

---

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR  
ET DE LA RECHERCHE SCIENTIFIQUE  
UNIVERSITE EL HADJ LAKHDAR-BATNA

**THESE**

Présentée à la :

FACULTE DES SCIENCES DE L'INGENIEUR  
DEPARTEMENT D'ELECTRONIQUE

Pour l'obtention du diplôme de

**DOCTORAT**

**Option : Contrôle**

Par :

**GOUICEM ALI MOHAMED TAHAR**

**THEME**

**OPTIMISATION PAR ALGORITHME GENETIQUE  
MULTIOBJECTIF DE LA PENALITE FLOUE POUR LA  
RECONSTRUCTION D'IMAGES A PARTIR DE  
PROJECTIONS EN TOMOGRAPHIE-X**

Soutenu le : 10/03/2013

Devant la commission d'examen :

Pr : DIBI ZOHIR	Université de Batna	Président
Pr : BENOUDJIT NABIL	Université de Batna	Examineur
Pr : BOUHOUCHE SALAH	URASM Annaba	Examineur
Pr : SAHRAOUI TAHAR	Université de Blida	Examineur
Pr : BENMAHAMMED KHIER	Université de Sétif	Promoteur
Mr : YAHY MOSTAPHA	CSC Alger	Promoteur
Pr : ABDELMALIK TALEB-AHMED	Université de Valenciennes	Invité
Pr : DRAI RADOUANE	CSC Alger	Invité

---

## Résumé

Puisque les approches de reconstruction d'images sont très mal posées par le fait que les projections sont en nombres limitées, les méthodes de reconstruction classiques comme la méthode analytique basée sur la transformée inverse de radon, ou les méthodes algébriques comme les moindres carrées, ne peuvent donner des résultats satisfaisants. Il est alors indispensable d'apporter de l'information a priori sur l'objet pour régulariser le problème. L'une des approches c'est la modélisation probabiliste de cette information et l'estimation bayésienne ainsi que l'inférence floue. Dans ces méthodes les paramètres sont estimés à partir des projections en définissant la solution comme un minimiseur d'un critère régularisé approprié; soit par Moindre Carrées (MC) ou une méthode itérative régularisée comme le Maximum-Likelihood (ML), ou le maximum a posteriori (MAP), ou la régularisation floue.

Les résultats après l'introduction des optimisateurs globaux, tels que les algorithmes génétiques et les optimisateurs PSO sont comparés avec l'utilisation des optimisateurs locaux tels que le gradient, newton-raphson etc. Notre nouvelle méthode a été testée et validée sur un ensemble d'images synthétiques et réelles. Les résultats simulés sont vraiment encourageants spécialement quant le nombre et les angles des projections sont limités. Quelques comparaisons avec les méthodes classiques (Analytiques, Algébriques et Probabilistes) sont faites pour attester les performances de nos méthodes proposées.

**Mots clés:** Tomographie, Reconstruction d'images, contrôle non destructif CND, Estimation analytique, Inférence bayésienne, Inférence floue, Optimisation génétique, Optimisateur PSO (Particle Swarm Optimization).

---

## Remerciements

*Ce travail n'aurait pu se dérouler dans les meilleures conditions sans l'aide précieuse et nécessaire de Monsieur le directeur de recherche du CSC Mostapha Yah, qui a toujours encadré mon travail avec propos.*

*Mes vifs remerciements vont aussi à Monsieur le Directeur de recherche Draï Radouane qui a suivi ce travail du premier pas à la finition, qu'il trouve ici ma respectueuse reconnaissance.*

*Je tiens à remercier Monsieur le professeur Abdelmalik Taleb-Ahmed pour avoir accepté d'évaluer ce travail durant tout les stages que j'ai réalisé dans son laboratoire à l'université de Valenciennes en France. Qu'il trouve ici l'expression de mes vifs remerciements.*

*Je remercie aussi Monsieur le professeur Dibi Zohir, qui m'a fait l'honneur d'accepter la présidence du jury*

*Je remercie aussi Monsieur le professeur Benoudjit Nabil, qui m'a fait l'honneur d'accepter d'examiner ce travail.*

*Je remercie aussi Monsieur le professeur Sahraoui Tahar, qui m'a fait l'honneur d'accepter d'examiner ce travail.*

*Je remercie aussi Monsieur le professeur Bouhouche Salah, qui m'a fait l'honneur d'accepter d'examiner ce travail.*

*Je témoigne de ma profonde reconnaissance à Monsieur le professeur benmhammed khier pour l'encadrement de cette thèse. Je le remercie sincèrement.*

*Je remercie aussi celle qui ma soutenu moralement pendant la réalisation de ce travail, et qui a eu la patience de me supporter : ma femme ; Guiri Samia.*

*Et bien particulièrement mes parents, mes sœurs, mes frères, mon fils Haithem.*

*Ali Mohamed Tahar*

---

## Dédicaces

*A l'âme de mon père Laabidi.*

*A ma mère Habilla.*

*A ma chère femme Guiri Samia.*

*A mes sœurs Naima, Wassila, Kamilia, Samiha.*

*A mes frères Nourdine, Kamel, Sofiane, Aiman.*

*A mes enfants Haithem, Allaa, Douaa, Arije.*

---

## SOMMAIRE

<b>Introduction générale</b>	10
------------------------------	----

### **Chapitre I: Reconstruction tomographique par Rayons-X**

I.1.Reconstruction tomographique et Contrôle Non Destructive (CND)	17
I.2.Modélisation des objets et nature des données	17
I.3.Introduction au Problème Inverse	20
I.4.Inférence floue	22
I.5.Optimisation par algorithme génétique	22
I.6.Les caractéristiques principales du tomographe Fein Focus.	23
I.7.Conclusion	29

