



HAL
open science

Une nouvelle approche combinant l'apprentissage profond et la modélisation stochastique pour extraire les propriétés en 3D des écoulements multiphasiques à partir d'images de projection en 2D

Kassem Dia, Fabrice Lamadie, Johan Debayle

► To cite this version:

Kassem Dia, Fabrice Lamadie, Johan Debayle. Une nouvelle approche combinant l'apprentissage profond et la modélisation stochastique pour extraire les propriétés en 3D des écoulements multiphasiques à partir d'images de projection en 2D. CFTL 2024 - Congrès Francophone de Techniques Laser, Sep 2024, Lyon, France. hal-04708960

HAL Id: hal-04708960

<https://hal.science/hal-04708960v1>

Submitted on 25 Sep 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Une nouvelle approche combinant l'apprentissage profond et la modélisation stochastique pour extraire les propriétés en 3D des écoulements multiphasiques à partir d'images de projection en 2D

Kassem DIA¹, Fabrice LAMADIE^{1*}, Johan DEBAYLE²

¹CEA, DES, ISEC, DMRC, Univ Montpellier, Marcoule, France

²MINES Saint-Etienne, SPIN/LGF UMR CNRS 5307, 158 cours Fauriel, Saint-Etienne, France

*(auteur correspondant : : fabrice.lamadie@cea.fr)

Résumé - Dans cette communication une nouvelle approche de traitement d'image pour les écoulements denses est introduite. Elle est basée sur la combinaison entre une modélisation par géométrie stochastique en 3D et des algorithmes d'apprentissage automatique. Le modèle stochastique simule numériquement des champs de particules 3D semblables aux champs expérimentaux, ce qui permet de créer d'énormes ensembles de données d'images 2D synthétiques labélisées avec leurs propriétés géométriques 3D. Ces jeux de données permettent ensuite d'entraîner des réseaux neuronaux convolutionnels (CNN) à prédire les propriétés 3D à partir d'images 2D. L'approche a d'abord été évaluée sur des images générées numériquement à l'aide du modèle stochastique, où les propriétés 3D telles que la fraction volumique, la distribution de taille des particules (pour les sphères) ou la distribution de l'axe principal et du rapport d'élongation (pour les ellipsoïdes) ont été correctement retrouvées, y compris dans le cas d'images à très forte densité d'objets. L'approche a ensuite été appliquée expérimentalement à deux écoulements réels : une suspension polydisperse de billes de PMMA calibrées puis un écoulement gaz/liquide

1. Introduction

Les réacteurs gaz-liquide, notamment les colonnes à bulles, sont des dispositifs couramment utilisés dans les industries chimiques et biochimiques. Ils ont fait l'objet d'une abondante littérature, décrivant des études numériques ou expérimentales [1, 2], et ont conduit à de nombreux développements de techniques instrumentales, en particulier dans le domaine de l'imagerie directe et du traitement d'image afin de caractériser géométriquement leur phase dispersée.

Ces différents traitements d'images peuvent être classés en deux catégories principales :

1. Les méthodes déterministes qui reposent principalement sur la segmentation, la reconnaissance de motifs, et, plus récemment, sur l'apprentissage automatique pour caractériser les images [3, 4, 5]. Elles sont généralement rapides mais sont moins efficaces pour caractériser des écoulements complexes (densités de particules élevées, amas...).
2. Les approches stochastiques qui utilisent des modèles géométriques capables de générer un grand nombre d'images numériques à partir de champs de particules 3D modélisés. Ces modèles peuvent alors être optimisés par des fonctions de coût afin de converger vers les images réelles, et retrouvent alors les caractéristiques géométriques moyennes des particules observées [6, 7] y compris pour des densités d'objets importantes dans les images.

Cette communication présente une nouvelle approche dans laquelle un algorithme d'apprentissage profond est combiné avec des modèles de géométrie stochastique pour extraire des propriétés 3D à partir d'images projetées 2D du système particulaire. Le modèle géométrique stochastique 3D est utilisé pour générer un grand ensemble d'images synthétiques 2D labélisées

avec les propriétés géométriques 3D du champ de particules et ayant les mêmes propriétés géométriques que les images expérimentales. Ce modèle peut être utilisé pour reproduire n'importe quel champ de particules 3D et générer des projections 2D adaptées à l'entraînement d'un CNN. À notre connaissance, ce type d'approche n'a été utilisé auparavant que par Fend *et al.* [8] pour reconstruire des structures 3D hautement poreuses à partir de données de microscopie électronique à balayage par faisceau d'ions focalisé.

