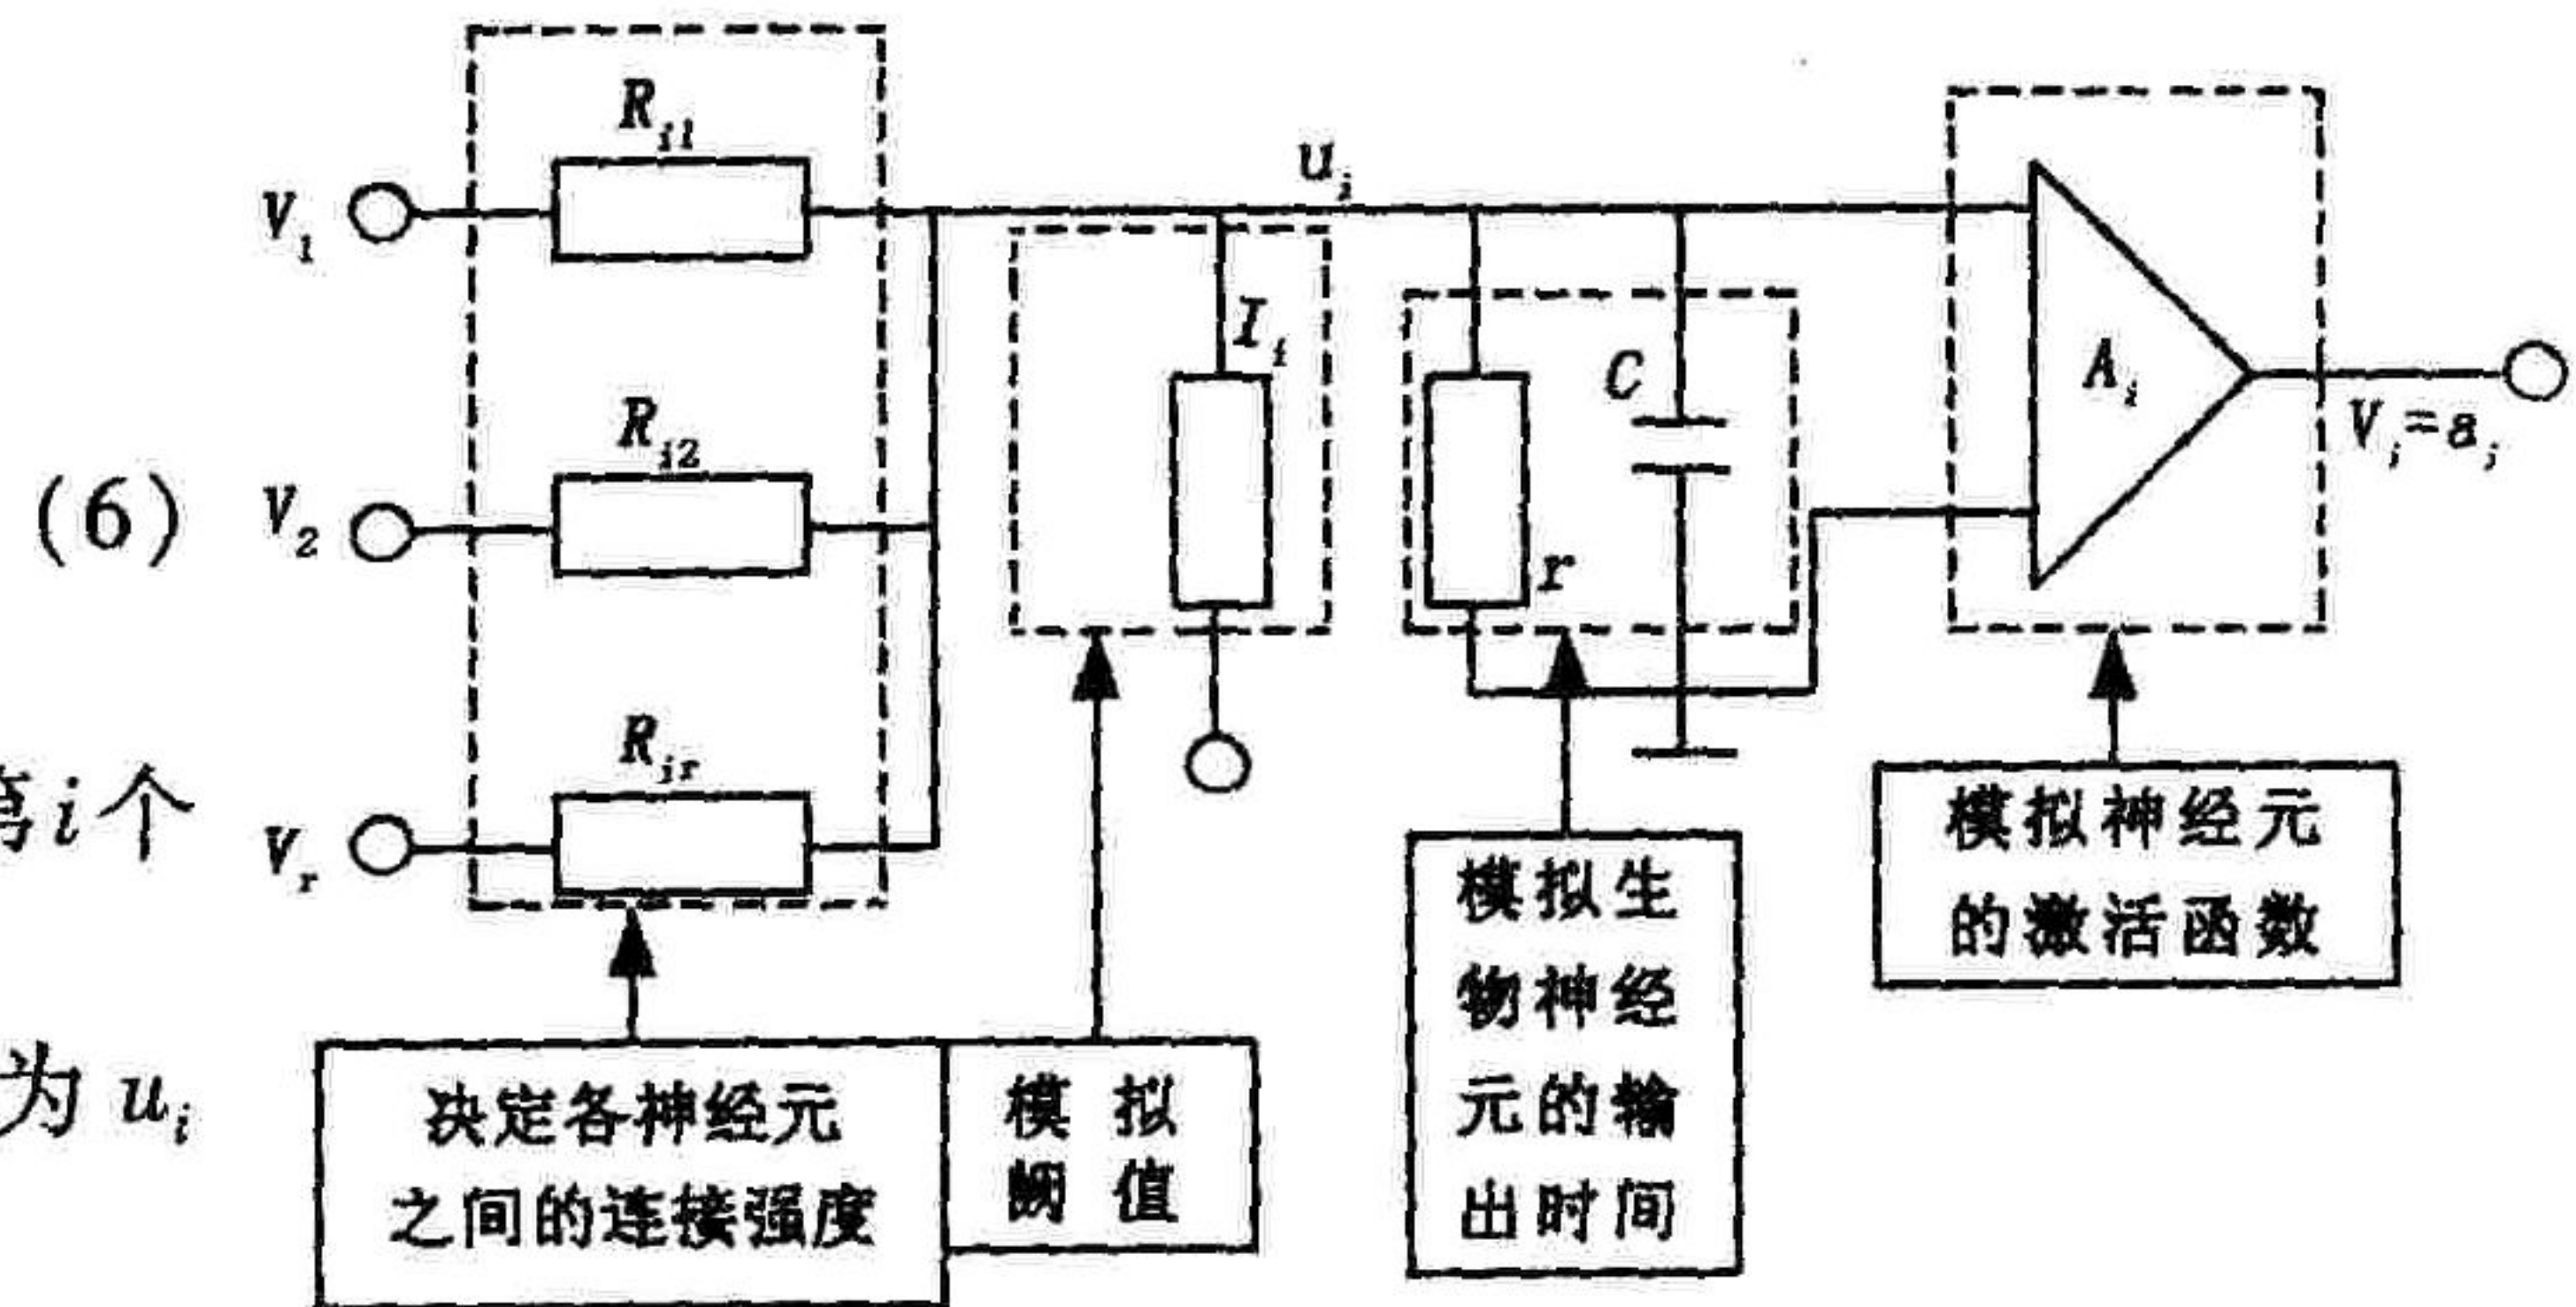


图 1 第 i 个输出神经元电路模式

在系统的运动过程中,其内部储存的能量随着时间的增加而逐渐减少,当运动到平衡状态时,系统的能量耗尽或变得最小,那么系统自然将在此平衡状态处渐近稳定,此时能量函数必定达到一个极限值,而此极限值正是系统的稳定点^[2]。因此,CHNN 是一个全局稳定的反馈网络。

2.2 Hopfield 能量函数应用于优化计算

所谓优化问题,是求解满足一定约束条件下目标函数的极小值问题。Hopfield 能量函数是一个反映了多维神经元状态的标量函数,可以用简单的电路形成人工神经网络,它们的互联形成了并联计算的机制^[3]。

