

学术前沿专栏:可激发介质网络动力学

基于储备池计算下的螺旋波波头轨迹预测

崔晓华¹,陈叶羽格¹,郑才溢²

(1.北京师范大学 系统科学学院,北京 100080;2.北京师范大学(珠海)文理学院,广东 珠海 519087)

摘要:螺旋波是自组织结构的一种特殊斑图,其形成和维持不需要外部干预,在生物学、化学和物理学的系统中都可以观测到.波头是螺旋波斑图的相奇点,控制住波头就能控制螺旋波.因此,如何通过少量的螺旋波时空状态数据去预测波头轨迹演化行为,是反应扩散系统研究中的一个重要问题.构建了一个混合储备池预测模型,将FitzHugh-Nagumo系统中单波头模式的时序数据和相应波头位置作为训练集;将上述数据输入,对混合储备池模型进行训练;然后利用训练好的混合模型,对螺旋波系统后续波头的演化轨迹进行预测.结果表明该混合模型可以实现螺旋波波头轨迹的长期精确预测,为反应扩散系统相奇点的预测提供了新的研究视角与方法.

关键词:储备池计算;螺旋波波头;轨迹预测

中图分类号:O415;N93;TP181

文献标志码:A

文章编号:1000-2367(2025)06-0008-06

螺旋波(spiral waves)是一种在空间反应扩散系统中广泛观察到的动态波模式,其特征以波以螺旋形态传播^[1].这种现象在化学、物理和生物等多个领域的复杂系统中均有体现,反映了系统内非线性相互作用的复杂性^[2].这些相互作用导致波前以非匀速传播,而波后的恢复动力学又决定了波前的形状和传播方向^[3].螺旋波的波源(即波头)是一个动态不稳定区域.在此区域,介质的激发状态不断循环,从而驱动螺旋波波头的持续移动^[4].大量研究发现,无论是心房颤动还是心室颤动,均伴随螺旋波现象,且螺旋波的破碎是心脏颤动发生的主要诱因之一^[5].螺旋波波头轨迹的预测,在心脏颤动的早期发现方面显得尤为关键.

心脏组织模型和实验研究^[6-7]发现螺旋波波头轨迹可以遵循不同类型的路径:从正圆形到弯曲的线性轨迹,以及一系列蜿蜒的、环状的曲线.这些轨迹会自行转向,被称为曲折轨迹.螺旋波波头的移动不仅取决于波长和可激发间隙^[8],还取决于临界曲率半径^[9-10],即上升率和激发阈值所决定的组织扩散和兴奋性.根据不同的参数设置,FENTON等^[11]给出了使用动力学模型获得的多组螺旋波波头轨迹,其中存在与发生在带有约1~2 cm长病灶的正常心脏组织中的螺旋波类似的轨迹^[12-13].然而,预测螺旋波的旋转周期和波头轨迹是困难的.目前只有在弱激发极限情况下,关于螺旋波运动的理论分析^[14]发展较为成熟.

储备池计算(reservoir computing)作为一种简化的循环神经网络模型,因其模型简洁高效,训练参数少,同时非线性动态系统的特征学习中具有极高的适用性得到了广泛的研究^[15-17].例如,有研究通过时滞自治布尔节点的储备池计算深入探讨了计算性能对系统参数的依赖性^[18]、利用经典储备池寻找系统的临界

收稿日期:2024-11-15;**修回日期:**2025-01-09.

基金项目:国家自然科学基金(11775020).

作者简介:崔晓华(1982-),女,山东招远人,北京师范大学副教授,博士,博士生导师,研究方向为非线性动力学,基于数据的建模分析,E-mail: xhcui@bnu.edu.cn.

通信作者:陈叶羽格,女,博士,研究方向为非线性动力学,机器学习在动力系统中的应用,E-mail: 202031250005@mail.bnu.edu.cn.

引用本文:崔晓华,陈叶羽格,郑才溢.基于储备池计算下的螺旋波波头轨迹预测[J].河南师范大学学报(自然科学版),2025,53(6):8-13.(Cui Xiaohua, Chen Yeyuge, Zheng Caiyi. Prediction of spiral wave tip trajectories under reservoir computing[J]. Journal of Henan Normal University(Natural Science Edition), 2025, 53(6): 8-13. DOI: 10.16366/j.cnki.1000-2367.2024.11.15.0004.)

