

基于视神经网络的混沌时间序列奇异信号 实时检测算法*

刘金海^{1)2)†} 张化光¹⁾ 冯 健¹⁾

1) (东北大学流程工业综合自动化教育部重点实验室, 沈阳 110004)

2) (东北大学信息科学与工程学院, 沈阳 110004)

(2009 年 10 月 12 日收到; 2009 年 10 月 23 日收到修改稿)

提出了一种基于视神经网络的实时检测混沌时间序列中的奇异点算法, 设计了视神经网络奇异点检测器 (RNNND); 然后设计了基于反向传播 (BP) 神经网络和径向基函数 (RBF) 神经网络的混沌时间序列奇异点检测器. 利用 Lorenz 理论模型产生的时间序列和实测输油管道压力时间序列分别检验了这 3 个奇异点检测器在抗干扰能力、检测微弱信号能力和运算速度等方面的性能. 仿真和分析表明, RNNND 具有良好的检测精度和较快检测速度. 最后详细分析了 3 种奇异点检测器优缺点并给出了适用场合.

关键词: 混沌时间序列, 实时, 奇异点检测, 视神经网络

PACC: 0545

1. 引 言

混沌作为一种自然现象已经越来越引起重视并广泛研究^[1-8]; 而混沌现象的实用化研究主要集中在对混沌时间序列的研究上, 主要是通过对混沌时间序列的研究发现其内部的动态特征, 从而可以对系统的行为进行描述和预测或者检测异常信号^[9-11].

混沌动态具有确定性特性, 但是含有混沌动态的系统一般无法精确建模. 神经网络作为一种具有全局逼近复杂系统能力的工具^[12], 对于无法精确建模的系统具有良好的分析和处理能力, 自然的成为研究混沌时间序列的重要工具. 如: 张军峰等^[13]以径向基函数 (RBF) 网络为基础对混沌时间序列进行预测; Varadan 等^[14]设计 GA-RBF (genetic algorithm-radial basis function) 算法对电力需求进行预测; Karunasinghe 等^[15]和 Oliveira 等^[16]利用反向传播 (BP) 神经网络对模型产生的混沌时间序列进行预测; Gautam 等^[17]利用 BP 神经网络对空气污染

指数时间序列进行预测. 基于神经网络的混沌时间序列的奇异信号检测也取得一些研究成果, 如 Leung 等^[18]设计 RBF 算法检测雷达信号中的小信号, 行鸿彦等^[19]利用 BP 网络完成混沌时间序列的微弱信号检测.

在实际应用中, 评价一种检测算法的性能有两个主要的指标, 检测精度和检测速度. 目前所研究的各种混沌时间序列的算法侧重点主要放在检测算法的精确性上. 特别对于很多实时系统, 如雷达监视系统、管道泄漏实时检测系统等, 除了要保证检测的精度还要保证检测的实时性, 以确保系统能够连续对所检测的目标实时监测.

2005 年 Hosoya 等^[20]在 Nature 上发表论文提出视神经网络 (retina neural network) 模型, 该模型根据动物视神经的特点设计, 具有模型简单、运算速度快、编码简单的特点. 本文着眼于实时检测混沌时间序列中的奇异信号问题, 根据视神经网络的特点, 设计一种基于视神经网络的快速检测算法检测混沌时间序列中的奇异信号, 并称为视神经网络奇异点检测器 (retina neural network novelty detector,

* 国家自然科学基金 (批准号: 60774048, 60774093, 60728307)、国家高技术研究发展计划 (批准号: 2009AA04Z127)、长江学者奖励计划、高等学校博士学科点专项科研基金 (批准号: 20070145015)、国家重点基础研究发展计划 (批准号: 2009CB320601) 和新世纪优秀人才支持计划 (批准号: NCET-08-0101) 资助的课题.

† E-mail: jh_lau@126.com

RNNND). 类似地, 设计了基于 BP 网络和 RBF 网络的奇异信号快速检测算法, 对应于 BP 网络奇异点检测器 (back-propagation neural network novelty detector, BPND) 和 RBF 网络奇异点检测器 (radial base function neural network novelty detector, RBFND). 然后通过实验对比分析了基于神经网络、BP 网络和 RBF 网络算法的各种特性及其在检测混沌时间序列微弱信号方面的性能.

