

Réseaux de neurones informés par la physique pour la reconstruction de courants de gravité

Yoann Cheny, Mickaël Delcey, Adrien Ganz & Sébastien K. de Richter

Université de Lorraine, France

yoann.cheny@univ-lorraine.fr

Situation typique : étude d'écoulements 3D à partir d'observations expé. 0D, 2D

Écoulements de Poudres et Suspensions, courants de gravité écoulements induits par $\Delta\rho$



Lock-exchange configuration
Western Washington University


Méetrologie des courants de gravité :

- (u, v) : Particle Image Velocimetry (PIV *2D-2C*)
- ρ : Planar Laser Induced Fluorescence (PLIF)
- $\bar{\rho} = \int \rho(z)dz$ Light Attenuation Technique (LAT)

Mesures volumétriques onéreuses : RMN, Tomo-PIV, 3D-LIF, 3DBoS...

Situation typique : étude d'écoulements 3D à partir d'observations expé. 0D, 2D

Écoulements de Poudres et Suspensions, courants de gravité écoulements induits par $\Delta\rho$



Métrologie des courants de gravité :

- (u, v) : Particle Image Velocimetry (PIV *2D-2C*)
- ρ : Planar Laser Induced Fluorescence (PLIF)
- $\bar{\rho} = \int \rho(z) dz$ Light Attenuation Technique (LAT)

Mesures volumétriques onéreuses : RMN, Tomo-PIV, 3D-LIF, 3DBoS...

Peut-on reconstruire l'écoulement 3D (ρ, u, v, w, p) à partir de données lacunaires ? [Delcey et al. 2023]

Deux classes de méthodes pour la reconstruction d'écoulement :

- **Méthodes orientées données** (POD, PCA, Machine Learning)

- ⊗ Requiert une connaissance *a priori* de l'écoulement

- **Assimilation de données :**

- Idée directrice : associer les données observées à un modèle physique (CFD)

- ⊗ Procédure itérative très gourmande en ressources CPU
 - ⊗ Pas adapté à l'assimilation des grandeurs intégrées

Point de départ : Physics-Informed Neural Networks (PINNs) [Raissi et al. 2020]


Enrichissement du Deep Learning par la physique sous-jacente (EDP)

Principe des PINNs

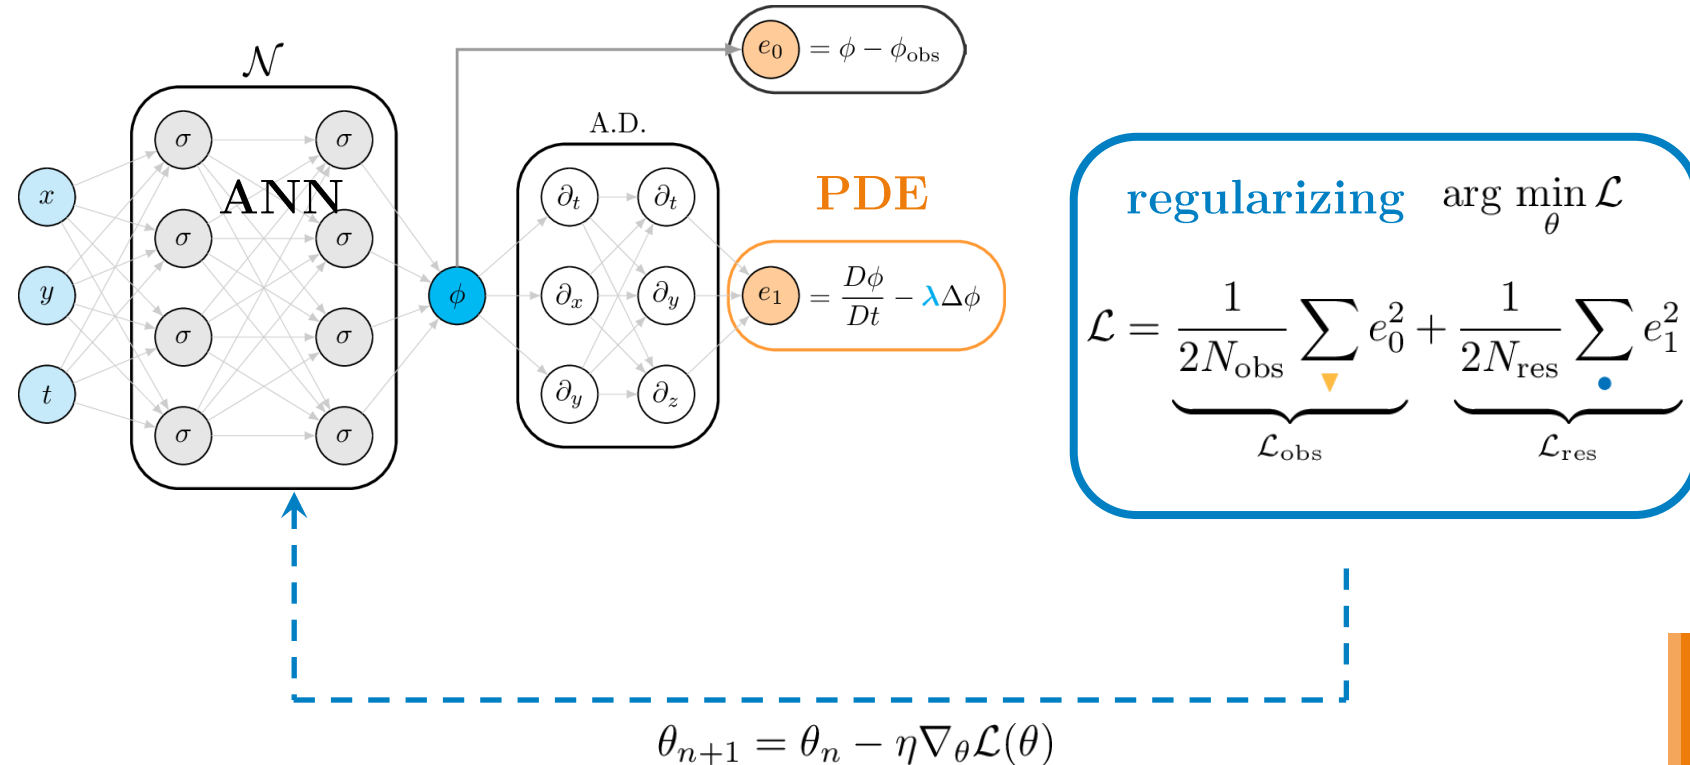
PINNs pour la reconstruction d'écoulements

