

# Analyse d'images expérimentales par apprentissage profond pour la caractérisation de la combustion de l'aluminium en propulsion solide

Magdeleine Airiau<sup>1</sup> (magdeleine.airiau@onera.fr), Guy Le Besnerais<sup>2</sup>, Robin Devillers<sup>1</sup>, Adrien Chan Hon Tong<sup>2</sup>, Julien Pichillou<sup>3</sup>

1. Onera DMPE/MPF, 2. Onera DMPE/IVA, 3. CNES

## CONTEXTE

### Utilisation de l'aluminium en propulsion solide

- Ajout de l'aluminium dans les propulseurs solides augmentant les performances propulsives de 10%
- Peut provoquer des oscillations de pression et donc des instabilités de fonctionnement de type ITHAC [1]
- Besoins de caractérisation de l'aluminium en combustion pour étudier la stabilité d'un moteur fusée

### Caractérisation de la combustion de l'aluminium

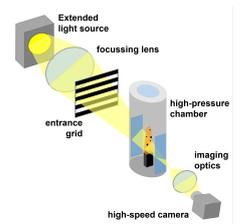
- Travaux de recherches réalisés pour qualifier les instabilités par simulations numériques avec le code CEDRE
- Les modèles numériques nécessitent de nombreuses données d'entrée comme la vitesse et la taille des gouttes d'aluminium pendant la combustion : importance de visualiser et quantifier ces données
- Forte sensibilité des simulations aux données d'entrée : besoin de mieux connaître les incertitudes notamment sur les tailles et les vitesses

### Ombroscopie à faisceaux convergents

- Essais à l'ONERA depuis 2008, ~1-2 campagnes par an depuis 2011 [2]
- Permet de visualiser des échantillons de propulseurs en combustion à haute cadence : montre les gouttes d'aluminium en combustion quittant la surface
- Images complexes : nombreux objets dans l'écoulement de gaz (particules inertes, gouttes en combustion, flamme, fumées...)



Image de la combustion de propulseur obtenue par ombroscopie



Montage d'ombroscopie à faisceaux convergents

Du fait de la complexité de ces images, plusieurs méthodes d'analyse ont été proposées ces dernières années et dans la thèse de M. Nugue [3], une approche par apprentissage profond a été utilisée pour la première fois.

## DÉMARCHE

### Améliorer et consolider les approches par apprentissage profond

- Méthodes de segmentation et détection d'objets
- Prise en compte de la physique des phénomènes, par pré/post-traitements dédiés et modification du comportement du réseau

### Déterminer avec précision un niveau d'incertitude des résultats

- Étudier le degré de confiance des résultats par une démarche de qualification de l'apprentissage
- Déterminer l'incertitude globale depuis les valeurs expérimentales jusqu'aux résultats de simulation numérique diphasique

## AMÉLIORATION DE LA MÉTHODE PAR APPRENTISSAGE PROFOND

### Méthode classique

- Méthodes de la segmentation d'instance
- Utilisation du réseau Mask R-CNN [4]

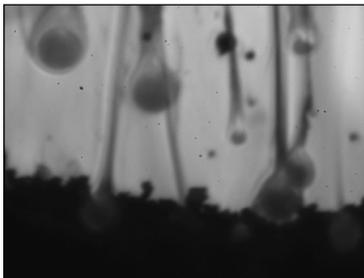


Image originale

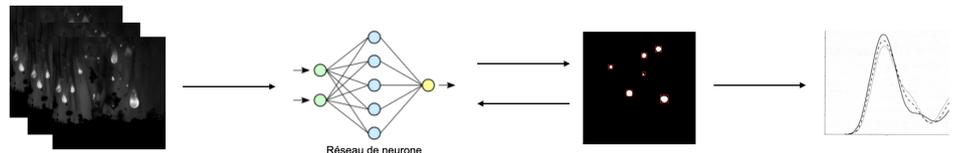


Segmentation d'instance

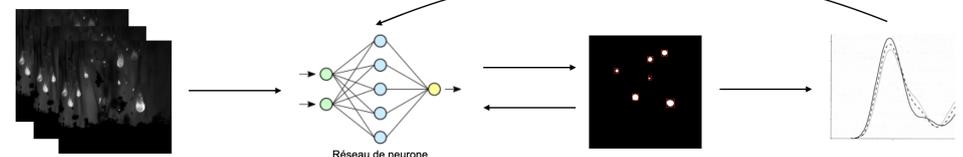
Le réseau cherche à maximiser ses performances de détection ce qui peut biaiser l'estimation de la distribution en taille des gouttes d'aluminium

### Méthode améliorée

- Ajout d'un régresseur de distribution de taille de gouttes pour rendre Mask R-CNN plus robuste :
  - *Mask R-CNN classique* : le réseau prend en compte la détection, la segmentation et la classification. La distribution de taille de gouttes est estimée en post traitement (hors réseau).



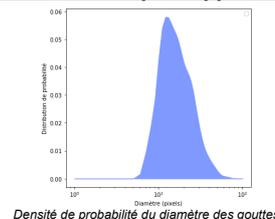
- *Mask R-CNN amélioré* : prise en compte de la distribution de taille dans l'apprentissage du réseau (ajout d'un terme à la fonction de perte : divergence de la distribution de la taille fournie par le réseau avec la distribution réelle)



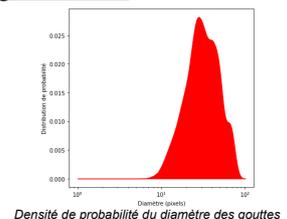
### Premières grandeurs physiques obtenues après apprentissage du réseau

Diamètre moyen	Diamètre moyen volumique	Diamètre moyen pondéré par la surface	Diamètre moyen pondéré par le volume
21.7	26.8	32.9	39.3

Diamètres équivalents des gouttes en pixels



Densité de probabilité du diamètre des gouttes



Densité de probabilité du diamètre des gouttes pondérée par le volume

## CONCLUSIONS

- Création et validation d'une méthode par apprentissage profond de détection des gouttes efficace, prenant en compte la répartition en diamètre des gouttes d'aluminium et donc la physique des phénomènes
- Extraction de premières grandeurs physiques

## PERSPECTIVES

- Extraction d'autres grandeurs physiques (profils de vitesse, épaisseur en combustion)
- Simulation d'un écoulement avec les données physiques obtenues par la méthode par apprentissage profond
- Mise en place d'une démarche de qualification (estimation d'erreur)

## BIBLIOGRAPHIE

- [1] O. Orlandi, M. Plaud, F. Godfroy, S. Lariou et N. Cesco, *Aluminium droplets combustion and SMR instabilities*, Acta Astronautica, 158, pp. 470-479 (2019).  
 [2] R. W. Devillers, C. Erades, D. Lambert et J. Bellès, *Mesure et suivi de particules, agglomérats et gouttes en combustion*, 14th CFTL (2014).  
 [3] Matthieu Nugue, *Outils pour l'étude conjointe par simulation et traitement d'images expérimentales de la combustion de particules d'aluminium utilisées dans les propulseurs solides*, Université Paris-Saclay, 2019.  
 [4] K. He, G. Gkioxari, P. Dollár et R. Girshick, *Mask R-CNN*, dans 2017 IEEE International Conference on Computer Vision (ICCV), pp. 2980-2988 (2017).