

Fermeture pour les équations de Vlasov-Poisson par apprentissage profond

L. Bois^{1,2} E. Franck^{1,2} L. Navoret^{1,2} V. Vigon¹

¹ Institut de Recherche Mathématique Avancée, UMR 7501,
Université de Strasbourg et CNRS, 7 rue René Descartes,
67000 Strasbourg, France

² INRIA Nancy-Grand Est, TONUS Project, Strasbourg, France

CEA-Gamni, 26/01/21

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données

Réseaux de neurones

③ Résultats

Réseaux de neurones

Modèle fluide


Difficultés: stabilité et coût calcul

① Contexte physique et mathématique Différents modèles

② Protocole Génération des données Réseaux de neurones


③ Résultats Réseaux de neurones Modèle fluide Difficultés: stabilité et coût calcul

Modèle cinétique

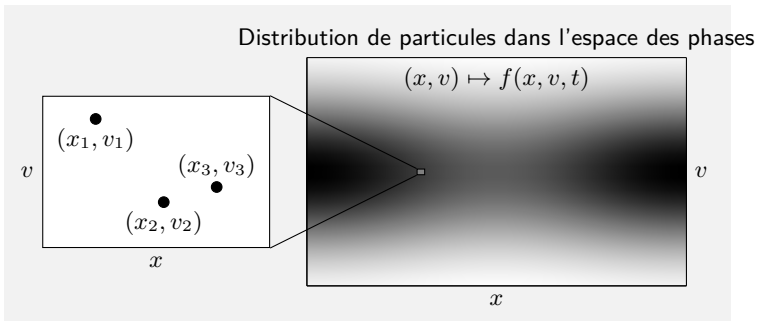


Modèle cinétique

Distribution de particules dans l'espace des phases



Modèle cinétique




Equation de Vlasov-Poisson:

$$(V) \quad \partial_t f + v \partial_x f - E \partial_v f = \frac{1}{\varepsilon} (M(f) - f)$$

$$(P) \quad E(x, t) \text{ donné (slide suivant)}$$

$E(x, t)$ champ électrique, $M(f)$ Maxwellienne de f , ε fréquence de collision.

Modèle cinétique



Equation de Vlasov-Poisson:

$$(V) \quad \partial_t f + v \partial_x f - E \partial_v f = \frac{1}{\varepsilon} (M(f) - f)$$

$$(P) \quad E(x, t) \text{ donné (slide suivant)}$$

$E(x, t)$ champ électrique, $M(f)$ Maxwellienne de f , ε fréquence de collision.

Côteux en 3D, puisqu'on résout une EDP en dimension 6.

Passage du cinétique au fluide

Modèle fluide: modèle sur des quantités macroscopiques.
Les quantités fluides ρ , u , T , q peuvent être calculés à partir des
moments en vitesse de la distribution f :

Passage du cinétique au fluide

Modèle fluide: modèle sur des quantités macroscopiques.
Les quantités fluides ρ , u , T , q peuvent être calculés à partir des
moments en vitesse de la distribution f :

$$\int f(x, v, t) dv = \rho(x, t) \quad \rho \text{ densité}$$

Passage du cinétique au fluide

Modèle fluide: modèle sur des quantités macroscopiques.

Les quantités fluides ρ , u , T , q peuvent être calculés à partir des moments en vitesse de la distribution f :

$$\int f(x, v, t) dv = \rho(x, t) \quad \rho \text{ densité}$$

$$\int f(x, v, t)v dv = \rho(x, t)u(x, t) \quad u \text{ vitesse moyenne}$$

Passage du cinétique au fluide

Modèle fluide: modèle sur des quantités macroscopiques.

Les quantités fluides ρ , u , T , q peuvent être calculés à partir des moments en vitesse de la distribution f :

$$\int f(x, v, t) dv = \rho(x, t) \quad \rho \text{ densité}$$

$$\int f(x, v, t)v dv = \rho(x, t)u(x, t) \quad u \text{ vitesse moyenne}$$

$$\int f(x, v, t)(v - u(x, t))^2 dv = \rho(x, t)T(x, t) \quad T \text{ température}$$

Passage du cinétique au fluide

Modèle fluide: modèle sur des quantités macroscopiques.

