

**UNIVERSITÉ CHOUAÏB DOUKKALI**

Faculté des Sciences — Département de Physique

Master Physique Computationnelle — Semestre 3

---

## **MODULE M232**

---

### **Téledétection SAR Radar**

*Du signal micro-onde à la détection de changement par Deep Learning*

**Dr. Imad HAMDİ** — Concepteur & Responsable

Docteur en Informatique Appliquée (IA) — UCD Maroc, 2022

Laboratoires LISTM-IMAGE & IMC-IEVIA

**Dr. Sara ZADA** — Co-Enseignante

**Année Universitaire 2025-2026**

[brilliantaiacademy.com](http://brilliantaiacademy.com)

## Table des matières

1. Objectifs pédagogiques du module
2. Principes fondamentaux du SAR
3. Le phénomène de Speckle
4. Pipeline de prétraitement SAR
5. Détection de changement : théorie et application
6. Deep Learning appliqué au SAR
7. Travaux Pratiques
8. QCM Évaluation SAR (30 questions)
9. Références scientifiques

## 1. Objectifs pédagogiques du module SAR

Ce document accompagne la Composante 2 (Télédétection) du module M232, spécifiquement la partie Télédétection Radar SAR. Il intègre les résultats de recherche publiés par l'enseignant (Hamdi et al., Computer Optics, 2021) et des données réelles Sentinel-1 du Maroc.

### Connaissances à acquérir

- Principes physiques du radar à synthèse d'ouverture (RSO)
- Interaction micro-ondes / surface terrestre (rétrodiffusion  $\sigma^0$ )
- Caractéristiques des bandes radar (L, C, X) et polarisations
- Techniques de traitement des images radar (calibration, filtrage speckle)
- Détection de changement (soustraction, log-ratio, composition colorée)
- Introduction au Deep Learning pour le SAR (Transfer Learning, ResNet-18)

### Compétences pratiques

- Workflow complet : import → calibration → filtrage → terrain correction
- Classification et seuillage sur données SAR
- Analyse avec Python (rasterio, numpy, matplotlib)
- Interprétation de séries temporelles SAR

### Applications (cas d'étude Maroc)

- Cartographie des inondations — Barrage El Mansour Eddahbi, Ouarzazate (sept. 2018)
- Estimation d'humidité du sol (SAR L-band / NISAR)

## 2. Principes fondamentaux du SAR

Le Radar à Synthèse d'Ouverture (SAR – Synthetic Aperture Radar) est un système d'imagerie actif qui émet ses propres impulsions micro-ondes et mesure le signal rétrodiffusé par la surface terrestre. Contrairement aux capteurs optiques passifs comme Sentinel-2, le SAR fonctionne de jour comme de nuit et à travers les nuages, ce qui en fait un outil indispensable pour la cartographie en cas de catastrophe.

### 2.1 Capteur actif vs passif

Le terme « synthèse d'ouverture » fait référence au mouvement du satellite le long de sa trajectoire : en combinant les signaux reçus à différentes positions, le SAR simule une antenne virtuelle beaucoup plus grande que l'antenne physique, obtenant ainsi une résolution azimutale très fine. Comme le rappelle l'article de Hamdi et al. (2021) : le SAR est considéré comme une technologie de télédétection active et puissante pour la collecte d'informations au sol quelles que soient les conditions.

### 2.2 Les bandes radar

Bande	$\lambda$	Fréquence	Mission	Application
X	~3 cm	8-12 GHz	TerraSAR-X, COSMO-SkyMed	Urbain, haute résolution
C	~5.6 cm	4-8 GHz	Sentinel-1 (ESA)	Inondations, agriculture
L	~23 cm	1-2 GHz	ALOS-2, NISAR (2025)	Biomasse, humidité sol

Tableau 1 : Bandes radar et missions SAR actuelles

### 2.3 Coefficient de rétrodiffusion $\sigma^0$

Le coefficient de rétrodiffusion  $\sigma^0$  (sigma-naught) est la mesure physique fondamentale en imagerie SAR : la section efficace radar normalisée par unité de surface, exprimée en décibels (dB). Les facteurs principaux qui influencent  $\sigma^0$  sont la rugosité de surface, l'humidité, l'angle d'incidence et la polarisation. Point clé : l'eau calme a un  $\sigma^0$  très faible (< -16 dB en bande C) car la surface lisse provoque une réflexion spéculaire, renvoyant l'énergie loin du capteur.

