

# 基于多反馈环结构提高硬件储备池记忆能力

李 磊, 方 捻, 王陆唐, 黄肇明

(上海大学通信与信息工程学院, 特种光纤与光接入网重点实验室, 上海 200072)

**摘 要:** 针对单反馈环硬件储备池记忆能力不足的问题, 提出一种基于多反馈环结构提高储备池记忆能力的方法. 通过增加反馈环将更早输入信号产生的响应重新注入回储备池, 使更早期的输入信号也影响储备池的内部动态, 从而增强储备池的记忆能力. 仿真研究了单个和多个反馈环结构的储备池的记忆能力及其在需要更长记忆能力的 NARMA30 任务中的预测性能. 结果表明, 把反馈环增加到 10 个, 虚节点数为 50 时储备池的记忆能力由单反馈环的 18.2 提高到 40.2. 仅用两个反馈环, 虚节点数为 1000 时 NARMA30 预测的归一化均方根误差可从单反馈环的 0.27 降到 0.09. 说明通过合理设置多个反馈环的参数, 可以设计出任务需要的特定记忆能力, 部分解决了储备池的适应性问题.

**关键词:** 递归神经网络; 硬件储备池; 多反馈环; 记忆能力; 30 阶非线性自回归移动平均 (NARMA30)

**中图分类号:** TP183, N93, TN29 **文献标识码:** A **文章编号:** 0372-2112 (2018)02-0298-06

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2018.02.006

## Improving Memory Capacity of Hardware Reservoir Computing by Multiple Feedback Loops

LI Lei, FANG Nian, WANG Lu-tang, HUANG Zhao-ming

(Key Laboratory of Specialty Fiber Optics and Optical Access Networks, School of Communication and Information Engineering, Shanghai University, Shanghai, 200072, China)

**Abstract:** In order to improve the memory capacity of hardware reservoir computing (HRC) based on a single feedback loop, a HRC scheme based on multiple feedback loops is proposed. Adding extra loops can feedback the responses stimulated by past input signals into the reservoir to increase the HRC memory capacity. Investigations on the performances of HRCs based on a single and multiple feedback loops were carried out by numerical simulation for the memory capacity and a NARMA30 task which needs a long memory capacity. Results show that the HRC memory capacity is increased to 40.2 at ten loops from 18.2 at a single loop when the node number is 50. For the NARMA30 task, the Normalized Root Mean Square Error is decreased to 0.09 at two loops from 0.27 at a single loop when the node number is 1000. Therefore, specific memory capacity needed by a task can be designed through setting the parameters of feedback loops, partially solving the adaptive problem of reservoir computing.

**Key words:** recurrent neural network; hardware reservoir computing (HRC); multiple feedback loops; memory capacity; 30th-order nonlinear auto regressive moving average (NARMA30)

### 1 引言

递归神经网络是一种适合处理时序信号的机器学习模型. 传统的递归神经网络训练算法计算量大、收敛慢. 为了简化递归神经网络训练过程, Jaeger<sup>[1]</sup> 在 2001 年提出了回声状态网络 (Echo State Networks, ESNs), Mass 等<sup>[2]</sup> 在 2002 年提出了液体状态机 (Liquid State Machines, LSMs). Verstraeten 等<sup>[3]</sup> 证明了 ESNs 和 LSMs

本质上一致, 并概括为储备池计算. 储备池计算的核心思想是用一个储备池代替经典神经网络的中间层, 输入连接权和内部连接权随机生成且保持不变, 只需对输出连接权进行训练. 储备池计算的软件实现<sup>[4-14]</sup> 在混沌时间序列预测和非线性信道均衡等基准任务上呈现出很好性能. 但储备池计算需要成百上千个节点, 硬件实现极为困难. Rodan 等<sup>[15]</sup> 研究了储备池计算实现的最简结构. 2011 年, Appeltant 等<sup>[16]</sup> 基于非线性延时反

收稿日期: 2017-01-16; 修回日期: 2017-07-03; 责任编辑: 马兰英

基金项目: 国家自然科学基金 (No. 61108004); 上海市浦江人才计划 (No. 14PJD017); 上海市特种光纤与光接入网重点实验室开放课题 (No. SKLSFO2015-02)

馈系统丰富的动态响应,用一个非线性节点和一个反馈环构成了 Mackey-Glass 混沌电路储备池,首次将储备池计算用硬件实现. 2012 年, Paquot 等<sup>[17]</sup> 和 Larger 等<sup>[18]</sup> 用不同器件分别实现了光电储备池. 随后,相继出现多种全光储备池硬件实现方案<sup>[19-27]</sup>.