Exemple simple : advection-diffusion $\frac{\partial \phi}{\partial t} + (\mathbf{v} \cdot \nabla) \phi - \lambda \Delta \phi = 0$ avec $\mathbf{v} = (1, 1)^T$

- ▼ N_{obs} points d'observation ϕ_{obs}
- N_{res} points de collocation



PINNs correspondent au pipeline “**ANN-PDE-regularizing**” [Kim et al. 21]




In fine : $\phi \simeq \mathcal{N}(x, y, t)$

PINNs pour la reconstruction d'écoulements

Reconstruction des courants de gravité

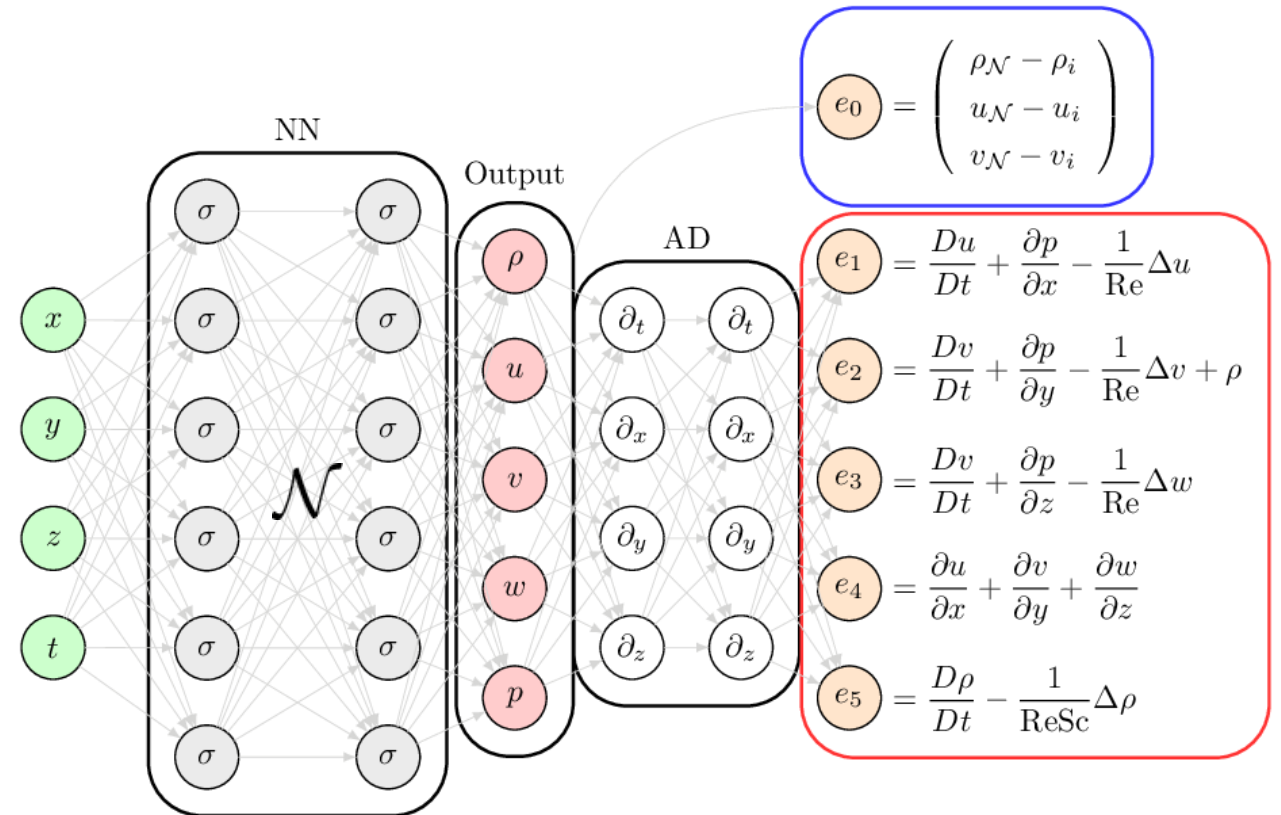
$$(\rho, u, v, w, p) \simeq \mathcal{N}(x, y, z, t)$$