### **Chapitre II: Passage en revue de quelques méthodes de reconstruction**

#### **II.1. Méthode Analytique et Transformée de Radon Inverse**

II.1.1 Transformée de Radon (TR) et la modélisation des mesures.	32
II.1.2. Problème direct.	32
II.1.3. Projections et bruit.	33
II.1.4. Problème de données incomplètes et détection de singularités.	34
II.1.5. Rétroprojection filtrée.	34
II.1.6. Résultats de simulation.	35
II.1.7.Conclusion.	40

#### **II.2. METHODES ALGEBRIQUE**

II.2.1. Discrétisation du problème.	41
-------------------------------------	----

---

II.2.2. Rétroprojection comme opérateur adjoint de la TR et sa matrice équivalente de transposition.	42
II.2.3. Moindre carrée(MC) et Inversion Généralisée(I.G).	42
II.2.4. Régularisation.	43
II.2.5. Inversion généralisée et Décomposition en Valeurs Singulières (SVD).	43
II.2.6.Résultats et discussion.	44
II.2.7.Conclusion.	46

### **II.3: METHODE ITERATIVE ET INFERENCE BAYESIENNE**

II.3.1. Introduction.	47
II.3.2. Régularisation Itérative.	47
II.3.3. L'algorithme Du Maximum Likelihood Expectation Maximisation MLEM	49
II.3.3.1. Implémentation de l'algorithme.	49
II.3.3.2.Résultats et discussion.	52
II.3.3.3.Conclusion.	56
II.3.4.L'Algorithme Du Maximum A Posteriori MAPEM.	57
II.3.4.1.Introduction à la régularisation (inférence Bayésienne).	57
II.3.4.2.Implémentation de l'algorithme.	58
II.3.4.3.Résultats et discussion.	59
II.3.4.5.Conclusion.	63

### **II.4: INFERENCE FLOUE**

II.4.1 Modélisation floue.	65
II.4.2 Bases Théoriques et implémentation de l'algorithme d'inférence floue.	67
II.4.2.1.La fonction potentielle floue.	68
II.4.2.1.1. Etape détection.	69
II.4.2.1.2. Etape pénalisation.	70
II.4.2.2.Algorithme de la méthode FPEM (Fuzzy Penalty Expectation Maximization	70
II.4.3.Résultats et discussion.	71
II.4.4.Conclusion	74

---

## **Chapitre III: Nouvelle Approche Génétique pour l'optimisation de la pénalité floue pour la Détermination des Paramètres d'un Objet à partir des Projections en Tomographie-X**

III.1.Introduction.	77
III.2.Opérateurs de l'algorithme génétique.	88
III.3.Optimisation à l'aide de l'algorithme génétique.	89
III.4.L'algorithme global de la méthode FPGA (Fuzzy Penalty Genetic Optimization).	91
III.5. Résultats et discussion.	92
III.5.1. Description des données.	92
III.5.2 Résultats de simulation.	92
III.5.3.Limites de l'algorithme FPGA.	93
III.5.4. Conclusion.	102
<b>Conclusion et perspectives</b>	104
<b>Bibliographie</b>	107

---

## Nomenclature

<i>GA</i>	: <i>Algorithme Génétique.</i>
<i>MLEM</i>	: <i>Maximum Likelihood Expectation Maximization.</i>
$\beta$	: <i>Paramètre de régularisation.</i>
$\lambda$	: <i>Paramètre de régularisation.</i>
$\Delta$	: <i>Distances Euclidienne.</i>
$\eta$	: <i>Bruit.</i>
$\mu$	: <i>Coefficient d'atténuation de l'objet.</i>
<i>SPECT</i>	: <i>Single-Photon Emission Computed Tomography</i>
<i>MAPEM</i>	: <i>Maximum A Posteriori Expectation Maximization.</i>
<i>OSEM</i>	: <i>Ordered Subsets Expectation Maximization.</i>
<i>FPGA</i>	: <i>Fuzzy Penalty Genetic Algorithm.</i>
<i>FPEM</i>	: <i>Fuzzy Penalty Expectation Maximization.</i>
$\theta$	: <i>Angle de projecxtion.</i>
<i>e</i>	: <i>Erreur.</i>
<i>w</i>	: <i>Paramètre de pondération.</i>
<i>PSO</i>	: <i>Particle Swarm Optimization.</i>
<i>MC</i>	: <i>Moindres carrées.</i>
<i>TV</i>	: <i>Variation Totale.</i>
<i>WLS</i>	: <i>Weighted least square (Moindres carrées pondéré).</i>
<i>J(f)</i>	: <i>Critère de régularisation.</i>
$\Omega(f)$	: <i>_log la loi de probabilité a priori.</i>
<i>CT</i>	: <i>La reconstruction tomographique.</i>
<i>CND</i>	: <i>Contrôle non destructive.</i>
<i>PET</i>	: <i>Positron emission tomography.</i>
<i>SNR</i>	: <i>Signal to noise ratio (Rapport signale sur bruit).</i>
<i>R</i>	: <i>Matrice du système.</i>
<i>p</i>	: <i>Projection.</i>
<i>f(x, y)</i>	: <i>Image pixels.</i>
<i>TS</i>	: <i>Takagi Sugéno</i>

---

<i>MM</i>	: <i>Mamdani</i>
<i>SVD</i>	: <i>Décomposition en valeurs singulières</i>
<i>E</i>	: <i>Edge (bord ou contour).</i>
<i>FIS</i>	: <i>Système d'Inférence flou.</i>
$G_N$	: <i>Différence entre les niveaux de gris des pixels.</i>
<i>FCM</i>	: <i>Regroupement flou (Fuzzy Means Clustering).</i>
<i>RWS</i>	: <i>Schéma de la roue de la loterie (Roulette Wheel Schemes).</i>
<i>MSE</i>	: <i>Median Square Error (carrée de l'erreur moyenne).</i>
<i>FBP</i>	: <i>Rétroprojection filtrée</i>

---

## INTRODUCTION GENERALE

En imagerie tomographique, on cherche à déterminer l'image non mesurable d'un objet à l'intérieur d'un corps, par l'intermédiaire des atténuations par rayon-x qui sont mesurable. Définir les relations mathématiques entre la grandeur inconnue et celle mesurée est la modélisation. La détermination de la fonction de transfert de l'appareillage de mesure tomographique est l'identification. La détermination de la grandeur inconnue à partir des mesures est ce qu'on appelle un problème inverse[1].