混沌电路储备池、光电储备池和全光储备池均采用单一反馈环的结构,统称为硬件储备池. 它们在波形识别、非线性信道均衡、10 阶非线性自回归移动平均 (Nonlinear Auto Regressive Moving Average, NARMA) 时间序列预测等任务中表现出良好的性能,但这些任务需要的记忆能力十分有限. 在需要更长记忆能力的任务中,如 NARMA30 时间序列预测,其预测性能会因记忆能力不足而显著下降. 为了提高硬件储备池的记忆能力,我们提出了基于多反馈环结构的硬件储备池改进方案,并对该方案在记忆能力和 NARMA30 任务中的性能进行了仿真测试. 结果表明,多反馈环硬件储备池的记忆能力和其在 NARMA30 任务中的预测性能均得到显著提高. 更有意义的是,通过设计多反馈环参数,可以设计出任务需要的特定记忆能力,部分解决了储备池的适应性问题<sup>[28]</sup>. 我们注意到,Ortin 等<sup>[29]</sup> 曾报道了多反馈环思想,但对所提出的方法和初步研究结果的描述不够清晰,后续也未见有更深入研究的报道.

## 2 储备池计算的原理

### 2.1 传统储备池计算

传统储备池计算由三层构成:输入层、储备池和输出层,如图 1 所示<sup>[16]</sup>. 储备池系统节点状态更新方程和输出方程为:




图1 传统储备池计算示意图

$$\mathbf{x}(n) = f(\mathbf{W}\mathbf{x}(n-1) + \mathbf{W}_{in}\mathbf{u}(n)) \quad (1)$$

$$\mathbf{y}(n) = f_{out}(\mathbf{W}_{out}\mathbf{x}(n))$$

其中,  $\mathbf{x}(n)$  为第  $n$  个时刻的节点状态,  $\mathbf{u}(n)$  为输入信号,  $\mathbf{y}(n)$  为输出信号.  $\mathbf{W}$ 、 $\mathbf{W}_{in}$ 、 $\mathbf{W}_{out}$  分别为内部连接权、输入连接权和输出连接权矩阵,  $f$  为节点激活函数, 一般为双曲正弦函数,  $f_{out}$  为输出函数, 一般为恒等函数<sup>[28]</sup>.

储备池计算的训练过程分为采样和权值计算两个阶段. 采样阶段中, 将训练输入信号注入到储备池, 然后将储备池内部节点状态收集到节点状态矩阵  $\mathbf{B}$  中, 而训练输出信号收集到矩阵  $\mathbf{T}_{out}$  中. 权值计算阶段中, 输出连接权根据节点状态矩阵  $\mathbf{B}$  和训练输出信号矩阵

$\mathbf{T}_{out}$  求得:

$$(\mathbf{W}_{out})^T = \mathbf{B}^{-1}\mathbf{T}_{out} \quad (2)$$

测试过程中, 将测试输入信号注入到储备池, 同样将储备池内部节点状态收集到节点状态矩阵  $\mathbf{B}$  中, 然后根据节点状态矩阵  $\mathbf{B}$  和训练得到的输出连接权矩阵  $\mathbf{W}_{out}$  求出测试输出信号  $\mathbf{P}$ :

$$\mathbf{P} = \mathbf{B}\mathbf{W}_{out} \quad (3)$$

根据预测输出信号和目标输出信号求得归一化均方根误差 (Normalized Root Mean Square Error, NRMSE), 用来评估储备池系统的预测性能<sup>[30]</sup>. NRMSE 定义如下:

$$NRMSE = \sqrt{\frac{\langle (\mathbf{y}_p(n) - \mathbf{y}_i(n))^2 \rangle}{\langle (\mathbf{y}_i(n) - \langle \mathbf{y}_i(n) \rangle)^2 \rangle}} \quad (4)$$

其中,  $\mathbf{y}_p(n)$  为预测输出信号,  $\mathbf{y}_i(n)$  为目标输出信号,  $\langle \rangle$  表示计算平均值.