Les quantités fluides ρ , u , T , q peuvent être calculés à partir des moments en vitesse de la distribution f :

$$\int f(x, v, t) dv = \rho(x, t) \quad \rho \text{ densité}$$

$$\int f(x, v, t)v dv = \rho(x, t)u(x, t) \quad u \text{ vitesse moyenne}$$

$$\int f(x, v, t)(v - u(x, t))^2 dv = \rho(x, t)T(x, t) \quad T \text{ température}$$

$$\frac{1}{2} \int f(x, v, t)(v - u(x, t))^3 dv = q(x, t) \quad q \text{ flux de chaleur}$$

Passage du cinétique au fluide

Modèle fluide: modèle sur des quantités macroscopiques.

Les quantités fluides ρ , u , T , q peuvent être calculés à partir des moments en vitesse de la distribution f :

$$\int f(x, v, t) dv = \rho(x, t) \quad \rho \text{ densité}$$

$$\int f(x, v, t)v dv = \rho(x, t)u(x, t) \quad u \text{ vitesse moyenne}$$

$$\int f(x, v, t)(v - u(x, t))^2 dv = \rho(x, t)T(x, t) \quad T \text{ température}$$

$$\frac{1}{2} \int f(x, v, t)(v - u(x, t))^3 dv = q(x, t) \quad q \text{ flux de chaleur}$$

L'équation de Poisson donne une relation entre E et ρ :

$$(P) \quad E = -\partial_x \phi \quad , \quad \partial_{xx} \phi = \rho - \int \rho dx$$

Passage du cinétique au fluide

En calculant les moments en vitesse de Vlasov on obtient les équations d'Euler:

$$(V) \quad \longrightarrow \int_v \longrightarrow \begin{aligned} \partial_t \rho + \partial_x(\rho u) &= 0 \\ \partial_t(\rho u) + \partial_x(\rho u^2 + \rho T) &= -E\rho \\ \partial_t w + \partial_x(wu + \rho u T + q) &= -E\rho u \end{aligned}$$

Passage du cinétique au fluide

En calculant les moments en vitesse de Vlasov on obtient les équations d'Euler:

$$\begin{aligned} (V) \quad & \int_v \longrightarrow \quad \partial_t \rho + \partial_x(\rho u) = 0 \\ & \partial_t(\rho u) + \partial_x(\rho u^2 + \rho T) = -E\rho \\ & \partial_t w + \partial_x(wu + \rho u T + q) = -E\rho u \end{aligned}$$

Problème: trois équations, quatre variables. Comment on règle cela ? En ajoutant des moments ? La processus fait apparaître toujours des moments supplémentaires de f et cela ne suffit pas pour fermer le système.

Fermature

Le flux de chaleur (pas d'équation temporelle dessus) q est donné par:

$$q(x, t) = \frac{1}{2} \int f(x, v, t) (v - u(x, t))^3 dv.$$

Principe de la **fermeture**: on cherche une **approximation \hat{q} de q** basée sur les quantités ρ, u, T etc:

$$\hat{q}(\rho, u, T, \epsilon, ..)$$

Fermature

Le flux de chaleur (pas d'équation temporelle dessus) q est donné par:

$$q(x, t) = \frac{1}{2} \int f(x, v, t) (v - u(x, t))^3 dv.$$

Principe de la **fermeture**: on cherche une **approximation \hat{q} de q** basée sur les quantités ρ, u, T etc:

$$\hat{q}(\rho, u, T, \epsilon, ..)$$

Deux approches:

Fermature analytique : faire des hypothèses f pour calculer analytiquement une expression de \hat{q} basée sur ρ, u et T .

Fermature basée sur les données : on simule f pour générer plusieurs $(\rho, u, T, \epsilon; q)$, et trouver une régression $(\rho, u, T, \epsilon) \mapsto \hat{q}$.

Fermetures analytiques

La fermeture la plus simple est celle d'*Euler*

$$\hat{q} = 0,$$

obtenue à partir de l'hypothèse $f = M(f) + O(\varepsilon)$ en tronquant les termes en ε .

Fermetures analytiques

La fermeture la plus simple est celle d'*Euler*

$$\hat{q} = 0,$$

obtenue à partir de l'hypothèse $f = M(f) + O(\varepsilon)$ en tronquant les termes en ε .

La seconde fermeture est celle de *Navier-Stokes*

$$\hat{q} = -\frac{3}{2}\varepsilon\rho T\partial_x T$$

obtenue avec l'approximation $f = M(f) + \varepsilon g + O(\varepsilon^2)$.

Elle est valide pour des petits ε .

Il s'agit d'une fermeture **locale**: on obtient $\hat{q}(x)$ à partir de $\rho(x)$, $u(x)$ et $T(x)$.