跃迁^[19]、相位相干性^[20],以及从时间序列估计动力系统的李雅普诺夫指数^[21].在实际应用中,储备池计算已被用于一些高维系统,如地震活动的预测^[22]和大气的预测^[23]等.其中,最为突出的例子之一是储备池计算在混沌系统预测中的应用.在大规模时空混沌序列的预测中,经典的并行储备池计算已经实现了5~6个李雅普诺夫时间的时空预测^[24].

对于螺旋波系统,已有研究利用储备池计算技术实现了静态模式下螺旋波波头的精确定位.CHEN等^[25]通过对经典储备池计算模型进行改进,设计了“定位储备池”模型.该模型能够对由各种反应扩散(RD)系统生成的不同模式下的波头实现实时精准定位,涵盖了单波头、双波头、多波头及湍流模式等复杂情况.然而,在实际应用中,螺旋波波头的动态预测具有更高的应用价值.准确预测波头轨迹不仅有助于判断螺旋波的变化趋势,还能为及时的控制干预提供依据.传统上,螺旋波的动态移动主要依赖于理论模型的数值模拟来预测其演化趋势.然而,随着机器学习技术的发展,基于实际观测数据的实时预测方法逐渐成熟,提供了更加精确和可靠的预测能力.因此,构建一个合适的模型以预测螺旋波波头轨迹的演化,对于指导实际应用和深入理解螺旋波动力学机制具有重要意义.

本文旨在基于少量的螺旋波时空状态数据,构建“定位储备池”模型^[25]和经典时序预测储备池模型组合而成的混合模型,并使用构建的混合模型预测系统波头的长时间演化行为.具体为,1)当系统存在动态螺旋波波头时,采集其演化的时间序列数据并利用理论方法计算得到相应的波头位置数据;2)将上述时序数据输入时序预测储备池模型进行训练,以及将时序数据与波头位置数据输入“定位储备池”模型进行训练;3)输入某一时刻的螺旋波时序状态数据到已训练好的混合模型中进行波头轨迹的长时间预测.

1 混合储备池计算模型

混合储备池模型(图1)主要由2个模块构成:预测模块预测时序数据;定位模块定位波头.这2个模块均由3部分组成:一个输入/储备(I/R)层,一个储备层(R),以及一个储备/输出(R/O)层.其I/R层都负责将低维输入向量映射到高维储备网络中,其中输入权重 $\mathbf{W}_{in}$ 矩阵元均为 $[-1, 1]$ 均匀分布随机数.同样,2个模块的储备层也均由一个稀疏随机Erdos-Renyi网络构建,邻接矩阵中非零元同样为 $[-1, 1]$ 的随机数.最后,R/O层将高维储备网络转换为低维输出向量,其中的输出权重 $\mathbf{W}_{out}$ 需要在训练阶段进行计算.2个模块的区别在于:预测模块中输入的是时刻 t 的状态向量,输出的是时刻 $t + \Delta t$ 的状态向量;而定位模块中,输入的是时刻 $t + \Delta t$ 的状态向量,输出的是时刻 $t + \Delta t$ 的0-1位置向量.




图1 混合储备池模型的计算框架示意图

Fig.1 Diagram of the computational framework of the hybrid reservoir computing model

1.1 模型训练阶段

在训练阶段,2个模块并行处理:预测模块主要目的是获得系统状态变量 $\mathbf{V}_s(t)$ 到 $\mathbf{V}_s(t + \Delta t)$ 的映射,通过已知数据来训练得到 $\mathbf{W}_{1,out}$ 的值;定位模块主要目的是获得系统状态变量 $\mathbf{V}_s(t + \Delta t)$ 到位置矩阵 $\mathbf{V}_L(t + \Delta t)$ 的映射,通过已知数据来训练得到 $\mathbf{W}_{2,out}$ 的值.