Dans le Contrôle Non Destructif (CND), on cherche un défaut de construction à l'intérieur d'une pièce. La détermination de la forme du défaut reste un problème difficile à résoudre. D'où le coup en calcul des méthodes de reconstructions existantes et qui reste un problème gênant dans les applications industrielles[1].

La reconstruction tomographique à partir d'un nombre limité de données est donc un problème mal-posé, car les données de projections sont initialement bruitées. L'algorithme ML (Maximum Likelihood) tend à faire croître ce bruit et particulièrement celui dû au bruit des artefacts à travers les itérations successives. Cette accumulation de bruit mène à un arrêt du processus de reconstruction ML-EM (Maximum Likelihood Expectation Maximization).

Dans les problèmes de reconstruction d'images, on est souvent amené à résoudre une équation intégrale de première espèce. L'inversion de cette équation est en général un problème mal-posé car elle ne satisfait pas les trois conditions; d'existence d'unicité et surtout de stabilité [1]. Une manière de transformer le problème en un problème bien-posé consiste à le régulariser, c'est-à-dire à introduire une information a priori sur la solution recherchée. Cette information a priori peut nous être donnée soit sous une forme déterministe, positivité par exemple, soit sous une forme stochastique (loi de probabilité de l'image ou plutôt contraintes sur cette loi de probabilité) [2].

Pour résoudre ces problèmes on doit le discrétiser, et alors trouver la solution d'un système d'équations linéaires. Qui est en général mal-déterminé. La difficulté est alors d'obtenir une solution unique et acceptable pour ce système d'équations linéaires, en exploitant l'information a priori dont on dispose sur la solution. Cette information a priori peut être la positivité de la solution par exemple[1]. Les erreurs et le bruit des mesures nous poussent à adopter une approche stochastique par exemple l'approche bayésienne pour la résolution de tel

---

problème inverse, puisqu'elle prend en compte l'information a priori sur la solution et celle sur les données[2].

Des méthodes ont été développées pour minimiser l'accumulation de bruit et améliorer la qualité de l'image reconstruite. On peut citer ceux de A.M.Djafari [1] où on inclut une fonction de pénalité(dites aussi techniques de régularisation) pour minimiser le bruit, c'est le cas de l'algorithme du Maximum A Posteriori (MAP) basé sur le théorème de Bayes [5]. La solution MAP peut être trouvée en combinant la fonction likelihood de Poisson avec l'a priori de l'image.

L'algorithme MAP présente des handicaps dans le voisinage local pour minimiser ou éliminer le bruit et lisser l'image reconstruite. Ils existent de nombreuses méthodes qui utilisent la technique de la préservation du contour comme l'a priori de Gibbs basé sur les champs de Markov [6], l'a priori d'entropie [5], l'a priori de la racine moyenne (MRP) [7], l'a priori de la variation totale (TV) [9]. Récemment, J.Fessler [3] utilise Une autre méthode de reconstruction itérative d'images c'est la méthode Moindre Carrée pondérée appelée Weighted Least Squares (WLS) method [3, 10]. Où il prouve que cet algorithme converge rapidement et produit des images de bonnes qualités.

Il y a eu plusieurs travaux dans la reconstruction d'images en relation avec ce problème inverse. On donne ici un résumé des différentes approches: au début Rajan et al [12] et Ville et al [7] utilisent le système d'inférence floue pour modéliser l'information a priori définie par la fonction de Gibbs dans le champ de Markov et le potentiel qui définit la nature de l'interaction pixel-pixel dans la fenêtre de voisinage. L'algorithme est constitué de deux étapes élémentaires: Détection de seuil flou (dans la fenêtre du voisinage proche) et le lissage flou (la pénalisation est réalisée seulement sur les pixels pour les quelles on n'a pas détecté de seuil). Qureshi et al [13] utilisent l'algorithme génétique pour optimiser l'erreur entre les projections mesurées et calculées. Günel et al [14] utilisent les données de projections avec l'algorithme GA de base pour la détermination des paramètres de l'objet. Cependant, les résultats obtenus restent dépendants du choix des paramètres de pondération.

Dans ce travail, nous proposons une nouvelle méthode combinée pour la reconstruction d'images avec la pénalisation de vraisemblance (ML) qui combine la fonction de Pénalité Floue (FP) avec l'optimisation par algorithme génétique (GA). L'algorithme proposé ne souffre pas des mêmes problèmes que ceux de l'algorithme ML-EM (maximum likelihood expectation maximization). Il converge rapidement vers une solution non bruitée même si le nombre d'itérations est élevé. Il donne une estimation globale et non pas une locale (comme

---

pour les algorithmes classiques par exemple le gradient), aux problèmes inverses de détermination des paramètres d'un objet.

Le modèle d'inférence flou approxime réellement la correction nécessaire pour le lissage de l'image, néanmoins il ne peut pas garantir l'obtention de la solution optimale. Les techniques évolutionnaires peuvent atteindre rapidement une bonne solution globale sans avoir besoin d'une grande mémoire ou des capacités de calcul importantes [15].

L'approche que nous proposons, combine l'inférence floue dans l'information a priori de pénalisation avec l'optimisation par algorithme génétique du critère pour obtenir l'image solution globale estimée du problème.

Dans ce travail, nous présentons une méthode qui exploite le raisonnement flou dans une forme de modèle de correction floue (lissage), ainsi la solution image optimale (globale) du problème inverse est donnée par l'algorithme GA de base pour éviter la solution locale.