Représentation des données (cas PLIF-PIV)

■ points d'observation

● points de collocation



$$\mathcal{L} = \underbrace{\frac{1}{2N_{\text{obs}}} \sum_{\blacksquare} e_0^2}_{\mathcal{L}_{\text{obs}}} + \underbrace{\frac{1}{2N_{\text{res}}} \sum_{\bullet} \sum_{k=1}^5 e_k^2}_{\mathcal{L}_{\text{res}}}$$

- Pour les problèmes « directs » :

$$\text{EDP+C.L.+C.I. connues} \rightarrow (\rho, u, v, w, p)$$

$$\mathcal{L} = \mathcal{L}_{\text{res}} + \mathcal{L}_{\text{C.L.}} + \mathcal{L}_{\text{C.I.}}$$

- Et les problèmes « indirects » :

- Reconstruction d'écoulement :

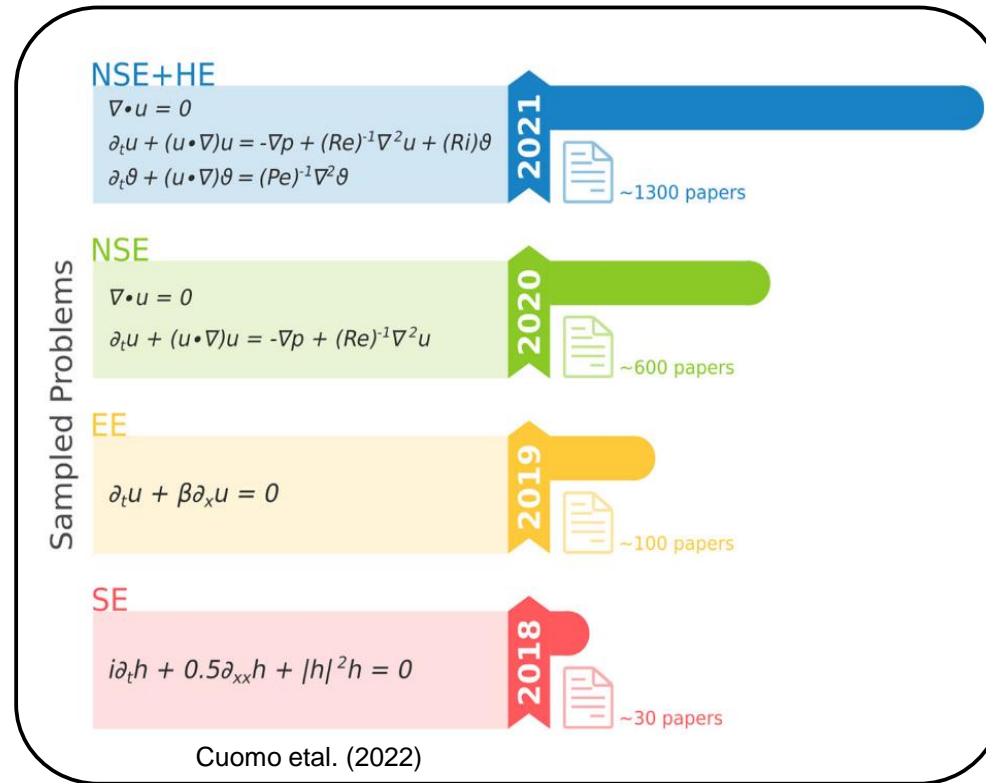
$$\text{EDP} + (\rho, u, v)_{\text{obs}} \rightarrow (\rho, u, v, w, p)$$