2. Principe du nouvel algorithme de traitement d'images

L'algorithme proposé combine donc approches stochastiques et méthodes d'apprentissage profond. Ses différentes étapes sont illustrées sur la figure 1. Pour que les images synthétiques soient représentatives, le système de particules simulé doit avoir les mêmes propriétés géométriques que le système étudié, c'est-à-dire être statistiquement représentatif du champ de particules observé. Dans ce but, le modèle stochastique 3D utilisé pour générer les images est un modèle de type "hard core shell", qui élimine toutes les interactions particule-particule et particule-paroi. Il est basé sur un processus ponctuel de type II de Matérn qui est lui-même un dérivé d'un processus ponctuel de Poisson homogène dans \mathbf{R}^d d'intensité λ muni d'une règle d'amincissement qui supprime le dernier point arrivé de toute paire de points située à moins d'une distance fixée. Le modèle génère des champs de particules à valeurs continues qui sont ensuite discrétisées lorsque les images synthétiques sont générées; la résolution des images peut ainsi être ajustée selon les besoins. Le processus complet est répété N fois pour constituer une base de données d'entraînement, et les propriétés géométriques de chaque modèle 3D (distribution de taille, distribution spatiale, etc.) sont toutes stockées avec les images 2D (cf. Figure 1, deuxième étape) en vue de leur labélisation. Il est à noter que les images d'entraînement doivent être du même

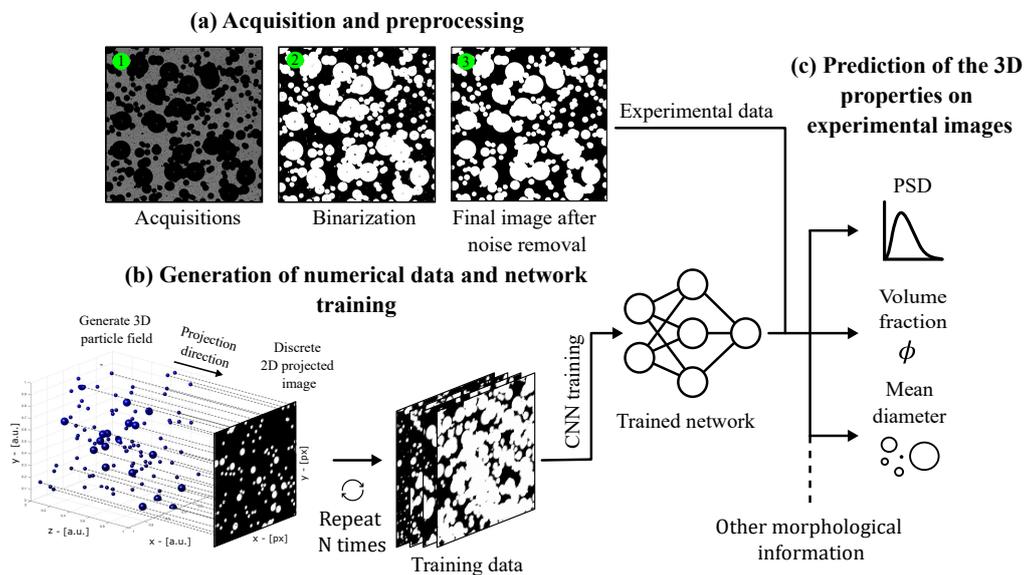


Figure 1 : Principe général de l'algorithme de traitement d'images

type que les images expérimentales, et que le modèle stochastique utilisé dans ce cas produit des images binaires. En conséquence, les images expérimentales ont été acquises en configuration bi-télécentrique avec un éclairage collimaté. Les images sont ensuite juste binarisées et débruitées avant d'être traitées par le CNN (voir Figure 1).

