

# Reservoir Computing et ces applications

DLR, Institute for AI Safety and Security

Tamon Nakano, Sebastian Bauer, Christoph R ath



Wissen f ur Morgen



# À propos de moi

Tamon Nakano, Ph.D.

-2014 Japon

2014-2018 Doctorat à l'ENSMA, Poitiers

2018-2020 Postdoc au CERFACS, Toulouse

2021-2022 Postdoc à l'INRIA, Paris-Saclay

2022- Chercheur au DLR, Sankt Augustin (près de Cologne)

Spécialité :

Simulation en mécanique des fluides => IA pour des problèmes en ingénierie mécanique



# Quelques informations sur le DLR

- Equivalent à la NASA, au CNES, à l'ONERA
- Divers domaines
  - Aérospatial
  - Aéronautique
  - Energie
  - Transport (automobile, ferroviaire)
- 54 instituts, 30 sites
- Plus de 10 000 employés
- Institute for AI Safety and Security
  - Sankt Augustin
  - Ulm



Sankt Augustin



Ulm



# Sujets

- Reservoir Computing
- Approche hybride
- Approche hybride en haute dimension (notre thème actuel)
- Quelques applications de Reservoir Computing (non-hybride)



# Reservoir Computing

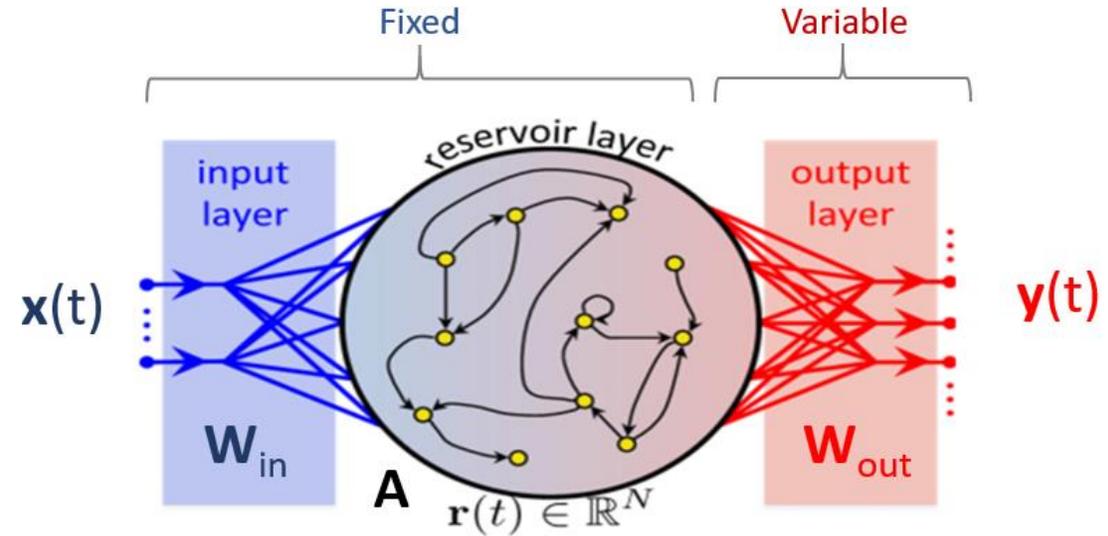


Wissen für Morgen



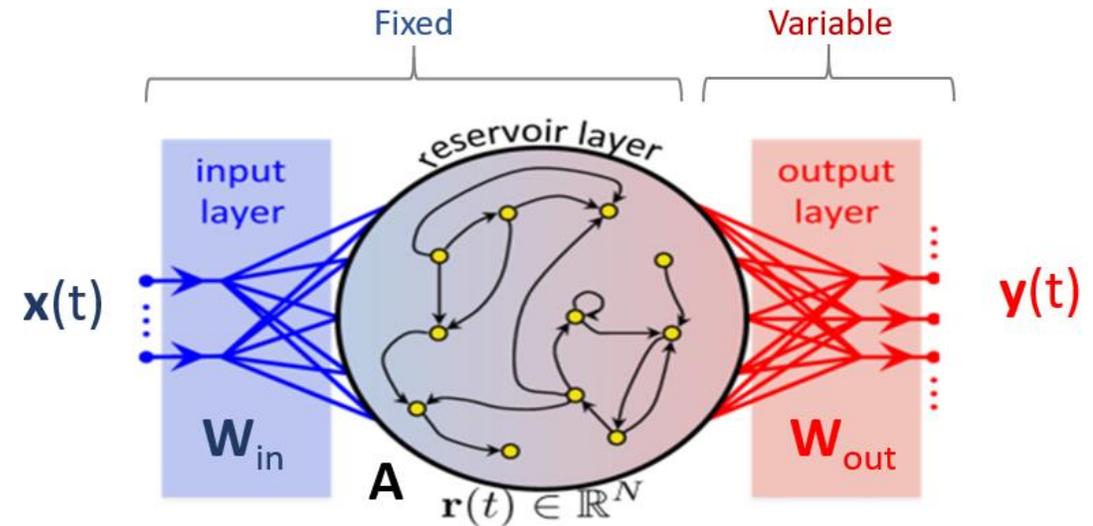
# Qu'est-ce qu'un Reservoir Computing ?

- Reservoir Computing est un type de RNN (Recurrent Neural Network).
- Caractérisé par sa structure en boucle (réservoir)
- Les pas de temps précédents sont redonnés dans le système
- Plus rapide que les RNN typiques, linéaire et plus transparent
- Développé notamment par les chercheurs en systèmes chaotiques, dynamiques complexes.



# Processus Mathématiques

- Signal d'entrée  $\mathbf{x}(t)$  : ensemble de données à  $D$  dimensions
- Input layer  $\mathbf{W}_{in}$  : matrice  $D_r \times D$
- Réservoir  $A$  : réseau aléatoire avec  $D_r$  nœuds
- Output  $\mathbf{W}_{out}$  : matrice  $D \times D_r$
- Signal de sortie  $\mathbf{y}(t)$  : ensemble de données à  $D$  dimensions
- Reservoir State  $\mathbf{r}_{i+1} = (1 - \gamma)\mathbf{r}_i + \gamma f(\mathbf{A}\mathbf{r}_i + \mathbf{W}_{in}\mathbf{x}_i + \mathbf{b})$



