

Modèle statistique apprenable de mélange de distributions et fusion de données multivariées pour l'imagerie d'exoplanètes

Théo BODRITO¹ Olivier FLASSEUR² Julien MAIRAL³ Jean PONCE^{1,4} Maud LANGLOIS² Anne-Marie LAGRANGE⁵

¹Département d'Informatique de l'École normale supérieure, ENS-PSL, CNRS, Inria, France

²Université Claude Bernard Lyon 1, Centre de Recherche Astrophysique de Lyon UMR 5574, ENS de Lyon, CNRS, France

³Université Grenoble Alpes, Inria, CNRS, Grenoble INP, LJK, France

⁴Courant Institute and Center for Data Science, New York University, USA

⁵Laboratoire d'instrumentation et de recherche en astrophysique, CNRS, Observatoire de Paris, CNRS, Université PSL, France

Résumé – L'imagerie des exoplanètes est un défi majeur en raison du fort contraste étoile-planète. Cet article propose un modèle statistique multi-échelle de la nuisance affectant des séries d'images multivariées. Intégré à une architecture apprenable, il exploite la physique du problème et permet la fusion de plusieurs observations d'une même étoile. Appliquée à des données réelles, la méthode améliore significativement la sensibilité de détection et la précision de l'estimation de la position et du flux des exoplanètes.

Abstract – Exoplanet imaging is a major challenge in astrophysics due to the high star-planet contrast. This paper presents a multi-scale statistical model for the nuisance component corrupting multivariate image series. Integrated into a learnable architecture, it leverages the physics of the problem and enables the fusion of multiple observations of the same star. Applied to real data, the method significantly improves the detection sensitivity and the accuracy of exoplanet position and flux estimation.

1 Introduction

Parmi les méthodes de détection d'exoplanètes, l'imagerie directe depuis la Terre permet notamment d'estimer leur position dans le ciel et leur spectre, qui constituent des informations précieuses pour leur caractérisation physique (e.g., âge, masse, température effective, présence et abondances moléculaires dans leur atmosphère) [6]. Cependant, cette technique récente reste complexe en raison du contraste extrême entre l'intensité de l'exoplanète et de son étoile hôte (plus de 5 ordres de grandeur en infrarouge). Malgré des corrections optiques avancées (optique adaptative extrême, coronographie), la détection de ces objets repose sur des algorithmes de traitement dédiés.

La Sect. 2 présente le principe d'observation. La Sect. 3 étend l'approche proposée dans [2], combinant une modélisation statistique multi-échelle de la nuisance et une estimation des paramètres par apprentissage profond sur des archives d'observations. La Sect. 4 compare les performances de la méthode proposée à l'état de l'art sur des données de l'instrument SPHERE opérant au Very Large Telescope (VLT).

2 Imagerie différentielle

L'imagerie différentielle angulaire et spectrale (ASDI) repose sur l'acquisition d'un cube de données 4D (spatial + temporel + spectral) en infrarouge, à travers plusieurs canaux spectraux et de courtes poses temporelles. Dans les données résultantes, les sources du champ décrivent une rotation apparente et prédictible autour de l'étoile, due à la rotation terrestre, tandis que la pupille du télescope reste fixe pour stabiliser les structures du fond. La diffraction et les aberrations résiduelles génèrent des speckles stellaires, contaminant les signaux des objets d'intérêt avec des corrélations spatiales marquées, surtout au centre du champ. Les speckles suivent une dilatation homothétique avec la longueur d'onde, conformément aux lois de la diffraction.