Le CNN est le deuxième pilier de l'approche proposée. Les réseaux neuronaux convolutifs

sont une classe d'algorithmes d'apprentissage profond conçus pour traiter des données avec une topologie en grille comme les images. Ces algorithmes sont classés dans la famille des algorithmes supervisés dans le sens où ils nécessitent à la fois des données et des labels pour être entraînés à effectuer une tâche donnée. Ils peuvent être utilisés pour résoudre des problèmes de classification et/ou de régression ; ici, seuls les CNN de régression ont été considérés, car le problème à traiter implique des valeurs continues. Un CNN se compose généralement de quatre types de couches. Une couche d'entrée qui traite les données fournies au réseau. Une (des) couche(s) d'extraction de caractéristiques ou couche convolutionnelle, qui combine(nt) des opérations de convolution, une fonction d'activation non linéaire (ReLU, sigmoïde,...) et un opérateur de pooling (par exemple max pooling, average pooling) pour extraire automatiquement les caractéristiques pertinentes des images. Une couche entièrement connectée (FC) à la fin du réseau, composée de plusieurs neurones interconnectés dont les poids sont ajustés pour apprendre au réseau à identifier les caractéristiques importantes. Et enfin, une couche de sortie, qui présente les prédictions. L'architecture utilisée dans ces travaux est de type VGG16.

3. Résultats et performances

3.1. Validation numérique

Après avoir défini le nombre de couches et les paramètres du CNN, les hyperparamètres optimaux du réseau ont été déterminés par optimisation bayésienne. Le jeu de données ($N=22\ 400$) utilisé pour entraîner le réseau a été divisé en trois catégories : un ensemble d'entraînement initial ($N_t=16\ 000$), un ensemble de validation ($N_v=2\ 000$) utilisé pour surveiller la performance globale du réseau à chaque itération, et un ensemble de test final ($N_e=4\ 400$) utilisé pour évaluer les performances du réseau entraîné. Toutes les images générées correspondaient à un volume de mesure de $25.79 \times 25.79 \times 53\ \text{mm}^3$ identique à celui de la configuration expérimentale. Les paramètres du modèle stochastique ont été choisis pour tenir compte de la variété des images expérimentales dans les applications réelles. L'intensité des particules, λ , a été ajustée entre 100 et 250, tandis que la distribution de taille des particules (PSD) a été modélisée par une fonction lognormale tronquée, $L_{tr}(\mu, \sigma^2, a, b)$, avec μ variant aléatoirement de -7.5 à 0.06, σ de 0 à 2.5, et a et b égaux respectivement à 0.005 et 0.08. Deux CNN, un pour prédire la fraction de phase dispersée et un pour prédire la distribution de taille, ont été entraînés sur un cluster équipé de cartes GPU, chacune dotée de 640 cœurs et d'une mémoire de 32 Go. Le processus d'entraînement a pris environ 30 minutes pour chaque CNN.

Les performances ont été évaluées en utilisant le jeu de données de test, avec des valeurs de fraction volumique, Φ , allant de 0,5% à 12,2%, et une distribution de la taille différente entre chaque image. Les résultats des prédictions comparés aux valeurs réelles sont présentés dans la Figure 2. La densité des particules dans les images augmente naturellement avec la fraction volumique, rendant les images plus complexes à traiter (cf. vignettes (c) et (a) de la Figure 2). Néanmoins, bien que les erreurs relatives des prédictions augmentent avec la fraction volumique, elles restent acceptables, confirmant la robustesse de l'approche. La Figure 2 montre par exemple que pour des valeurs de $\phi < 10\%$ (93% de la surface occupée dans les images), plus de 77% des prédictions du réseau se situent dans l'intervalle de confiance à 95%. Il en est de même pour les distributions de taille qui sont retrouvées y compris pour des images à très fort recouvrement de particules.

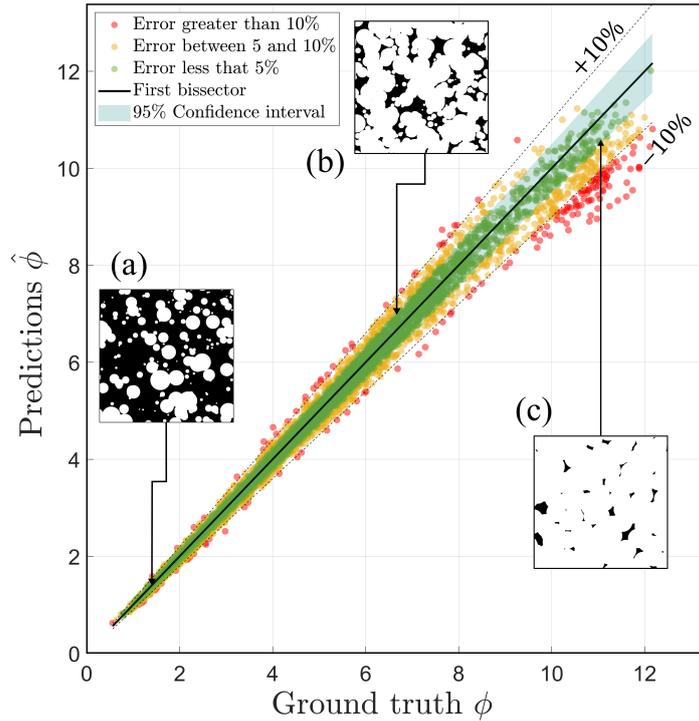


Figure 2 : Fraction volumique 3D prédite en fonction de la valeur réelle. Les vignettes montrent des images types provenant du jeu de données de test.