La méthode a été testée et validée sur un ensemble de données d'images synthétiques et réelles.

Les résultats simulés sont vraiment encourageants particulièrement quand le nombre et les angles des projections sont limités. Quelques comparaisons avec les méthodes classiques sont faites pour montrer les performances des solutions proposées.

Ce travail est organisé de la façon suivante. Nous donnons dans le chapitre 1 une brève introduction théorique de la reconstruction tomographique. Dans le chapitre 2 nous présentons un historique des méthodes de reconstructions d'images ; La méthode analytique et les méthodes algébriques de reconstruction. Nous parlons aussi de l'inférence bayésienne et nous présentons les caractéristiques principales de l'inférence floue pour la modélisation de la correction ainsi que la méthode utilisée pour construire le modèle flou que nous proposons. Le chapitre 3 présente notre nouvelle méthode de l'AG combiné avec l'inférence floue et qui est utilisée pour trouver et optimiser l'image solution globale du problème inverse. Nous présentons nos résultats d'applications de notre méthode pour des images synthétiques et réelles. Nous terminons par les conclusions et les perspectives de ce travail.

---

# CHAPITRE 1

---

# **Chapitre I**

## **Reconstruction tomographique par Rayons-X**

### **Résumé**

La tomographie c'est la reconstruction de fonction d'image d'une ligne intégrale des projections, c'est un problème inverse mal posé. Les mathématiques de la reconstruction tomographique se concentrent autour des questions d'existence, d'unicité, et de stabilité. Ce problème mathématique se rencontre dans de nombreux domaines de diverses spécialités, en médecine et en technologie comme le contrôle Non destructif (CND). De ce fait plusieurs aspects de la reconstruction tomographique ont été étudiés et sont maintenant bien déterminés. Un autre grand problème, c'est la reconstruction trois dimensions qui reste un problème numérique ouvert.

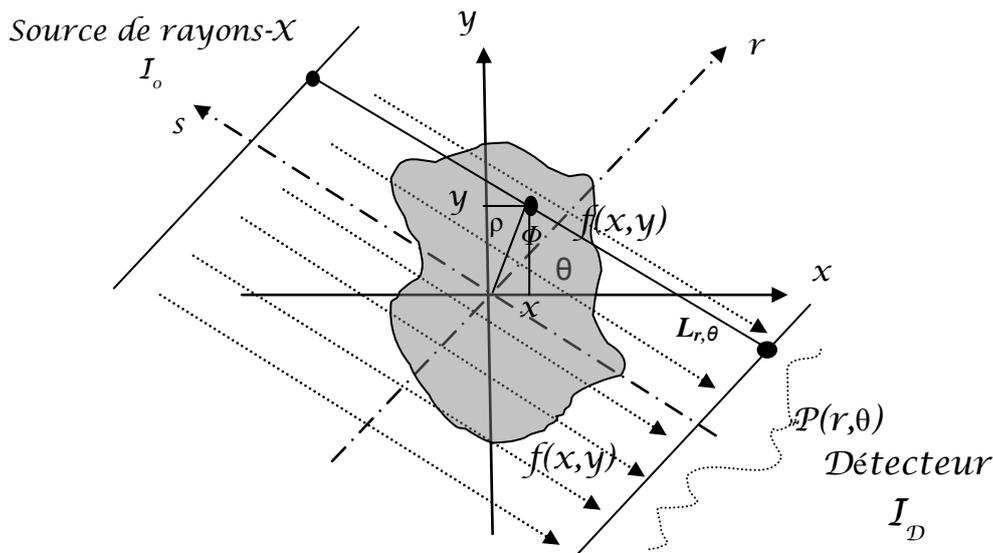
## I.1.Reconstruction Tomographique et contrôle non destructive CND

La reconstruction tomographique nous permis l'accès a des informations sur un objet 3D non destructive. La reconstruction tomographique est un problème inverse mal posé. Les algorithmes analytiques sont dérivés de la théorie de Radon qui est appliquée aux signaux continus [Radon 1917]. Dans la reconstruction tomographique le bruit contribue aussi à la malposition du problème de reconstruction[7].

## I.2. Objets et Données

Si un objet (figure.I.1) est illuminé par des rayons X l'intensité du rayon mesuré à la sortie est donnée par l'équation (I-1). Les données que l'on appelle projections sont formées par  $n$  images 2D (radiographiques). Le phénomène physique est modélisé par:

$$I_D = I_0 \exp\left(-\int_L \mu(x, y) f(x, y) dl\right) \quad (I-1)$$



*Figure.I-1: mesure de projections en tomographie à rayon-x*

Où

- $r = x \cdot \cos\theta + y \cdot \sin\theta$  ;  $(r; \theta)$  : représente les coordonnées relative de l'objet.
- $L$  est la distance parcourue par le rayon.
- $dl$  est l'élément de longueur sur le parcours  $L$ .
- $r$  désigne le rayon de projection, c'est la ligne dont la normale à travers l'origine forme un angle  $\theta$  avec l'axe- $x$  positive.
- $I_0$  valeur de l'intensité de source de rayon-x.
- $I_D$  valeur de l'intensité mesurée.

---

- $f$  fonction densité de l'objet.

- $\mu$  coefficient d'atténuation de l'objet.