### 2.2 单反馈环硬件储备池

储备池计算硬件实现的基本思想是用一个非线性节点 NL 和一个反馈环构成储备池, 如图 2 所示<sup>[16]</sup>, 并利用时分复用思想在反馈环中设置虚节点. 硬件储备池系统的训练过程需要三个阶段: 预处理、收集虚节点状态和后处理. 在预处理阶段, 原始信号经过一个采样保持过程, 变成分段离散信号, 然后与一个 mask 信号相乘, 构成最终输入信号. mask 信号是为了打破系统对称性, 使储备池呈现更丰富动态. 在收集虚节点状态阶段, 最终输入信号注入到储备池, 激发丰富的储备池动态, 然后将虚节点状态收集起来. 在后处理阶段, 根据收集到的虚节点状态和目标输出信号确定输出连接权.




图2 储备池计算硬件实现示意图

设 Mask 信号周期为  $\tau$ , 光沿反馈环传播一周需要的时间为环的周期, 记作  $\tau'$ . 若  $\tau' = (1 + \frac{1}{N})\tau$ , 其中  $N$  为虚节点数, 则单反馈环硬件储备池的节点状态更新方程为:

$$x_i(n) = \begin{cases} F_{NL}(\alpha x_{N+i-1}(n-2) + \beta m_i u(n)), & i=1 \\ F_{NL}(\alpha x_{i-1}(n-1) + \beta m_i u(n)), & 2 \leq i \leq N \end{cases} \quad (5)$$

式中,  $x_i(n)$  为第  $n$  个时刻第  $i$  个节点状态,  $F_{NL}$  为非线性节点产生的节点状态激活函数,  $u(n)$  为输入信号,  $\alpha$  为反馈增益,  $\beta$  为输入增益,  $m_i$  为第  $i$  个节点对应的 mask 值.

## 3 多反馈环硬件储备池

单反馈环硬件储备池的记忆能力是有限的. 通过

增加一个或多个不同长度的反馈环,可以把更早输入信号产生的响应也注入回储备池,增强其记忆能力.基于此思想,我们提出了多反馈环硬件储备池系统,如图3所示.反馈环的数量 $p$ 、长度 $L_i$ 和反馈增益 $\alpha_i$ 可以根据具体记忆能力需求进行设计.通过增加反馈环,可以保存过去不同时刻的输入信号在储备池中产生的响应.反馈环越长,越能保存更早时刻的输入信号在储备池中产生的响应.将这些响应以适当的强度重新注入回储备池,使更早时刻的输入信号不同程度地影响当前储备池的动态,从而提高储备池的记忆能力.




图3 多反馈环硬件储备池系统示意图

只有两个反馈环时,设短环的周期为 $\tau_1' = (1 + \frac{1}{N})\tau$ ,

长环的周期为 $\tau_2' = N_1(1 + \frac{1}{N})\tau$ , $N_1$ 表示将 $N_1$ 个时刻前输入信号产生的响应注入回储备池,则两个反馈环硬件储备池的节点状态更新方程为:

$$x_i(n) = \begin{cases} F_{NL}(\alpha_1 x_{N+i-1}(n-2) \\ \quad + \alpha_2 x_{N+i-N_1}(n-N_1-1) \\ \quad + \beta m_i u(n)), & i=1 \\ F_{NL}(\alpha_1 x_{i-1}(n-1) \\ \quad + \alpha_2 x_{N+i-N_1}(n-N_1-1) \\ \quad + \beta m_i u(n)), & 2 \leq i \leq N_1 \\ F_{NL}(\alpha_1 x_{i-1}(n-1) \\ \quad + \alpha_2 x_{i-N_1}(n-N_1) \\ \quad + \beta m_i u(n)), & N_1+1 \leq i \leq N \end{cases} \quad (6)$$

式中, $\alpha_1$ 、 $\alpha_2$ 为两个环的反馈增益,其它参数的含义与式(5)一样.

以此类推,每当在硬件储备池中增加一个反馈环,节点状态更新方程的分段函数就会多一段,从而可以增强硬件储备池的记忆能力,特别是增强硬件储备池对特定时刻的过去输入的记忆能力.因此,可以根据任务对记忆能力的具体要求去设计反馈环的数量和长度以及反馈增益,部分解决储备池计算的适应性问题.

对于前述的三种硬件储备池,尽管其实现器件不同,但它们都是基于单反馈环的结构.通过增加反馈环,都可以将更早输入信号产生的响应重新注入回储备池,使更早期的输入信号也影响储备池的内部动态,从而增强储备池的记忆能力.因此,通过增加反馈环,这三种硬件储备池的记忆能力都可以得到提高.