3.2. Applications expérimentales

Après avoir validé l'approche sur des données simulées, des validations expérimentales ont été effectuées en utilisant des billes sphériques calibrées de poly(méthacrylate de méthyle) (PMMA) (précision du diamètre $\pm 1\%$) immergées dans une solution saline iso-dense et mises en mouvement par agitation dans une maquette optique rectangulaire. Dans un deuxième temps, la même maquette a été mise à profit pour la caractérisation d'un écoulement gaz-liquide.

3.2.1. Particules calibrées de PMMA

Les particules sphériques calibrées de PMMA ont été agitées dans une phase continue d'un litre de saumure (330 g de NaCl dissous dans 1 L d'eau) à l'aide d'une hélice à quatre pales. La saumure a été choisie ici pour ajuster la densité de la phase continue à celle de la phase dispersée afin d'éviter les effets de crémage et garantir une dispersion homogène des particules dans l'écoulement. Une distribution lognormale ne pouvant pas être reproduite expérimentalement avec des billes calibrées pour des raisons de temps et de coût (une fraction volumique de 1,48 % correspond par exemple à environ 10 000 particules), seules quatre tailles de particules ont été utilisées (0,39, 0,5, 0,79 et 1,59 mm de diamètre), avec quatre fractions volumiques et une distribution de taille discrète identique pour chaque expérience. Le nombre de particules utilisées dans chaque expérience a été déterminé en les pesant avec une balance de précision de laboratoire, permettant d'associer une incertitude à la fraction volumique. Le mélange a été placé dans un réservoir rectangulaire avec des dimensions externes de $25 \times 15 \times 6,7 \text{ cm}^3$ et une capacité de 1,1 L, équipé de deux fenêtres de qualité optique. Le mélange a été agité à 2000 tr/min pour produire un écoulement homogène. Les images ont été capturées à une taille de 1280×1024 ,