2. 算 法

2.1. 神经网络奇异信号实时检测算法

2.1.1. 神经网络模型

客观世界是由不同的对象构成的, 这些对象的一般特点是空间或者时间上相邻的像点具有近似的光强度. 这种相邻点具有近似光强度的特性为视网膜成像提供了物质基础. 视网膜细胞的接收域中心和周边呈现一种空间和时间的对抗性, 这样对于一个给定的图像点, 视神经可以根据其空间上周围的点或者时间上的前一点来预测当前点的光强度, 并且记录下预测点和实际点的差值. 所以活跃的视神经信号不是图像的原始信号, 而是预测与实际信号的差值. 这个差值信号通常波动范围比较小, 相应的编码也较少, 适合于神经纤维传输. 例如人如果从一个黑暗环境里突然进入一个光亮的环境里, 眼睛无法睁开, 需要适应一段时间, 这是因为黑暗和光明之间的差值非常大, 视网膜无法瞬时完成对信号的编码并送给大脑, 所以对于环境的强烈变化, 需要相当长的时间来适应.

Hosoya 等^[20] 根据对动物的实验提出神经键具有可塑性. 这种可塑性可以通过固定神经键和可变神经键来说明. 假定固定神经键到活跃细胞在某些情况下是可变的, 这种变化指如果两个神经元之间有关联关系, 对应的神经键变得强壮, 反之变弱. 这种规则理论上称之为反 Hebb 规则. Hosoya 等根据对动物的实验提出了视神经网络原始模型, 如图 1 所示.

该网络输入层与输出层通过两种权连接. 一种是固定权值 b_{ij} , 该值根据网络事先给定, 并且不再改变; 另外一种是可变权值 a_{ij} , 通过反 Hebb 学习率修改. 如果 x_i 是输入, y_j 是输出, 那么有

$$y_j = \sum_i (b_{ij} + a_{ij}) x_i. \quad (1)$$




图 1 神经网络模型

网络通过调整 a_{ij} 适应环境. a_{ij} 的调整遵循反 Hebb 规律, 即有

$$\frac{da_{ij}}{dt} = \frac{-a_{ij} - \beta \sigma_{m_1}(y_j, x_i)}{\tau} \quad (\tau, \beta > 0), \quad (2)$$

其中, $\sigma_{m_1}(y_j, x_i)$ 是 y_j 和 x_i 在 m_1 时间步长下的协方差, 用来确定 x_i 和 y_j 之间的关系. 常量 β 和 m_1 是神经网络的参数: β 控制网络对输入的适应速度, τ 决定网络学习新知识和遗忘旧知识的速度, m_1 控制计算协方差的向量的长度. τ 和 m_1 一起控制网络敏感的时间带, β 根据网络适应环境的期望反应而设置, 所以这三个参数虽然固定, 但是要根据不同的应用场合适应合理选择. 如果 β 过小, 网络对输入没有反应, 如果 β 过大则减小了抑制作用, 导致反应过慢. 如果 τ 小, 学习和遗忘的速度都很快, 导致不能完全适应新环境, 如果过大, 则 τ 学习的速度很慢, 需要很长的时间才能完成学习, 增加学习的时间. m_1 过小, 则并不能完全地反映环境前后的联系, 或者协方差为 0 导致 β 失去作用; 如果 m_1 过大则把没有关联度的环境联系在一起, 导致对权重的学习误差甚至错误. β, τ 和 m_1 这三个参数要根据不同的环境进行不同的调整, 目前在实际当中以试凑法最为有效.

2.1.2. RNNND 设计

根据混沌时间序列可以重构相空间的特性, 可以以相空间的维数作为神经网络的输入, 以预测值作为输出, 设计基于神经网络的信号检测器 RNNND. 检测器结构有 d 个输入, 1 个输出, 如图 2 所示.