具体来说,假设在 $t \in [0, T_1]$ 时刻内(T_1 为训练长度),螺旋波系统状态变量 $\mathbf{V}_s(t)$ 和波头位置矩阵 $\mathbf{V}_L(t)$ 是已知的.在预测模块中,将 $t \in [0, T_1]$ 对应的系统状态变量 $\mathbf{V}_s(t)$ 划分为输入向量与输出向量,其中前 $T \in [0, T_1 - \Delta t]$ 的状态变量作为输入向量,后 $t \in [\Delta t, T_1]$ 的状态变量作为输出向量.同时通过训练来获得空间状态变量在 t 时刻与 $t + \Delta t$ 时刻的映射关系,即计算得到输出权重 $\mathbf{W}_{1,\text{out}}$,如此便可以得到训练好的预测模块,将其保留以备后续时序预测使用.在定位模块中,将 $t \in [0, T_1]$ 对应的系统状态变量 $\mathbf{V}_s(t + \Delta t)$ 与波头位置矩阵 $\mathbf{V}_L(t + \Delta t)$ 分别作为定位模块的输入向量与输出向量.接着,使用上述向量来获得 $t + \Delta t$ 时刻空间状态变量与对应 $t + \Delta t$ 时刻位置矩阵的映射关系,即计算得到输出权重 $\mathbf{W}_{2,\text{out}}$.如此便可以得到训练好的定位模块,同样将其保留以备后续波头定位使用.在训练过程中,为了保持数据符合真实情况,预测模块与定位模块中已知数据的长度需保持一致.

将预测模块与定位模块的计算过程用公式表示可记为如下形式.预测模块的储备池网络状态

$$\mathbf{r}_1(t + \Delta t) = (1 - \alpha)\mathbf{r}_1(t) + \alpha \tanh(\mathbf{A}_1 \mathbf{r}_1(t) + \mathbf{W}_{1,\text{in}}(\mathbf{V}_s(t) + \boldsymbol{\xi})),$$

输出向量

$$\mathbf{V}_s(t + \Delta t) = \mathbf{W}_{1,\text{out}} \mathbf{R}_1(t),$$

其中,向量 $\mathbf{R}_1(t) = [\mathbf{r}_1(t + \Delta t); \mathbf{V}_s(t); \boldsymbol{\xi}]$, $\mathbf{r}_1(t + \Delta t)$ 为储备池状态向量, $\boldsymbol{\xi}$ 为偏差参数.接着利用岭回归算法在最小二乘意义上将输出值与实际值进行拟合可以得到预测模块的输出权重

$$\mathbf{W}_{1,\text{out}} = \mathbf{V}_s(t + \Delta t) \mathbf{R}_1^T (\mathbf{R}_1 \mathbf{R}_1^T + \eta \mathbf{I}).$$

同样,定位模块的储备池中

$$\mathbf{r}_2(t + \Delta t) = (1 - \alpha)\mathbf{r}_2(t) + \alpha \tanh(\mathbf{A}_2 \mathbf{r}_2(t) + \mathbf{W}_{2,\text{in}}(\mathbf{V}_s(t + \Delta t) + \boldsymbol{\xi})),$$

$$\mathbf{V}_L(t + \Delta t) = \mathbf{W}_{2,\text{out}} \mathbf{R}_2(t),$$

其中,向量 $\mathbf{R}_2(t) = [\mathbf{r}_2(t + \Delta t); \mathbf{V}_s(t + \Delta t); \boldsymbol{\xi}]$,由输入向量 $\mathbf{V}_s(t + \Delta t)$ 、储备池状态向量 $\mathbf{r}_2(t + \Delta t)$ 和偏差参数 $\boldsymbol{\xi}$ 组成.接着同样利用岭回归算法将输出值与实际值进行拟合得到定位模块的输出权重

$$\mathbf{W}_{2,\text{out}} = \mathbf{V}_L(t + \Delta t) \mathbf{R}_2^T (\mathbf{R}_2 \mathbf{R}_2^T + \eta \mathbf{I}).$$

其中, η 为正则参数.

1.2 模型预测阶段

在预测阶段,其目标是输入 T_1 时刻的状态变量,输出 T_1 时刻之后多步的时空状态变量 $\mathbf{V}_s(t)$ 以及其对应的位置矩阵 $\mathbf{V}_L(t)$, $t \in [0, T_2]$ (T_2 为预测长度).为了实现这个目标,在预测模块中,将输出的 $\mathbf{V}_s(t + \Delta t)$ 代入到模型输入中,以此来实现多步预测的目的.具体过程如下

$$\mathbf{V}_s(t + \Delta t) = \mathbf{W}_{1,\text{out}} \mathbf{R}_1(t),$$

$$\mathbf{r}_1(t + 2\Delta t) = (1 - \alpha)\mathbf{r}_1(t + \Delta t) + \alpha \tanh(\mathbf{A}_1 \mathbf{r}_1(t + \Delta t) + \mathbf{W}_{1,\text{in}}(\mathbf{V}_s(t + \Delta t) + \boldsymbol{\xi})),$$

$$\mathbf{V}_s(t + 2\Delta t) = \mathbf{W}_{1,\text{out}} \mathbf{R}_1(t + \Delta t), \dots,$$

以此循环生成多步预测的结果.