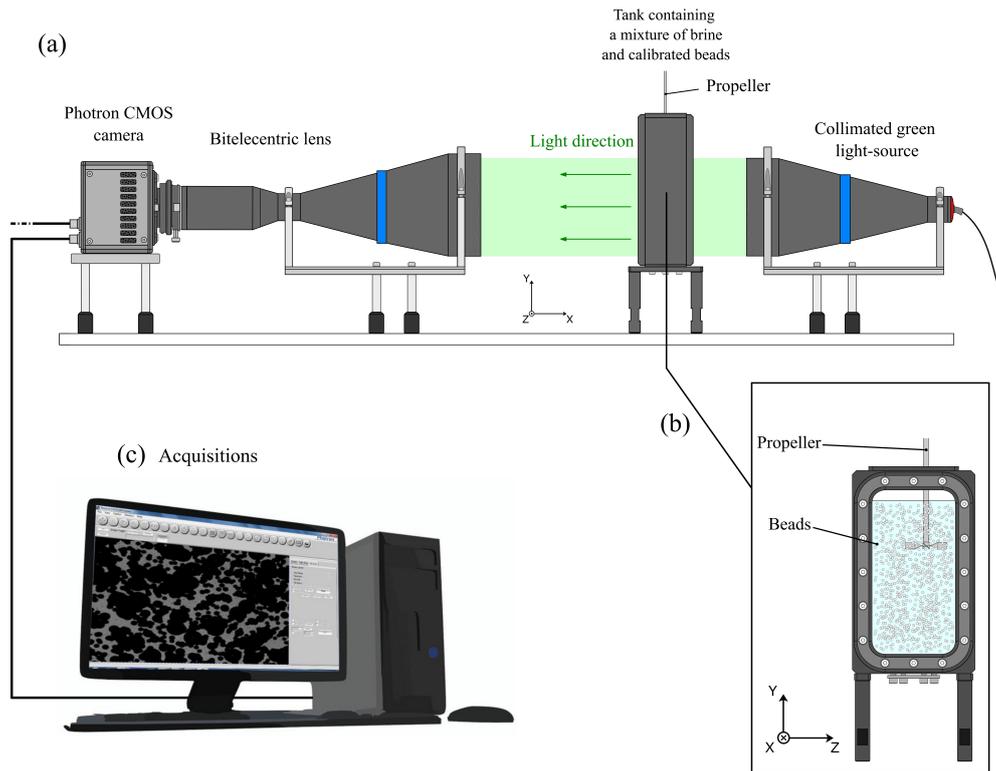


Figure 3 : (a) Vue latérale du dispositif expérimental avec, de gauche à droite, la caméra rapide, l'objectif bi-télécentrique, le réservoir et la source de lumière verte collimatée. (b) Vue de face du réservoir. (c) Ordinateur avec un exemple typique d'image capturée à l'écran ($\Phi = 2,91\%$).

correspondant à un champ de vision de $33,7 \times 29,9 \text{ mm}^2$ (facteur d'échelle, $2,6 \times 10^{-2} \text{ mm/px}$). Elles ont été binarisées et recadrées à une taille de 980×980 ($25,8 \times 25,8 \text{ mm}^2$) pour correspondre au standard des couches d'entrée du réseau. Le réservoir a une largeur interne de $5,3 \text{ cm}$ suivant l'axe optique, inférieure à la profondeur de champ de l'objectif, de sorte que le volume de mesure total était de $35,3 \text{ cm}^3$.

La Figure 4 montre qu'aux deux fractions volumiques les plus faibles, le CNN retrouve correctement la distribution de taille des particules, moyennant une légère sous-estimation de la proportion des plus petites attribuable aux imperfections du procédé de binarisation. À des fractions volumiques plus élevées, la PSD est moins bien évaluée, avec une surestimation des grandes particules et une sous-estimation des plus petites liées au très grand chevauchement des particules dans les images. Les ordres de grandeur restent tout de même cohérents. Pour les quatre expériences la fraction volumique est correctement évaluée.

3.2.2. Écoulement Gaz-Liquide "académique"

Le même réservoir a été utilisé pour caractériser un écoulement gaz-liquide air-eau. Dans ce cas, les bulles d'air sont introduites depuis le fond du réservoir rempli d'un litre d'eau, remontent dans le réservoir, puis s'échappent par le sommet. Le gaz est injecté grâce à un débitmètre ayant une plage de débit allant de 0 à 50 L/h , avec une précision de $\pm 0,5 \%$, à travers un verre fritté ayant des pores allant de 40 à 90 nm , produisant une distribution de taille des bulles pseudo-reproductible. Neuf débits différents de gaz ont été considérés : $Q = \{2,5, 5, 10,$

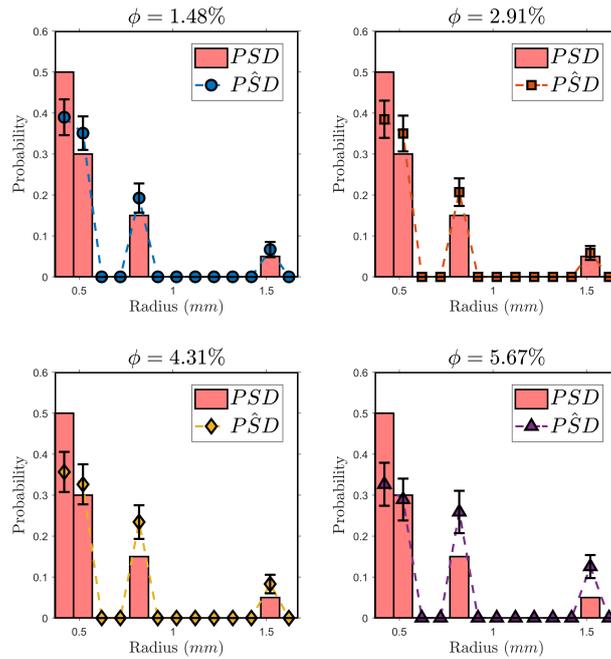


Figure 4 : Comparaison entre les distributions de tailles de particules prédites (\widehat{PSD}) et la vérité terrain (PSD) pour les quatre fractions volumiques de particules considérées.

15, 20, 25, 30, 35 et 40} L/h.