## 4 仿真结果

受篇幅限制,仅以光电储备池<sup>[17]</sup>为例,给出单个和多个反馈环结构的储备池的记忆能力及其在需要更长记忆能力的NARMA30任务中的预测性能的仿真结果.

### 4.1 记忆能力

记忆能力定义<sup>[19]</sup>如下:输入信号 $u(n)$ 为独立同分布的随机变量,任务为重构 $k$ 时间步前的输入信号,即: $y_k(n) = u(n-k)$ ,记忆能力为 $M[y_k] = 1 - NRMSE[y_k]$ .如果储备池对过去某个时间点的输入信号具有完美记忆,则对应的记忆能力为1.以时间步为横坐标,记忆能力为纵坐标,可以画出储备池的记忆能力曲线.记忆能力曲线反映了储备池的记忆能力随时间的变化趋势.考虑 $k$ 的取值范围为从1到无穷大,储备池总的记忆能力定义为:

$M = \sum_{k=1}^{\infty} M[y_k]$ ,实际中 $k$ 一般取到记忆能力不再明显变化为止.

系统参数设置如下:虚节点数为50,输入增益为0.5,反馈增益为0.43,偏置为0.取输入信号 $u(n)$ 为 $[-1, 1]$ 间均匀分布的随机数,对单反馈环光电储备池进行记忆能力测试.在10个随机产生的数据集上测试的结果如图4(a)所示,曲线由10次测试的平均值构成,误差条表示误差范围.从图4(a)可以看出,储备池可以很好地记忆17个时间步前的输入,然后记忆能力快速衰减,直到完全不能记忆更早时刻的输入.储备池总的记忆能力的平均值为18.2.同样在50个虚节点条件下,对多反馈环光电储备池进行记忆能力测试.以10个反馈环为例,其周期 $\tau_j'$ 与mask信号周期 $\tau$ 的关系为 $\tau_j' = j(1 + \frac{1}{N})\tau$ ,其中 $j=1, 2, \dots, 10$ ,每个环的反馈增益均为0.043.同样在10个随机产生的数据集上进行测试,结果如图4(b)所示.可以看出,10个反馈环的光电储备池的记忆能力曲线是缓慢下降的,总的记忆能力的平均值为40.2.相比单反馈环光电储备池,10个反馈环的光电储备池的记忆能力得到显著提高.

### 4.2 NARMA30 任务

NARMA30任务中,数据生成方程<sup>[30]</sup>为:

$$y_{n+1} = 0.2y_n + 0.04y_n \left[ \sum_{i=0}^{29} y_{n-i} \right] + 1.5u_n u_{n-29} + 0.001 \quad (7)$$

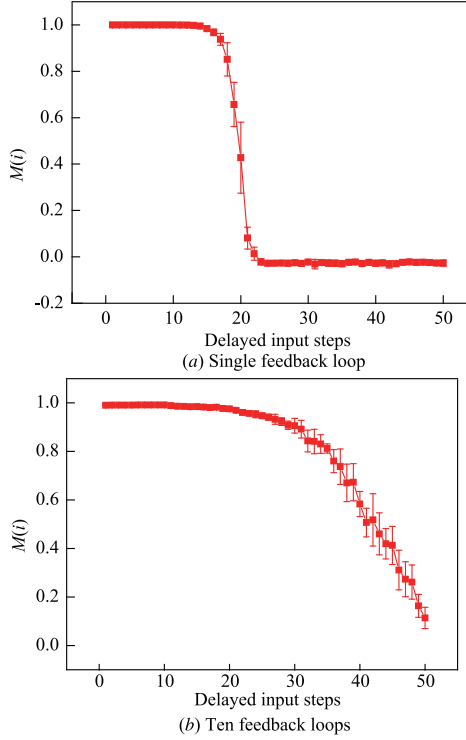


图4 不同反馈环数的光电储备池的记忆能力曲线

式中,  $u_n$  为输入数据,  $y_n$  为输出数据. 从式(7)可以看出, 第  $n+1$  个时间点的输出不仅和第  $n$  个时间点的输入有关, 还和第  $n-29$  个时间点的输入有关; 当然还和第  $n$  个时间点的输出以及前 29 个时间点的输出有关, 但并不占输出的主要部分, 对输出起主要作用的是  $1.5u_n u_{n-29}$  项. 这就要求储备池既要记住上一时间点的输入, 又要记住第  $n-29$  个时间点的输入.