$$\mathcal{L} = \mathcal{L}_{\text{res}} + \mathcal{L}_{\text{obs}}$$

- « Découverte » de modèles :

$$\left\{ \begin{array}{l} (u, v, p)_{\text{obs}} + \frac{D\mathbf{v}}{Dt} = \nabla \cdot \boldsymbol{\sigma} \\ \text{avec } \boldsymbol{\sigma} = \alpha p \mathbf{I} + \beta (\nabla \mathbf{v} + \nabla^T \mathbf{v}) + \gamma \frac{1}{p} \nabla(p\mathbf{v}) \end{array} \right.$$

$$\alpha = -1, \beta = \frac{1}{Re}, \gamma = 0$$




Énorme potentiel pour
trouver des modèles de
fermeture !

Base de données & Cas tests étudiés

Données synthétiques pour la reconstruction d'écoulement

Cas test : Lock-Exchange $Re = 5500$ et $Sc = 1$ avec hypothèse de Boussinesq



$$\begin{aligned} \frac{\partial \mathbf{v}}{\partial t} + (\mathbf{v} \cdot \nabla) \mathbf{v} + \nabla p - \frac{1}{Re} \nabla^2 \mathbf{v} + \rho \mathbf{e}_y &= 0 \\ \frac{\partial \rho}{\partial t} + (\mathbf{v} \cdot \nabla) \rho - \frac{1}{Re Sc} \nabla^2 \rho &= 0 \\ \nabla \cdot \mathbf{v} &= 0 \end{aligned}$$


Résolu par code spectral Nek5000

Données de référence $\mathcal{D}^{\text{ref}} = \left\{ \rho_{\mathbf{x}}, u_{\mathbf{x}}, v_{\mathbf{x}}, w_{\mathbf{x}}, p_{\mathbf{x}} \right\}$ acquises dans Ω_{obs} pour $t \in [8, 10]$

domaine spatio-temporel discrétisé unif. $50 \times 76 \times 51 \times 18$

$$|\mathcal{D}^{\text{ref}}| = 14M$$





- Construction de dispositifs exp. synthétiques
- Pour mesurer l'erreur de l'inférence



Isovaleurs de ρ à $z = \frac{l_z}{2}$

- **3D-LIF** : mes. volumétriques de ρ dans Ω_{obs}
experimental cost : ★★★★★
- **PLIF-PIV** : (ρ, u, v) at $z = \frac{l_z}{2}$
experimental cost : ★★★
- **LAT** : $\bar{\rho} = \frac{2}{l_z} \int_0^{\frac{l_z}{2}} \rho(\cdot, z) dz$
 $\bar{\rho}_N \simeq Quad_z(\rho_N)$ (trapèzes)
$$\mathcal{L}_{data} = \frac{1}{N_{data}} \sum_{i=1}^{N_{data}} ||Quad_z(\rho_N) - \bar{\rho}_i||^2$$

experimental cost : ★
- **LAT-2PIV** : **LAT** + (u, v) en $z = \frac{l_z}{2}$ et $z = \frac{l_z}{4}$
experimental cost : ★★★



Résultats numériques

Erreur globale de l'inférence par PINN

Calcul de la norme L2 de l'erreur dans l'ensemble du domaine spatio-temporel
$$\epsilon_\rho = \frac{100}{\sup_{\Omega} |\rho_{\mathbf{x}}|} \sqrt{\frac{\sum_{\mathbf{x} \in \Omega} |\rho_{\mathcal{N}}(\mathbf{x}) - \rho^{\text{ref}}(\mathbf{x})|^2}{|\Omega|}}$$


Réseaux de 10 couches cachées de 200 neurones, arrêt entraînement à 300 epochs, temps GPU ~ 24 h

Cas	ϵ_ρ	ϵ_u	ϵ_v	ϵ_w	ϵ_p	$\bar{\epsilon}$	Coût	Data
3D-LIF	0.53%	5.99%	5.00%	4.08%	3.91%	3.90%	★★★★★	2800000
LAT	9.98%	14.49%	26.20%	11.24%	8.47%	14.07%	★	252000
PLIF-PIV	19.99%	18.20%	18.83%	8.87%	5.12%	14.20%	★★★	756000
LAT-2PIV	5.34%	3.31%	6.36%	3.43%	1.23%	3.93%	★★★	1260000