### 3. Le phénomène de Speckle

Le speckle (chatoiement) est un phénomène inhérent aux systèmes d'imagerie cohérente comme le SAR. Il résulte de l'interférence constructive et destructive entre les échos provenant de multiples diffuseurs élémentaires au sein d'une cellule de résolution.

#### 3.1 Distribution de Rayleigh

L'amplitude d'une image SAR suit une distribution de Rayleigh :  $f_R(h;\sigma) = \kappa \cdot (h/\sigma^2) \cdot \exp(-h^2/\sigma^2)$ . Cette distribution a été vérifiée expérimentalement sur nos données Sentinel-1B du barrage Eddahbi ( $\sigma \approx 0.045$ ).

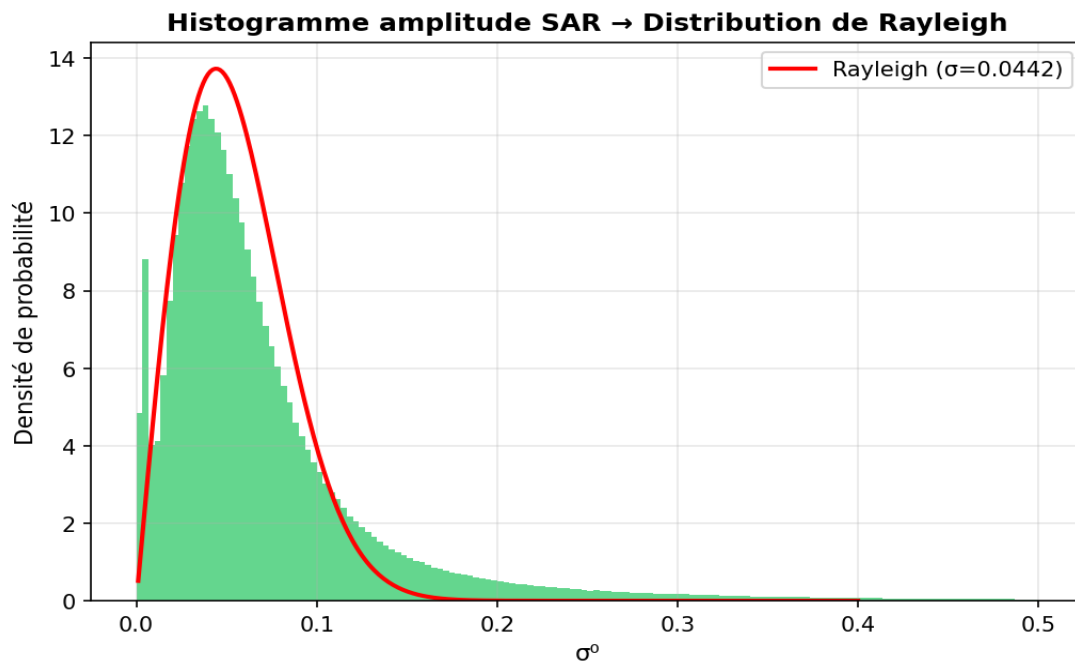


Figure 1 : Distribution de Rayleigh de l'amplitude SAR (image pré-inondation)

#### 3.2 Méthodes de filtrage

- Filtre de Lee (utilisé dans notre workflow, fenêtre 7×7) : adaptatif, préserve les contours
- Filtre de Frost : adaptatif exponentiel
- Filtres non-locaux (NL-Means) : meilleure préservation des détails
- CNN Despeckling (Hamdi et al., IEEE Morgeo 2020) : réseau de neurones convolutif

## 4. Pipeline de prétraitement SAR

Le pipeline standard de prétraitement SAR comprend 4 étapes essentielles, réalisées dans l’outil de traitement d’images satellitaires :

### Étape 1 : Calibration radiométrique

Convertit les valeurs numériques (DN) en valeurs physiques de  $\sigma^0$ . Sans cette étape, les valeurs de pixels n’ont aucune signification physique.

