

Détection non supervisée d'aiguilles en échographie 3D avec une représentation neuronale implicite

Lukmán EL HADI Mathilde MONVOISIN Diana MATEUS

Nantes Université, École Centrale Nantes, LS2N, CNRS, UMR 6004, F-44000 Nantes, France

Résumé – Ce travail présente une méthode de détection non supervisée d'aiguilles en échographie 3D basée sur le modèle DRUID, une représentation neuronale implicite (RNI) qui permet la compression, et l'amélioration de la qualité de volumes échographiques 3D. DRUID est utilisé pour reconstruire un volume à partir de données ultrasonores. Des métriques de similarité telles que la MSE et le SSIM sont exploitées pour identifier les intensités anormales, corrélées à la présence d'aiguilles. Une stratégie de décision sur la présence d'aiguille est également proposée et évaluée, permettant d'atteindre jusqu'à 100% en sensibilité et en précision.

Abstract – This work presents a method for unsupervised needle detection in 3D ultrasound based on the DRUID model, an implicit neural representation (INR) that enables compression and quality improvement of 3D ultrasound volumes. DRUID is used to reconstruct a volume from ultrasound data. Similarity metrics such as MSE and SSIM are exploited to identify abnormal intensities corresponding to the presence of needles. A decision strategy on needle presence is also proposed and evaluated, achieving up to 100% sensitivity and accuracy.

1 Introduction

Les avancées récentes dans le domaine des représentations neuronales implicites (RNI) ont démontré une efficacité remarquable dans l'approximation continue des champs scalaires et vectoriels [10]. En représentant avec précision des scènes 3D complexes, les RNI ont trouvé des applications dans divers domaines, notamment la reconstruction d'objets 3D et la synthèse de nouvelles vues [5, 2]. Récemment, l'utilisation de RNIs pour la modélisation d'images ultrasonores (US) a suscité un intérêt croissant. Par exemple, Gu et al [4] et Yeung et al [11] utilisent une RNI pour modéliser des volumes 3D à partir de données US 2D à main levée. Wysocki et al. [8] ont proposé une technique de rendu neuronal basée sur le tracé des rayons pour apprendre les propriétés des tissus à partir d'images en mode B. Monvoisin et al [6] ont présenté DRUID, une RNI qui permet la compression et l'amélioration de la qualité de volumes US 3D en radio-fréquence ou en mode B.

Parmi les interventions guidées par échographie, la détection d'aiguille est importante pour la réussite de l'injection d'anesthésique [9] ou d'interventions fœtales telles que l'amniocentèse [3]. Il existe des méthodes de détection d'aiguille à partir des k-moyennes [1], ou à partir de graphes [12]. A notre connaissance, il n'existe pas de travaux de détection d'aiguilles à partir de RNI.

Récemment, Piecuch et al [7] a développé une méthode de détection non supervisée d'anomalie à partir d'une RNI apprise sur des masques de segmentation de muscles. Ce travail s'en inspire pour proposer une stratégie non supervisée de détection d'aiguille dans un volume US, à partir du volume préalablement inféré avec DRUID [6].

2 Méthode

L'objectif de l'approche est de détecter la présence d'une aiguille dans un volume US. La tâche à résoudre est donc modélisée comme un problème de détection d'anomalies.

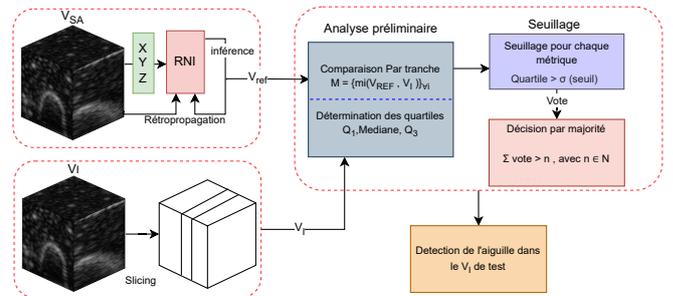


FIGURE 1 : Pipeline représentant la reconstruction et la détection.

2.1 Définition du problème

Etant donnée une image volumique de la zone d'intervention, l'objectif de notre méthode est de discriminer de façon non-supervisée les volumes sans aiguille V_{SA} , des volumes où une aiguille a été insérée V_{AA} grâce à des métriques de comparaison.