将上述时序预测结果输入到已训练好的定位模块,得到对应的螺旋波波头位置.计算过程如下

$$\mathbf{V}_L(t + \Delta t) = \mathbf{W}_{2,\text{out}} \mathbf{R}_2(t),$$

$$\mathbf{r}_2(t + 2\Delta t) = (1 - \alpha)\mathbf{r}_2(t + \Delta t) + \alpha \tanh(\mathbf{A}_2 \mathbf{r}_2(t + \Delta t) + \mathbf{W}_{2,\text{in}}(\mathbf{V}_s(t + \Delta t) + \boldsymbol{\xi})),$$

$$\mathbf{V}_L(t + 2\Delta t) = \mathbf{W}_{2,\text{out}} \mathbf{R}_2(t + \Delta t), \dots,$$

最终得到系统 T_1 时刻之后螺旋波波头轨迹的多步预测结果.

2 预测结果

为了对混合储备池模型的可行性进行测试,选取 FitzHugh-Nagumo(FHN)系统下的动态单波头数据^[25]进行实验.

采用单波头数据对混合储备池模型可行性进行测试.该数据下仅存在一个随时间漂移且轨迹为不规则圆形的波头.数据由 FHN 系统生成,系统动力学方程为

$$\frac{\partial x_{i,j}}{\partial t} = \frac{1}{\varepsilon} (1 - \sigma \varepsilon) x_{i,j} - \alpha x_{i,j}^3 - y_{i,j} + \frac{\sigma}{Q} \sum_{k,p} (x_{k,p} - x_{i,j}),$$

$$\frac{\partial y_{i,j}}{\partial t} = \gamma x_{i,j} - y_{i,j} + \beta,$$

其中, $\alpha = 1/3, \beta = 0.001, \epsilon = 0.2, \gamma = 0.7, Q = 8$, 参数 α, β, γ 决定了振荡器的动力学行为, 其中参数 ϵ 确定了特征时间尺度的关系, β 定义了系统不对称度. 每个元素在晶格中的位置由动态变量 $x_{i,j}$ 和 $y_{i,j}$ 的双索引确定, 其中 $i, j = 1, \dots, N$. 参数 k, p 为整数, 表示耦合的非局部特性. 参数 Q 表示每个元素的耦合邻居集合. 晶格大小设为 $N \times N = 50 \times 50$, 迭代步长设为 0.02, 总迭代步数设为 10^5 . 在排除瞬态数据之后, 将剩余的数据作为测试数据. 为了更加直观地展示数据中波头轨迹的运动, 绘制了 [4 000, 5 500] 时间段内波头的运动轨迹 (如图 2). 其中, 背景为 $t = 5\ 500$ 时, 系统状态变量对应的时间切片, 粉色五角星为使用雅可比行列式方法^[26] (JM) 计算得到的波头位置, 白色折线为对应时间段内波头的运动轨迹.

在预测模块的训练中, 将向量 $(\mathbf{x})^{t-\Delta t}$ 作为输入向量 $\mathbf{V}_s(t)$, 向量 $(\mathbf{x})^t$ 作为输出向量 $\mathbf{V}_s(t + \Delta t)$ 来实现空间状态变量的时序预测 ($T_1 = 4\ 000$). 同时, 使用网格搜索法 (grid search) 来选取模块的最优参数, 最终选定模型超参数为: 储备层节点数 $M = 5\ 000$, 学习率 $\alpha = 0.2$, 偏置参数 $\xi = 0.1$, 正则参数 $\eta = 10^{-8}$. 通过训练, 预测模块成功实现了动态单波头下的时序预测, 其预测步长达到了 100 步左右. 图 3 展示了通过 T_1 时间预测 T_2 时间长度的结果.




图2 单波头螺旋波下波头轨迹示意图

Fig.2 Diagram of the tip trajectory under single tip spiral wave




图3 单波头螺旋波下预测模块的部分计算结果

Fig.3 Partial computational results of the prediction module under single tip spiral wave

这里选用 RMSE(均方根误差)来表示预测误差,通过计算,对于 T_2 为 100 步时其状态变量 x 平均误差 RMSE 仅为 5.6×10^{-4} ,这说明储备池计算模型在空间状态预测方面的强大学习能力.