### Étape 2 : Filtrage du Speckle

Réduit le bruit multiplicatif. Paramètres recommandés : filtre Lee, taille 7x7, bande source Sigma0\_VV.

### Étape 3 : Correction de Terrain (Range-Doppler)

Projette l’image de la géométrie capteur (slant range) vers une projection géographique. DEM : SRTM 3Sec, Pixel Spacing : 10 m.

### Étape 4 : Découpage

Extraction de la zone d’étude via un shapefile ou des coordonnées géographiques.

## Capture d’écran du workflow dans le logiciel de traitement

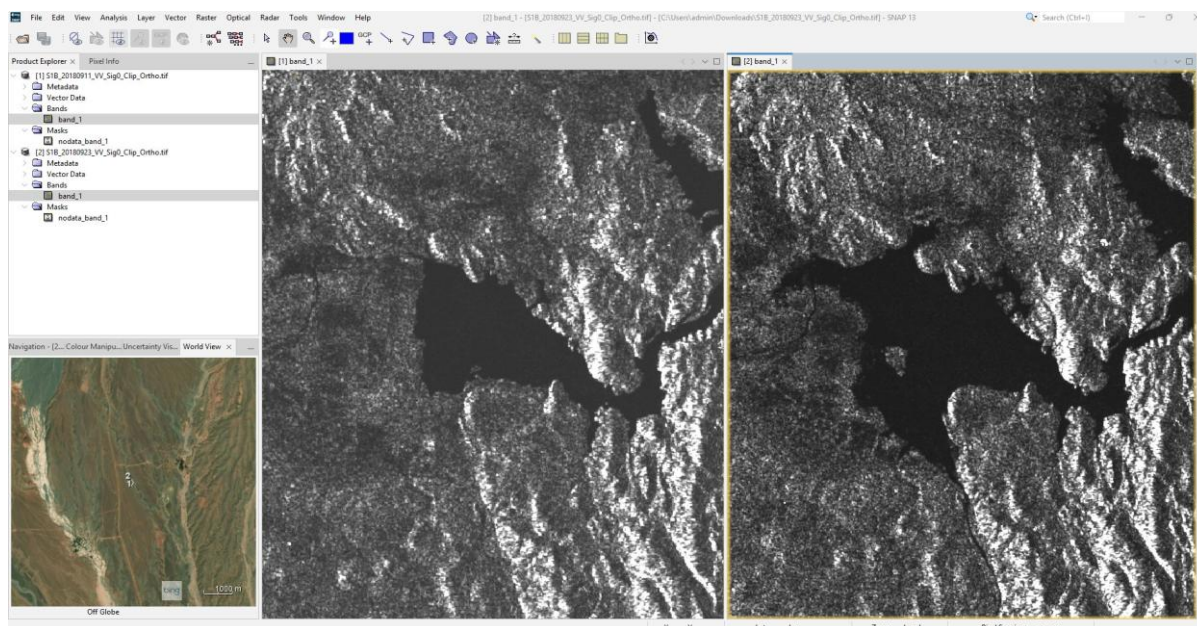


Figure 2 : Deux images Sentinel-1B (11 et 23 sept 2018) ouvertes dans le logiciel de traitement

## 5. Détection de changement : théorie et application

La détection de changement par imagerie SAR analyse une paire d'images acquises sur la même zone géographique à des instants différents pour identifier les changements survenus entre les dates d'acquisition (Hamdi et al., Computer Optics, 2021).

### 5.1 Les trois étapes fondamentales

1. Prétraitement des deux images selon le pipeline (chapitre 4)
2. Calcul de la différence : par soustraction ( $D = I_2 - I_1$ ), par ratio ou par log-ratio
3. Seuillage et classification : extraction des zones de changement

### 5.2 Images Sentinel-1B : pré et post-inondation

Images Sentinel-1B VV — Barrage Eddahbi, Ouarzazate




Figure 3 : Images Sentinel-1B VV avant (11/09/2018) et après (23/09/2018) inondation — Barrage Eddahbi