Pour mesurer la rétention de gaz dans la cuve et valider les prédictions du réseau l'élévation du niveau de la phase continue au sommet du réservoir a été mesurée par imagerie. Pour chaque débit de gaz injecté, une centaine d'acquisitions ont été réalisées puis moyennées en une seule image et comparées au cas sans débit de gaz. La différence entre les deux niveaux de la phase continue permet alors de calculer une différence de volume qui est attribuable au volume moyen de phase dispersée pendant l'expérience. La figure 5 compare les valeurs prédites par le réseau à partir des images et les valeurs mesurées par élévation de niveau. On voit que l'accord est très bon, y compris aux plus hautes rétentions de gaz confirmant les performances du réseau.

A l'inverse de la fraction volumique, obtenir des mesures précises du rapport d'allongement des bulles et de leur demi-grand axe est particulièrement difficile, surtout dans les cas d'image à forte densité d'objet. Afin de quand même pouvoir évaluer les prédictions du réseau, ces dernières ont été comparées aux résultats de détection obtenus en utilisant un algorithme de détection d'ellipses dans des images 2D [4]. Pour chaque débit, 500 images ont été traitées avec cet algorithme et des distributions ont été calculées en utilisant le même nombre de classes que pour le réseau. La figure 6 montre les résultats de cette comparaison pour le demi-grand axe. A nouveau l'accord est bon, il en est de même pour la mesure du rapport d'élongation.

4. Conclusion

Cet article présente une nouvelle technique de traitement d'image, combinant un modèles géométriques stochastiques et réseaux neuronaux convolutifs, qui permet d'extraire les propriétés 3D d'un écoulement diphasique à partir de simples projections 2D. Grâce à cette approche, toutes les propriétés géométriques moyennes de la phase dispersée (fraction volumique, distribution de la taille...) peuvent être directement prédites à partir des images. Après une validation numérique sur des images simulées, l'approche a été validée sur des images expérimentales