# Approche Hybride



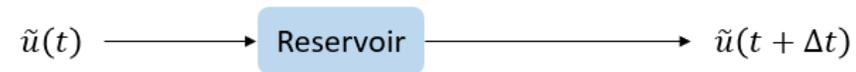
Wissen für Morgen



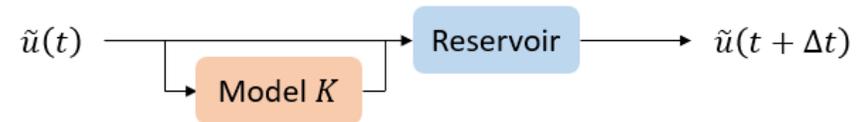
# Approche Hybride

- Reservoir + KBM (Knowledge Based Model)
  - KBM: équations incorrectes
- Plusieurs façons de combiner

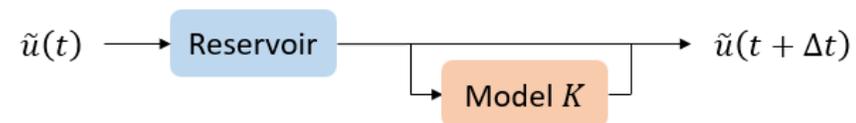
Normal



Input hybrid



Output hybrid



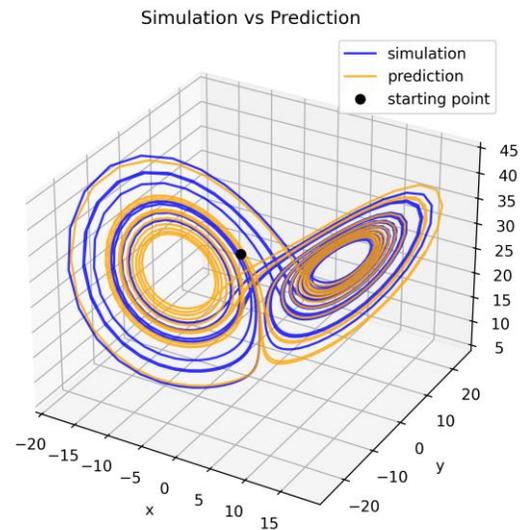
Full hybrid



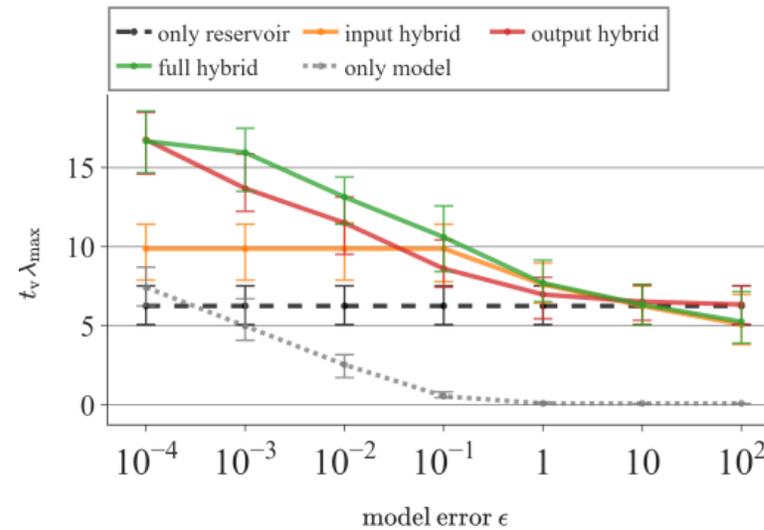
# Approche Hybride

Ducan et. al (2023)

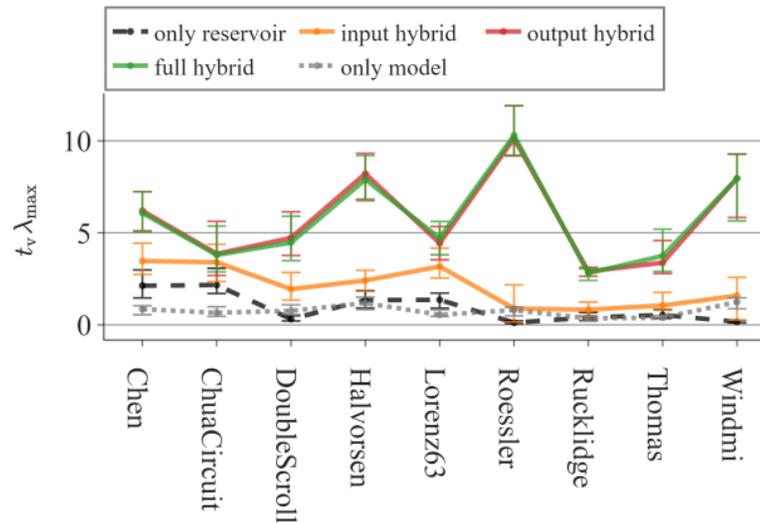
- Comparaison des méthodes hybrides dans des problèmes de faible dimension (jusqu'à environ 50 dimensions)
- Conclusion : Output Hybrid est le meilleur choix en termes de précision et de robustesse de la prédiction.



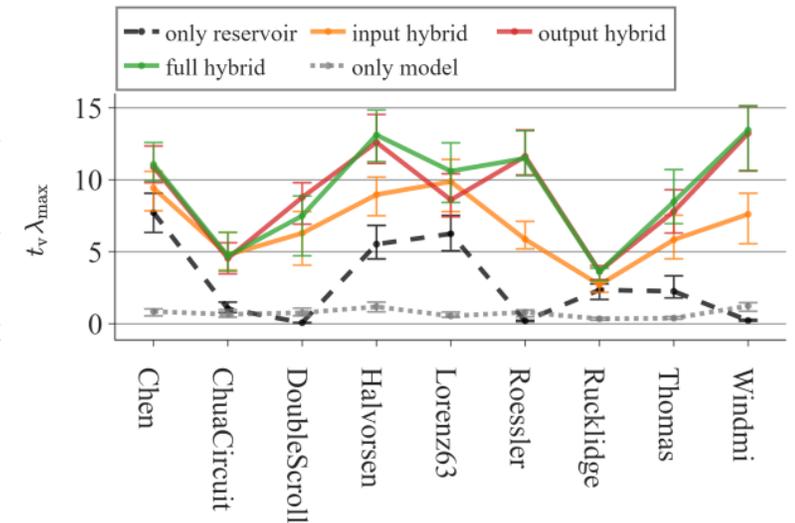
Lorenz 63



(b) Reservoir dimension fixed at  $r_{\text{dim}} = 500$



(a) Smaller reservoir  $r_{\text{dim}} = 50$



(b) Larger reservoir  $r_{\text{dim}} = 500$

# Approche hybride en haute dimension

(notre thème actuel)