针对 NARMA30 任务这一特点, 设计了两个多反馈环方案. 方案 1 是 4.1 节的 10 个反馈环的光电储备池, 作为较多反馈环的设计实例. 方案 2 是两个反馈环的光电储备池, 即最简单的多反馈环形式. 短环的周期为  $\tau_1' = (1 + \frac{1}{N})\tau$ , 长环的周期为  $\tau_2' = 9(1 + \frac{1}{N})\tau$ , 两个环的反馈增益均为 0.215. 两个反馈环的光电储备池的节点状态更新方程为:

$$x_i(n) = \begin{cases} \sin(\alpha_1 x_{N+i-1}(n-2) \\ + \alpha_2 x_{N+i-9}(n-10) \\ + \beta m_i u(n)), & i=1 \\ \sin(\alpha_1 x_{i-1}(n-1) \\ + \alpha_2 x_{N+i-9}(n-10) \\ + \beta m_i u(n)), & 2 \leq i \leq 9 \\ \sin(\alpha_1 x_{i-1}(n-1) \\ + \alpha_2 x_{i-9}(n-9) \\ + \beta m_i u(n)), & 10 \leq i \leq N \end{cases} \quad (8)$$

除了特别说明的参数设置, 两种方案的其它参数设置均和 4.1 节中相同. 仿真结果如表 1 所示, 可以看出, 相对于单反馈环光电储备池, 方案 1 在 NARMA30 任务中的预测性能并未得到明显改善. 而方案 2 在 NARMA30 任务中的预测性能则得到了显著提升. 特别是虚节点数为 1000 时, 两个反馈环的储备池的预测 NRMSE 下降到了 0.09, 预测输出与目标输出几乎完全一致了, 如图 5(a) 所示; 而单反馈环储备池的预测 NRMSE 为 0.27, 其预测输出和目标输出相差较大, 如图 5(b) 所示.

表 1 三种不同反馈环数的光电储备池在 NARMA30 预测任务中的 NRMSEs

Node number	Single feedback loop	Ten feedback loops	Two feedback loops
50	0.85	0.82	0.4
100	0.72	0.70	0.25
500	0.42	0.40	0.15
1000	0.27	0.25	0.09

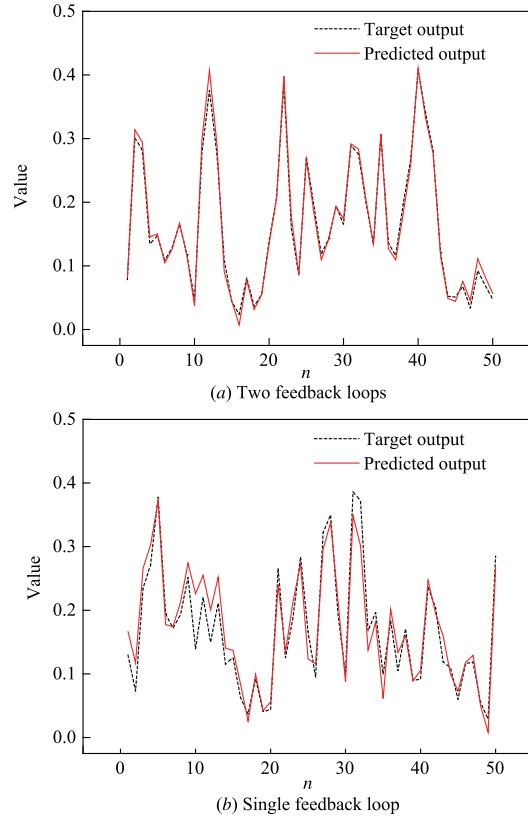


图5 不同反馈环数的光电储备池在 NARMA30 任务中的预测输出与目标输出

为了究其原因, 对方案 2 的光电储备池进行了记忆能力测试, 得到的记忆能力曲线如图 6 所示. 可以看出, 记忆能力曲线存在周期性下陷点, 记忆能力先下降后上升, 但储备池对  $u_n$  和  $u_{n-29}$  的记忆能力均很强. 而对这两个输入点的记忆正是 NARMA30 任务需要的, 因而方

案 2 在 NARMA30 任务中能够取得更好的预测性能. 图 6 的记忆能力曲线带来的更重要的启示是: 硬件储备池的记忆能力曲线并不是只能单调下降, 它可以先降再升, 即硬件储备池的记忆能力曲线可以被设计. 因此, 可以根据具体任务对记忆能力的要求不同, 对储备池的记忆能力曲线进行针对性设计, 部分解决储备池计算的适应性问题.