由于实际当中采集到的数据都为离散数据, 所以按照离散方式处理数据, 首先根据图 1 得到输入输出的关系 (1) 式及学习规则 (2) 式. (2) 式离散化后得到

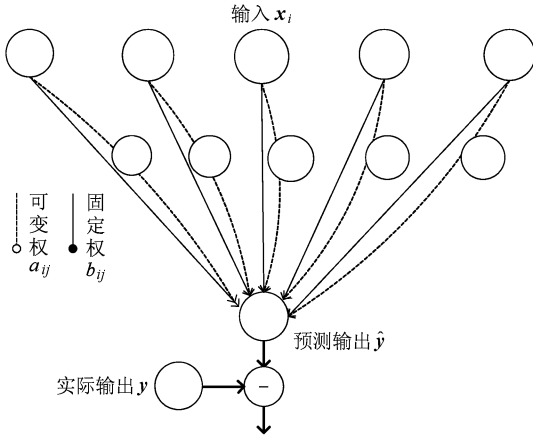


图2 信号检测器

$$\frac{a_{ij}(k+1) - a_{ij}(k)}{\Delta t} = \frac{-a_{ij}(k) - \beta\sigma_{m_1}(y, x_i)}{\tau}, \quad (3)$$

其中 Δt 为采样时间, y 与 x_i 分别为 m_1 维向量, (3) 式整理后, 有

$$a_{ij}(k+1) = \left(1 - \frac{\Delta t}{\tau}\right)a_{ij}(k) - \frac{\Delta t}{\tau}\beta\sigma_{m_1}(y, x_i). \quad (4)$$

(4) 式就是求取可变权的依据。

算法流程描述如下:

1) 求出嵌入延迟 τ 和最佳嵌入维 d , 利用历史时间序列 $\{x_i, t = 0, 1, 2, \dots, N\}$ 重构相空间为

$$X_i = (x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(d-1)\tau}), \quad (5)$$

其中 $t = 1, 2, \dots, N_1, n = N - (d-1)\tau, N$ 是历史数据

的个数. 这 n 个 d 维矢量在 d 维相空间描述出的轨迹将把混沌吸引子完全展开, 在拓扑等价的意义上恢复原来系统的动力学行为; 然后将利用 X_i 构造 $n \times d$ 维相空间矩阵为

$$V = (X_1, X_2, \dots, X_{N_1})^T. \quad (6)$$

2) 将 $n \times d$ 维相空间矩阵 V 的每一列作为 RNNND 的一个输入向量, 训练神经网络. 训练过程中对所有样本的个数 n 和嵌入维尺寸 d 进行循环, 并判断, 若样本个数小于 d , 则输入和输出的协方差为 1; 否则计算新的权重, 并计算预测和实际输出的差值 x_e .

3) 比较差值信号 x_e 和设定阈值, 判断时间序列的状态是否发生改变.

4) 重复 2)–3), 完成对数据的实时诊断.

这里为了保证数据一致性, 原始时间序列规范到 $[-1, 1]$ 之间. 关于初始条件的确定: 由于训练数据应为正常数据, 输入和输出是相关的, 所以初始的协方差选择 1, 且令 $m_1 = d$, 即 $\sigma_d(y, x_j) = 1$, 由于初始时可以是外部环境不变的, 所以可变权重的初值 $a(0) = 0$.

2.2. 基于 BP 和 RBF 神经网络的奇异信号检测算法

基于 BP 与 RBF 神经网络的奇异点检测器 (BPND 和 RBFND) 结构如图 3 所示. 步骤如下:




图3 神经网络在线故障诊断方法结构图

- 1) 求出嵌入延迟 τ 和最佳嵌入维 d ;
- 2) 利用混沌时间序列的历史数据学习 BP 和 RBF 神经网络参数;
- 3) 实时数据 v_i 联合历史数据组成输入向量 $a_i = (x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(d-1)\tau})$, 作为当前神经网络的输入, 则可以得到预测的下一步输出 \bar{x}_{i+1} ;

5) $x_{i+\tau}$ 和其预测值 $\bar{x}_{i+\tau}$ 的预测误差值 x_e 作为故障判断的依据;

6) 重复 3)–5), 完成对实时数据的检测.

3. 实验研究及对比分析

3.1. Lorenz 系统仿真研究

为了验证 RNNND 的有效性, 以 BPND 和

4) 实时数据 v_i 和其前面相邻的若干历史数据实时训练网络, 得到的权值用来实时更新下一步预测网络的权值;

RBFND 为参照,以 Lorenz 混沌时间序列为例分别验证这 3 种奇异点检测器的性能.

利用 Lorenz 系统生成 Lorenz 时间序列,截取 Lorenz 序列的中间 2500 个数据点,前 500 个数据作为学习数据,后 2000 个数据作为测试数据.在测试数据中间加入 5 个具有 10 个数据宽度的脉冲奇异点.