Fermatures analytiques

La fermeture la plus simple est celle d'*Euler*

$$\hat{q} = 0,$$

obtenue à partir de l'hypothèse $f = M(f) + O(\varepsilon)$ en tronquant les termes en ε .

La seconde fermeture est celle de *Navier-Stokes*

$$\hat{q} = -\frac{3}{2}\varepsilon\rho T\partial_x T$$

obtenue avec l'approximation $f = M(f) + \varepsilon g + O(\varepsilon^2)$.

Elle est valide pour des petits ε .

Il s'agit d'une fermeture **locale**: on obtient $\hat{q}(x)$ à partir de $\rho(x)$, $u(x)$ et $T(x)$.

Autre fermeture: *Hammitt-Perkins* qui permet de récupérer l'amortissement Landau.

Il s'agit d'une **fermeture non-locale**: on obtient $\hat{q}(x)$ en fonction de $\rho(\cdot)$, $u(\cdot)$ et $T(\cdot)$.


Fermeture basée sur les données

Deux phases de calcul:

Fermeture basée sur les données

Deux phases de calcul:


Phase hors-ligne




Fermeture basée sur les données

Deux phases de calcul:

Phase hors-ligne



Phase en ligne



Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données
Réseaux de neurones

③ Résultats

Réseaux de neurones
Modèle fluide
Difficultés: stabilité et coût calcul

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données

Réseaux de neurones

③ Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et coût calcul

Génération des données

On considère une **fermeture globale** : $\hat{q}(\rho(\cdot), u(\cdot), T(\cdot), \epsilon)$

Les données sont calculées avec cinétique




kinetic
model

Génération des données

On considère une **fermeture globale** : $\hat{q}(\rho(\cdot), u(\cdot), T(\cdot), \epsilon)$


On prend un nombre de Knudsen ϵ , une condition initiale f_0 , et 20 temps t_1, \dots, t_{20} .



Génération des données

On considère une **fermeture globale** : $\hat{q}(\rho(\cdot), u(\cdot), T(\cdot), \epsilon)$


Les quantités sont générés aléatoirement. En particulier, $\epsilon \in [0.01, 1]$.



Génération des données

On considère une **fermeture globale** : $\hat{q}(\rho(\cdot), u(\cdot), T(\cdot), \epsilon)$


Le modèle donne f_1, \dots, f_{20}
aux temps t_1, \dots, t_{20} respectivement.



Génération des données


On considère une **fermeture globale** : $\hat{q}(\rho(\cdot), u(\cdot), T(\cdot), \epsilon)$

Finalement les fonctions ρ , u , T et q sont calculées et stockées avec ϵ .



Génération des données

On considère une **fermeture globale** : $\hat{q}(\rho(\cdot), u(\cdot), T(\cdot), \epsilon)$



Deux jeux de données ($500 \times 20 = 10\,000$) sont générés: un pour l'entraînement, et un pour la validation.

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données

Réseaux de neurones


③ Résultats

Réseaux de neurones

Modèle fluide


Difficultés: stabilité et coût calcul

Un *réseau de neurones* une fonction particulière non-linéaire dépendante d'un grand nombre de **paramètres**.



Entrainement

L'*entrainement* d'un réseau est un processus d'optimisation qui permet d'ajuster les paramètres.



Fermeture pour les équations de Vlasov-Poisson par apprentissage profond

E. Franck

Contexte physique et mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

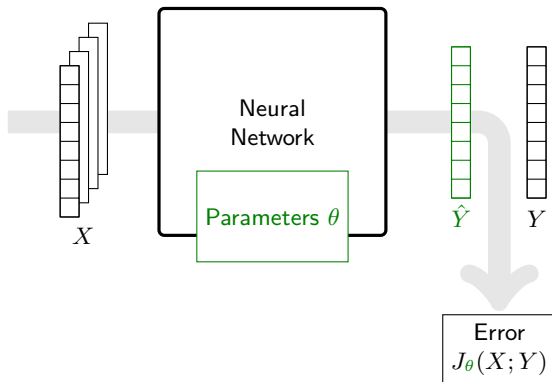
Difficultés: stabilité et coût calcul

Conclusion

Extra

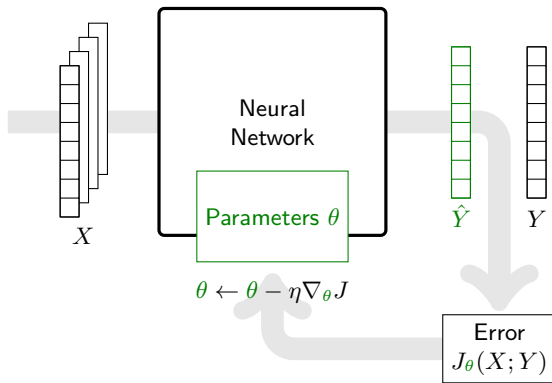
Entrainement

pour chaque couple (X, Y) dans l'ensemble de données,
une erreur est calculée entre la prédiction \hat{Y} et la solution Y .