### 5.3 Image de différence




Figure 4 : Différence Post-Pré. Les zones bleues indiquent une baisse de  $\sigma^0$  (apparition d'eau)

### 5.4 Distribution gaussienne de la différence

Résultat clé (Vu et al., SPIE 2015) : la différence entre deux images SAR suit une distribution gaussienne. Ce résultat a été vérifié sur nos données avec  $\mu \approx 0.01$  et  $\sigma \approx 0.05$  :

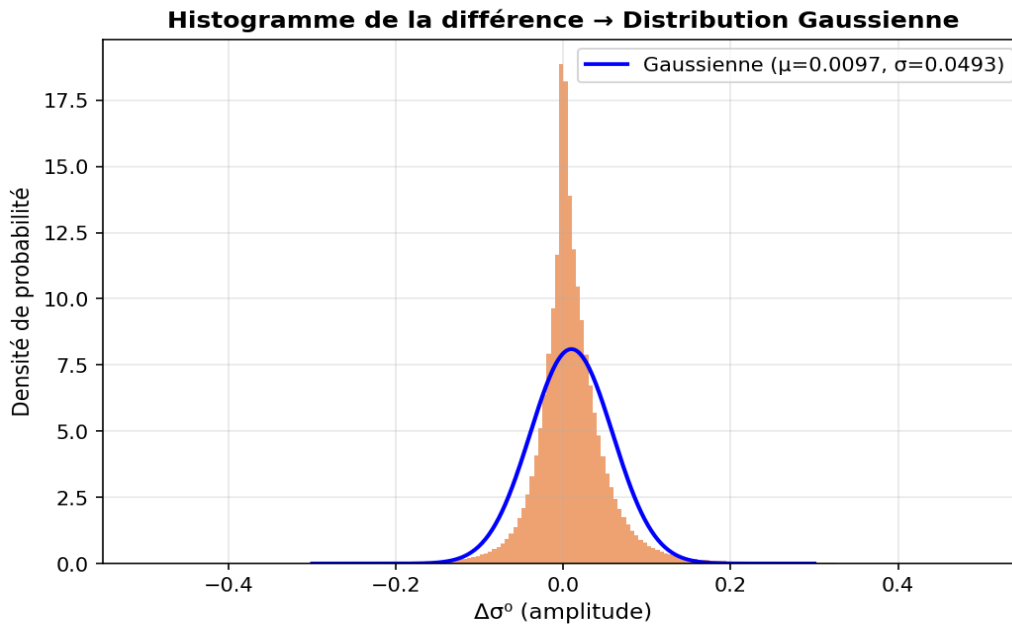


Figure 5 : Histogramme de la différence — distribution gaussienne confirmée sur données marocaines

### 5.5 Composition colorée multi-temporelle

R = image date 1 (pré-événement), V+B = image date 2 (post-événement). Les zones en cyan indiquent l'apparition de nouvelles surfaces d'eau.




Figure 6 : Composition RGB multi-temporelle — Barrage Eddahbi

### 5.6 Seuillage et masque d'inondation

Expression de binarisation :  $255 \times (\text{Sigma0\_VV} < 2.22\text{E-}2)$ . Ce seuil ( $\sim -16.5$  dB) est déterminé par analyse de l'histogramme de  $\sigma^0$ . Résultat :  $\sim 7.8\%$  de la zone classée comme inondée.

**Zones inondées détectées (seuil  $\Delta\sigma^0 < -0.04$ )**  
**Surface inondée: 7.8%**




Figure 7 : Masque de zones inondées détectées (seuil  $\Delta\sigma^0 < -0.04$ )

## 6. Deep Learning appliqué au SAR

Les méthodes classiques de seuillage ont des limitations : le choix du seuil est manuel et sensible au speckle résiduel. L'approche proposée par Hamdi et al. (2021) utilise le Transfer Learning avec ResNet-18.