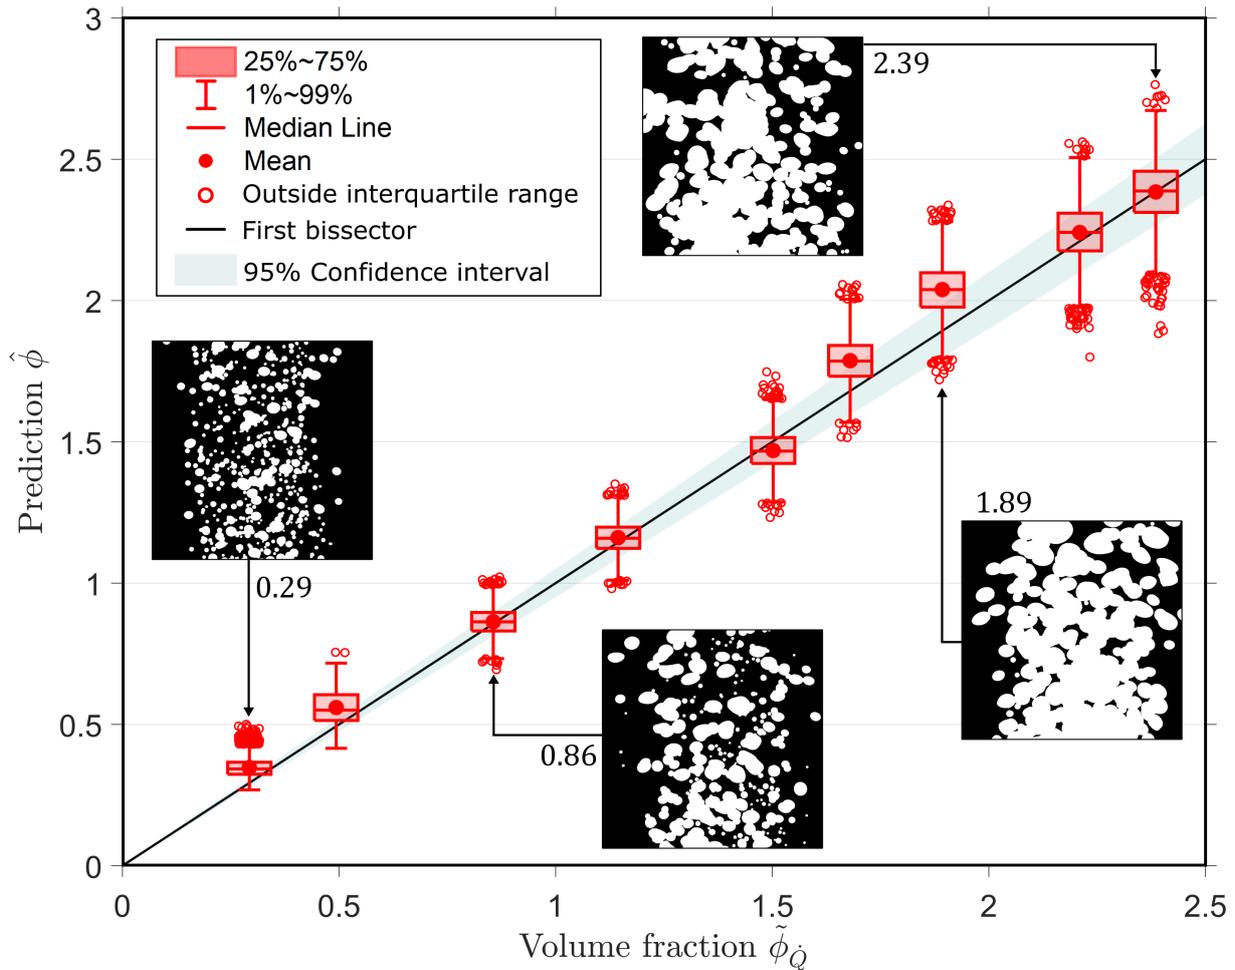


Figure 5 : Fractions volumiques prédites par le réseau en fonction des fractions volumiques mesurées pour les neuf débits de gaz considérés. Quatre exemples d’images expérimentales sont montrés pour les débits $Q = \{2, 5, 10, 30, 40\}$ L/h avec la fraction volumique correspondante.

de billes calibrées et d’un écoulement gaz-liquide. Les résultats confirment sa pertinence et montre qu’elle permet de retrouver des propriétés 3D moyennes d’un champ de particule à partir d’un seul accès optique, y compris aux plus hautes fractions volumiques. Cette méthode est facile à mettre en œuvre et peut être facilement appliquée à différents types d’écoulements multiphasiques, ce qui la rend adaptée à de nombreuses applications en génie chimique.

Références

- [1] K. Shimizu, S. Takada, K. Minekawa and Y. Kawase, “Phenomenological model for bubble column reactors : prediction of gas hold-ups and volumetric mass transfer coefficients,” *Chemical Engineering Journal*, vol. 78, no. 1, pp. 21–28, 2000.
- [2] A. Buffo, M. Vanni and D.L. Marchisio, “Simulation of a reacting gas–liquid bubbly flow with cfd and pbm : Validation with experiments,” *Applied Mathematical Modelling*, vol. 44, pp. 43–60, 2017.
- [3] R. Cerqueira, E. Paladino, B. Ynumaru, and C. Maliska, “Image processing techniques for the measurement of two-phase bubbly pipe flows using particle image and tracking velocimetry (piv/ptv),” *Chemical Engineering Science*, vol. 189, pp. 1–23, 2018.
- [4] M. de Langlard, H. Al-Saddik, S. Charton, J. Debayle, and F. Lamadie, “An efficiency improved recognition algorithm for highly overlapping ellipses : Application to dense bubbly flows,” *Pattern Recognition Letters*, vol. 101, pp. 88–95, 2018.
- [5] Y. Fu and Y. Liu, “Bubgan : Bubble generative adversarial networks for synthesizing realistic bubbly