L'expression  $-\text{Log } I_D/I_0$  correspond aux données de projections.

$$p(r, \theta) = \int_{L_{r,\theta}} f(x, y) dl \quad \text{C'est le problème direct} \quad (I-2)$$

En se référant à la figure.1, on voit que cette équation peut aussi s'écrire sous la forme.

$$p(r, \theta) = \iint_D f(x, y) \delta(r - x \cos \theta - y \sin \theta) dx dy \quad (I-3)$$

$p(r, \theta)$  la transformée de Radon de la fonction  $f(x, y)$ .  $\delta$ : distribution de Dirac. Radon a montré l'existence et l'unicité de cette transformée symbolisée par  $p(r, \theta) = R(f(x, y))$  et de son inverse :  $f(x, y) = IR(p(r, \theta))$  exprimée par :

$$f(x, y) = \left( \frac{-1}{2\pi^2} \right) \int_0^\pi \int_{-\infty}^{+\infty} \frac{\frac{\partial}{\partial r} p(r, \theta)}{(r - x \cos \theta - y \sin \theta)} dr d\theta \quad (I-4)$$

Les mesures de projections sont limités donc Le problème de reconstruction d'image est la détermination de la fonction  $f(x, y)$  à partir des projections  $p(r, \theta)$ . C'est un problème inverse qui est généralement mal posé. Pour le résoudre deux méthodes sont envisagées:

- Approche analytique : intégration numérique de la transformée inverse de radon.
- Approche par discrétisation de l'équation (I-2) ce qui peut s'écrire :

$$p = R.f + n \quad (I-5)$$

$n$ : bruit

$R$ : matrice du système de projection.

La solution approchée est définie comme un minimiseur d'un critère:

$$J(f) = \Delta_1(p, Rf) + \lambda \Delta_2(f, f_0) \quad (I-6)$$

$\lambda$ : paramètre de régularisation.  $f_0$  solution a priori de l'objet.  $\Delta_1$  et  $\Delta_2$  deux distances (Euclidienne par exemple) qui sont:

$$\Delta_1(p, Rf) = Q(f) = \|p - Rf\|^2 \quad (I-7)$$

$$\Delta_2(f, f_0) = \Omega(f) = \|f - f_0\|^2$$

On peut choisir  $J(f)$  comme étant un critère du maximum a posteriori (MAP) dans l'estimation bayésienne.  $Q(f)$  représente le terme  $\log\_likelihood$ , et  $\Omega(f)$   $\_log$  la loi de probabilité a priori. Le types de fonction  $\Omega(f)$  dans notre etude est markovienne.

-Loi Markovienne

$$\Omega(f) = \sum_{j=1}^N \sum_{i \in N_j} v(f_j, f_i) \quad (I-8)$$

Avec  $v(x, y)$  une fonction de potentiel convexe telle que :

$$v(x, y) = \left\{ |x - y|^p, -|x - y| \log(x/y), \log \cosh|x - y|, \sqrt{1 + |x - y|^2}, \dots \right\}$$

Ou alors  $v(x, y)$  une fonction de potentiel non convexe telle que :

$$v(x, y) = \left\{ \min \{ |x - y|^2, 1 \}, -1/(1 + |x - y|^2), \dots \right\}$$

La modélisation Markovienne permet de construire des modèles qui peuvent prendre en compte les discontinuités dans une image.

### **I.3. Introduction au Problème Inverse**

La forme de l'équation intégrale du premier ordre est:

$$p(\theta_i) = \int_D f(r).R(r, \theta_i)dr + n(\theta_i) \quad i=1, M \quad (I-9)$$

Où

- $p$  sont les mesures des projections.
- $f$  est l'objet.
- $D$  est le support Objet.
- $R$  Matrice du système.
- $n$  représente l'erreur.

L'inversion de cette équation est un problème mal posé car elle ne satisfait pas les trois conditions d'existence, d'unicité et de stabilité. Une méthode pour transformer un problème mal posé en un problème bien déterminé consiste à faire une régularisation par introduction d'information a priori sur la solution.

#### **Définition**

D'après Hadamard, un problème est dit bien posé si le problème dans un espace dit de Hilbert admet une solution (Existence), si elle est unique (Unicité) et si elle est stable (Stabilité). Le problème est dit mal posé si au moins une de ces trois conditions n'est pas vérifiée.

---

La résolution numérique du problème doit passer par l'étape de la discrétisation. Nous devons résoudre un système d'équations de la forme:  $p = R.f + n$  Où  $f$  est un vecteur de  $N$  dimensions contenant les pixels de l'image.  $p$  est un vecteur de  $M$  dimensions contenant les mesures.  $R$  est une matrice du système.  $n$  est le vecteur des erreurs.

Si la matrice  $R$  est carrée la solution sera:

$$\hat{f} = R^{-1} \cdot p \quad (I-10)$$

Quand la matrice n'est pas carrée, on cherche la solution au moyen des moindres carrés:

$$f = \arg \min \{Q(f) = [p - Rf]^t [p - Rf]\} \quad (I-11)$$

Si la matrice  $R^t \cdot R$  est réversible alors la solution est donnée par:

$$f = [R^t R]^{-1} R^t p \quad (I-12)$$

Mais généralement,  $M < N$  les matrices  $R$  et  $R^t R$  sont singulières. La solution inverse généralisée ou la solution des moindres carrés assure seulement l'unicité de la solution quand elle existe. Mais le problème de stabilité via les erreurs persistent. dans ce cas on utilise les informations a priori sur la solution.

#### **I.4. Inférence floue**

Depuis l'introduction de la théorie des ensembles flous par Zadeh en 1965[17], elle a été développée rapidement dans le domaine du traitement du signal. Dans notre travail les règles floues ont été incluses dans l'algorithme du MAP, où la fonction potentielle a été modélisée sur la base des dérivées floues et des ensembles flous. La méthode est vraiment efficace pour éliminer le bruit sans perdre l'information utile contenue dans l'image reconstruite. La logique floue est proposée pour modéliser la nature de l'interaction entre les pixels voisins. L'algorithme proposé est composé de deux étapes:

- Détection de seuil: les bases de règles floues dérivatives sont utilisées pour la détection de seuil dans la fenêtre de proche voisinage.
- Lissage (régularisation) floue: la pénalisation est réalisée seulement sur les pixels pour lesquels on n'a pas détecté de seuil dans la fenêtre de proche voisinage.