### 6.1 Pipeline proposé (4 étapes)

4. Pré-traitement : réduction du speckle par CNN (Hamdi et al., Morgeo 2020)
5. Segmentation : Mask R-CNN pour délimiter les régions d'intérêt
6. Augmentation de données : de 100 patches (224×224×3) à 1104 images
7. Transfer Learning avec ResNet-18 pré-entraîné sur ImageNet

### 6.2 Architecture ResNet-18

ResNet-18 comprend 18 couches pondérées organisées en 5 blocs convolutionnels. Les trois dernières couches sont remplacées par une nouvelle couche Fully Connected, Softmax et Classification (2 classes : changé/non-changé). Entraînement : 810 itérations, 10 epochs, batch size 10. Précision globale : 94.84%.

### 6.3 Résultats comparatifs

Dataset	FCM (Q%)	DCNet (Q%)	Notre méthode (Q%)
Ottawa	88.30	90.56	<b>92.51</b>
Mexico	89.01	90.90	<b>91.59</b>
Shimen (Taiwan)	85.26	93.55	<b>94.86</b>

Tableau 2 : Performance comparative — Hamdi et al. (2021) vs FCM et DCNet

## 7. Travaux Pratiques

### TP1 : Détection d'inondation par seuillage

#### Données :

S1B\_20180911\_VV\_Sig0\_Clip\_Ortho.tif (pré) + S1B\_20180923\_VV\_Sig0\_Clip\_Ortho.tif (post)

#### Étapes :

8. Ouvrir les deux images dans le logiciel de traitement
9. Appliquer le pipeline de prétraitement (calibration → filtrage → terrain correction)
10. Calculer le log-ratio via l'algorithme de détection de changement
11. Analyser l'histogramme du log-ratio
12. Appliquer le seuil de binarisation :  $255 * (\text{Sigma0\_VV} < 2.22E-2)$
13. Générer l'image composée couleur (RGB)
14. Exporter en KMZ pour Google Earth

**Livrable : Image de changement + rapport avec histogramme**

### TP2 : Analyse Python

Script Python utilisant rasterio et numpy pour reproduire la détection de changement :

```
import rasterio, numpy as np
pre = rasterio.open('S1B_20180911_VV_Sig0.tif').read(1)
post = rasterio.open('S1B_20180923_VV_Sig0.tif').read(1)
diff = post - pre # Différence
flood = diff < -0.04 # Masque inondation
```