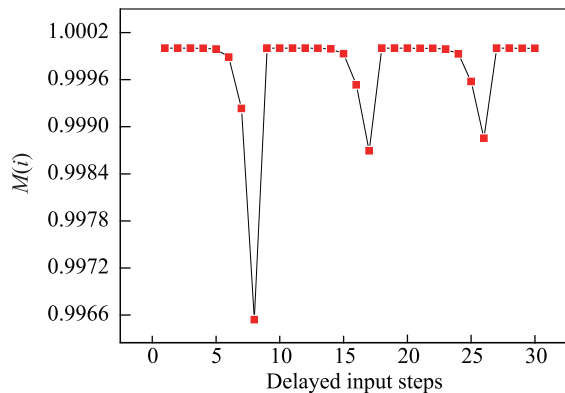


图6 两个反馈环光电储备池的记忆能力曲线

两种方案的预测结果说明, 反馈环并不是越多越好, 即不是记住越多过去的输入, 越能更好地处理任务, 有些不需要的记忆反而降低了储备池的性能. 所以, 10 个反馈环条件下的预测精度均低于两个反馈环条件下的预测精度. 因为两个反馈环的记忆能力是与 NARMA30 任务的记忆能力需求相匹配的. 因此, 要从具体任务对记忆能力的需求与结构简单两方面综合考虑, 在满足任务记忆能力需求的前提下, 选择尽可能少的反馈环数.

## 5 结论

针对单反馈环硬件储备池记忆能力不足的问题, 提出了基于多反馈环结构提高硬件储备池记忆能力的方法. 该方法具有以下优点: 仅从储备池记忆能力来说, 多反馈环硬件储备池的记忆能力得到了明显提高. 基于多反馈环结构, 可以根据任务对记忆能力的需求设计储备池的记忆能力曲线, 提高储备池对该任务的处理能力, 从记忆能力角度, 部分解决储备池计算的适应性问题.

然而, 增加反馈环一定程度上增加了储备池的结构复杂度, 同时需要更多光纤. 但光纤作为一种价格便宜的器件远比通过增加半导体光放大器等器件来改进储备池更实惠. 对于难以评估记忆能力需求的任务, 多反馈环储备池的设计将遇到困难. 但从另一个角度看, 可以通过尝试不同个数和长度的反馈环对任务进行测试, 从而探测到任务的记忆能力需求.

## 参考文献

- [1] Jaeger H. The “Echo State” approach to analyzing and training recurrent neural network [R]. Bremen: GMD-German National Research Institute for Computer Science, 2001. GMD Report 148.
- [2] Maass W, Natschlagler T. Real-time computing without stable states: A new framework for neural computation based on perturbations [J]. *Neural Computation*, 2002, 14(11): 2531–2560.
- [3] Verstraeten D, et al. An experimental unification of reservoir computing methods [J]. *Neural Networks*, 2007, 20(3): 391–403.
- [4] Jaeger H, Haas, H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication [J]. *Science*, 2004, 304(5667): 78–80.
- [5] Jaeger H, et al. Optimization and applications of echo state networks with leaky-integrator neurons [J]. *Neural Networks*, 2007, 20(3): 335–352.
- [6] Ozturk, et al. Analysis and design of echo state networks [J]. *Neural Computation*, 2007, 19(1): 111–138.
- [7] Li D C, et al. Chaotic time series prediction based on a novel robust echo state network [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, 23(5): 787–799.
- [8] 彭宇, 等. 模糊回声状态网络 [J]. *电子学报*, 2011, 39(7): 1538–1544.  
Peng Y, et al. Fuzzy echo state networks [J]. *Acta Electronica Sinica*, 2011, 39(7): 1538–1544. (in Chinese)
- [9] Shi Z W, Han, M. Support vector echo-state machine for chaotic time-series prediction [J]. *IEEE Transactions on Neural Networks*, 2007, 18(2): 359–372.
- [10] 韩敏, 等. 储备池状态空间重构与混沌时间序列预测 [J]. *物理学报*, 2007, 56(1): 43–50.  
Han M, et al. Reservoir neural state reconstruction and chaotic time series prediction [J]. *Acta Physica Sinica*, 2007, 56(1): 43–50. (in Chinese)
- [11] Zhao Q C, et al. Performance optimization of the echo state network for time series prediction and spoken digit recognition [A]. 11th International Conference on Natural Computation [C]. Zhangjiajie: 2015. 502–506.
- [12] Bozhkov L, et al. Reservoir computing for emotion valence discrimination from EEG signals [J]. *Neurocomputing*, 2017, 231(SI): 28–40.
- [13] Malik Z K, et al. Multilayered echo state machine: A novel architecture and algorithm [J]. *IEEE Transaction on Cybernetics*, 2017, 47(4): 946–959.
- [14] Zhong S S, et al. Genetic algorithm optimized double-reservoir echo state network for multi-regime time series pre-