Wissen für Morgen



## Extension to higher dimensions

Zimmermann et al. (2018)

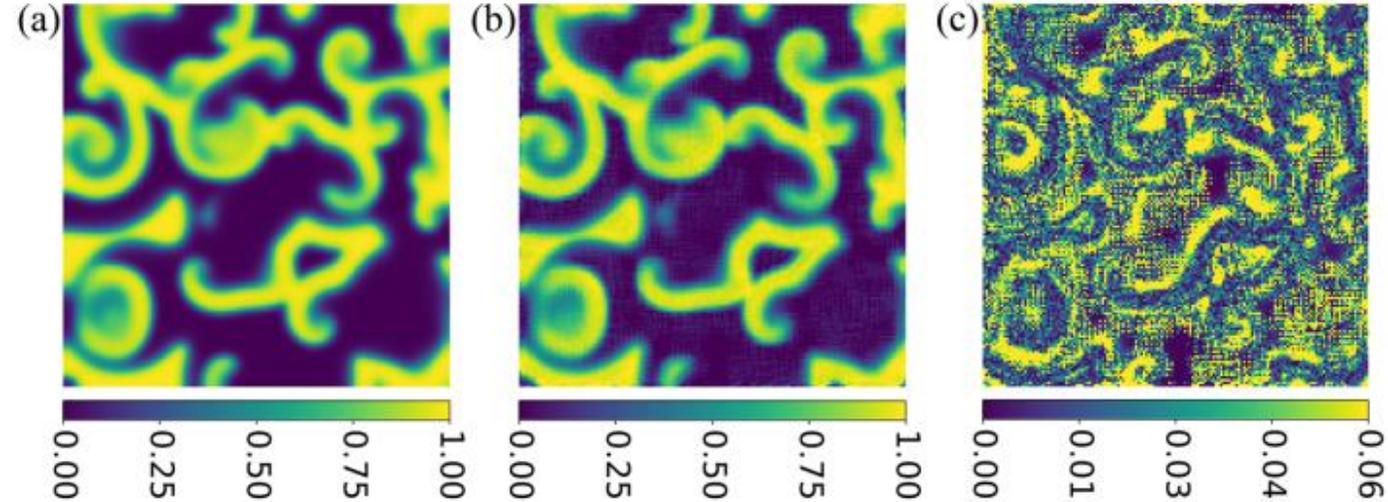
- Reservoir Computing classique (non-hybride)
- Modèle de Barkley, un système chaotique avec des variables  $u(t)$ ,  $v(t)$ .
- Méthode de prédiction parallélisée (Local States)
- Image 2D 150x150 dimensions
- Prédiction croisée
  - $u(t)$  à partir de  $v(t)$ ,  $v(t)$  à partir de  $u(t)$
- Plutôt une mapping/reconstruction
- Cette méthode n'est possible que si l'une des variables est disponible

Ground truth

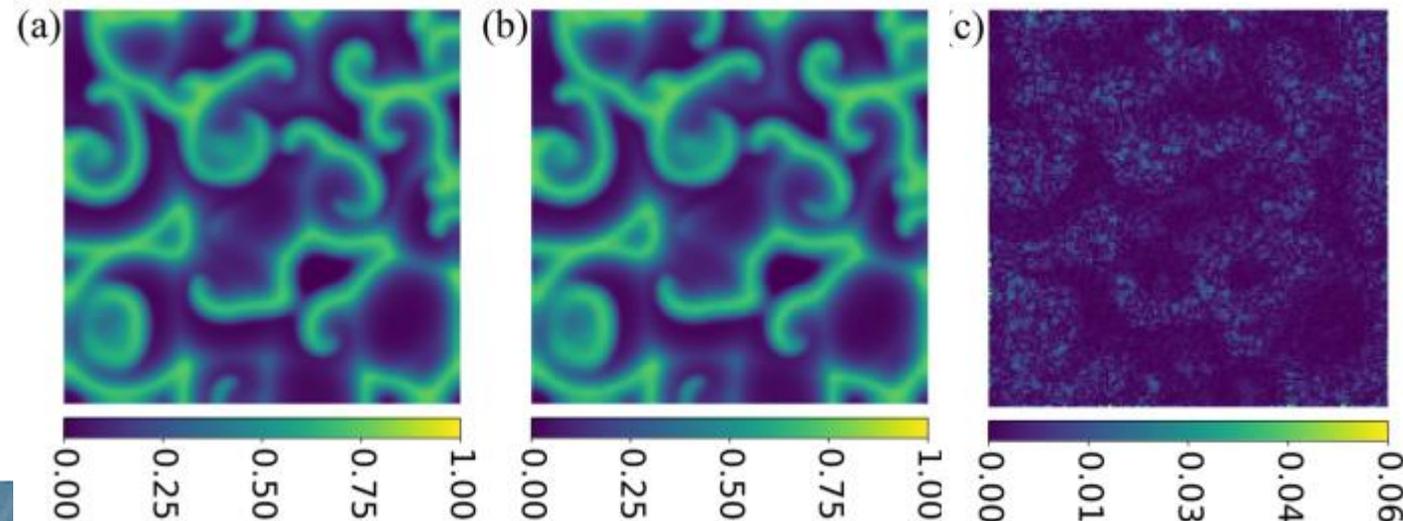
Prediction

Error

$u(t)$   
de  $v(t)$



$v(t)$   
de  $u(t)$



## Objectif de notre étude actuelle

- Développer une méthode hybride de Reservoir Computing à l'aide d'une méthode de prédiction parallèle (Local States) pour les systèmes de haute dimension et analyser ses caractéristiques.

