

■ 添付資料




図1 従来型の RC と提案した SM-RC の構造の比較

従来型のレザバコンピュティング (RC) は、入力層、レザバ層、出力層で構成されており、出力層のみを学習します。レザバ層は典型的にはランダム結合した再帰型ニューラルネットワーク (RNN) を用いますが、様々な力学系を用いることが可能です。提案した自己制御型 RC (SM-RC) は新たに入力ゲート g^{in} 、レザバゲート g^{res} を有しており、それぞれ、入力信号、レザバ層のスペクトル半径を制御することができます。SM-RC では、出力層に加えて、レザバ層から、各ゲートへの重みを学習します。




図2 単純アテンションタスクにおける従来型 RC と SM-RC の動作比較

単純アテンションタスクは、ノイズ中に存在するパルス信号を入力とし、一定時間後にパルスを出力するタスクです。左図は従来型レザバーコンピューティング (RC) の学習結果であり、上から、入力信号、レザバー層、出力層 (青実線：出力信号、橙破線：教師信号)、鋭敏性 (青実線：平均値、橙破線：最大値)の時間発展を表します。右図は考案した自己制御型 RC (SM-RC)の学習結果であり、上から、入力信号、レザバー層、出力層(青実線：出力信号、橙破線：教師信号)、ゲート(青実線：入力ゲート、橙破線：スペクトル半径)、鋭敏性 (青実線：平均値、橙破線：最大値)の時間発展を表します。SM-RC では、ノイズ強度を3倍にして、より困難なタスクになっていますが、出力層において、教師信号(橙破線)と、出力信号(青実線)がほぼ一致していることがわかります。鋭敏性に関しては、RC の場合は、常に負の値をとりますが、SM-RC の場合には一部の正の値をとります。これは、SM-RC におけるレザバー層がカオス状態をとっていることを示しています。

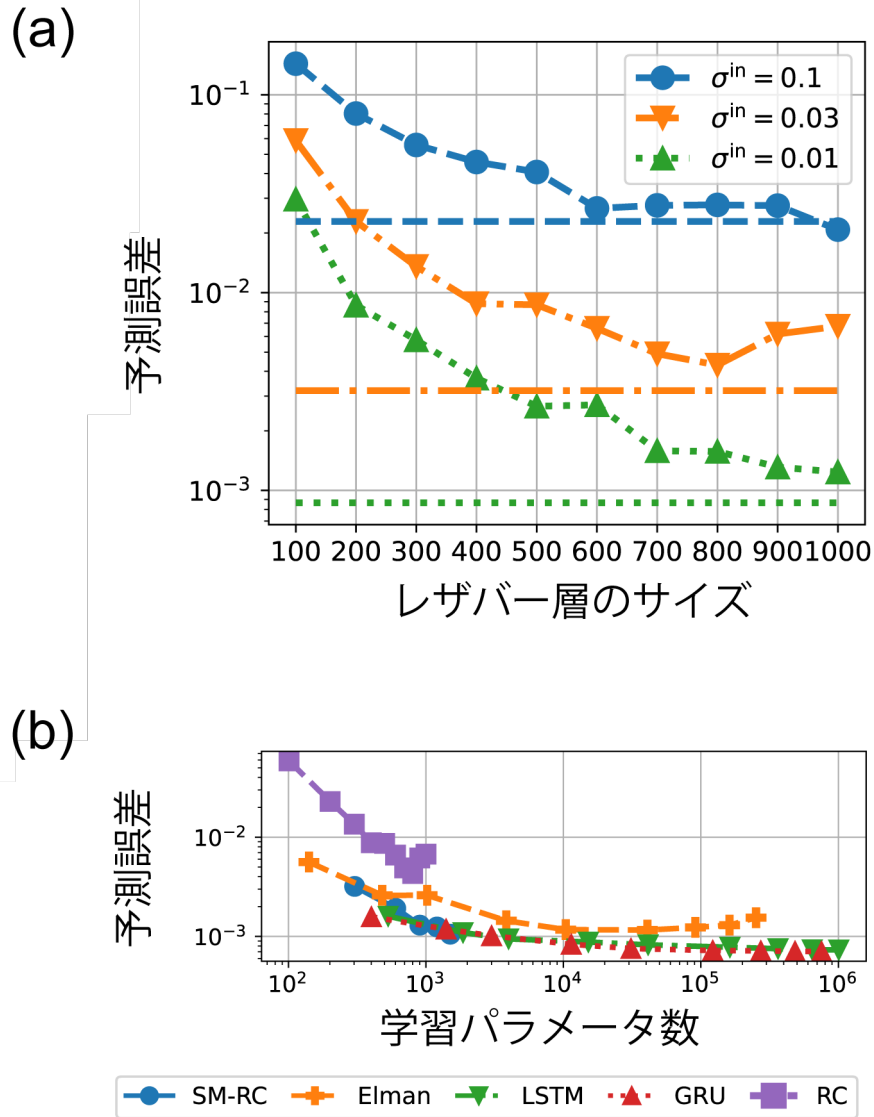


図3 カオス時系列予測の学習性能比較

(a) 従来型レザバコンピューティング (RC)の予測誤差を、レザバ層のサイズを横軸としてプロットしています。また、入力されるカオス時系列に様々なノイズ σ^{in} が存在する場合を重ねてプロットしています。SM-RCのレザバ層サイズは100に固定しており、予測精度は横線で表されています。(b) 様々な再帰型ニューラルネットワーク(RNN)モデルについて、学習パラメータを横軸として予測誤差をプロットした結果を示しています。

表1 各種 RNN モデルの比較

	LSTM & GRU	RC	SM-RC
学習速度	低速	高速	低速
予測性能	高い	中程度	高い
物理実装性	低い	高い	やや高い