- diction[J]. *Neurocomputing*, 2017, 238: 191 – 204.
- [15] Rodan A, Tino, P. Minimum complexity echo state network[J]. *IEEE Transaction on Neural Networks*, 2011, 22 (1): 131 – 144.
- [16] Appeltant L, et al. Information processing using a single dynamical node as complex system[J]. *Nature Communications*, 2011, 2: 468.
- [17] Paquot Y, et al. Optoelectronic reservoir computing[J]. *Scientific Reports*, 2012, 2: 287.
- [18] Larger L, et al. Photonic information processing beyond Turing: an optoelectronic implementation of reservoir computing [J]. *Optics Express*, 2012, 20 (3): 3241 – 3249.
- [19] Duport F, et al. All-optical reservoir computing[J]. *Optics Express*, 2012, 20(20): 22783 – 22795.
- [20] Ortín S, et al. Photonic single nonlinear-delay dynamical node for information processing[A]. *Conference on Semiconductor Lasers and Laser Dynamics V*[C]. Brussels: 2012. 843214.
- [21] Hicke K, et al. Information processing using transient dynamics of semiconductor lasers subject to delayed feedback [J]. *IEEE J Sel Top Quantum Electron*, 2013, 19, 1501610.
- [22] Qin J, et al. Optical packet header identification utilizing an all-optical feedback chaotic reservoir computing [J]. *Modern Physics Letters B*, 2016, 1650199.
- [23] Nakayama J, et al. Laser dynamical reservoir computing with consistency: an approach of a chaos mask signal[J]. *Optics Express*, 2016, 24(8): 8679 – 8692.
- [24] Zhang H, et al. Integrated photonic reservoir computing based on hierarchical time-multiplexing structure[J]. *Optics Express*, 2014, 22(25): 31356 – 31370.
- [25] Dejonckheere A, et al. All-optical reservoir computer based on saturation of absorption [J], *Optics Express*, 2014, 22(9): 10868 – 10881.
- [26] Salehi M R, Dehyadegari L. Nanophotonic reservoir computing for noisy speech recognition[J]. *Opt Quant Electron*, 2016, 48: 281.
- [27] Duport F, et al. Fully analogue photonic reservoir computer[J]. *Scientific Reports*, 2016, 6: 22381.
- [28] 彭宇, 等. 储备池计算概述 [J]. *电子学报*, 2011, 39 (10): 2387 – 2396.  
Peng Y, et al. Survey on reservoir computing [J]. *Acta Electronica Sinica*, 2011, 39 (10): 2387 – 2396. (in Chinese)
- [29] Ortin S, et al. Information processing using an electro-optic oscillator subject to multiple delay lines [A]. *Munich* [C]. Germany: IEEE, 2013.
- [30] Schrauwen B, et al. Improving reservoirs using intrinsic plasticity[J]. *Neurocomputing*, 2008, 71: 1158 – 1171.

#### 作者简介



李 磊 男, 1989 年 5 月出生, 山西晋城人, 硕士研究生, 2011 年毕业于山西大学物理电子工程学院. 主要从事储备池计算软件算法和硬件实现方案方面的研究.

E-mail: 13546720226@163.com



方 捻(通信作者) 女, 1972 年 1 月出生, 河南西华人, 上海市浦江学者, 博士, 教授, 博士生导师. 主要从事光通信、光传感以及非线性动力学系统及其应用方面的研究.

E-mail: nfang@shu.edu.cn