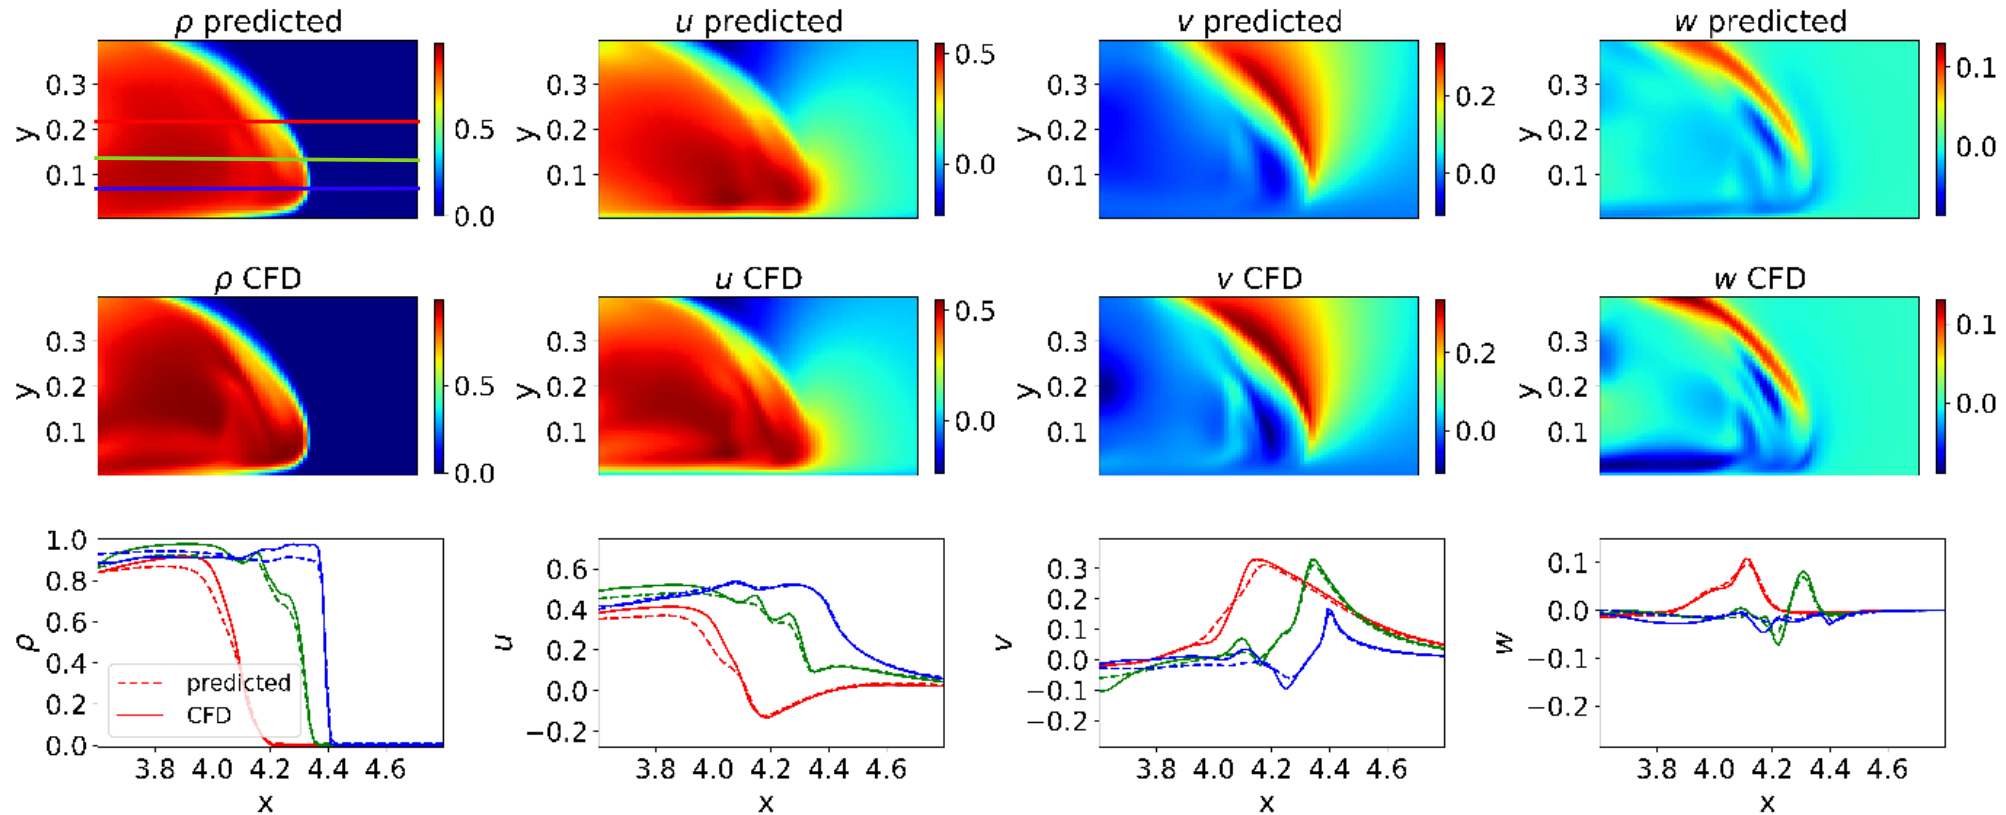
Conclusions partielles :