Les détections sont obtenues en comparant la performance du réseau à reconstruire des variantes de la scène observée. Le réseau DRUID est utilisé pour représenter implicitement la situation de référence, c'est-à-dire l'absence d'aiguille. DRUID est un perceptron multicouche (MLP) à trois couches entièrement connectées utilisant des activations sinusoidales $\sin(\omega x)$, avec ω_0 pour la première couche et ω pour les autres. Le réseau prend en entrée les coordonnées spatiales des voxels et prédit leur intensité. Après l'apprentissage pendant m itérations, le volume V_{REF} peut être inféré à des résolutions spatiales arbitraires à partir du réseau appris. Le réseau devient donc une représentation continue de la scène de référence.

2.2 Stratégie de détection

La stratégie de détection proposée s'appuie sur l'hypothèse qu'il existe un ensemble de métriques $M = \{m_1, m_2, \dots, m_n\}$

qui permet de discriminer les V_{SA} des V_{AA} en les comparant à V_{REF} , et par conséquent qu'il existe un ensemble de seuils $\sigma_M = \{\sigma_{m_1}, \sigma_{m_2}, \dots, \sigma_{m_n}\}$ qui scinde les valeurs prises pour chaque métrique m_i tel que $m_i(V_{REF}, V_{SA}) < \sigma_{m_i} < m_i(V_{REF}, V_{AA})$.

La méthode présentée étant non supervisée, l'objectif est de fournir une prédiction pour un nouveau volume, sans avoir d'information sur la présence d'une aiguille. Ce volume est noté comme étant indéterminé V_I .

On définit d comme étant la décision "une aiguille est présente dans le volume". L'équation 1 permet de prendre la décision d_i pour chaque métrique.

$$d_i = \begin{cases} VRAI & \text{si } m_i(V_{REF}, V_I) > \sigma_{m_i} \\ FAUX & \text{sinon} \end{cases} \quad (1)$$

Le vecteur de comparaison noté v_{vote} contient les évaluations de chaque métrique d_i sur la décision.

$$v_{vote} = \{d_1, d_2, \dots, d_n\} \quad (2)$$

Enfin, une majorité simple sur les votes de v_{vote} permet de prendre la décision d , c'est-à-dire que $d = VRAI$ si v_{vote} contient $p\%$ de votes $VRAI$.

Comparaison volumique Dans une première approche, les volumes entiers V_I et V_{REF} sont comparés, par conséquent $M = \{m_i(V_{REF}, V_I)\}_{\forall i}$.

Comparaison par tranches Dans cette seconde approche, chaque volume est découpé en tranches 2D selon les trois directions orthogonales (axiale \mathcal{V}_X , sagittale \mathcal{V}_Y et coronale \mathcal{V}_Z). Dans ce cas, $M = \{m_i(\mathcal{V}_{REF_X}, \mathcal{V}_{I_X}), m_i(\mathcal{V}_{REF_Y}, \mathcal{V}_{I_Y}), m_i(\mathcal{V}_{REF_Z}, \mathcal{V}_{I_Z})\}_{\forall i}$.

3 Expériences

Cette section permet d'évaluer l'approche proposée à partir de données échographiques en mode B avec ou sans aiguilles. Une représentation d'un volume sans aiguille est tout d'abord apprise avec DRUID, par les paramètres $\omega_0 = 80$, $\omega = 25$, et 1000 itérations. La représentation apprise est ensuite utilisée pour inférer V_{REF} .

Une analyse préliminaire de la distribution des valeurs prises par l'erreur moyenne quadratique (MSE) et l'indice de similarité structurelle (SSIM) en comparant les V_{SA} et les V_{AA} au V_{REF} est réalisée sur chaque jeu de données. Cette analyse permet de déterminer empiriquement les seuils σ_{MSE} et σ_{SSIM} . Enfin, la stratégie décrite dans la section 2 est utilisée pour faire la détection d'aiguilles. Les expériences ont été réalisées sur un GPU NVIDIA RTX 3050 Laptop. Une stratégie de filtrage a été testée en baseline, dont les résultats ne peuvent être détaillés par manque de place. Celle-ci présente l'inconvénient majeur d'être trop sensible au bruit, ce qui ne permet pas de détecter l'aiguille de manière fiable, surtout pour les volumes sans structure anatomique.