Entrainement

L'erreur permet d'ajuster les paramètres avec un algorithme de gradient.




Structure générale

L'entrée passe successivement dans des *couches* cachées.



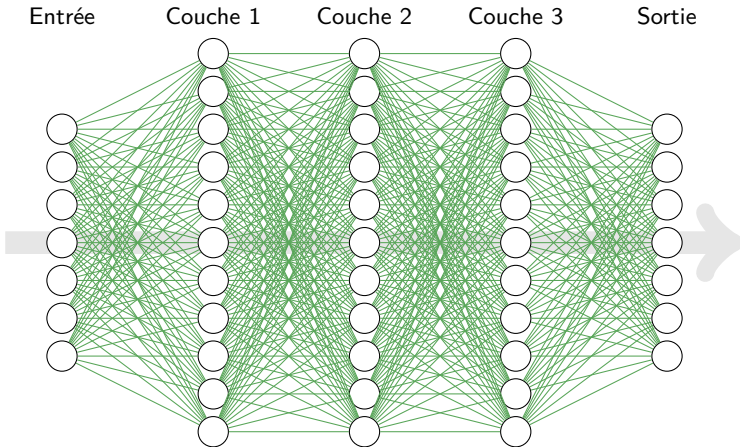
Structure générale

Chaque arête contient un **paramètre** qui peut être ajusté dans l'entraînement.



Structure générale

Chaque neurone applique une fonction d'activation nonlinéaire à son résultat.



Convolution

Réseaux convolutifs: étape linéaire basée sur des **convolutions contre des petits noyaux**.

Avantages: **Réseau de neurones creux**. Très efficace pour les **données structurées** (données spatiale sur grilles cartésiennes, images, signaux temporelles etc).


Exemple : détection de discontinuités dans des fonctions.
On génère 1000 fonctions avec des modes de Fourier choisis aléatoirement. On ajoute une discontinuité aléatoire. 890 (entraînement), 110 (pour monitorer le sur-apprentissage).

But: classifier avec/sans discontinuité:

$$f(x, y) = \left(\sum_{i=1}^5 \alpha_i \cos(2\pi k_i x) \sin(2\pi l_i y) \right) Disc(x, y)$$

avec k_i, l_i aléatoire entre 0 et 4, $\alpha_i \in [-1, 1]$ et $Disc$ une discontinuité aléatoire. Maillage: 48×48 .

Convolution II



Test: 200 fonctions supplémentaires.

Réseau totalement connecté (4 couches) 1: 566 000 poids. Efficacité
 $\approx 0.5 - 0.6$.


Réseau totalement connecté (4 couches) 2: 230 000 poids. Efficacité
 $\approx 0.5 - 0.6$.

CNN (3 couches Conv, 3 couches denses) : 41 300 poids. Efficacité
 $\approx 0.8 - 0.92$.


Convolution

Base


Couche convolutive:




Les paramètres sont localisés dans le noyau.




Le produit avec le noyau applique un filtre.



Le produit avec le noyau applique un filtre.




Le produit avec le noyau applique un filtre.



Convolution

Padding


Pour obtenir une sortie de même taille: "padding".



Convolution

Entrée à plusieurs vecteurs


Entrées multiples: couleurs dans une image...



Convolution

Entrée à plusieurs vecteurs


La sortie est donnée par la somme des produits scalaires.



Convolution


Sortie à plusieurs vecteurs

On peut appliquer plusieurs filtres (noyau).




"Sous et sur échantillonnage"

On utilise une convolution différente pour diminuer la taille du signal.




"Sous et sur échantillonnage"

Noyau de taille 2 avec un *pas* de 2




"Sous et sur échantillonnage"

En négligeant les bords, sortie = entrée / pas




"Sous et sur échantillonnage"

En négligeant les bords, sortie = entrée / pas




"Sous et sur échantillonnage"

Ici la sortie est deux fois échantillonnée que l'entrée.




"Sous et sur échantillonnage"

L'opération inverse:




"Sous et sur échantillonnage"

on duplique les coefficients.