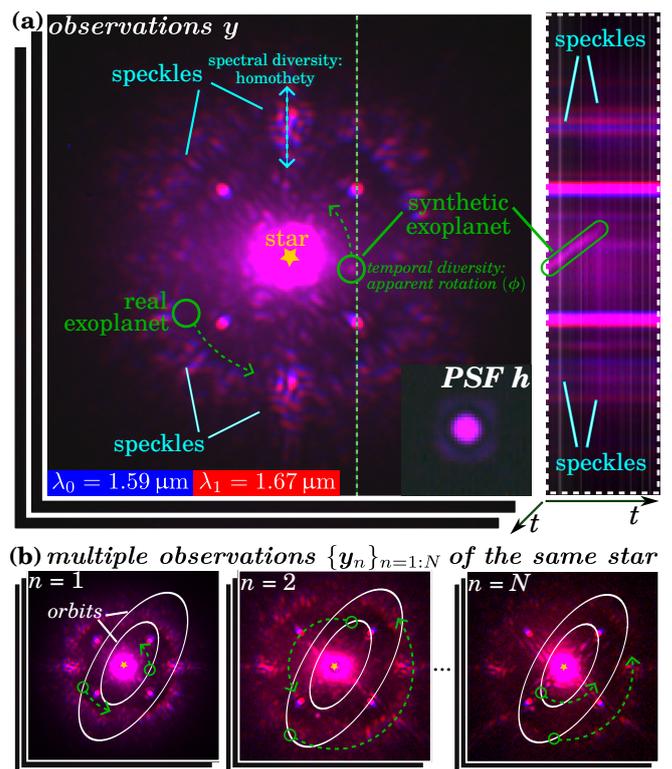


FIGURE 1 : (a) Gauche : Observations y typiques et PSF h de l'instrument SPHERE. Droite : coupe spatio-temporelle le long de la ligne verticale. L'exoplanète synthétique est très lumineuse à des fins d'illustration. Le mouvement orbital des exoplanètes est négligeable au cours d'une nuit d'observation. (b) Ensemble d'observations $\{y_n\}_{n=1:N}$ de la même étoile au cours de plusieurs mois/années. Les ellipses indiquent les orbites des exoplanètes au cours de ces N observations.

La rotation temporelle des sources et l'homothétie spectrale des speckles sont les diversités clés pour démêler les si-

gnaux exoplanétaires de la nuisance. La Fig. 1(a) illustre ces spécificités à partir de données de l'instrument SPHERE.

3 Méthode proposée

La Fig. 2 illustre l'architecture de la méthode proposée.

3.1 Modèle direct de formation d'images

Une observation $\mathbf{y} \in \mathbb{R}^{C \times T \times H \times W}$ se compose de T images temporelles de $H \times W$ pixels dans C canaux spectraux. Le modèle direct s'écrit :

$$\mathbf{y}_{c,t} = \beta_c \mathbf{D}_{\lambda_c/\lambda_1} \mathbf{s}_{1,t} + \sum_{k=1}^K \alpha_c^{(k)} \mathbf{h}_c(\mathbf{x}_t^{(k)}) + \epsilon_{c,t}, \quad (1)$$

où $\beta_c \in \mathbb{R}$ est l'amplitude des speckles dans le canal c , $\mathbf{D}_{\lambda_c/\lambda_1}$ est l'opérateur d'alignement des speckles du canal de référence (λ_1) sur ceux du canal c via une homothétie spatiale de facteur λ_c/λ_1 , $\mathbf{s}_{1,t} \in \mathbb{R}^{H \times W}$ est la contribution des speckles à λ_1 , et $\epsilon_{c,t} \in \mathbb{R}^{H \times W}$ est un bruit additif (thermique, photonique, de lecture) avec $\epsilon \ll s$. Le nombre d'exoplanètes K est inconnu. La signature spatiale de l'exoplanète k dans le canal c est donnée par la PSF instrumentale $\mathbf{h}_c \in \mathbb{R}^{H \times W}$ avec un flux $\alpha_c^{(k)} \in \mathbb{R}_+$. Sa position $\mathbf{x}_t^{(k)}$ au temps t est définie par une rotation apparente $r(\mathbf{x}_1^{(k)}, \phi_t)$ autour de l'étoile, où ϕ_t est l'angle de rotation cumulée entre t_1 et t , et $\mathbf{x}_1^{(k)} \in \mathbb{R}^2$ est sa position initiale dans l'image à $t = 1$.