设计等价最小的能量函数 E 为

$$E = f(u) + \sum |g_i(u)| \quad u \in R^r \quad (7)$$

式中, $f(u)$ 为优化目标函数,即人工神经网络的状态,也是目标函数中的变量; $\sum |g_i(u)|$ 称为惩罚函数,因为在约束条件 $g_i(u) = 0$ 不能满足时, $\sum |g_i(u)|$ 的值总是大于零,造成 E 不是最小。

根据 Hopfield 能量函数的要求,只有 E 在负的方向上有界,即 $|E| < E_{max}$ 。同时 $\frac{dE}{dt} \leq 0$, 则系统最后总能达到 E 的最小且 $\frac{dE}{dt} = 0$ 的点,此点同时又是系统稳定点,即 $\frac{du_i}{dt} = 0$ 的点。由于求解优化问题的 E 往往是状态 u 的函数,所以,为了方便求解,常将 $\frac{dE}{dt} \leq 0$ 的条件转化为对状态求导的条件如下:

$$\frac{\partial E(u_i, v_i)}{\partial v_i} = -\frac{dv_i}{dt} \quad (8)$$

所以在用 Hopfield 能量函数求解优化问题时,首先应把问题转化为目标函数和约束条件,然后构造出能量函数,并利用条件求出能量函数中的参数,由此得到人工神经网络的连接权值。