"Sous et sur échantillonnage"

On applique une convolution de taille 2 pour régulariser.




"Sous et sur échantillonnage"

On applique une convolution de taille 2 pour régulariser.




"Sous et sur échantillonnage"

On applique une convolution de taille 2 pour régulariser.



"Sous et sur échantillonnage"

On a, au final, doublé la taille.




Réseau V-Net

On utilise une version 1D de l'architecture V-Net, pour la fermeture non-locale.



Réseau V-Net

On applique deux couches de convolutions pour obtenir d (profondeur) signaux de sortie. Activation: softplus.




⊗ Convolution

▷ Softplus

Réseau V-Net

On sous échantillonne,
on applique deux convolutions en multipliant par deux la profondeur.



↗ Convolution




Down-sampling

▷ Softplus

⋯→ Small shortcut

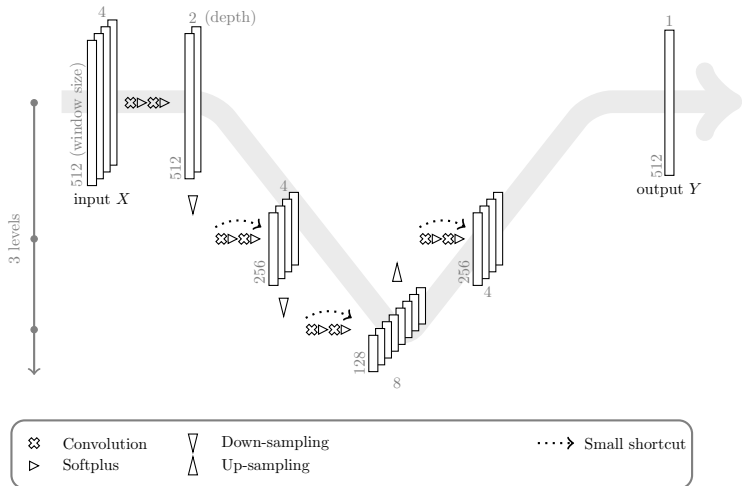
Réseau V-Net

L'opération est répétée sur ℓ niveaux.




Réseau V-Net

On applique les opérations inverses pour obtenir la résolution d'origine.




Réseau V-Net

On applique les opérations inverses pour obtenir la résolution d'origine.




Réseau V-Net

A l'aide d'une moyenne pondérée pour obtenir la sortie.



Réseau V-Net

On moyenne les signaux avant et après reconstruction



Hyper-paramètres

Hyper-paramètres	Valeur
taille de l'entrée	512
nombre de niveau (ℓ)	5
profondeur initiale (d)	4
taille des noyaux (p)	11
fonction d'activation	softplus

Nombre total de paramètres: 161 937

Préparation des données (standardisation, découpage, normalisation) en
annexe.

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données

Réseaux de neurones

③ Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et coût calcul

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données

Réseaux de neurones


③ Résultats

Réseaux de neurones

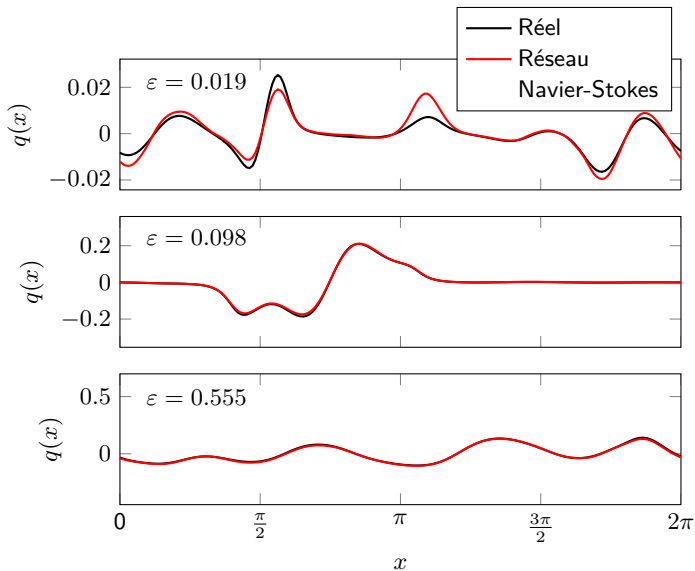
Modèle fluide

Difficultés: stabilité et coût calcul


Exemples issus du jeu de données test




Exemples issus du jeu de données test



Exemples issus du jeu de données test



Influence de ε



Comme attendu l'erreur explose pour Navier-Stokes quand ε augmente. L'erreur semble quasiment uniforme pour le réseau (moins bon pour les petits ε).