3.1 Données

Deux jeux de données contenant des volumes US en mode B ont été acquis avec une sonde matricielle sur un fantôme

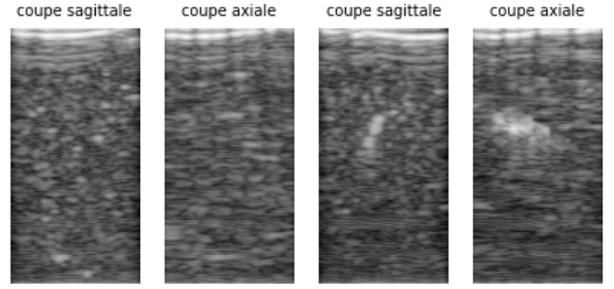


FIGURE 2 : Coupes d'un V_{SA} (les deux de gauche) et V_{AA} (les deux de droite) du jeu de données #1.

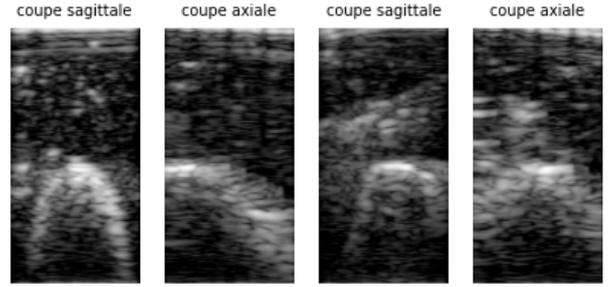


FIGURE 3 : Coupes d'un V_{SA} (les deux de gauche) et V_{AA} (les deux de droite) du jeu de données #2.

de torse. Le premier (jdd #1) a été acquis sur une zone ne contenant pas de structure anatomique, et le deuxième (jdd #2) sur une zone avec une vertèbre visible. Il contiennent respectivement 2 V_{AA} et 1 V_{SA} , et 2 V_{AA} et 4 V_{SA} . Les volumes ont une résolution de $512 \times 256 \times 256$ (H \times W \times D). Les figures 2 et 3 présentent une coupe de V_{AA} et de V_{SA} des jdd #1 et #2. La figure 4 montre une coupe sagittale du volume V_{REF} inféré par DRUID, contenant une vertèbre du fantôme.

3.2 Analyse préliminaire

Comparaison volumique La figure 5 illustre les résultats obtenus pour les métriques MSE et SSIM calculés sur les volumes entiers. On n'y observe pas de distinction claire entre les valeurs prises par les V_{SA} et les V_{AA} . Cela suggère qu'une approche basée uniquement sur des comparaisons de volumes entiers n'est pas suffisante pour distinguer la présence de l'aiguille.

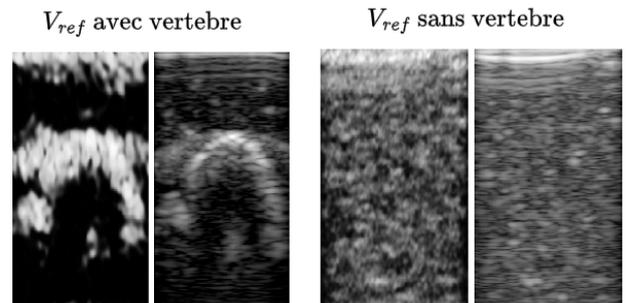


FIGURE 4 : Comparaison entre une tranche du V_{REF} (volume inféré) et la tranche correspondante du volume réel, pour la zone avec vertèbre et zone sans vertèbre.

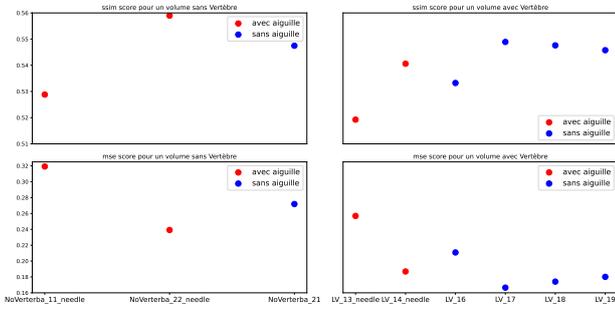


FIGURE 5 : Métriques SSIM et MSE pour la détection volumique avec vertèbres.