3.2 Modèle statistique convolutionnel

La nuisance, spatialement corrélée et non-stationnaire, constitue la principale limite à la détection d'exoplanètes et nécessite donc une modélisation fine. Nous proposons une représentation locale de cette nuisance. Plutôt que de modéliser directement les corrélations entre pixels à l'échelle d'un patch, nous proposons de les représenter, par un modèle gaussien multivarié, dans un espace de caractéristiques par projection linéaire :

$$\forall (j, c, t) \in \llbracket 1, M \rrbracket \times \llbracket 1, L \rrbracket \times \llbracket 1, T \rrbracket, \mathbf{A} \mathbf{y}_{c,t}^{(j)} \sim \mathcal{N}(\mathbf{m}_{c,j}, \mathbf{C}_j),$$

où $\mathbf{y}_{c,t}^{(j)} \in \mathbb{R}^p$ est un patch en j (parmi les M possibles) extrait des observations $\mathbf{y}_{c,t}$ et $\mathbf{A} \in \mathbb{R}^{m \times p}$ est une matrice de projection avec $m \leq p$. Les paramètres $\mathbf{m}_{c,j} \in \mathbb{R}^m$ et $\mathbf{C}_j \in \mathbb{R}^{p \times p}$, représentant respectivement la moyenne temporelle au canal c et la covariance spatiale de la distribution gaussienne, sont estimés par maximum de vraisemblance avec une régularisation non-supervisée de \mathbf{C}_j par shrinkage, assurant un compromis biais/variance optimal [5]. On notera $\Omega_{c,j} = \{\mathbf{m}_{c,j}, \mathbf{C}_j\}$. La projection linéaire \mathbf{A} , apprise à partir des données, permet de décorrélérer l'espace des caractéristiques, où la distribution statistique est définie, à partir de l'espace des pixels. Ce modèle capture des corrélations spatiales à longues portées avec un nombre de degrés de liberté limité. En supposant que les collections de patches le long de la trajectoire d'une exoplanète sont indépendantes, ce modèle statistique local permet d'estimer le flux $\hat{\alpha}_c$ (temporellement invariant) à la position initiale $\mathbf{x}_1 \in \mathbb{R}^2$ en maximisant la vraisemblance globale :

$$\hat{\alpha}_c = \arg \max_{\alpha_c} \ell(\alpha_c, \mathbf{x}_1), \quad \text{avec :} \quad (2)$$

$$\ell(\alpha_c, \mathbf{x}_1) = \prod_{c,t} \prod_{j \in S(\mathbf{x}_t)} \mathbb{P} \left(\mathbf{A} \left(\mathbf{y}_{c,t}^{(j)} - \alpha_c \mathbf{h}_c^{(j)}(\mathbf{x}_t) \right) \middle| \hat{\Omega}_{c,j} \right)^{w_j}$$

où $\mathbf{h}_c^{(j)}(\mathbf{x}_t) \in \mathbb{R}^p$ est le patch j de la PSF centrée sur \mathbf{x}_t , et $S(\mathbf{x}_t)$ est le sous-ensemble des distributions modélisées pour

les patches autour de la position \mathbf{x}_t , chaque distribution j étant pondérée par $w_j \in \mathbb{R}_+$, avec $\sum w_j = 1$. À chaque position et date, plusieurs distributions sont donc modélisées mais la somme de leur contribution est unitaire, préservant ainsi l'hypothèse d'indépendance. Cette approche est aussi robuste aux données aberrantes car elle agrège les contributions de tous les patches se superposant (partiellement) à la position \mathbf{x}_t , modélisant ainsi la nuisance comme un processus convolutionnel. Par ailleurs, cette formulation est flexible car elle permet d'intégrer d'autres types de corrélations (voir Sect.3.3). La résolution de (2) à la position \mathbf{x}_1 donne l'estimateur du flux $\hat{\alpha}_c$, l'écart-type $\hat{\sigma}_c$ associé, ainsi que la valeur du critère de détection $\hat{\gamma}$ permettant de décider, par comparaison à un seuil de détection τ , entre l'absence (hypothèse \mathcal{H}_0) ou la présence (hypothèse \mathcal{H}_1) d'une exoplanète positionnée à \mathbf{x}_1 dans l'image à $t = 1$:

$$\hat{\alpha}_c = \frac{\sum_t b_{c,t}(\mathbf{x}_t)}{\sum_t a_{c,t}(\mathbf{x}_t)}, \hat{\sigma}_c = \frac{1}{\sqrt{\sum_t a_{c,t}(\mathbf{x}_t)}}, \hat{\gamma} = \frac{\sum_{c,t} b_{c,t}(\mathbf{x}_t)}{\sqrt{\sum_{c,t} a_{c,t}(\mathbf{x}_t)}}$$

avec

$$\begin{cases} b_{c,t}(\mathbf{x}_t) = \sum_{j \in S(\mathbf{x}_t)} w_j \mathbf{h}_c^{(j)}(\mathbf{x}_t)^\top \mathbf{A}_j^\top \hat{\mathbf{C}}_j^{-1} (\mathbf{A}_j \mathbf{y}_{c,t}^{(j)} - \hat{\mathbf{m}}_{c,j}), \\ a_{c,t}(\mathbf{x}_t) = \sum_{j \in S(\mathbf{x}_t)} w_j \mathbf{h}_c^{(j)}(\mathbf{x}_t)^\top \mathbf{A}_j^\top \hat{\mathbf{C}}_j^{-1} \mathbf{A}_j \mathbf{h}_c^{(j)}(\mathbf{x}_t). \end{cases}$$

Le critère de détection $\hat{\gamma}$ correspond au rapport de vraisemblance généralisé (GLRT) et suit, sous \mathcal{H}_0 , une distribution gaussienne $\mathcal{N}(0, 1)$. Il peut être interprété comme un rapport signal-sur-bruit de détection, associé à une probabilité de fausse alarme. En pratique, les estimations de $\hat{\alpha}_c, \hat{\sigma}_c, \hat{\gamma}$ sont conjointement effectuées à celles des statistiques $\hat{\Omega}_{c,j}$ caractérisant la nuisance, car ces dernières peuvent initialement être biaisées par la présence d'une exoplanète (voir Sect. 3.3). Les estimateurs $\hat{\alpha}_c, \hat{\sigma}_c$ et $\hat{\gamma}$ dans $\mathbb{R}^{H \times W}$ sont obtenus en tout point du champ en résolvant indépendamment (2) pour chaque position. Après seuillage de la carte de détection $\hat{\gamma}$ à un niveau de fausse alarme $1 - \Phi(\tau)$, une estimation affinée du flux et de la position sous-pixellique des exoplanètes est obtenue par optimisation continue autour du maximum du GLRT.

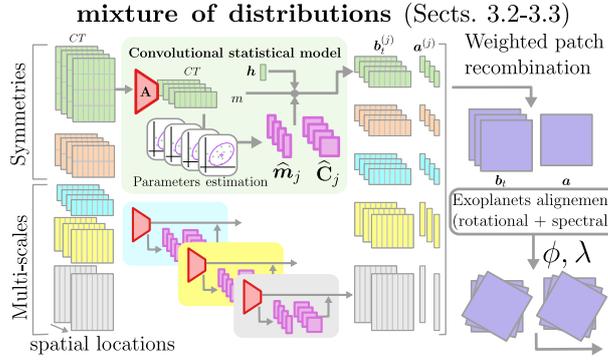
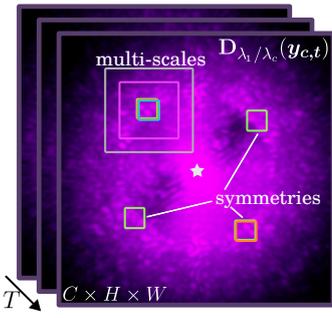
3.3 Modèle de mélange de distributions

Modélisation multi-échelle. Nous généralisons le modèle présenté en Sect. 3.2 en intégrant des distributions à plusieurs échelles spatiales via des patches de tailles variables $p \in \mathcal{P}$. L'ensemble des distributions modélisées est noté $\bigcup_{p \in \mathcal{P}} S_p(\mathbf{x}_t)$, où $S_p(\mathbf{x}_t)$ regroupe les patches de taille p contenant \mathbf{x}_t . La projection \mathbf{A} réduit la dimension des caractéristiques pour les grands patches, assurant le passage à l'échelle.