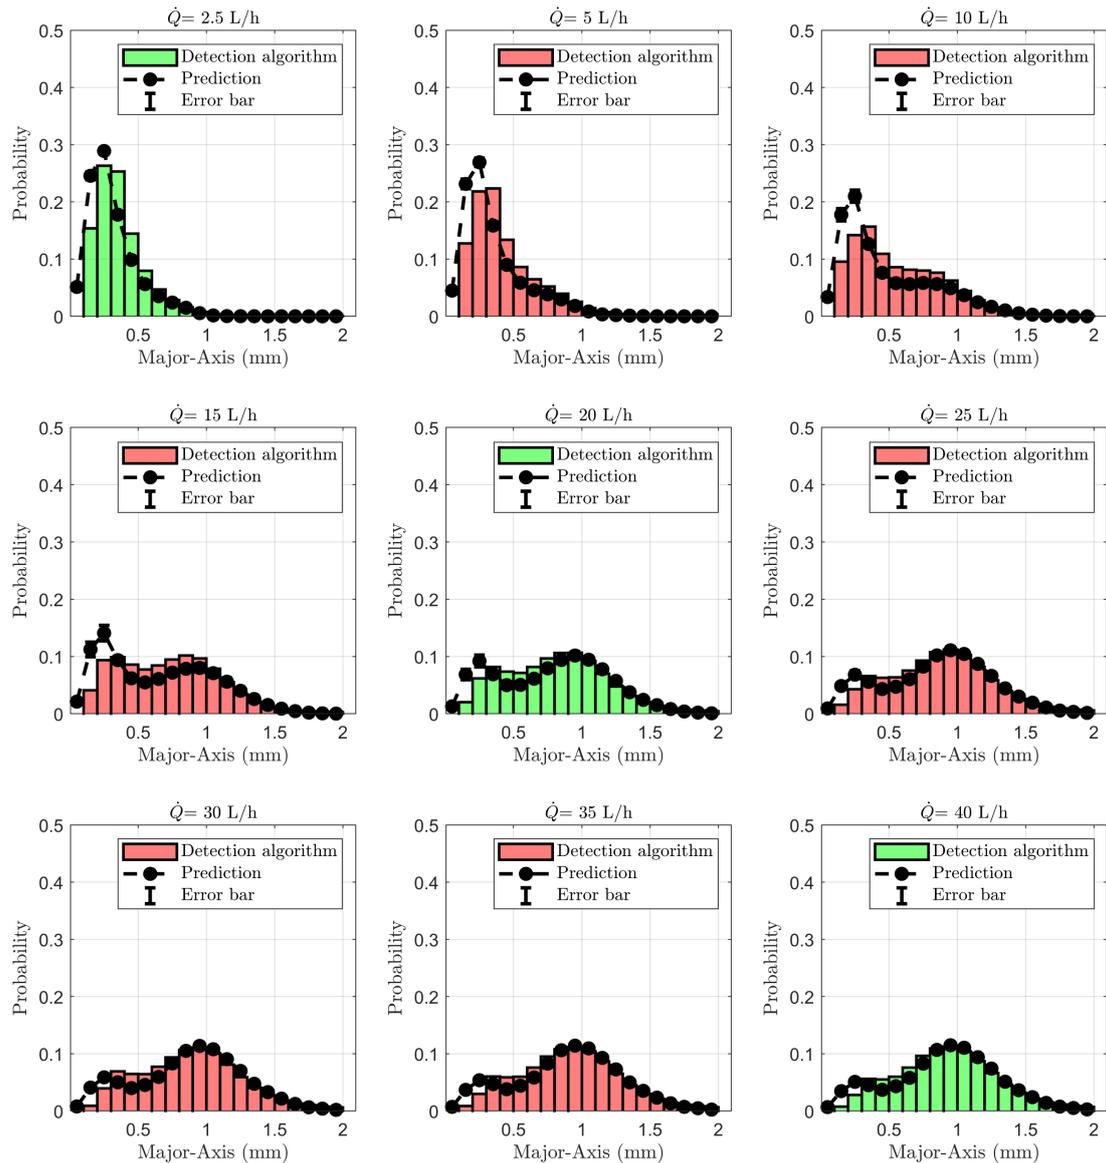


Figure 6 : Comparaison entre les prédictions du réseau et les résultats de détection avec l'algorithme déterministe pour l'estimation du demi-grand axe aux différents débits considérés. Les histogrammes en vert indiquent les cas utilisés pour l'entraînement du réseau.

flow images,” Chemical Engineering Science, vol. 204, pp. 35–47, 2019.

[6] W. Kracht, X. Emery, and C. Paredes, “A stochastic approach for measuring bubble size distribution via image analysis,” International Journal of Mineral Processing, vol. 121, pp. 6–11, 2013.

[7] M. de Langlard, F. Lamadie, S. Charton, and J. Debayle, “A 3D stochastic model for geometrical characterization of particles in two-phase flow applications,” Image Analysis and Stereology, vol. 37, no. 3, p. 233–247, 2018.

[8] C. Fend, A. Moghiseh, C. Redenbach and K. Schladitz, Reconstruction of highly porous structures from FIB-SEM using a deep neural network trained on synthetic images, Journal of Microscopy, vol 281, p. 16-27, 2021

Remerciements

Ces travaux ont été soutenus par la Direction de l’Energie du CEA (projet PRATA).