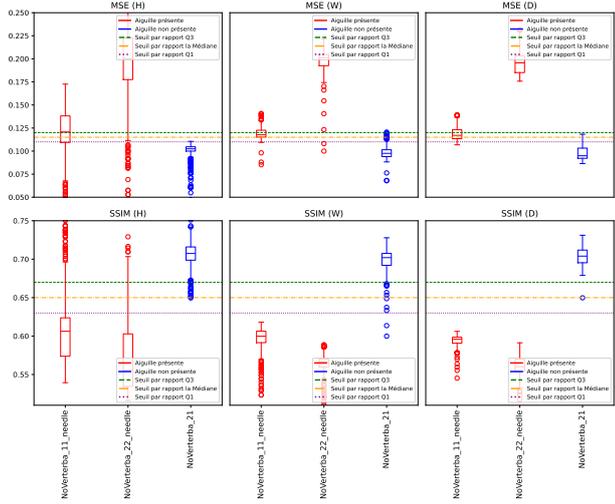


FIGURE 6 : Boîtes à moustaches de la MSE et de la SSIM sur chaque direction de coupe sur le jeu de données #1. Les V_{SA} en bleu et les V_{AA} en rouge. Les seuils σ identifiés pour Q1, médiane, et Q3 respectivement sont les lignes horizontales violette, jaunes, vertes.

Comparaison par tranche : jdd #1 La figure 6 présente les résultats des calculs de MSE et SSIM coupe par coupe toutes coupes confondues sous forme de boîtes à moustaches. On peut y voir que pour MSE comme pour SSIM, la distinction est marquée entre la distribution des valeurs prise par le groupe sans aiguille et le groupe avec aiguille. Cela suggère que l'application de la méthode de la section 2 permettrait de détecter efficacement l'aiguille. Les seuils identifiés pour séparer les deux groupes sont $\sigma_{MSE_{Q1}} = 0.11$, $\sigma_{MSE_{Med}} = 0.115$, $\sigma_{MSE_{Q3}} = 0.12$, $\sigma_{SSIM_{Q1}} = 0.63$, $\sigma_{SSIM_{Med}} = 0.65$, $\sigma_{SSIM_{Q3}} = 0.67$.

Comparaison par tranche : jdd #2 La figure 7 présente les mêmes boîtes à moustaches que précédemment, mais cette fois-ci appliquées à des volumes US incluant une structure osseuse (vertèbre). Les seuils identifiés pour séparer les deux groupes sont $\sigma_{MSE_{Q1}} = 0.165$, $\sigma_{MSE_{Med}} = 0.175$, $\sigma_{MSE_{Q3}} = 0.2$, $\sigma_{SSIM_{Q1}} = 0.536$, $\sigma_{SSIM_{Med}} = 0.543$, $\sigma_{SSIM_{Q3}} = 0.555$.

3.3 Performances en détection

Pour déterminer l'efficacité de l'approche pour détecter l'aiguille, un jeu de test de 9 volumes avec vertèbre et 3 sans vertèbre, qui n'a pas été utilisé dans l'analyse préliminaire,

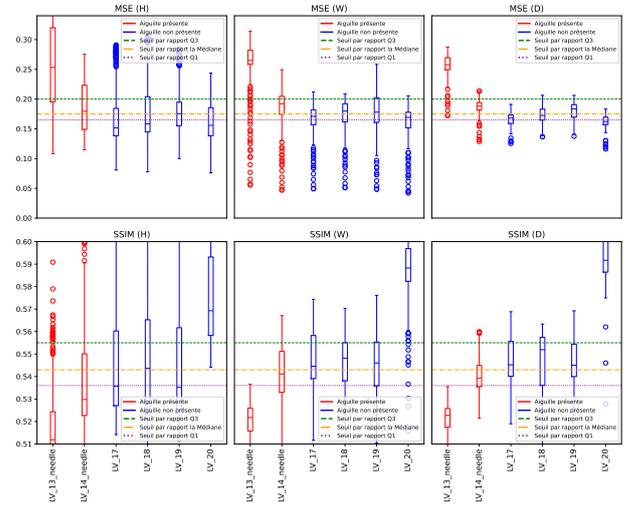


FIGURE 7 : Boîtes à moustaches de la MSE et de la SSIM sur chaque direction de coupe pour jdd #2.