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données
Réseaux de neurones

③ Résultats

Réseaux de neurones
Modèle fluide
Difficultés: stabilité et coût calcul

On compare l'énergie électrique $\mathcal{E}(t) = \int E(x, t)^2 dx$
dans les modèles suivants:

———— Cinétique

Dans la suite: Il y a des différences entre "le modèle cinétique" and "le modèle fluide+cinétique". Cela semble provenir des méthodes numériques. **On peut pas faire mieux que:"fluide + cinétique"**.

On compare l'énergie électrique $\mathcal{E}(t) = \int E(x, t)^2 dx$
dans les modèles suivants:

————— Cinétique

----- Fluide+Cinétique: $\hat{q} = q$

Dans la suite: Il y a des différences entre "le modèle cinétique" and "le modèle fluide+cinétique". Cela semble provenir des méthodes numériques. **On peut pas faire mieux que:"fluide + cinétique"**.

Modèle fluide

On compare l'énergie électrique $\mathcal{E}(t) = \int E(x, t)^2 dx$
dans les modèles suivants:

————	Cinétique
-----	Fluide+Cinétique: $\hat{q} = q$
-----	Fluide+Réseau: $\hat{q} = C_{\theta}(\varepsilon, \rho, u, T)$

Dans la suite: Il y a des différences entre "le modèle cinétique" and "le modèle fluide+cinétique". Cela semble provenir des méthodes numériques. **On peut pas faire mieux que: "fluide + cinétique"**.



Modèle fluide

On compare l'énergie électrique $\mathcal{E}(t) = \int E(x, t)^2 dx$ dans les modèles suivants:

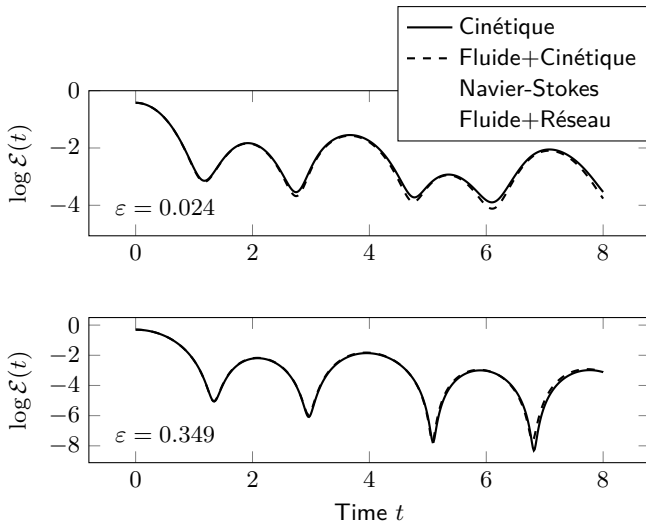
- Cinétique
- - - - - Fluide+Cinétique: $\hat{q} = q$
- - - - - Fluide+Réseau: $\hat{q} = C_\theta(\varepsilon, \rho, u, T)$
- - - - - Navier-Stokes: $\hat{q} = -\frac{3}{2}\varepsilon\rho T\partial_x T$

Dans la suite: Il y a des différences entre "le modèle cinétique" and "le modèle fluide+cinétique". Cela semble provenir des méthodes numériques. **On peut pas faire mieux que: "fluide + cinétique"**.


Exemples (1/2)




Exemples (1/2)



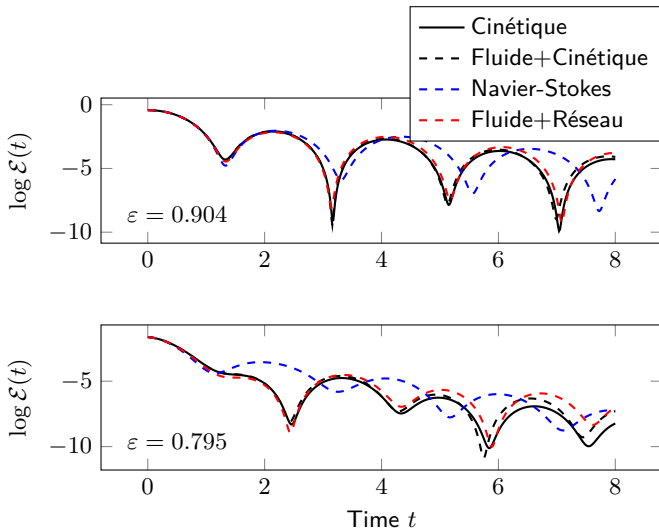
Exemples (1/2)




Exemples (1/2)



Exemples (2/2)



Influence de ε



L'erreur du modèle "Fluide+Réseau" augmente de façon similaire à celle du modèle "Fluide+Cinétique". Dérive de l'erreur expliquée par des problèmes numériques ?