- **3D-LIF** erreur < 6 % pour chaque cas
- **LAT** aussi précise que **PLIF-PIV** pour une fraction du coût expé (et 3 fois moins de données)
- **LAT-2PIV** permet une inférence aussi précise que **3D-LIF** (tests à venir dans l'OS)

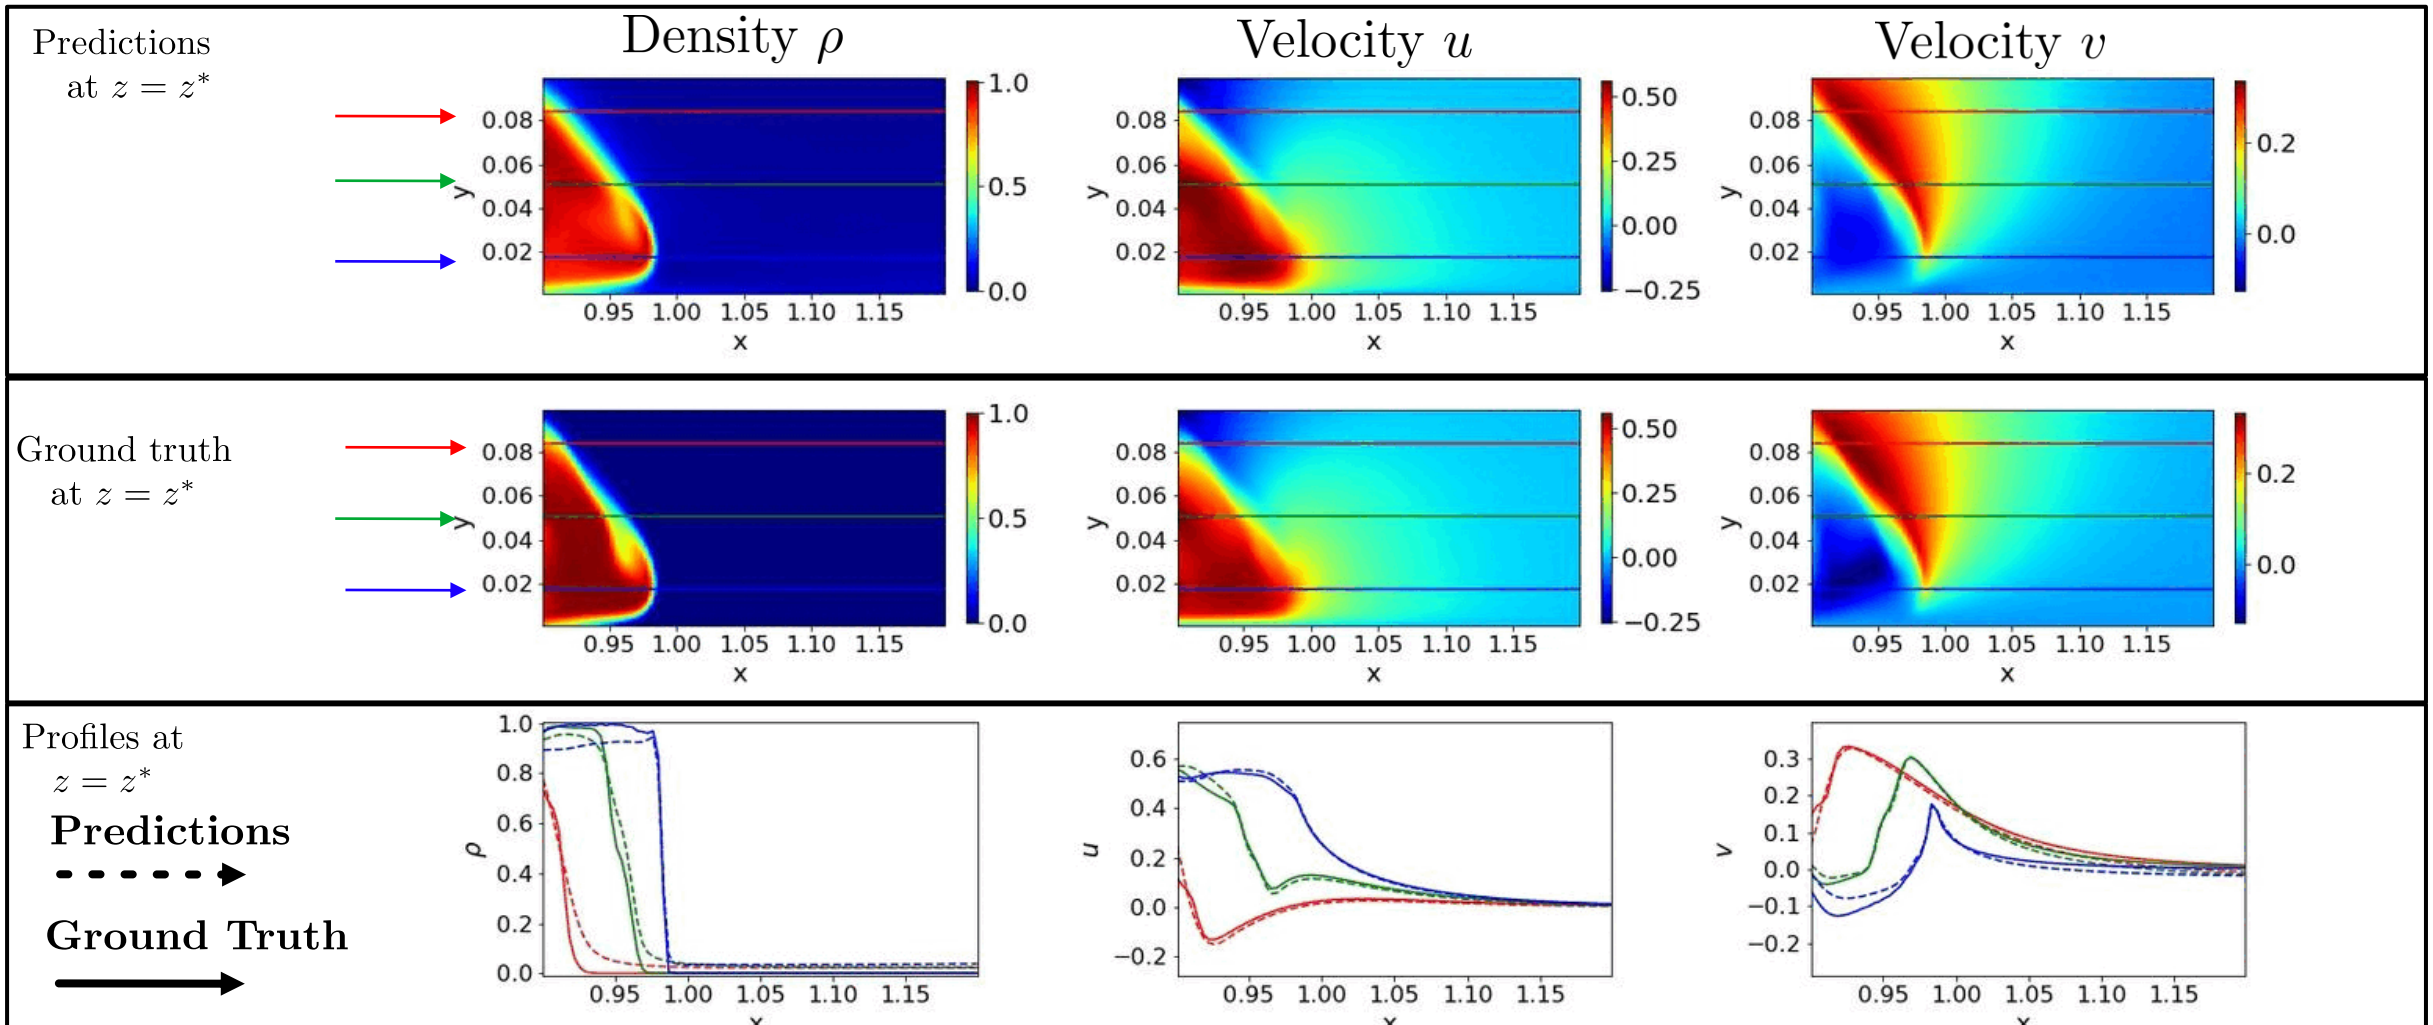
Profils des champs prédits en $z=0.16$ i.e. proche plan de symétrie