Les deux opérations sont réalisées itérativement avec un algorithme d'optimisation jusqu'à la convergence vers la solution. Les analyses quantitatives montrent que l'algorithme de reconstruction proposé à base de règles floues est capable de produire de bons résultats en reconstruction d'image quand il est comparé avec les algorithmes de reconstruction comme le MAP et le MLEM, qui souffrent du problème d'accumulation de bruit quand le nombre d'itérations augmente.

---

### **I.5. Optimisation par algorithme génétique**

La technique stochastique de l'algorithme génétique, originalement développé par Holland [18], était basée sur la théorie de Darwin [19,18]. Les données de projections sont utilisées avec l'algorithme génétique de base pour la détermination des paramètres de l'objet inconnu (dimension et coefficient d'atténuation). La population initiale la plus efficace est la rétroprojection filtrée FBP (Filtered Back Projection). Dans ce travail la fonction fitness d'optimisation de l'Algorithme-Génétique est choisie comme étant le critère à optimiser lui-même, ou l'une des erreurs connues RMSE (root mean squared error) ou MSE (mean squared error)...etc.

### **I.6. Les caractéristiques principales du Tomographe Fein-Focus FXS 160.50**



**Image du tomographe Fein-Focus FXS 160.50**

#### **Caractéristiques du système :**

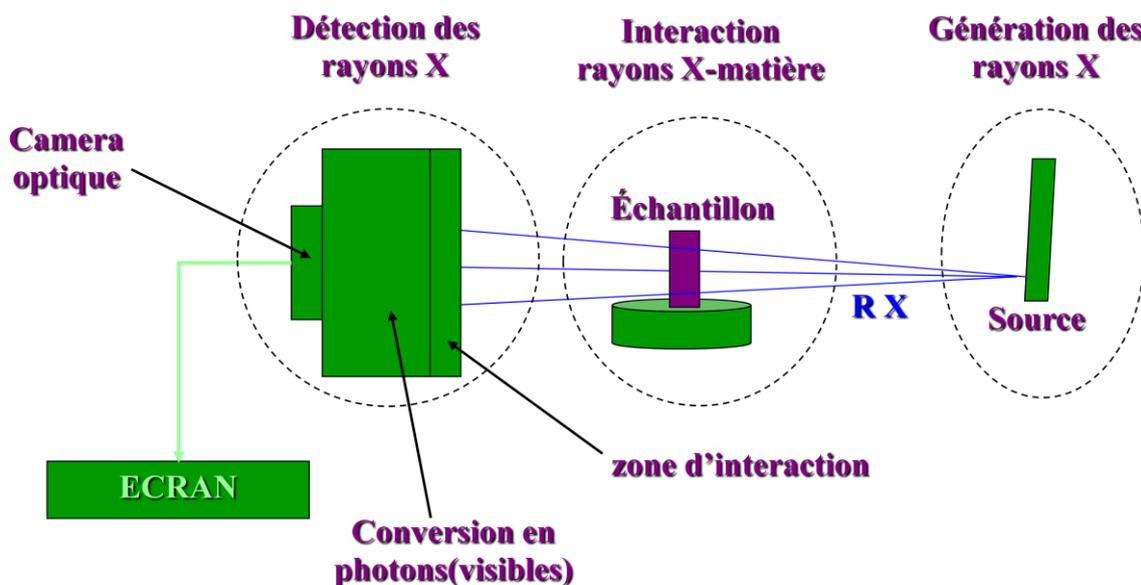
*Radioscope:* type FXS160.50 Fein Focus.

---

*Source:* Rayons X poly-chromatique, cible Molybdène.

*Détecteur:* H641VR02 (Fein-Focus) + Convertisseur en RS170

*Acquisition:* Support Matrox MVP+Logiciel FIP400 v4.0, Image Niveau de gris en 8 bits  
512\*512 pixels.



---

## La chaîne de la radioscopie

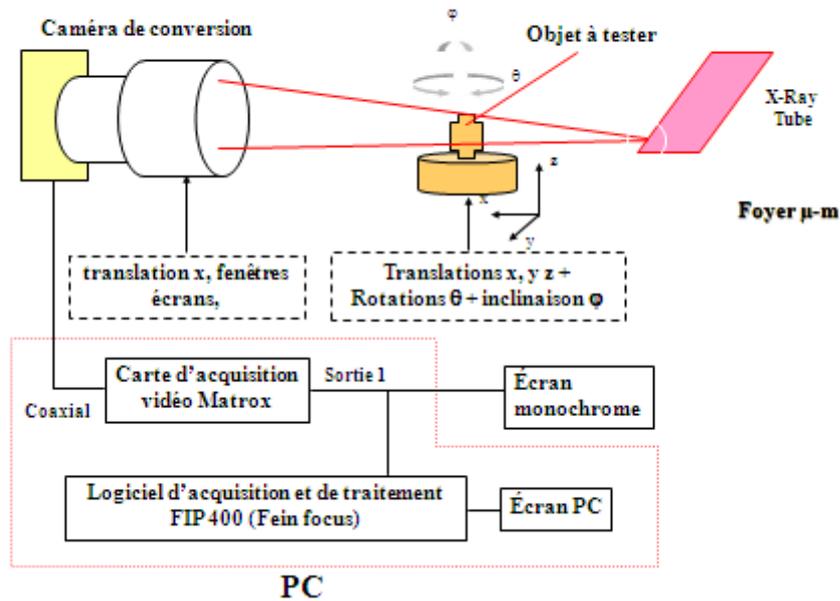
---

### Principales Caractéristiques

- Accélération du faisceau d'électrons 10 - 160 kv sous un courant au Max 1 mA.
- Stabilisation des paramètres par régulation électronique du courant et de la tension.
- Réglage automatique de l'épaisseur du faisceau.
- Possibilités de réglage manuel du point focal du faisceau.
- Système de protection fiable – surtension/courant – normes de radioprotections.