RNNND 参数分别取嵌入维 3,嵌入延迟 1, $\beta = 100$, $\tau = 10$, $m_1 = 2$.

BPND 算法中,BP 神经网络采用 3 层结构,输入节点 3 个,隐含层节点 28 个,一个输出节点;离线训练数据集包含 500 个向量,在线学习的历史向量

为 20 个,训练 800 代;处理方式选用批处理;隐含层激活函数 logsig,输出层激活函数 purelin;训练算法采用 Levenberg Marquardt 的 BP 算法;学习算法采用自适应学习速率的梯度下降法.

RBFND 中的 RBF 神经网络采用 3 层结构,训练目标 10^{-10} ,传播速度 0.5,最大神经元个数为 100,离线学习数据 90 个,在线学习数据 20 个,输入层有 3 个节点,隐含层 90 个节点,采用单步预测.

仿真结果如图 4 所示,从图中可以看到 3 种检测器都可以正确检测出 5 个奇异点.其中,RBFND 具有最强的检测能力,BPND 次之,RNNND 检测能力稍差.




图 4 用 3 种神经网络检测 Lorenz 时间序列中的奇异点 (a)输入时间序列,(b)RNNND 输出时间序列,(c)BPND 输出时间序列,(d)RBFND 输出时间序列

利用数学模型产生的时间序列都是理想的情况,没有噪音干扰.而在客观世界中所获得的实测数据都有噪音干扰,通常用信噪比来表示原始信号和噪音信号的关系.信噪比定义为

$$\gamma_{SN} = 10 \lg \frac{\frac{1}{n} \sum_{n=1}^N |x(n)|^2}{\sigma^2}, \quad (7)$$

其中, $x(n)$ 为含有噪声的信号, N 为信号的长度, σ^2 为噪声的方差.

在 Lorenz 系统中加上与原信号信噪比为 -2.27 dB 的白噪声测试 3 种检测器的抗干扰能力,

检测结果如图 5 所示.RNNND 和 BPND 能够出来全部 5 个奇异点,证明该方法对于含有噪声干扰的信号具有较为理想的效果,而 RBFND 抗干扰能力较差,会产生一些误报.

下面研究 RNNND, BPND 和 RBFND 检测微弱信号的能力.在 Lorenz 时间序列中加上 6 个不同幅值奇异信号,把奇异信号作为原信号,Lorenz 时间序列作为背景噪声,实验结果如图 6 所示.从图中看到 RBFND 可以把全部的奇异点信号很容易地检测出来;BPND 效果次之;RNNND 只能有效检测出两个较大的奇异点.这三种检测器对 Lorenz 系统的检




图5 检测信噪比为 -2.7 dB Lorenz 数据的奇异点 (a) 输入时间序列, (b) RNNND 输出时间序列, (c) BPND 输出时间序列, (d) RBFND 输出时间序列

测结果见表 1. 表 1 中抗干扰能力是把 Lorenz 作为源信号, 把 Lorenz 系统加上白噪声信号作为含噪声信号所得的结果; 检测微弱信号能力是把奇异点作为源信号, 把奇异点和 Lorenz 系统的叠加信号作为含噪声的信号; 检测时间是指同一台机器上完成 2000 个数据的实时检测所用的时间, 所有测试都是在双核、1.86 GHz 主频的 CPU, 1 G 的内存的计算机上完成. 从表 1 中可以看到对于 Lorenz 系统三种检测器都有较好的检测性能, 其中 RBFND 检测微弱信号能力最强, RNNND 运算速度最快, 比 RBFND 快两个数量级、比 BPND 快 3 个数量级, 且抗干扰能力较强.

表 1 RNNND, BPND 和 RBFND 检测 Lorenz 系统性能

	抗干扰能力/dB	检测微弱信号能力/dB	检测所用时间/s
RNNND	-2.7	-35.2	0.92
BPND	1.6	-55.9	8600
RBFND	7.7	-137	114

3.2. 输油管道压力数据仿真

上面已经仿真研究了 RNNND 以及 BPND, BPND 对于 Lorenz 模型产生的时间序列的奇异点在各种情况下的检测能力, 但是实际时间序列往往比

模型产生的理论时间序列有更为严重的干扰, 所以有必要研究 3 种检测器检测实测时间序列奇异点的效果.