Modélisation des symétries. En imagerie directe, les speckles présentent des symétries centrales et par rotation liées à la physique de l'instrument, voir Fig. 1(a). Nous les exploitons pour modéliser la nuisance et atténuer l'effet d'*auto-soustraction* dû à une rotation apparente des exoplanètes trop limitée à proximité de l'étoile. Il entraîne un biais sur l'estimation des paramètres $\hat{\Omega}_{c,j}$ en raison de la présence potentielle d'exoplanètes à la position j , réduisant ainsi la sensibilité de détection. Pour y remédier, nous modélisons la distribution conjointe des patches extraits en j après rotation des images par $2\pi/K$:

$$\forall (j, c, t), \mathbf{A} [\mathbf{R}_{2\pi k/K} \mathbf{y}_{c,t}^{(j)}]_{k=1:K} \sim \mathcal{N}(\mathbf{m}_{c,j}, \mathbf{C}_j), \quad (3)$$

spectrally aligned data \mathbf{y}



learned object prior (Sect. 3.4)

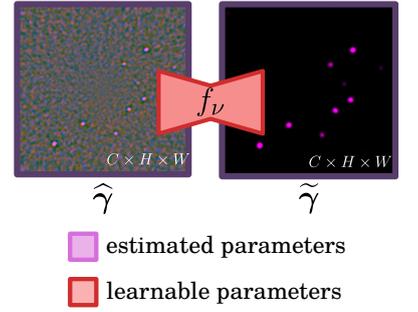


FIGURE 2 : Approche proposée combinant paramètres estimés et apprenables. Elle exploite la diversité spectrale des observations \mathbf{y} via un modèle convolutionnel de mélange de distributions capturant les symétries et les corrélations de la nuisance à différentes échelles spatiales. Le réseau f_ν (U-Net) apprend un a priori sur l’objet pour filtrer le score de détection $\hat{\gamma}$ issu du modèle statistique.

avec $\mathbf{A} \in \mathbb{R}^{m \times Kp}$. Les paramètres du modèle de mélange résultant (pour $K = 1, 2, 4$) sont moins sensibles à l’auto-soustraction, car la probabilité d’observer une exoplanète simultanément dans tous les patches modélisés est faible.

Modélisation spatio-spectrale jointe. La nuisance au canal c quelconque étant liée à celle du canal $c = 1$ (Sect. 3.1), nous proposons un modèle spatio-spectral conjoint :

$$\forall (j, c, t), \quad \beta_{c,j}^{-1} \mathbf{A} \mathbf{D}_{\lambda_1/\lambda_c}(\mathbf{y}_{c,t})^{(j)} \sim \mathcal{N}(\mathbf{m}_{c,j}, \mathbf{C}_j). \quad (4)$$

Cette approche réduit le biais sur l’estimation des paramètres $\hat{\Omega}_{c,j}$ en distinguant speckles et exoplanètes grâce à leur signature spectrale différente. L’amplitude locale $\hat{\beta}_{c,j}$ est estimée via l’écart-type des pixels de la collection $\mathbf{D}_{\lambda_1/\lambda_c}(\mathbf{y}_{c,t})^{(j)}$.

3.4 Entraînement supervisé

Nous combinons le modèle statistique de la nuisance (Sects. 3.3-3.4) avec un a priori sur les signaux exoplanétaires. La distribution spatiale de flux $\hat{\alpha}_c$ est ainsi estimée comme :

$$\hat{\alpha}_c = \arg \min_{\alpha_c \in \mathbb{R}^{H \times W}} \varphi_\theta(\alpha_c, \chi(\mathbf{y}_c)) + \psi_\nu(\alpha_c). \quad (5)$$