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

Extra

① Contexte physique et mathématique

Différents modèles

② Protocole

Génération des données
Réseaux de neurones

③ Résultats

Réseaux de neurones
Modèle fluide
Difficultés: stabilité et coût calcul

Schéma :

- On calcule Q_θ^n avec ρ^n , u^n et T^n
- On calcule l'approximation de $\partial_x Q_\theta^n$
- On calcule le modèle fluide avec un schéma explicite $\partial_x Q_\theta^n$ traité comme un terme source.


On ne peut pas assurer que Q_θ^n et $\partial_x Q_\theta^n$ ne génèrent pas des oscillations numériques.

Les oscillations peuvent détruire **la stabilité du schéma complet**. C'est le cas en pratique.

1ère approche (simple): Régularisation Gaussienne.


Exemple

Exemple de flux de chaleur particulièrement oscillant.




Exemple

On régularise la prédiction avec une convolution et un noyau Gaussien de paramètre σ .




Analyse de stabilité

Première figure: erreur de prédiction en fonction du lissage.





Analyse de stabilité

Cette deuxième figure montre la proportion croissante de simulations réussies à mesure que le lissage augmente.



Analyse de stabilité

Nous avons choisi $\sigma \simeq 0.06$,
car cela semble être suffisant pour assurer la stabilité
sans pour autant diminuer la précision.



Coût CPU

Temps moyen pour des simulations avec $T_f = 8$ avec $N_x = 512$ et
 $N_v = 101$:

Cinétique	70 sec
Fluide+Cinétique	78 sec
Fluide+Réseau	74 sec
Navier-Stokes	3 sec

Une partie du temps de calcul peut venir de problème d'implémentation
(communications CPU/GPU)

Complexité selon la dimension:

V-Net 1D	$O(2^\ell d^2 p N_x)$
V-Net 2D	$O(\ell d^2 p^2 N_x^2)$
V-Net 3D	$O(d^2 p^3 N_x^3)$
Cinétique m D	$O(N_v^m N_x^m)$