在以前的研究中^[21]已经证明输油管道压力时间序列 (oil pipeline press time series, OPPTS) 是混沌时间序列. 其中, 输油管道的混沌参数为嵌入维为 5, 嵌入延迟为 4. 本文利用 OPPTS 来检验 RNNND, BPND 和 RBFND 在实际应用中的性能. 图 7(a) 采集自我国某成品油长输管道, 是含有典型故障的压力数据集. 图 7(b) — (d) 分别是 RNNND, BPND 和 RBFND 的检测结果, 可以看出对于较为明显的故障可以给出理想的效果, 3 种检测器都可以给出较为理想的效果.

4. 结 论

RNNND 和 BPND, RBFND 整体性能如表 2 所示. RNNND 对于 Lorenz 时间序列和 OPPTS 都具有较好的检测效果, 而且该算法实时性非常好, 但是在对 Lorenz 微弱信号检测上表现稍差; RBFND 对于理想混沌时间序列具有最好的检测能力和较快的检测速度, 特别是对于混沌系统中的微弱信号检测具有极强的能力, 可以检测混沌系统中 -137 dB




图6 混沌背景下检测微弱信号的能力 (a)原始时间序列,(b)RNNND输出时间序列,(c)BPND输出时间序列,(d)RBFND输出时间序列




图7 RNNND, BPND 和 RBFND 对 OPPTS 故障的诊断结果 (a)输油管道压力时间序列,(b)RNNND输出时间序列,(c)BPND输出时间序列,(d)RBFND输出时间序列

的微弱信号,但是该算法在抗干扰能力上表现较差;BPND 无论对 Lorenz 时间序列还是对 OPPTS 都具有较好的检测效果,但是其检测速度非常慢,在要求实时运算的场合不适合应用. 在 Lorenz 系统的仿真中,BP 网络完成 2000 个数据的诊断所用时间为 8600 s,在 OPPTS 中,BP 网络完成 1000 个数据的

诊断所用时间为 120 s,这说明 BPND 的运算速度严重依赖于数据的混乱程度,混乱程度越大完成诊断时间越长,而 RBFND 和 RNNND 对于数据混乱程度的依赖度较低,所以 RBFND 和 RNNND 稳定性更强.

表 2 不同仿真数据类型的神经网络奇异点检测器性能对比

	BPND		RBFND		RNNND	
	Lorenz	OPPTS	Lorenz	OPPTS	Lorenz	OPPTS
常规故障检测	好	好	好	好	一般	好
检测弱信号能力	一般	较好	很好	较好	差	较好
检测速度	慢	较快	较快	较快	快	快
抗干扰能力	一般	一般	较差	较差	好	好

通过对结果的分析,关于这三种诊断器的应用可以作如下的归纳:

1) 如果检测带干扰的实测数据中的奇异点,并且要求实时性高的场合,应该优先选择 RNNND 作为核心算法. 该算法对于计算资源的消耗最小,而且通过仿真研究发现对于实测数据三种奇异点检测器的检测性能相近,但是 RNNND 最快.

2) 如果在离线仿真或者理论研究,而且数据量

不大的情况下,优先选择 RBFND,因为 RBFND 对于模型混沌时间序列中的奇异信号具有最好的检测能力,而且对于混沌背景下的微弱故障信号检测也具有极强的检测能力.

3) BP 网络是一种被广泛研究的神经网络,BPND 的检测性能无论对于 Lorenz 时间序列还是实测时间序列都具有折中的检测性能,适应性较广泛,但是运算速度慢.