Le terme d’attache aux données φ_θ est défini par la co-log-vraisemblance du modèle de nuisance (Sects. 3.2-3.3), et ψ_ν est un a priori sur les signaux d’exoplanètes implémenté par un réseau neuronal. Les paramètres $\theta = \{\mathbf{A}_j, w_j\}_j$ et ν sont estimés conjointement à partir de données d’entraînement. Les paramètres de la nuisance $\chi(\mathbf{y}_c) = \{\hat{\Omega}_{c,j}, \hat{\beta}_{c,j}\}$ sont spécifiques à chaque observation \mathbf{y}_c . Nous proposons une approche en deux étapes pour résoudre (5) et estimer $\{\hat{\alpha}_c, \hat{\sigma}_c, \hat{\gamma}\}$. La résolution se fait d’abord avec le seul terme d’attache aux données, puis avec le réseau de neurones seul filtrant ainsi le flux estimé à l’étape précédente. Cette double approche repose sur le fait que, sous \mathcal{H}_0 , le critère $\hat{\gamma}$ suit approximativement une distribution gaussienne $\mathcal{N}(0, 1)$. Ainsi, l’extraction des signaux des exoplanètes consiste à débruiter $\hat{\gamma}$ afin d’éliminer le bruit résiduel. Ceci se formalise par $\tilde{\gamma} = f_\nu(\hat{\gamma})$, où f_ν est un débruiteur implémenté par un U-Net et $\tilde{\gamma}$ est la carte de détection finale. L’incertitude sur le flux est supposée être peu modifiée par le réseau (i.e., $\tilde{\sigma}_c = \hat{\sigma}_c$) car elle est principalement due à la variabilité des speckles, qui est largement capturée par le modèle statistique à l’étape précédente. La distribution spatiale de flux estimée est alors $\tilde{\alpha}_c = f_\nu(\tilde{\gamma}) \times \hat{\sigma}_c$. Cette formulation donne une distribution gaussienne pixel à pixel : $\mathcal{N}(\tilde{\alpha}_c, \tilde{\sigma}_c)$. L’estimation des paramètres θ et ν se fait par apprentissage supervisé en simulant de manière réaliste des exoplanètes synthétiques via (1), avec une distribution

spatiale de flux α_c^{gt} . La fonction objective minimisée est la co-log-vraisemblance entre α_c^{gt} et les estimées $(\tilde{\alpha}, \tilde{\sigma})$:

$$\mathcal{L}(\tilde{\alpha}, \tilde{\sigma}, \alpha_c^{\text{gt}}) = 0.5 \sum_c (\tilde{\alpha}_c - \alpha_c^{\text{gt}})^2 / \tilde{\sigma}_c^2 + \log \tilde{\sigma}_c. \quad (6)$$

Enfin, le modèle est calibré pour associer $\tilde{\gamma}$ à une probabilité de fausse alarme. Ceci se fait en estimant la fonction de répartition de $\tilde{\gamma}$ sous l’hypothèse \mathcal{H}_0 à partir d’un jeu de calibration.

3.5 Fusion multi-observations

Pour améliorer davantage la sensibilité de détection, nous fusionnons N observations \mathbf{y} de la même étoile (à nuisance indépendante) acquises sur plusieurs années, voir Fig. 1(b). Bien que le mouvement orbital des exoplanètes soit négligeable sur les quelques heures d’acquisition d’une seule observation \mathbf{y} , il devient significatif sur plusieurs mois. La fusion multi-observations consiste donc à estimer les paramètres orbitaux $\mu \in \mathbb{R}^7$ d’une exoplanète conjointement à sa détection [3]. La fusion optimale des N observations $\{\mathbf{y}_n\}_{n=1:N}$ revient à combiner les statistiques suffisantes $\{\mathbf{a}_n, \mathbf{b}_n\}_{n=1:N}$ produites pour chaque observation. L’estimateur du maximum de vraisemblance des éléments orbitaux μ est :

$$\hat{\mu} = \arg \max_{\mu} \left\{ \mathcal{C}(\mu) = \sum_{n=1}^N \frac{([\mathbf{b}_n(\mathbf{x}_n(\mu))]_+)^2}{\mathbf{a}_n(\mathbf{x}_n(\mu))} \right\}. \quad (7)$$