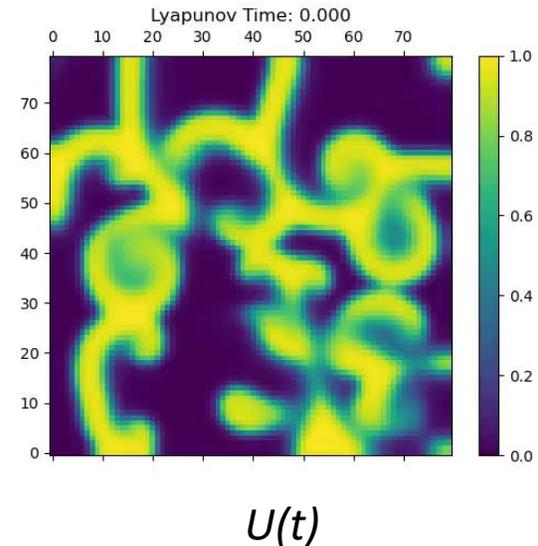


## Use-case: Modèle de Barkley

$$\frac{\partial u}{\partial t} = D \cdot \nabla^2 u + \frac{1}{\epsilon} (1 - u) \left( u - \frac{v + b}{a} \right)$$

$$\frac{\partial v}{\partial t} = u^3 - v.$$

- Système chaotique non linéaire
- Equations différentielles partielles (EDP) avec un terme de diffusion du 2ème ordre
- $\epsilon=0.08$  ,  $a=0.75$ ,  $D=0.02$  et  $b=0.06$
- Consiste en deux variables  $u(t)$ ,  $v(t)$
- 80x80 points
- Coefficient de diffusion  $D$
- $\epsilon$ ,  $a$  et  $b$  caractérisent le comportement du système
- Le modèle est utilisé pour décrire les ondes d'excitation électrique dans le tissu cardiaque, par exemple.
- Utiliser la simulation avec la méthode d'intégration temporelle explicite comme Ground Truth.



Simulation par  
Zimmermann et al. (2018)

# Approche de la prédiction

## Local States

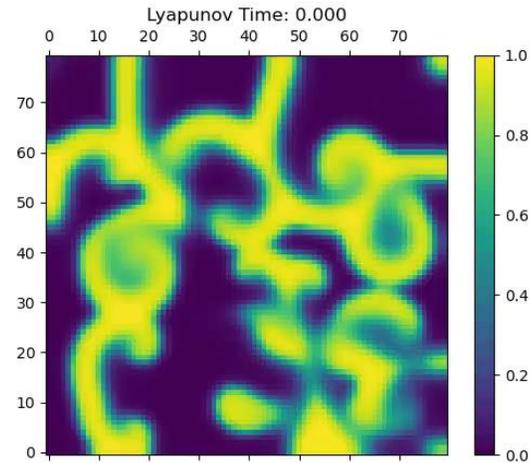
- Similaire à la méthode des différences finies
- Un réservoir effectue l'apprentissage et la prédiction à chacun des 80x80 points.
- Prédire un point (rouge) à partir des 8 points voisins (jaune)
- 80x80 réservoirs au total

## Méthodes hybrides

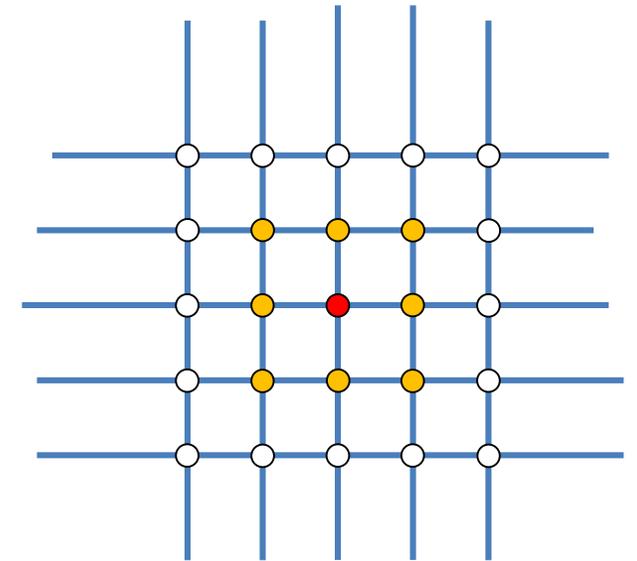
- Input, Output, Full-hybrid
- Knowledge Based Model,  $\varepsilon = \varepsilon(1 + e)$ ,  $e$  : erreur du modèle

$$\frac{\partial u}{\partial t} = D \cdot \nabla^2 u + \frac{1}{\epsilon} (1 - u) \left( u - \frac{v + b}{a} \right)$$

$$\frac{\partial v}{\partial t} = u^3 - v.$$



80x80 points



Points voisins



# Hyperparamètres

Les hyperparamètres ont été choisis à partir d'une étude préliminaire.

Points de grille : 80x80

Dimension du réservoir : 400

Bruit : 1,0e-6

Average degree : 3

Spectral Radius : 0,5

Régularisation : 1,0e-6

Prédiction sur  $u(t)$ ,  $v(t)$

Apprentissage : 30 000 pas (environ 30 temps de Lyapunov)

Prédiction : 10 000 pas (environ 10 temps de Lyapunov)

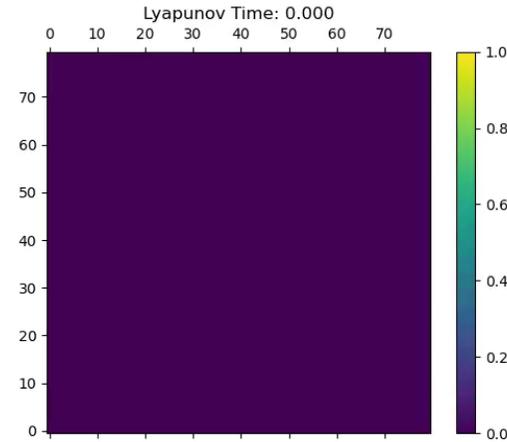
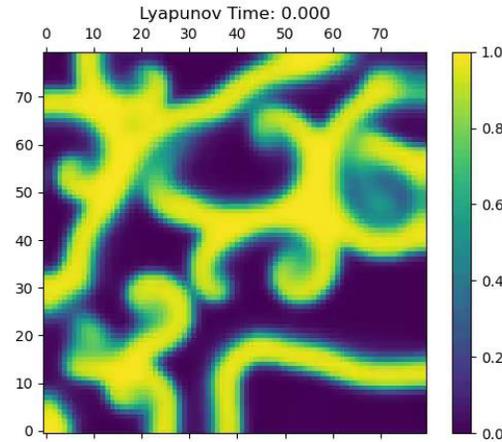
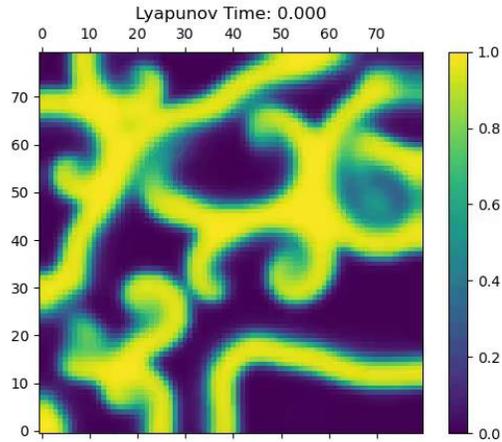
Train\_Synch : 200, Pred\_Synch : 200