- [1] Hoskin P W O 2000 *Geochim. Cosmochim. Acta* **64** 1905
- [2] Haykin S, Puthusserypaday S 1997 *Chaos* **7** 777
- [3] Zhang H G, Ma D Z, Wang Z S, Feng J 2010 *Acta Phys. Sin.* **59** 147 (in Chinese) [张化光、马大中、王占山、冯 健 2010 物理学报 **59** 147]
- [4] Wang X Y, Meng J 2009 *Acta Phys. Sin.* **58** 3780 (in Chinese) [王兴元、孟 娟 2009 物理学报 **58** 3780]
- [5] Yang D S, Zhang H G, Zhao Y, Song C H, Wang Y C 2010 *Acta Phys. Sin.* **59** 1562 (in Chinese) [杨东升、张化光、赵 琰、宋崇辉、王迎春 2010 物理学报 **59** 1562]
- [6] Wang X Y, Zhao Q 2008 *Acta Phys. Sin.* **57** 2812 (in Chinese) [王兴元、赵 群 2008 物理学报 **57** 2812]
- [7] Zhang H G, Ma T D, Fu J, Tong S C 2009 *Chin. Phys. B* **18** 3742
- [8] Wang Z S, Zhang H G, Wang Z L 2006 *Acta Phys. Sin.* **55** 2687 (in Chinese) [王占山、张化光、王智良 2006 物理学报 **55** 2687]
- [9] Han M, Shi Z W, Guo W 2007 *Acta Phys. Sin.* **56** 43 (in Chinese) [韩 敏、史志伟、郭 伟 2007 物理学报 **56** 43]
- [10] Zhang Y, Guan W 2009 *Acta Phys. Sin.* **58** 756 (in Chinese) [张 勇、关 伟 2009 物理学报 **58** 756]

- [11] Ma Q L, Peng H, Qin J W, Zheng Q L, Zhong T W 2008 *Chin. Phys. B* **17** 536
- [12] Han M, Xi J, Xu S, Yin F 2004 *IEEE Trans. Sign. Process.* **52** 3409
- [13] Zhang J F, Hu S S 2007 *Acta Phys. Sin.* **56** 713 (in Chinese) [张军峰、胡寿松 2007 物理学报 **56** 713]
- [14] Varadan V, Leung H, Bossé E 2006 *IEEE Trans. Instrum. Measur.* **55** 327
- [15] Karunasinghe D S K, Liong S Y 2006 *J. Hydrol.* **323** 92
- [16] Oliveira K A D, Vannucci A, Silva E C D 2000 *Physica A* **284** 393
- [17] Gautam A K, Chelani A B, Jain V K, Devotta S 2008 *Atmosphere Environm.* **42** 4409
- [18] Leung H, Dubash N, Xie N 2002 *IEEE Trans. Aerospace and Electron. Syst.* **38** 98
- [19] Xing H Y, Xu W 2007 *Acta Phys. Sin.* **56** 3771 (in Chinese) [行鸿彦、徐 伟 2007 物理学报 **56** 3771]
- [20] Hosoya T, Baccus S A, Meister M 2005 *Nature* **436** 71
- [21] Liu J H, Zhang H G, Feng J 2008 *Acta Phys. Sin.* **57** 6868 (in Chinese) [刘金海、张化光、冯 健 2008 物理学报 **57** 6868]

Real-time novelty detector of chaotic time series based on retina neural network*

Liu Jin-Hai^{1)2)†} Zhang Hua-Guang¹⁾ Feng Jian¹⁾

1) (Key Laboratory of Integrated Automation of Process Industry of Ministry of Education, Northeastern University, Shenyang 110004, China)

2) (School of Information Science and Engineering, Northeastern University, Shenyang 110004, China)

(Received 12 October 2009; revised manuscript received 23 October 2009)

Abstract

A kind of novelty detection method based on retina neural network is proposed, which could find the novelty in chaotic time series. To demonstrate the capability of the novelty detection method, we designed three novelty detectors, namely the neural network novelty detector (RNNND), back-propagation (BP) novelty detector (BPND) and radial base function (RBF) novelty detector (RBFND), which are based on retina neural network, BP neural network and RBF neural network, respectively. Using Lorenz time series and oil pipeline pressure time series, we tested the performance of the three novelty detectors, including performances of anti-jamming, micro-novelty detection and the computing speed. The results show that the three novelty detectors have good precision and fast computing speed. Finally, the merits and shortcomings of the proposed novelty detection method are analyzed based on retina neural network, BP and RBF neural network, and their applicabilities are given.

Keywords: chaotic time series, real-time, novelty detection, retina neural network

PACC: 0545

* Project supported by the National Natural Science Foundation of China (Grant Nos. 60774048, 60774093, 60728307), the National High Technology Research and Development Program of China (Grant No. 2009AA04Z127), the Cheung Kong Scholars Program of China, the Specialized Research Fund for the Doctoral Program of Higher Education of China (Grant No. 20070145015), the National Basic Research Program of China (Grant No. 2009CB320601), and the Program for New Century Excellent Talents in University of Ministry of Education of China (Grant No. NCET-08-0101).

† E-mail: jh_lau@126.com