Cet estimateur permet de combiner de manière optimale les signaux d’une exoplanète potentielle le long de son orbite à travers les N observations. Le critère de détection fusionné, correspondant au GLRT multi-observations peut être approximé par $\gamma^{\text{comb}}(\mu) \simeq \sqrt{\mathcal{C}(\mu)}$. La résolution de (7) par exploration des paramètres μ peut se faire via un algorithme de Monte-Carlo hamiltonien, comme dans l’algorithme PACOME [3] qui optimise le critère (7) avec $\{\mathbf{a}_n, \mathbf{b}_n\}_{n=1:N}$ issus de l’algorithme PACO [4], basé sur une modélisation multi-variée gaussienne de la nuisance à l’échelle locale de patches.

4 Résultats

Nous évaluons les performances de la méthode sur des données réelles de l’instrument VLT/SPHERE. Les données 4D \mathbf{y} comprennent $T \in \llbracket 15; 300 \rrbracket$ images de $H \times W = 256^2$ pixels dans $L = 2$ canaux spectraux. Le modèle est entraîné sur 220 observations issues des archives de l’instrument. La détection est évaluée via l’aire sous la courbe (AUC) de caractéristique de performance du détecteur (ROC), qui mesure le compromis précision-retour en fonction du seuil de détection.

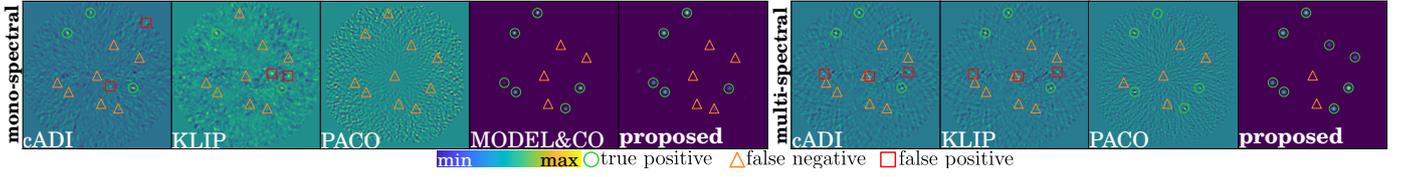


FIGURE 3 : Exemples de cartes de détection $\tilde{\gamma}$ obtenues sur données réelles avec simulations réalistes d'exoplanètes.

méthode	mono-spectral	multi-spectral
cADI	0.369 ± 0.010	0.416 ± 0.011
KLIP	0.478 ± 0.010	0.515 ± 0.009
PACO	0.520 ± 0.011	0.693 ± 0.011
MODEL&CO	0.644 ± 0.010	N/A
proposée	0.645 ± 0.005	0.762 ± 0.008

TABLE 1 : Scores de détection (AUC) agrégés pour différents algorithmes en ADI (traitement mono-spectral indépendant) et en ASDI (traitement multi-spectral conjoint). Le mode ASDI n'est pas supporté par MODEL&CO.

méthode	erreur flux	erreur position
PACO	0.56	0.21
proposée	0.51	0.11

TABLE 2 : Erreurs d'estimation des modèles statistiques sur le flux (ARE) et sur la position (RMSE).

L'estimation du flux α est quantifiée par l'erreur relative absolue (ARE), tandis que l'estimation de la position x_1 est évaluée par l'erreur quadratique moyenne (RMSE). Ces métriques sont calculées via simulation d'exoplanètes synthétiques par (1).

Nous comparons l'approche proposée aux méthodes cADI [7], KLIP [8], PACO [4] et MODEL&CO [1]. cADI et KLIP estiment empiriquement la nuisance, puis la soustraient aux données. cADI utilise une médiane temporelle (les speckles étant quasi-statiques, voir Fig. 1(a)), tandis que KLIP applique une décomposition en composantes principales tronquée. Ces approches produisent des estimés biaisés. PACO modélise statistiquement les covariances spatiales de la nuisance, capturant sa structure locale mais ignorant les corrélations à grande échelle. Toutes ces approches restent limitées par l'auto-soustraction, limitant la sensibilité de détection. MODEL&CO répond à ces limites via un modèle de nuisance construit à partir de plusieurs observations par apprentissage profond. Notre approche s'inscrit dans ce cadre et offre une meilleure interprétabilité grâce à une modélisation statistique, intégrant les symétries, les corrélations multi-échelles et la diversité des données.