3x3 Points

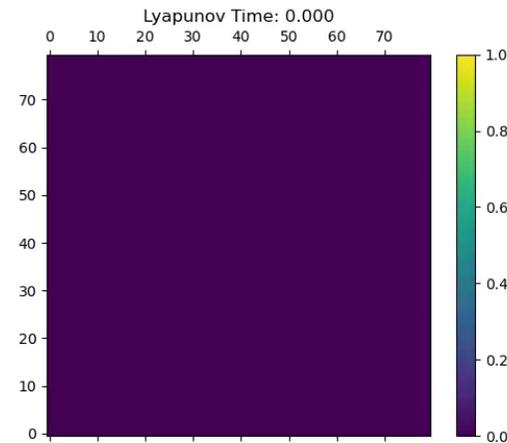
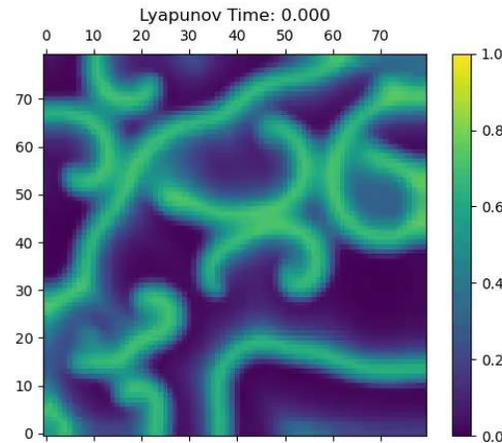
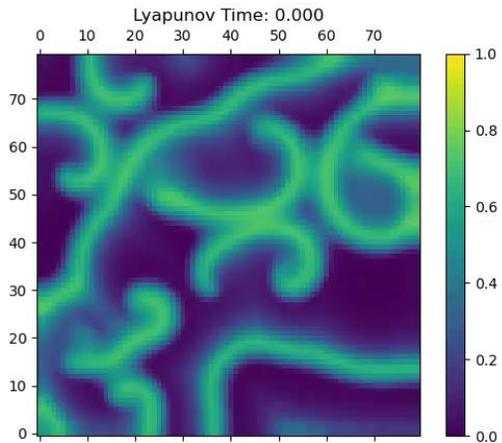


# Prédiction : Réservoir (non-hybride)

$U(t)$



$V(t)$



Ground truth

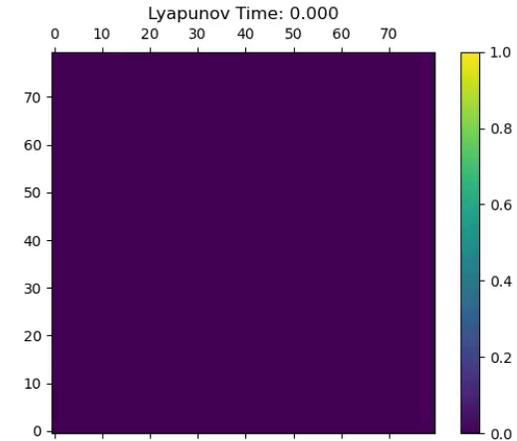
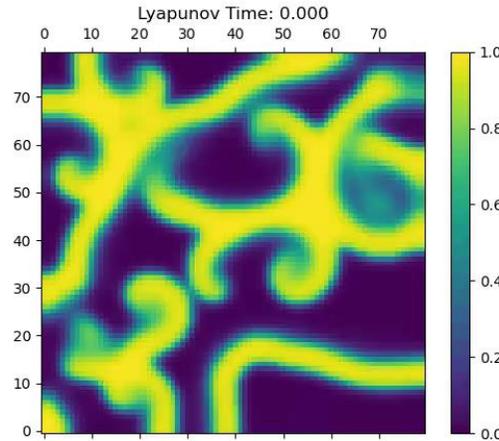
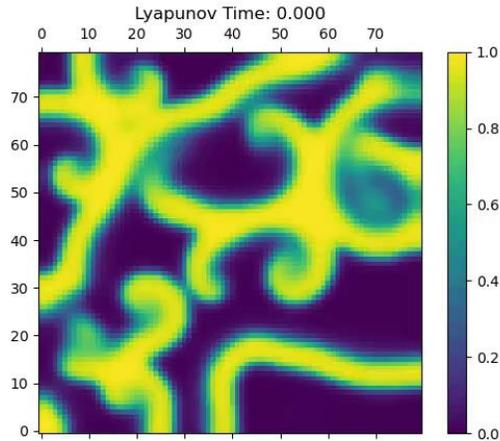
Prediction

Error

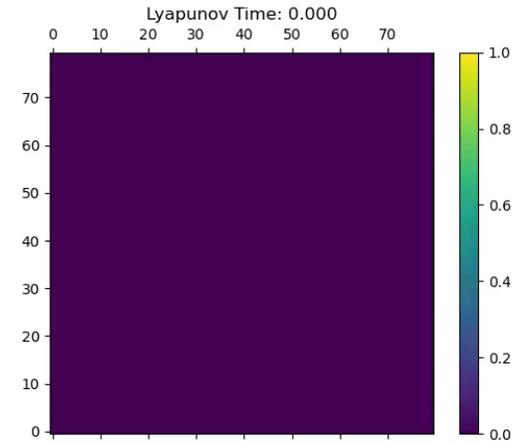
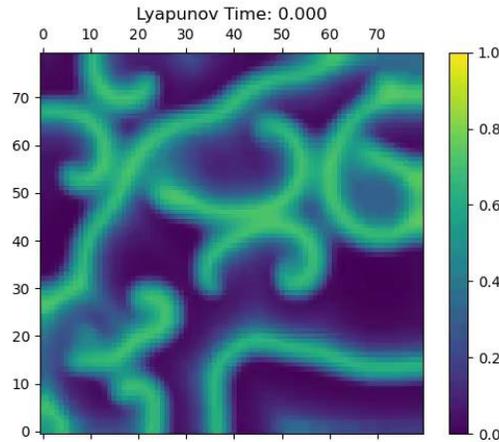
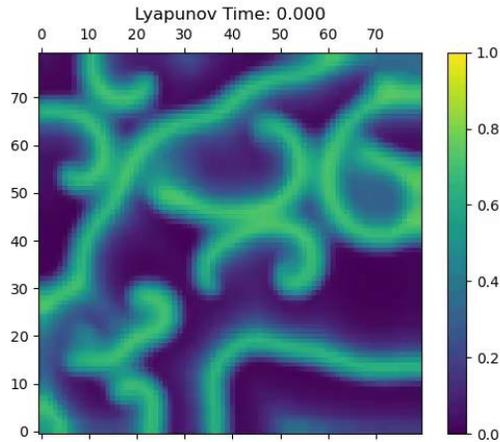