同时,利用已知数据对定位模块进行训练.通过网格搜索法选定其超参数为:储备层节点数 $M=5\,000$,学习率 $\alpha=0.7$,偏置参数 $\xi=0.1$,正则参数 $\eta=10^{-8}$.在波头定位任务中,将输入向量定为时序状态矩阵 $\mathbf{V}_S(t+\Delta t)=(x)^{t_1}$,输出向量定为位置矩阵 $\mathbf{V}_L(t+\Delta t)$ 来实现时序数据到螺旋波波头位置的映射($T_1=4\,000$).同时,需确保选取的时间区间包含在预测模块的训练数据范围内,以保证模型训练的合理性.图 4 展示了将预测模块得到的时序数据输入到已训练好的定位模块中输出的螺旋波波头位置与真实位置的对比.预测结果与 JM 计算结果(即真实值)较为符合.由于所有结果偏差距离均在误差允许范围内,因此 $T_2=100$ 时准确率^[25]为 100%.这表明,轨迹预测模型在单波头情形下不仅能够成功运行,而且训练数据量少、模型结构简洁、需调整参数少以及卓越的计算效率.




图4 单波头螺旋波下定位模块的计算结果

Fig.4 Computational results of the recognition module under single tip spiral wave

3 结论与展望

本文开发了一种结合时序预测模块与空间波头定位模块的混合储备池计算模型,用于预测动态螺旋波系统波头的演化轨迹.在单波头场景下对模型的可行性进行了测试,结果显示该模型的长期预测能力尤为突出,能精确预测 100 个时间步长内的波头轨迹.实验数据表明,本研究所提出的混合储备池模型优秀的预测性能有效且稳定性.

螺旋波现象在一般反应扩散系统中较为常见且重要,该方法为这类反应扩散系统中波头识别工作提供了新的研究方向与方法.例如,在心律失常疾病中,药物治疗的效果有限,更多通过立体导管消融手术对波头(病灶)位置进行精确消融,从而有效消除心律失常现象.而该方法在预测上设置上采用滑窗式训练,可以对螺旋波波头进行实时精确轨迹预测,对于实际心脏消融手术中波头的准确定位具有一定的参考价值.同时,如何调整模型各参数及结构使得该方法可以有效实现螺旋波类型转变的预测也是一个重要的研究方向.

参 考 文 献

[1] 黄晓东,汪瑞.窦房结律调控的动力学机制综述[J].河南师范大学学报(自然科学版),2024,52(6):97-106.
HUANG X D,WANG R.A review on the dynamical mechanisms of rhythmic regulation of sinoatrial node[J].Journal of Henan Normal University(Natural Science Edition),2024,52(6):97-106.

[2] EPSTEIN I R,POJMAN J A.An introduction to nonlinear chemical dynamics:oscillations,waves,patterns,and chaos[M].Oxford:Oxford University Press,1998.

[3] MAZUMDAR J.An introduction to mathematical physiology and biology[M].Cambridge:Cambridge University Press,1999.

[4] PANFILOV A V,HOLDEN A V.Self-generation of turbulent vortices in a two-dimensional model of cardiac tissue[J].Physics Letters A,1990,151(1/2):23-26.

[5] PANDIT S V,JALIFE J.Rotors and the dynamics of cardiac fibrillation[J].Circulation Research,2013,112(5):849-862.

[6] DAVIDENKO J M,PERTSOV A V,SALOMONSZ R,et al.Stationary and drifting spiral waves of excitation in isolated cardiac muscle[J].Nature,1992,355(6358):349-351.

[7] BARKLEY D.Euclidean symmetry and the dynamics of rotating spiral waves[J].Physical Review Letters,1994,72(1):164-167.

[8] WINFREE A T.Heart muscle as a reaction-diffusion medium:the roles of electric potential diffusion,activation front curvature,and anisotropy[J].International Journal of Bifurcation and Chaos,1997,7(3):487-526.

[9] BEAUMONT J,DAVIDENKO N,DAVIDENKO J M,et al.Spiral waves in two-dimensional models of ventricular muscle:formation of a stationary core[J].Biophysical Journal,1998,75(1):1-14.

[10] OTANI N F.A primary mechanism for spiral wave meandering[J].Chaos,2002,12(3):829-842.

[11] FENTON F H,CHERRY E M,HASTINGS H M,et al.Multiple mechanisms of spiral wave breakup in a model of cardiac electrical activity[J].Chaos,2002,12(3):852-892.

[12] KRINSKY V I,EFIMOV I R,JALIFE J.Vortices with linear cores in excitable media[J].Proceedings of the Royal Society of London Series A:Mathematical and Physical Sciences,1992,437(1901):645-655.