La Fig. 3 montre des exemples de cartes de détection. Les Tables 1 et 2 rapportent les métriques de détection et d'estimation moyennées sur 5 jeux de données. La méthode proposée améliore significativement les performances, avec un gain supplémentaire apporté par le traitement multi-spectral conjoint. Enfin, la Fig. 4 illustre la stratégie de fusion décrite en Sect. 3.5 en combinant 23 observations de l'étoile HR 8799 collectées entre 2014 et 2022. L'approche proposée permet de détecter les trois exoplanètes connues dans le champ de vue et d'estimer conjointement leurs orbites, tout en améliorant la confiance de détection.

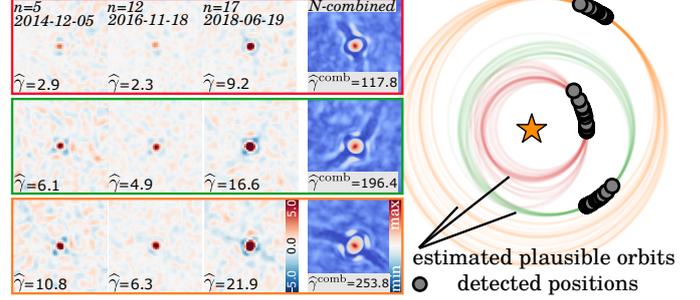


FIGURE 4 : Fusion de 23 observations de l'étoile HR 8799. Gauche : Exemples de cartes de détections individuelles $\hat{\gamma}$ et fusionnées $\hat{\gamma}^{\text{comb}}$ centrées sur les trois exoplanètes connues. Droite : Orbites $\hat{\mu}$ estimées conjointement à la détection.

5 Conclusion

Nous avons proposé une approche hybride combinant un modèle statistique multi-échelle et apprentissage profond, capturant les corrélations spatiales de la nuisance pour l'imagerie d'exoplanètes. Testée sur des données de l'instrument VLT/SPHERE, elle surpasse les méthodes de l'état de l'art et offre des garanties statistiques sur les estimées. L'approche sera étendue pour la reconstruction d'objets étendus, tels que les disques circumstellaires où se forment les exoplanètes, à partir de données à plus haute résolution spectrale.

Références

- [1] T. BODRITO *et al.* : MODEL&CO : Exoplanet detection in angular differential imaging by learning across multiple observations. *MNRAS*, 2024.
- [2] T. BODRITO *et al.* : A new statistical model of star speckles for learning to detect and characterize exoplanets in direct imaging observations. *In CVPR*, 2025.
- [3] J. DALLANT *et al.* : PACOME : Optimal multi-epoch combination of direct imaging observations for joint exoplanet detection and orbit estimation. *A&A*, 2023.
- [4] O. FLASSEUR *et al.* : PACO ASDI : an algorithm for exoplanet detection and characterization in direct imaging with integral field spectrographs. *A&A*, 2020.
- [5] O. FLASSEUR *et al.* : Shrinkage MMSE estimators of covariances beyond the zero-mean and stationary variance assumptions. *In EUSIPCO*, 2024.
- [6] K. FOLLETTE : An introduction to high contrast differential imaging of exoplanets and disks. *PASP*, 2023.
- [7] C. MAROIS *et al.* : Angular differential imaging : a powerful high-contrast imaging technique. *ApJ*, 2006.
- [8] R. SOUMMER *et al.* : Detection and characterization of exoplanets and disks using projections on Karhunen-Loève eigenimages. *ApJL*, 2012.

Ce travail est soutenu par l'ANR (PR[AI]RIE-PSAI ANR-23-IACL-0008, PEPR Origins ANR-22-EXOR-0016), l'ERC (APHELEIA 101087696, COBREX 885593) et l'ASHRA (CNRS/INSU).