# Prédiction : Output Hybride, $\epsilon=0.1$ : erreur du modèle

$U(t)$



$V(t)$



Ground truth

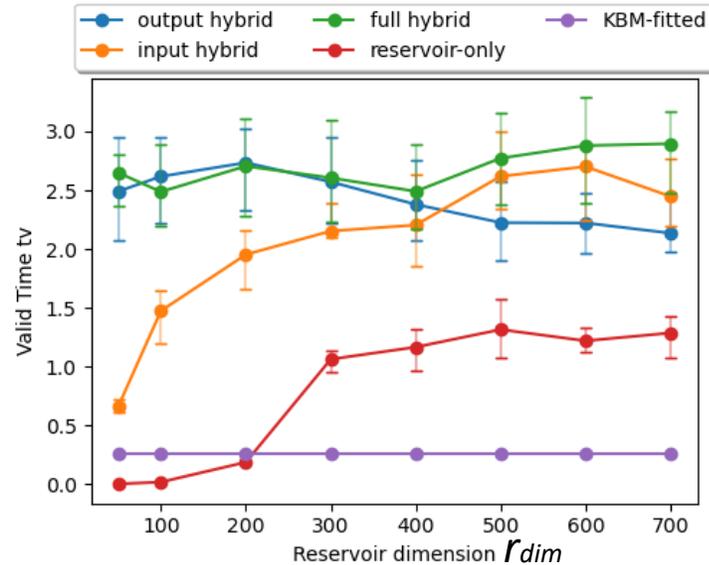
Prediction

Error



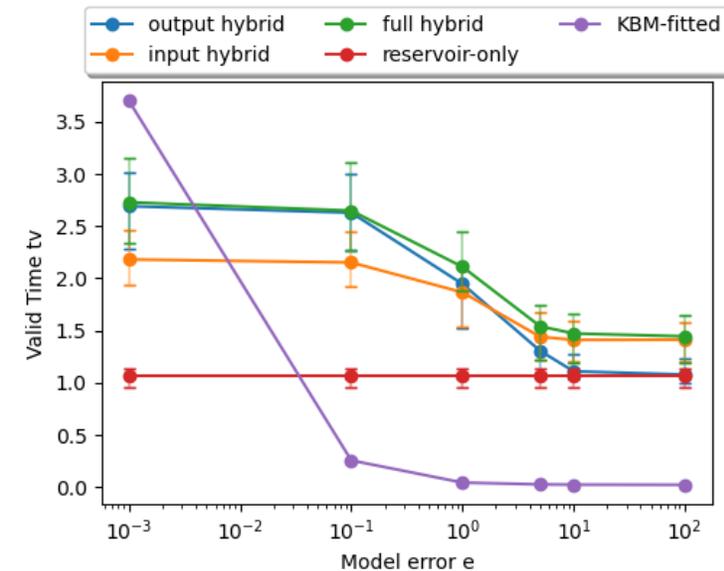
# Performance de prédiction

$e = \text{varié}, r_{dim} = 100$



- IH améliore le temps de validité d'environ 1 par rapport au cas du réservoir seul.
- OH et FH sont également performants dans des dimensions plus petites.
- L'augmentation de la dimension empêche OH mais améliore IH.
- FH semble profiter des avantages de IH et de OH.

$e = 0.1, r_{dim} = \text{varié}$



- Toutes les méthodes hybrides sont plus performantes que la méthode du réservoir seul lorsque l'erreur de modèle  $e$  est plus faible.
- Les méthodes hybrides deviennent imprécises à mesure que l'erreur de modèle  $e$  augmente
- Lorsque l'erreur est importante, la méthode OH est beaucoup plus proche de la méthode du réservoir seul.
- IH conserve une meilleure précision que OH.
- FH hérite de cet avantage de IH et est donc plus robuste que OH.



## Résumé (pour cette étude)

- Nous avons développé un calcul de réservoir hybride soutenu par des états locaux pour des systèmes de plus grande dimension.
- Notre calcul de réservoir a permis de prédire avec succès le modèle de Barkley avec et sans l'approche hybride.
- Toutes les méthodes hybrides ont amélioré les performances de prédiction.
- Dans la gamme de paramètres testés, l'hybride complet et l'hybride de sortie ont montré une supériorité par rapport à l'hybride d'entrée.
- Comme application future, nous considérons les systèmes non linéaires à évolution temporelle, tels que les simulations d'écoulement dans la dynamique des fluides et les modèles atmosphériques.



# Quelques applications de Reservoir Computing (non hybride)



Wissen für Morgen



# FAMPRED

## Famine Prediction



“Forecasting trends in food security with real time data”  
J. Herteux, Nature, communications earth & environment  
Oct. 2024