3 利用 CHNN 实现低分辨仪器的高分辨观测的模型建立

3.1 公式转化

将式(3) 做如下变换:

$$f_i^{(t+1)} - b_i = \sum_{j \neq i} \left(-\frac{P_{ij}}{P_{ii}}\right) (f_j^{(t)} - b_j) + \left(-b_i + \sum_{j \neq i} \left(-\frac{P_{ij}}{P_{ii}}\right) b_j + \frac{c_i}{P_{ii}}\right) \quad (9)$$

当激活函数 $F(x) = \begin{cases} x & x \geq 0 \\ 0 & \text{其它} \end{cases}$ 时,比较式(4) 与式(9) 得如下对应关系式:

$$x_i = f_i - b_i \quad (10); \quad T_i = c_i/P_{ii} - \sum_{j \neq i} (P_{ij}/P_{ii})b_j - b_i \quad (11); \quad w_{ij} = -P_{ij}/P_{ii} \quad (12)$$

所以,直接解调算法可以利用连续 Hopfield 神经网络求解。由于 CHNN 的全局稳定性,所以所得结果是稳定收敛和全局最佳的:收敛于在 Hopfield 能量函数意义下的总体误差最小^[4]。

3.2 模型建立

用 Hopfield 神经网络设计一个变换器,要求将一个经某成像仪器调制后的像 c 变化为灵敏度和分辨率更高的像 f ,使其与真实的 f 值误差最小。该问题可以通过 CHNN 能量函数求得优化解。

采用人工神经网络进行转换,首先需定义能量函数。若观测像 f 有 N 个,则该变换器可以用具有 N 个输出节点的 CHNN 来实现。假定神经元的输出量 v_i ($v_i = f_i - b_i$) 可在 0 与 1 之间连续变化,当网络达到稳态时,各节点的输出为 0 或 1:为 0 则表示强度分布 f_i 与背景强度 b_i 完全融合,无法区分;为 1 则表示强度分布 f_i 与背景强度 b_i 反差最为合适,易于分辨。若此时的输出状态所表示的值与模拟输入量 u ($u = c$) 相等,则表明此人工神经网络达到变换器的功能。将 P 表示为 $P = [P_1, P_2, P_3, \dots, P_N]^T$,此时输入与输出之间的关系则满足

$$下式: u = \sum_{i=1}^N P_i(v_i + b_i) \quad (13)$$

利用最小方差的概念,对输出的 v_i 按下列指标来选取 $f(u)$:

$$f(u) = \frac{1}{2P_{ii}P_i} \left(u - \sum_{i=1}^N P_i(v_i + b_i) \right)^2 \quad (14)$$

这里所选择的 $f(u)$ 表示的是神经元输入与对应输出最小方差,此目标函数大于零,所以 $f(u)$ 存在极小值,且当 $f(u) = f_{\min}(u)$ 时, v_i 为 u_i 的正确转换。

将 $f(u)$ 展开,并整理后得:

$$f(u) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \frac{P_{ij}}{P_{ii}} (v_i + b_i)(v_j + b_j) - \sum_{i=1}^N \frac{u_i}{P_{ii}} (v_i + b_i) + \frac{1}{2} \sum_{i=1}^N u^2 \quad (15)$$

仅用一项 $f(u)$ 并不能保证 v_i 的值充分接近逻辑值 0 或 1,因为可能存在其他 v_i 值, (v_i 值可以在 $[0, 1]$ 中连续变化) 使 $f(u)$ 最小,为此,增加一个约束条件:

$$g(u) = -\frac{1}{2} \sum_{i=1}^N (v_i - 1)v_i \quad (16)$$

$g(u)$ 保证了输出只有在 $\{0, 1\}$ 时取最小值零,而对于 v_i 为 0 与 1 之间的实数时, $g(u) \neq 0$ 。所以此约束条件保证了输出为 0 或 1。具体设计步骤如下:

1) 写出能量函数 E

$$E = f(u) + g(u) + \sum_{i=1}^N \frac{1}{R_i} \int_0^{v_i} F^{-1}(\eta) d\eta = \frac{1}{2P_{ii}P_i} \left(u - \sum_{i=1}^N P_i(v_i + b_i) \right)^2 - \frac{1}{2} \sum_{i=1}^N (v_i - 1)v_i + \sum_{i=1}^N \frac{1}{R_i} \int_0^{v_i} F^{-1}(\eta) d\eta \quad (17)$$

若选择使用高增益放大器,能量函数中的积分部分可以忽略不计。

2) 计算 $\frac{du_i}{dt}$

因为 $\frac{dv_i}{dt} = F(u_i) \frac{du_i}{dt}$, 而 $F(u_i) > 0$, 在放大区内可以近似为一个常数 C , 即: $F(u_i) = C$ 。所以有: $\frac{\partial E}{\partial v_i} =$

$\frac{dv_i}{dt} = -C \frac{du_i}{dt}$, 而 $\frac{\partial E}{\partial v_i} = \sum_{j \neq i} \frac{P_{ij}}{P_{ii}} v_j + \sum_{j \neq i} \frac{P_{ij}}{P_{ii}} b_j - \frac{u_i}{P_{ii}} \frac{1}{2} + \frac{u_i}{r} = -C \frac{du_i}{dt}$, 该式经整理可得:

$$C \frac{du_i}{dt} = \frac{u_i}{R} + \sum_{j \neq i} \left(-\frac{P_{ij}}{P_{ii}} \right) v_j + \left(\sum_{j \neq i} \left(-\frac{P_{ij}}{P_{ii}} \right) b_j + \frac{u_i}{P_{ii}} - \frac{1}{2} \right) \quad (18)$$

3) 将上式与实现电路的状态方程组相比较可得:

$$w_{ij} = w_{ji} = -\frac{P_{ij}}{P_{ii}} \quad (i \neq j, w_{ii} = 0) \quad (19); \quad I_i = -\sum_{j \neq i} \frac{P_{ij}}{P_{ii}} b_j + \frac{u_i}{P_{ii}} - \frac{1}{2} \quad (20)$$

比较式(11)与(19)、式(12)与(20)可知,权值的设计完全符合要求,但是阈值的模拟相差常数 $(\frac{1}{2} - b_i)$, 因此将式(20)两边各加上该常数得:

$$I'_i = I_i + \left(\frac{1}{2} - b_i\right) = - \sum_{j \neq i} \frac{P_{ij}}{P_{ii}} b_j + \frac{u_i}{P_{ii}} - \frac{1}{2} + \left(\frac{1}{2} - b_i\right) = - \sum_{j \neq i} \frac{P_{ij}}{P_{ii}} b_j + \frac{u_i}{P_{ii}} - b_i = T_i \quad (21)$$

根据上面的设计,可以设计出完成优化求解的模拟电路人工神经网络系统。权的负值是通过倒相运算放大器来完成的,所得到的负输出再用一次倒相变正。

在每次运行网络之前,应使状态复位为零,这样,当给网络输入 u 值时,网络的运行后的稳定输出即为 u 的正确对应的输出。若运行前没有进行复位,那么在下次进行转换时,状态仍停留在上次转换的输出状态,即局部极小值上,因而难以跳出,可能造成错误的转换。

4 实验结果

图 2 和图 3 为上述模型的仿真结果。通过对比原始图像与输出图像,表明该模型对于实现高分辨观测是有效的。该方法能更充分地提取数据中的信息,特别是对于低分辨率仪器的低信噪比观测,能有效地抑制噪声,获得明显好于直接调解结果的分辨率。