---

## Synoptique du radioscope FXS 160.50



---

## Synoptique du radioscope FXS 160.50

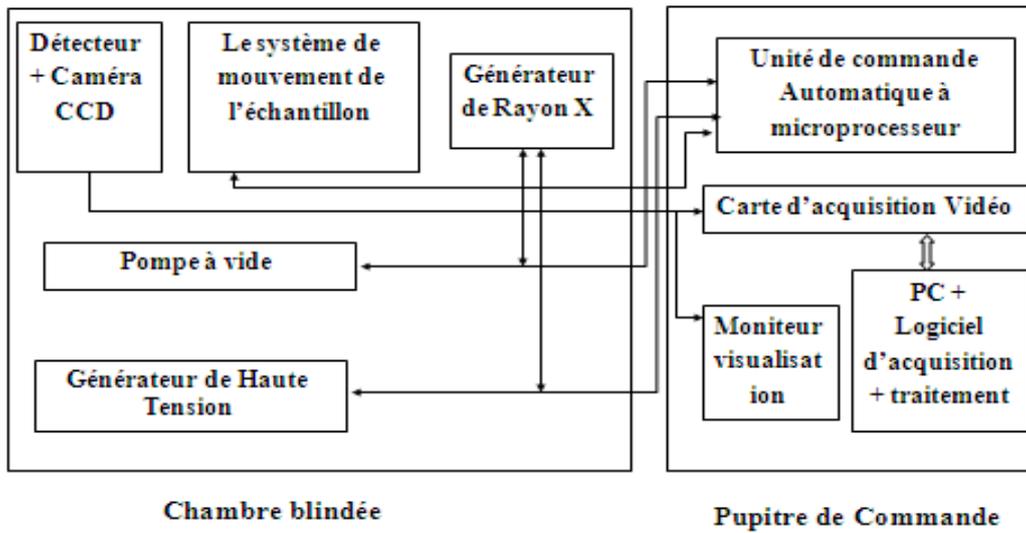
### Avantages et Inconvénients de la tomographie

#### Avantages

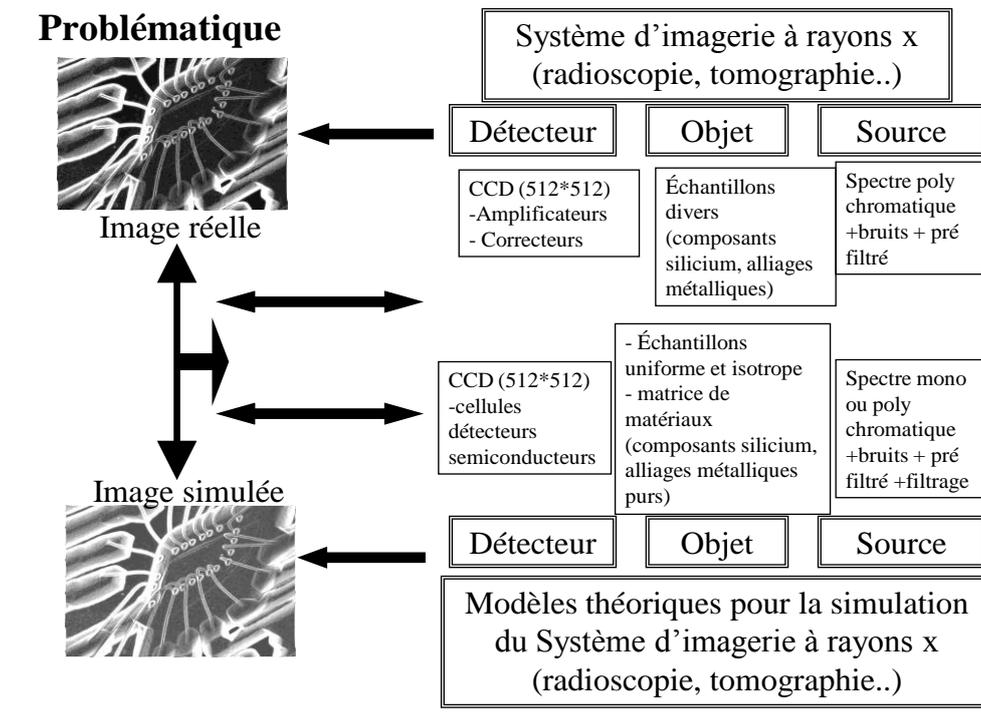
- Rapidité de diagnostic.
- Possibilités de déplacer l'objet suivant plusieurs degrés de liberté => Richesses des images en informations.