[13] GARFINKEL A,CHEN P S,WALTER D O,et al.Quasiperiodicity and chaos in cardiac fibrillation[J].The Journal of Clinical Investigation,1997,99(2):305-314.

[14] HAKIM V,KARMA A.Spiral wave meander in excitable media;the large core limit[J].Physical Review Letters,1997,79(4):665-668.

[15] GAUTHIER D J,BOLLT E,GRIFFITH A,et al.Next generation reservoir computing[J].Nature Communications,2021,12:5564.

[16] 徐荣幸,赵鸿.机器学习在座逾渗相变问题中的应用[J].河南师范大学学报(自然科学版),2019,47(1):45-51.

XU R X,ZHAO H.Study site percolation phase transitions based on machine learning[J].Journal of Henan Normal University(Natural Science Edition),2019,47(1):45-51.

[17] 王江峰,陈银霞,祁月盈,等.基于机器学习由暂态数据预测系统的演化[J].河南师范大学学报(自然科学版),2024,52(6):113-119.

WANG J F,CHEN Y X,QI Y Y,et al.Predicting the evolution of systems based on a transient data with machine learning[J].Journal of Henan Normal University(Natural Science Edition),2024,52(6):113-119.

[18] HAYNES N D,SORIANO M C,ROSIN D P,et al.Reservoir computing with a single time-delay autonomous Boolean node[J].Physical Review E,Statistical,Nonlinear,and Soft Matter Physics,2015,91(2):020801.

[19] KONG L-W,FAN H-W,GREBOGI C,et al.Machine learning prediction of critical transition and system collapse[J].Physical Review Research,2021,3:013090.

[20] ZHANG C,JIANG J J,QU S X,et al.Predicting phase and sensing phase coherence in chaotic systems with machine learning[J].Chaos,2020,30(8):083114.

[21] PATHAK J,LU Z X,HUNT B R,et al.Using machine learning to replicate chaotic attractors and calculate Lyapunov exponents from data[J].Chaos,2017,27(12):121102.

[22] LIMBECK J,BISDOM K,LANZ F,et al.Using machine learning for model benchmarking and forecasting of depletion-induced seismicity in the Groningen gas field[J].Computational Geosciences,2021,25(1):529-551.

[23] ARCOMANO T,SZUNYOGH I,PATHAK J,et al.A machine learning-based global atmospheric forecast model[J].Geophysical Research Letters,2020,47(9):e2020GL087776.

[24] PATHAK J,HUNT B,GIRVAN M,et al.Model-free prediction of large spatiotemporally chaotic systems from data;a reservoir computing approach[J].Physical Review Letters,2018,120(2):024102.

[25] CHEN Y,WU X,QIAN Y,et al.Identifying spiral wave tips with reservoir computing[J].Chaos,Solitons & Fractals,2024,180:114579.

[26] LI T C,PAN D B,ZHOU K S,et al.Jacobian-determinant method of identifying phase singularity during reentry[J].Physical Review E,2018,98(6):062405.

Prediction of spiral wave tip trajectories under reservoir computing

Cui Xiaohua¹, Chen Yeyuge¹, Zheng Caiyi²

(1. College of System Sciences, Beijing Normal University, Beijing 100080, China;

2. Faculty of Arts and Sciences, Beijing Normal University(Zhuhai), Zhuhai 519087, China)

Abstract: Spiral waves are a special form of self-organized structures that are formed and maintained without external intervention reflecting the complexity of nonlinear system interactions, and have been observed in systems of biology, chemistry, and physics. The tip is the phase singularity of the spiral wave pattern, so controlling the tip can control the spiral wave. Therefore, how to predict the tip trajectory from a small amount of spiral wave spatio-temporal state data is an important problem in the reaction-diffusion systems study. In this paper, a hybrid reservoir computing prediction model is constructed, in which the time series data of the single tip mode and the corresponding tip positions in the FitzHugh-Nagumo system are used as the training set; the above data are inputted to train the hybrid reservoir computing model; and then the trained hybrid model is utilized to predict the evolution trajectories of the subsequent tips in the spiral wave system. The results show that the hybrid model can realize the long-term accurate prediction of the trajectories of spiral tip, which provides a new research perspective and method for the prediction of phase singularities of reaction-diffusion systems.

Keywords: reservoir computing; spiral wave tip; trajectories prediction

[责任编辑 杨浦 刘洋]