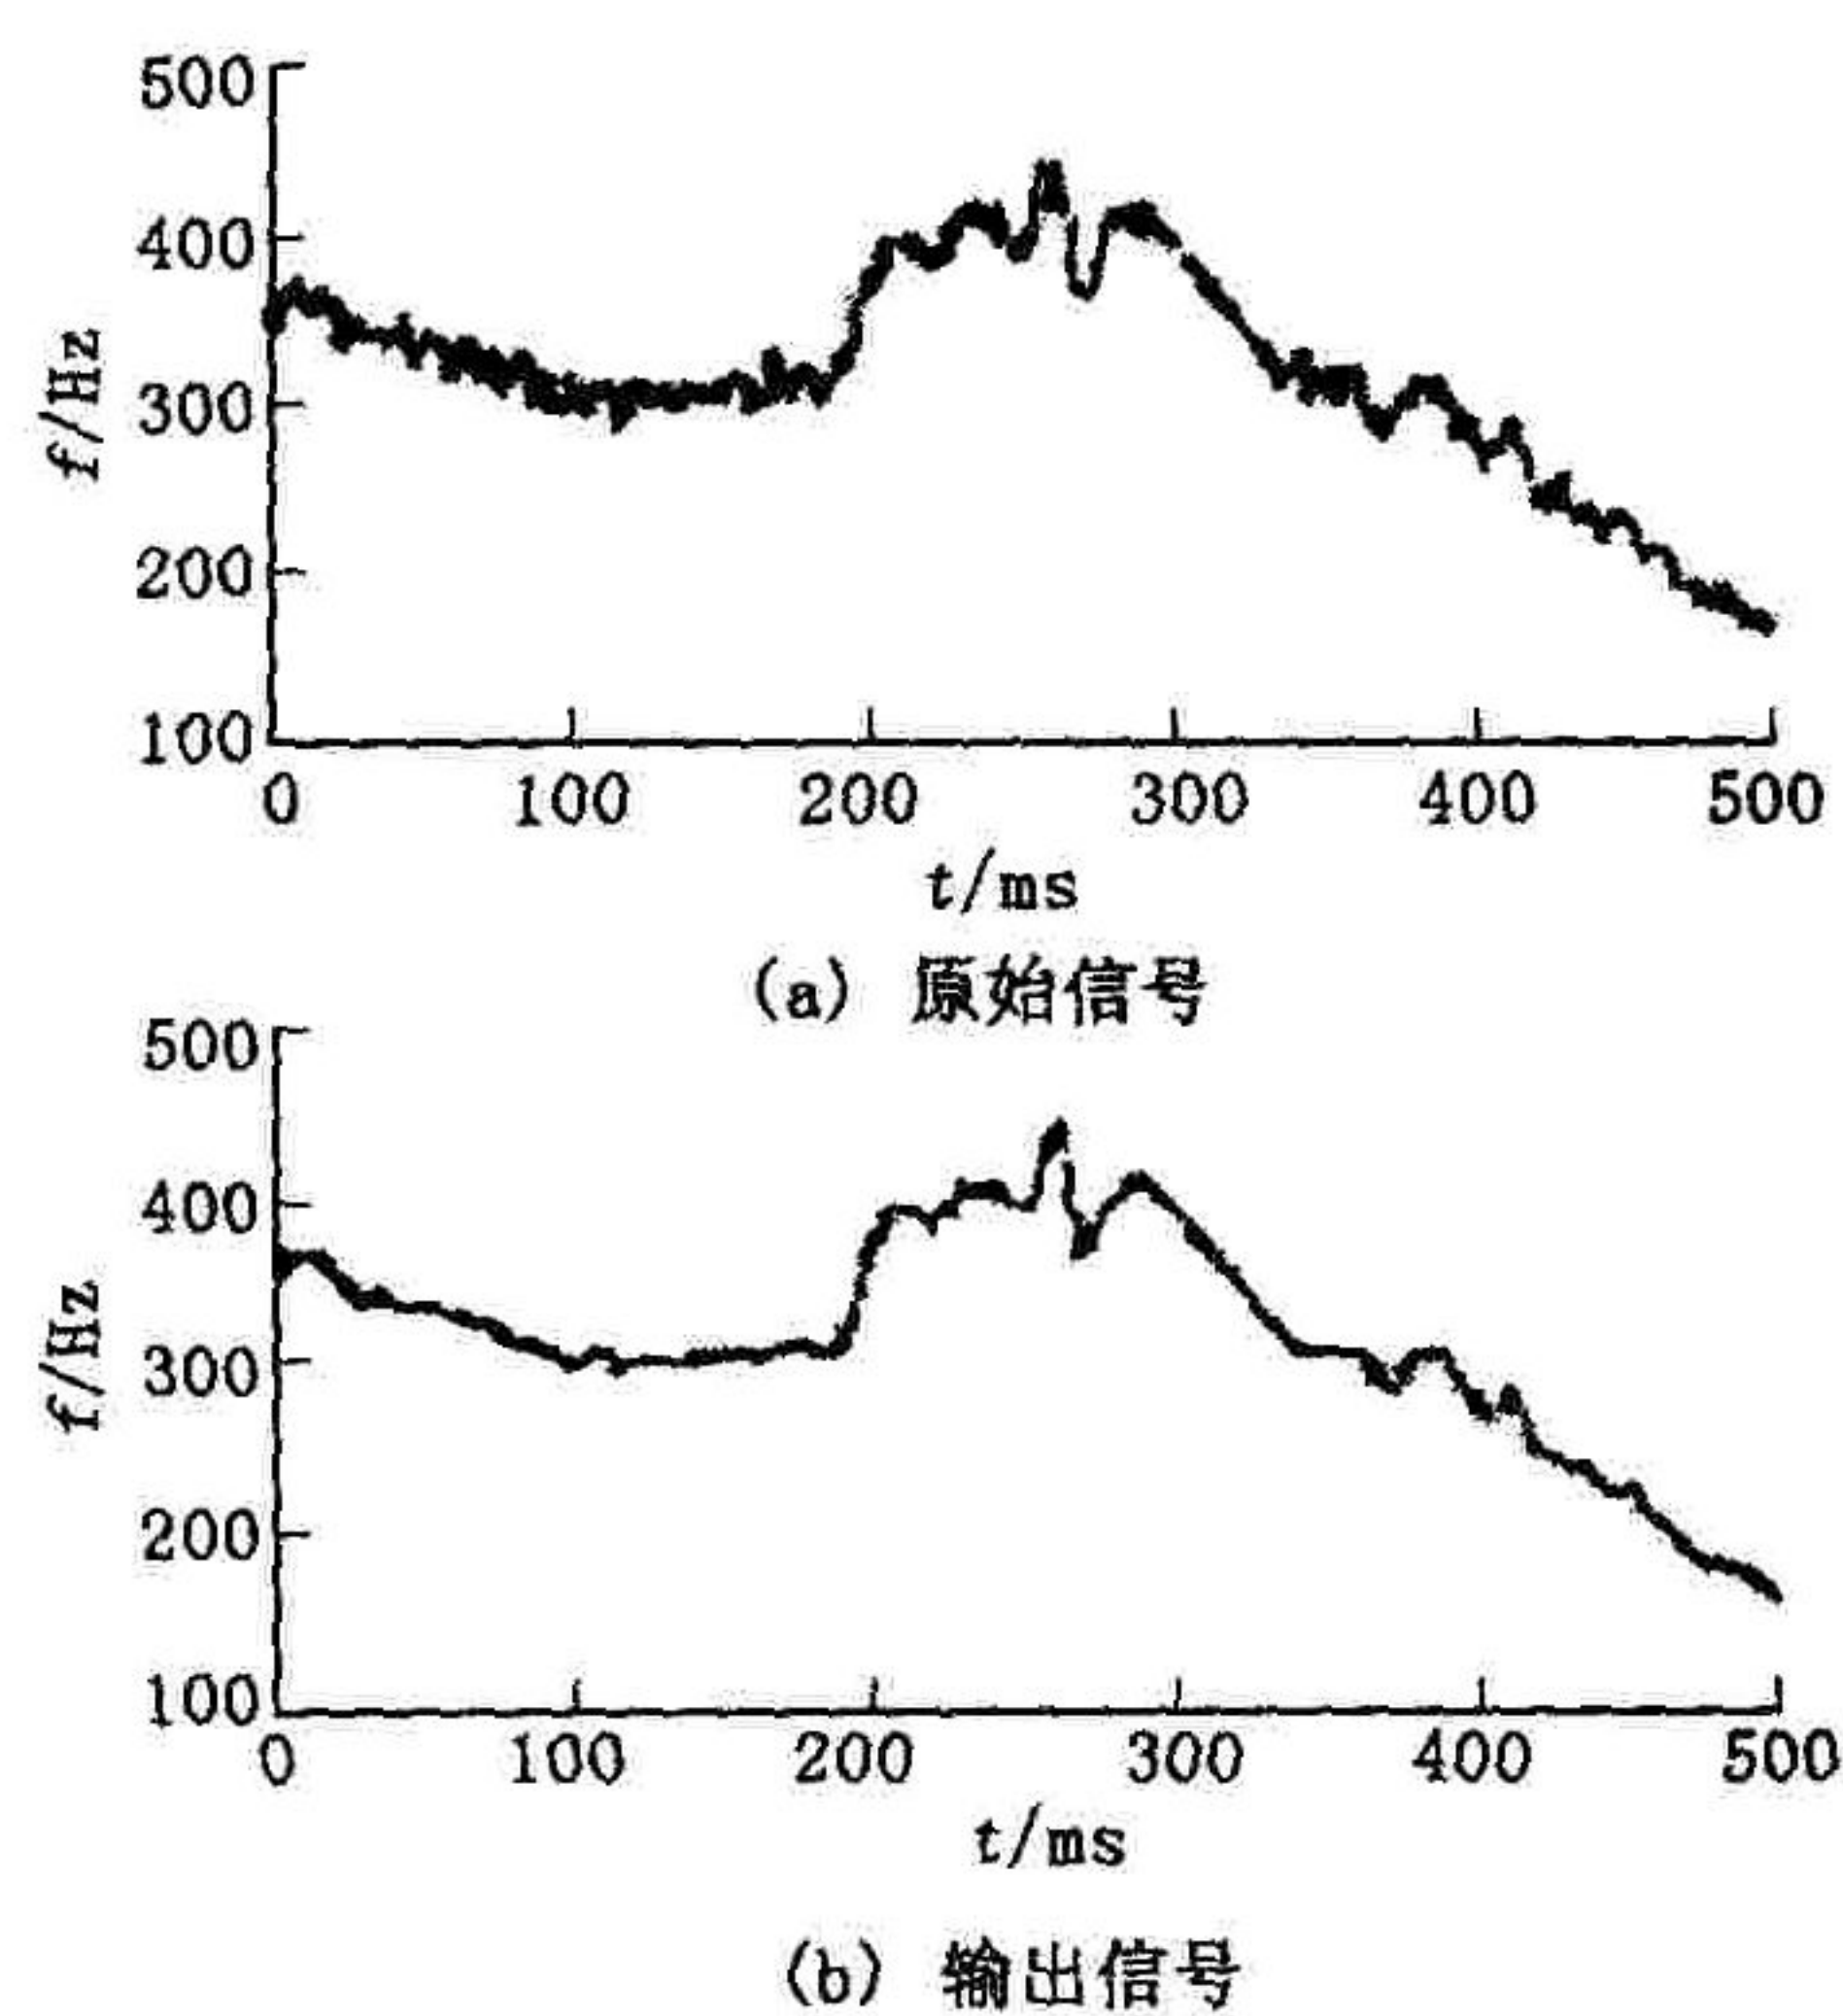


图 2 仿真结果(I)




图 3 仿真结果(II)

参考文献:

- [1] 李惕碚. 能不能用低分辨率仪器实现高分辨观测[J]. 大自然探索, 1999, 8(67): 45-46.
- [2] 丛爽. 面向 MATLAB 工具箱的神经网络理论与应用[M]. 安徽: 中国科学技术大学出版社, 2003.
- [3] 边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 2002.
- [4] 吴伟, 惠晓滨, 沈建明, 等. 基于 Monte Carlo 仿真的重大型号工程时度风险研究[J]. 空军工程大学学报(自然科学版), 2003, 4(5): 7-9.

(编辑: 门向生)

Realizing High Resolution Observation with Low Resolution

Instruments by Continuous Hopfield Neural Network

PAN Qi, YANG Fan, YAO Pei -yang

(The Telecommunication Engineering Institute, Air Force Engineering University, Xi'an, Shaanxi 710077, China)

Abstract: Realizing high resolution observation with low resolution instrument by continuous Hopfield neural network (CHNN) based on direct modulation technique is demonstrated firstly. The corresponding neural network model is applied and the result demonstrates that this method is feasible in practice.

Key words: direct modulation technique; neural network; continuous Hopfield neural network; optimization algorithm