### Planche d'analyse complète

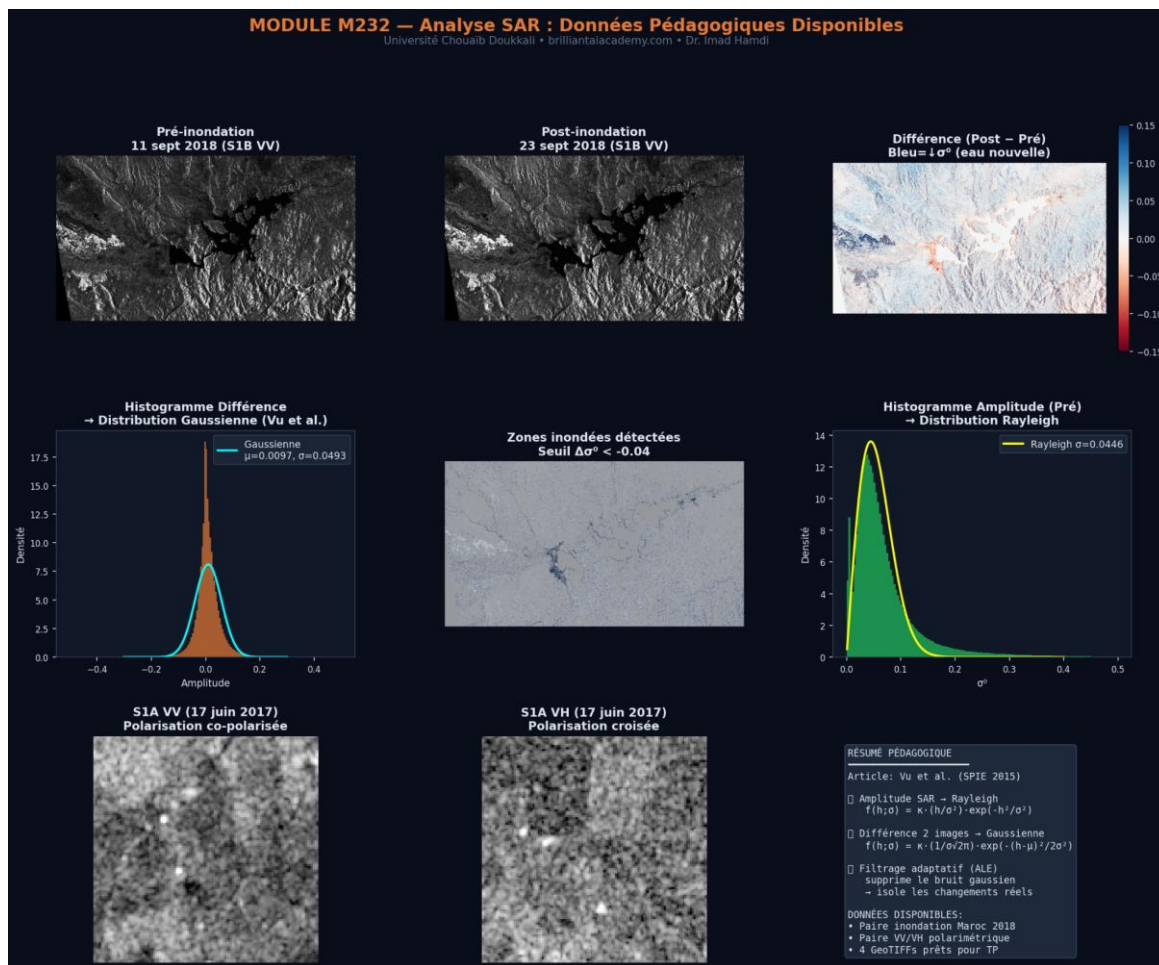


Figure 8 : Planche d'analyse SAR complète — 6 visualisations des données pédagogiques

## 8. QCM Évaluation SAR — 30 questions

Durée : 45 minutes | Barème :  $30 \times 0.67 = 20$  points | Documents non autorisés

### Distribution des questions

- Bloc A (10 questions) : Principes et prétraitement SAR
- Bloc B (10 questions) : Détection de changement
- Bloc C (10 questions) : Deep Learning SAR

Le QCM complet avec réponses et justifications est disponible en document séparé.

### Exemples de questions

#### Q1. Le SAR est un capteur :

- A) Passif qui mesure le rayonnement solaire réfléchi
- B) Actif qui émet et reçoit ses propres ondes micro-ondes ✓
- C) Passif qui mesure l'émission thermique de la surface

#### Q13. La distribution de la différence entre deux images SAR suit :

- A) De Rayleigh
- B) Exponentielle
- C) Gaussienne (normale) ✓

#### Q26. La précision de Hamdi et al. (2021) sur Ottawa :

- A) 88.30% (Q)
- B) 90.56% (Q)
- C) 92.51% (Q) ✓

## 9. Références scientifiques

- [1] Hamdi I., Tounsi Y., Benjelloun M., Nassim A. (2021). Evaluation of the change in synthetic aperture radar imaging using transfer learning and residual network. *Computer Optics*, 45(4): 600-607. DOI: 10.18287/2412-6179-CO-814
- [2] Hamdi I., Tounsi Y., Benjelloun M., Nassim A. (2020). Batch despeckling of SAR images by a CNN-based method. *IEEE Morgeo*. DOI: 10.1109/Morgeo49228.2020.9121890
- [3] Vu V.T., Machado R., Pettersson M.I., Dammert P., Hellsten H. (2015). SAR image statistics and adaptive signal processing for change detection. *SPIE Vol. 9475*, 947509.
- [4] He K., Gkioxari G., Dollár P., Girshick R. (2017). Mask R-CNN. *IEEE ICCV 2017*: 2980-2988.
- [5] He K., Zhang X., Ren S., Sun J. (2015). Deep Residual Learning for Image Recognition. *arXiv:1512.03385*.
- [6] Gao Y., Gao F., Dong J., Wang S. (2019). Change detection from SAR based on channel weighting deep cascade network. *IEEE JSTARS*, 12(11): 4517-4529.
- [7] Wang Z., Bovik A.C. (2002). A universal image quality index. *IEEE Signal Processing Letters*, 9(3): 81-84.