Profils des champs prédits en $z=0.05$ i.e. proche paroi




Profiles horizontaux au cours du temps




Predictions
at $z = z^*$



Ground truth
at $z = z^*$



Profiles at
 $z = z^*$
 Predictions
 - - - - -
 Ground Truth
 ————

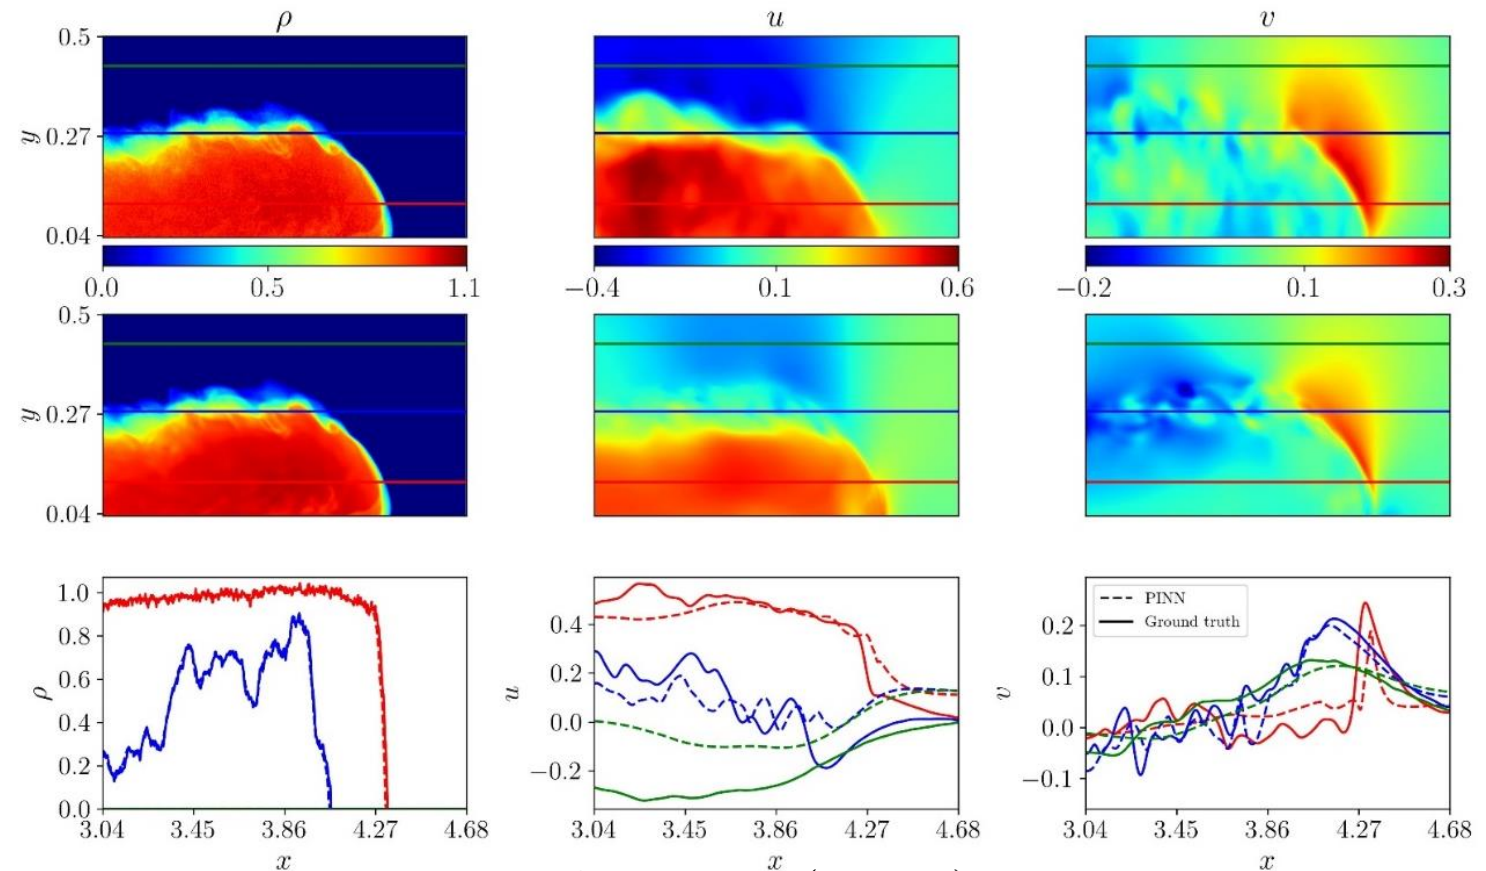


Une preuve de concept donnée sur des données synthétiques [Delcey et al. PoF 2023] :

- capacité de reconstruction jusqu'aux parois
- faible sensibilité au bruit (non-présenté)
- LAT-2PIV un dispositif prometteur pour l'étude exp. des courants de gravité

Application aux données expérimentales (soumis à Ocean Modelling) :

- validation partielle (équations 2D)
- donne accès à la pression



LAT-PIV : $(\bar{\rho}, u, v)$