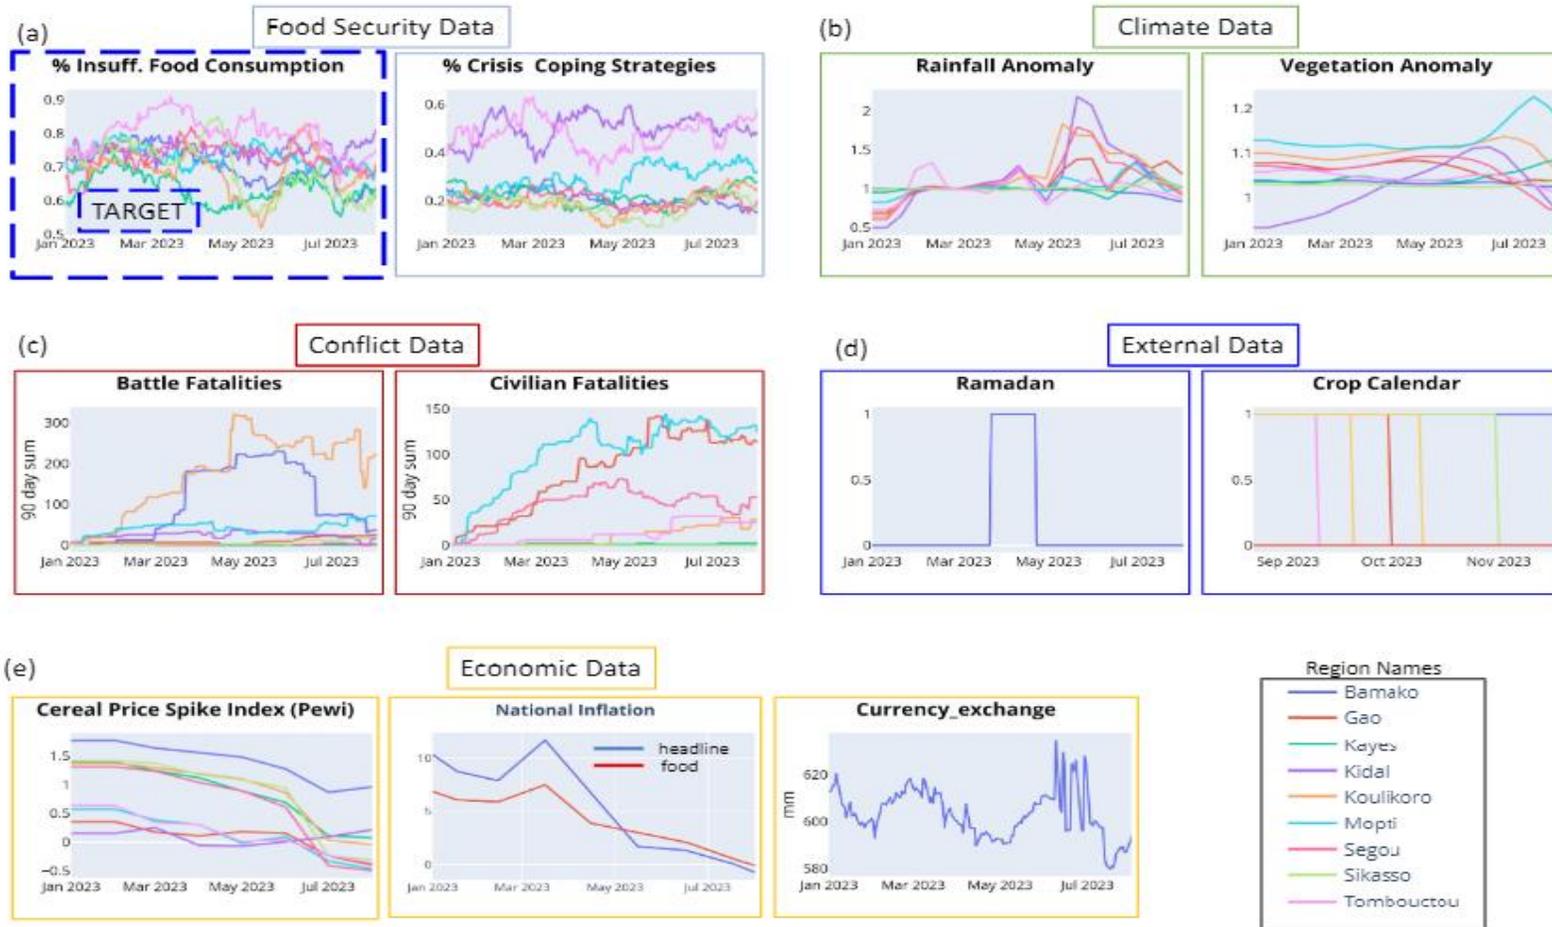
- WFP’s Real-Time Monitoring Suite est un système intégré de surveillance de la faim dans le monde qui collecte des données,
  - qui traite et affiche des informations en temps réel sur les indicateurs clés de la sécurité alimentaire, les conflits, les événements météorologiques et d'autres facteurs d'insécurité alimentaire dans près de 90 pays (36 + 52 estimés)
- Tout en temps réel