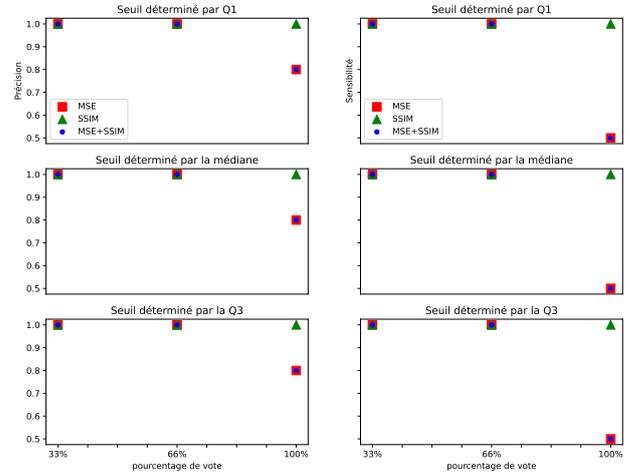


FIGURE 8 : Résultats en précision (gauche) et sensibilité (droite) pour les trois seuils Q1 (en haut), médiane (au milieu) et Q3 (en bas) pour jdd #1.

est évalué. Les seuils déterminés à partir des figures 6 et 7 sont utilisés pour le test. On souhaite notamment déterminer le pourcentage p idéal, qui représente le nombre de vote V_{RAI} de v_{vote} (section 2) pour que la décision $d = V_{RAI}$ soit prise. Le temps d'apprentissage de DRUID est d'environ 6 minutes et le temps d'inférence et de détection de moins de 40 secondes.

Les figures 8 et 9 montrent les performances en précision et en sensibilité respectivement pour les jeux de données #1 et #2, en fonction de p . On constate que la précision et la sensibilité sont toujours à 100% pour le jeu de données #1 tant que $p \leq 66\%$, quelles que soient les métriques utilisées. Il est notable qu'utiliser seulement la SSIM permet de maintenir une précision et une sensibilité parfaite quel que soit p .

Pour le jdd #2, la sensibilité est à 100% tant que $p \leq 66\%$. La précision est maximisée (90%) avec MSE+SSIM pour $p = 100\%$ lorsque le seuil est déterminé en fonction de la médiane, et avec SSIM sinon. On remarque cependant sur la figure 9 que l'utilisation de MSE+SSIM permet des résultats plus stables en précision, moins dépendants de p .

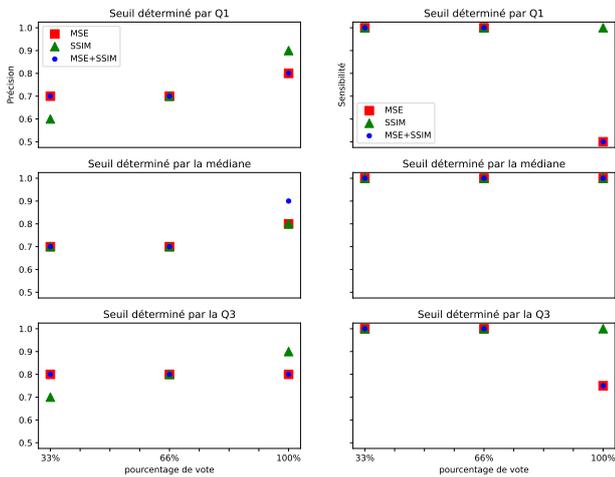


FIGURE 9 : Résultats en précision (gauche) et sensibilité (droite) pour les trois seuils Q1 (en haut), médiane (au milieu) et Q3 (en bas) pour jdd #2.

4 Conclusion

La méthode présentée montre qu'il est possible d'effectuer de la détection d'aiguille dans un volume échographique de façon non supervisée en utilisant une représentation implicite. Cette approche, appliquée ici avec la MSE et la SSIM, permet d'obtenir une détection robuste à l'aide de seuils empiriques et d'un vote majoritaire simple. On conclut que dans la majorité des cas, utiliser uniquement la SSIM permet d'obtenir les meilleures performances. Cette méthode pourrait être appliquée pour de la détection d'anomalies à partir de volumes US, tels que des objets étrangers, par exemple.

Utiliser une représentation implicite a plusieurs avantages. L'apprentissage reste valable même en cas de déplacement de la sonde, ce qui n'est pas le cas d'une méthode simple de différence avec V_{REF} , car il faudrait acquérir V_{REF} pour chaque nouvelle orientation. La méthode peut également être utilisée pour trouver plus facilement l'aiguille sous un nouvel angle. Entraîner DRUID sur plusieurs volumes sans aiguilles au lieu d'un seul afin de construire V_{REF} pourrait également améliorer la généralisabilité de l'approche.