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones


Modèle fluide

Difficultés: stabilité et
coût calcul

Conclusion

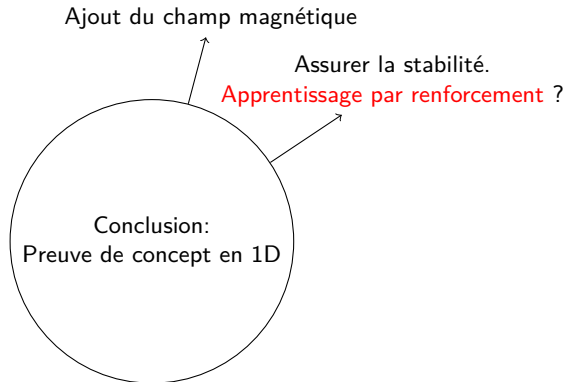
Extra

Conclusion



Conclusion:
Preuve de concept en 1D

Conclusion



Fermeture pour les équations de Vlasov-Poisson par apprentissage profond

E. Franck

Contexte physique et mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

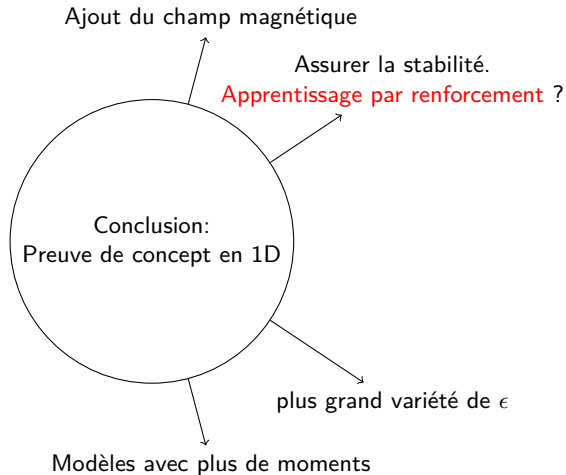
Modèle fluide

Difficultés: stabilité et coût calcul

Conclusion

Extra

Conclusion



Fermeture pour les équations de Vlasov-Poisson par apprentissage profond

E. Franck

Contexte physique et mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

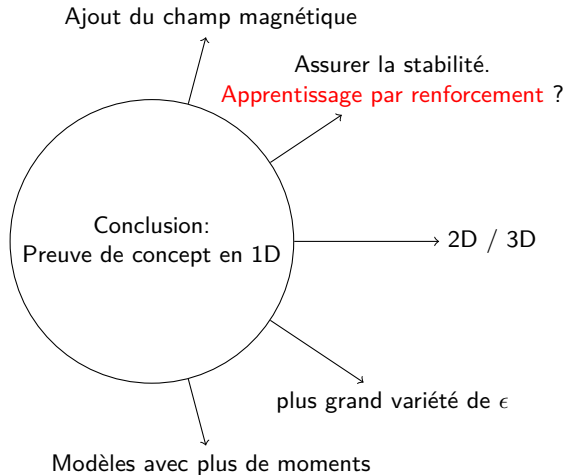
Modèle fluide

Difficultés: stabilité et coût calcul

Conclusion

Extra

Conclusion



Fermeture pour les équations de Vlasov-Poisson par apprentissage profond

E. Franck

Contexte physique et mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et coût calcul

Conclusion

Extra

Fermeture pour les
équations de
Vlasov-Poisson par
apprentissage
profond

E. Franck

Contexte physique et
mathématique

Différents modèles

Protocole

Génération des données

Réseaux de neurones

Résultats

Réseaux de neurones

Modèle fluide

Difficultés: stabilité et
coût calcul



Conclusion

Extra

Extra

Hyper-paramètres


Résultats pour des jeux d'hyper-paramètres




Préparation des données

Préparation des données.

Training




Prediction




Préparation des données

Les données sont découpées (SI) en plusieurs morceaux.

Training





Prediction





Préparation des données

Pour l'entraînement, la sortie de référence (SI) est aussi découpée.





Préparation des données

Pour la prédiction, la sortie est reconstruite (R) à partir des morceaux.





Préparation des données

Les données sont standardisées (S).





Préparation des données

Pour l'entraînement, la sortie de référence est normalisée (N).



Préparation des données

Pour la prédiction, on applique la normalisation inverse (I).



- ① Electric field:

$$E = -\partial_x \phi, \quad \partial_{xx} \phi = \rho - \int_0^L \rho dx$$

Finite difference method.

- ② Transport:

$$\partial_t f + v \partial_x f - E \partial_v f = 0$$

Discretization in velocity:

$$\frac{\mathbf{f}^{n+1} - \mathbf{f}^n}{\Delta t} + \Lambda \partial_x \mathbf{f}^n + EB(\mathbf{f}^n) = 0$$

Finite volume method with upwind flux.

- ③ Collision operator:

$$\partial_t f = \frac{1}{\varepsilon} (M(f) - f)$$

Implicit scheme.

① Electric field:

$$E = -\partial_x \phi, \quad \partial_{xx} \phi = \rho - \int_0^L \rho dx$$

Finite difference method.

② Fluid equations:

$$\partial_t \mathbf{U} + \partial_x \mathbf{F}(\mathbf{U}) = -E\mathbf{H}(\mathbf{U}),$$

$$\mathbf{U} = (\rho, \rho u, w), \quad \mathbf{F}(\mathbf{U}) = (\rho u, \rho u^2 + p, wu + pu + q), \quad \mathbf{H}(\mathbf{U}) = (0, \rho, \rho u)$$

Finite volume method with local Lax-Friedrichs numerical flux and explicit scheme in time.

$$\frac{\mathbf{U}_i^{n+1} - \mathbf{U}_i^n}{\Delta t} + \frac{\mathbf{F}(\mathbf{U})_{i+\frac{1}{2}}^n - \mathbf{F}(\mathbf{U})_{i-\frac{1}{2}}^n}{\Delta x} = -E_i^n \mathbf{H}(\mathbf{U})_i^n$$

- ① Electric field:

$$E = -\partial_x \phi, \quad \partial_{xx} \phi = \rho - \int_0^L \rho dx$$

Finite difference method.

- ② First two fluid equations: same as Euler
③ Third fluid equation:

$$\partial_t w + \partial_x (wu + pu) - \frac{3}{2} \varepsilon \partial_x (p \partial_x T) = -E \rho u$$

with $w = \frac{1}{2} \rho u^2 + \frac{1}{2} \rho T$

Finite difference approximation for $\partial_x (p \partial_x T)$ and implicit scheme in time.