# FAMPRED

## Famine Prediction

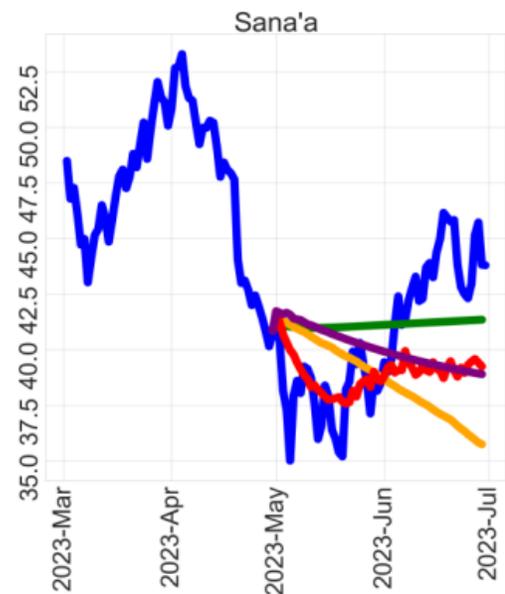
### Input Data Examples



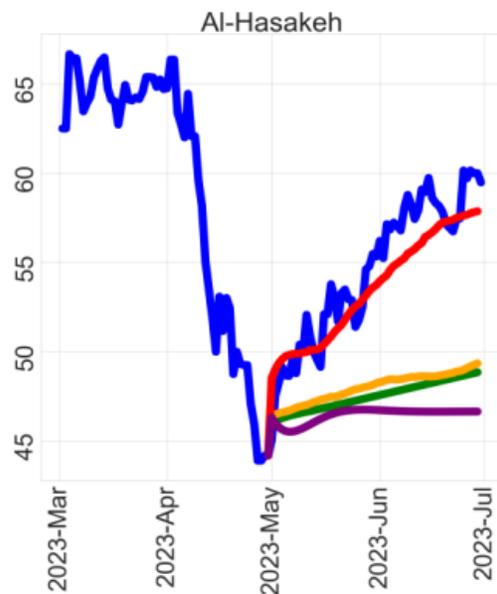
# FAMPRED

## Famine Prediction – 60 days prediction

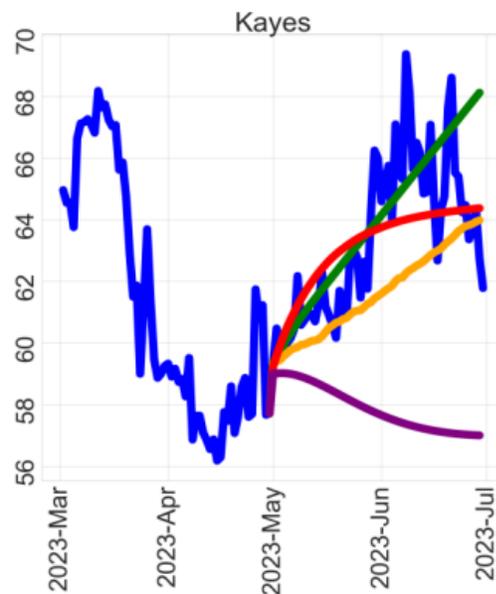
Yemen



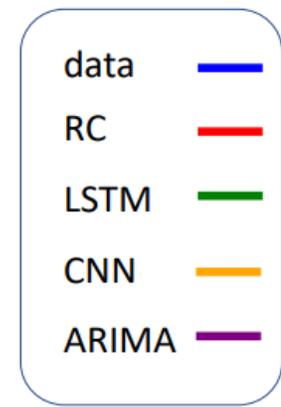
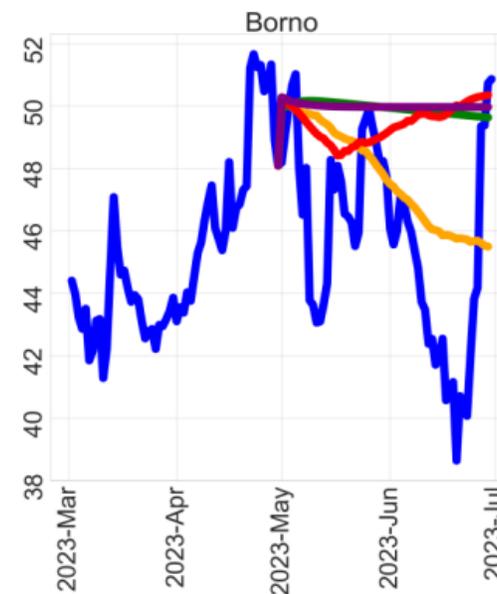
Syria



Mali



Nigeria



“Forecasting trends in food security with real time data”  
J. Herteux, Nature, communications earth & environment  
Oct. 2024



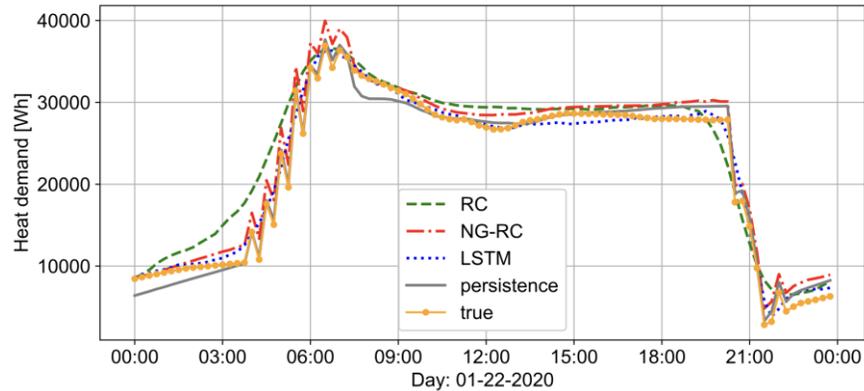
# Prédiction de la demande d'énergie

Prévoir la demande de chaleur et d'électricité d'un ménage 24 heures à l'avance.

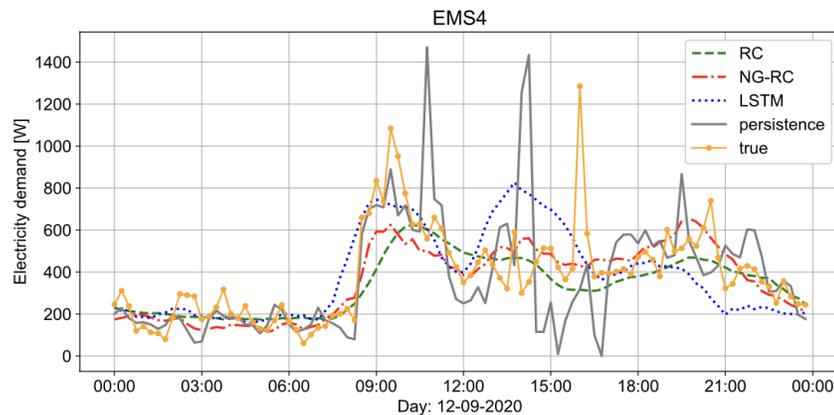
L'étude a comparé l'approche de persistance standard (la prédiction est la demande des dernières 24 heures), LSTMS, l'informatique de réservoir (RC) et l'informatique de réservoir de nouvelle génération (NGRC) en termes de performance de prédiction, mesurée l'erreur absolue moyenne (MAE), l'erreur quadratique moyenne (RMSE) et le pourcentage d'erreur absolue moyenne (MAPE).

Die beiden Graphiken sind Beispiele. Die Fehler die berechnet wurden stammen aus tausenden solchen Vorhersagen  
 kleinster RMSE gibt an das Ausreißer in den Daten am besten gelernt wurden, daher ist die vorhersage mit NG besonders interessant

A) Heat demand



B) Power demand



A) Space heat demand test set			
Prediction Method	MAE [Wh]	RMSE [Wh]	MAPE [%]
Persistence	984.40	1933.62	<b>23.93</b>
LSTM	<b>829.64</b>	1636.95	42.49
RC	938.98	1240.42	59.92
NG-RC	876.67	<b>1060.68</b>	47.11
B) EMS 4			
Persistence	217.56	377.32	101.06
LSTM	178.23	304.20	<b>62.08</b>
RC	172.03	265.06	62.09
NG-RC	<b>169.76</b>	<b>254.67</b>	70.19

Table: Error measures of all prediction methods



## Some other ongoing projects

- Traffic simulation
  - Simulate the behavior of a car following another car ahead
  - RC could perform better in simulating chaotic behavior of a driver
  - Simulate the traffic phenomena such as traffic jam
- Fatigue prediction by simulating vibration
  - Reduce the simulation length by partially replacing





# Numerical Resource

- 12th Gen Intel(R) Core(TM) i9-12900K
- CPU MHz: 1215.617
- 24CPUs
- Approximately 20-24 hours with on CPU
- Memory: 4-5GB / case



# Lyapunov Time

$$e(t) = \frac{\|\mathbf{y}(t) - \mathbf{y}_r(t)\|}{\langle \|\mathbf{y}(t)\|^2 \rangle^{1/2}}$$



$$\mathbf{r}(t + \Delta t) = \tanh [\mathbf{A}\mathbf{r}(t) + \mathbf{W}_{\text{in}} \mathbf{x}(t)]$$

$$\mathbf{W}_{\text{out}} = \min_{\mathbf{W}_{\text{out}}} [\|\mathbf{W}_{\text{out}} \tilde{\mathbf{r}}(t) - \mathbf{y}_T(t)\| + \beta \|\mathbf{W}_{\text{out}}\|]$$