Une des perspectives d'amélioration serait d'établir une méthode de localisation de l'aiguille dans un volume US. Pour cela, une des pistes envisagées est d'identifier les maxima locaux en ligne et colonne des métriques, qui correspondraient à la position de l'aiguille. Il serait également intéressant d'explorer d'autres seuils que ceux calculés à partir des quartiles. Enfin, une piste d'amélioration serait d'étudier le nombre minimal de coupes 2D qui permette d'obtenir des performances satisfaisantes en détection. Cela permettrait de réduire le temps d'inférence, et donc de se rapprocher du temps réel, pour une application clinique.

Références

[1] Rodrigo Eduardo AREVALO-ANCONA, Daniel HARO-MENDOZA, Manuel CEDILLO-HERNANDEZ et Victor J GONZALEZ-VILLELA : Uminse : An unsupervised method for segmentation and detection of surgical instru-

ments based on k-means. *Revista Mexicana de Ingeniería Biomedica*, 45(3):20–50, 2024.

- [2] Yu CHEN et Gim Hee LEE : Dbarf : Deep bundle-adjusting generalizable neural radiance fields. pages 24–34, 2023.
- [3] F. DAFFOS, M. CAPELLA-PAVLOVSKY et F. FORESTIER : Fetal blood, sampling during pregnancy with use of a needle guided by ultrasound : A study of 606 consecutive cases. *American Journal of Obstetrics and Gynecology*, 153(6):655–660, 1985.
- [4] Ang Nan GU, Purang ABOLMAESUMI, Christina LUONG et Kwang Moo YI : Representing 3d ultrasound with neural fields. In *Medical Imaging with Deep Learning (MIDL)*, 2022.
- [5] Ben MILDENHALL, Pratul P SRINIVASAN, Matthew TANCIK, Jonathan T BARRON, Ravi RAMAMOORTHI et Ren NG : Nerf : Representing scenes as neural radiance fields for view synthesis. *Communications of the ACM*, 65(1):99–106, 2021.
- [6] Mathilde MONVOISIN, Yuxin ZHANG et Diana MATEUS : Implicit neural representation for 3-dimensional radio-frequency ultrasound.
- [7] Louise PIECUCH, Jeremie HUET, Antoine FROUIN, Antoine NORDEZ, Anne-Sophie BOUREAU et Diana MATEUS : Unsupervised anomaly detection on implicit shape representations for sarcopenia detection. *arXiv preprint arXiv :2502.09088*, 2025.
- [8] Magdalena WYSOCKI, Mohammad Farid AZAMPOUR, Christine EILERS, Benjamin BUSAM, Mehrdad SALEHI et Nassir NAVAB : Ultra-nerf : Neural radiance fields for ultrasound imaging. In *Medical Imaging with Deep Learning (MIDL)*, 2024.
- [9] Wenfeng XIA, Simeon J WEST, Jean-Martial MARI, Sebastien OURSELIN, Anna L DAVID et Adrien E DESJARDINS : 3d ultrasonic needle tracking with a 1.5 d transducer array for guidance of fetal interventions. pages 353–361. Springer, 2016.
- [10] Yiheng XIE, Towaki TAKIKAWA, Shunsuke SAITO, Or LITANY, Shiqin YAN, Numair KHAN, Federico TOMBARI, James TOMPKIN, Vincent SITZMANN et Srinath SRIDHAR : Neural fields in visual computing and beyond. In *Computer Graphics Forum*, volume 41, pages 641–676. Wiley Online Library, 2022.
- [11] Pak-Hei YEUNG, Linde HESSE, Moska ALIASI, Monique HAAK, Weidi XIE, Ana IL NAMBURETE *et al.* : Implicitvol : Sensorless 3d ultrasound reconstruction with deep implicit representation. *arXiv preprint*, 2021.
- [12] Yupei ZHANG, Xiuxiu HE, Zhen TIAN, Jiwoong Jason JEONG, Yang LEI, Tonghe WANG, Qiulan ZENG, Ashesh B. JANI, Walter J. CURRAN, Pretesh PATEL, Tian LIU et Xiaofeng YANG : Multi-needle detection in 3d ultrasound images using unsupervised order-graph regularized sparse dictionary learning. *IEEE Transactions on Medical Imaging*, 39(7):2302–2315, 2020.