#### Inconvénients

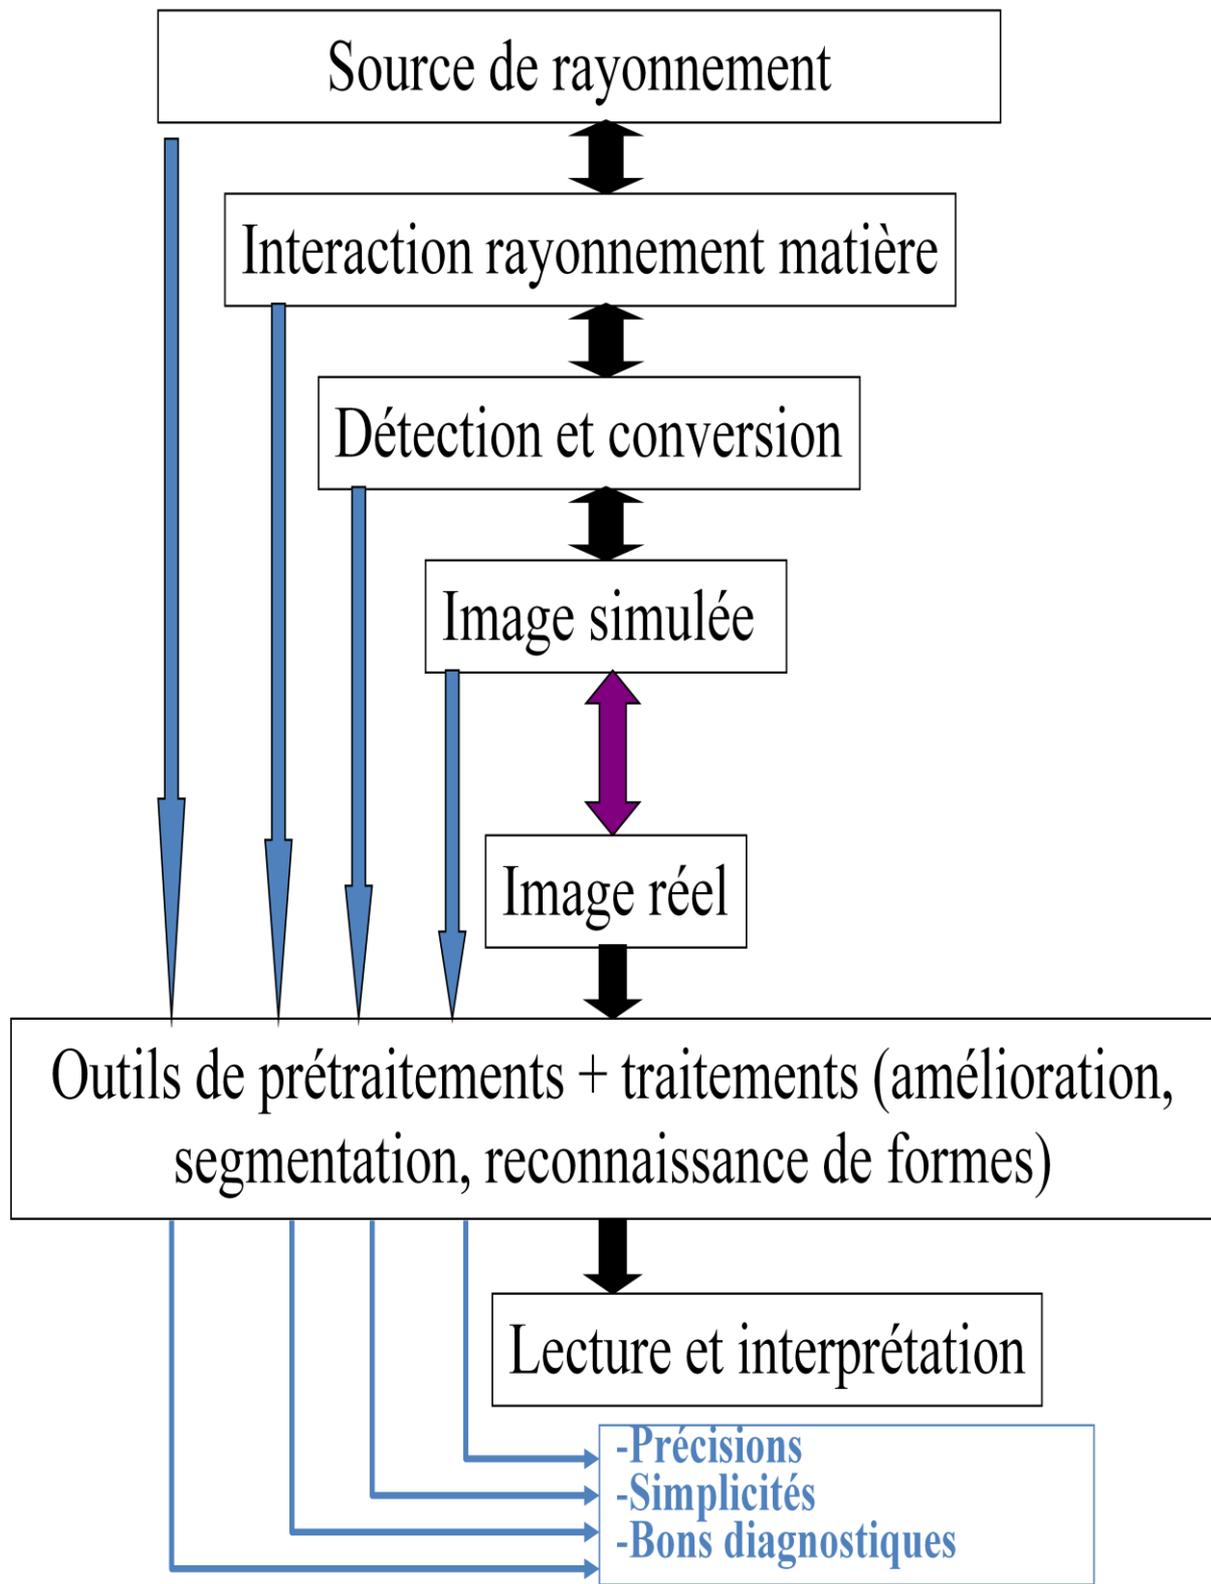
- Système lourd.
- Limitation aux faibles épaisseurs.
- Limitation en géométrie et poids des échantillons.



**Schéma de la chaîne de radioscopie ou de tomographie**



**Image réelle et simulée en tomographie-x**



Logigramme du principe de fonctionnement d'un tomographe

---

## Méthodologie pour la reconstruction tomographique

- **Hypothèses de base**
- **Mise en équations**
- **Approximations et simplification**
- **Adaptation de la structure géométrique**
- **Discrétisations (éléments finis, volumes finis, différences finies)**
- **Traitement numérique des équations**
- **Visualisation, interprétation et validation**
- **Comparaison à l'expérience**
- **Correction des modèles et les hypothèses et les approximations pour se rapprocher du cas réel**

## Éléments principaux d'un tomographe

### I-Source

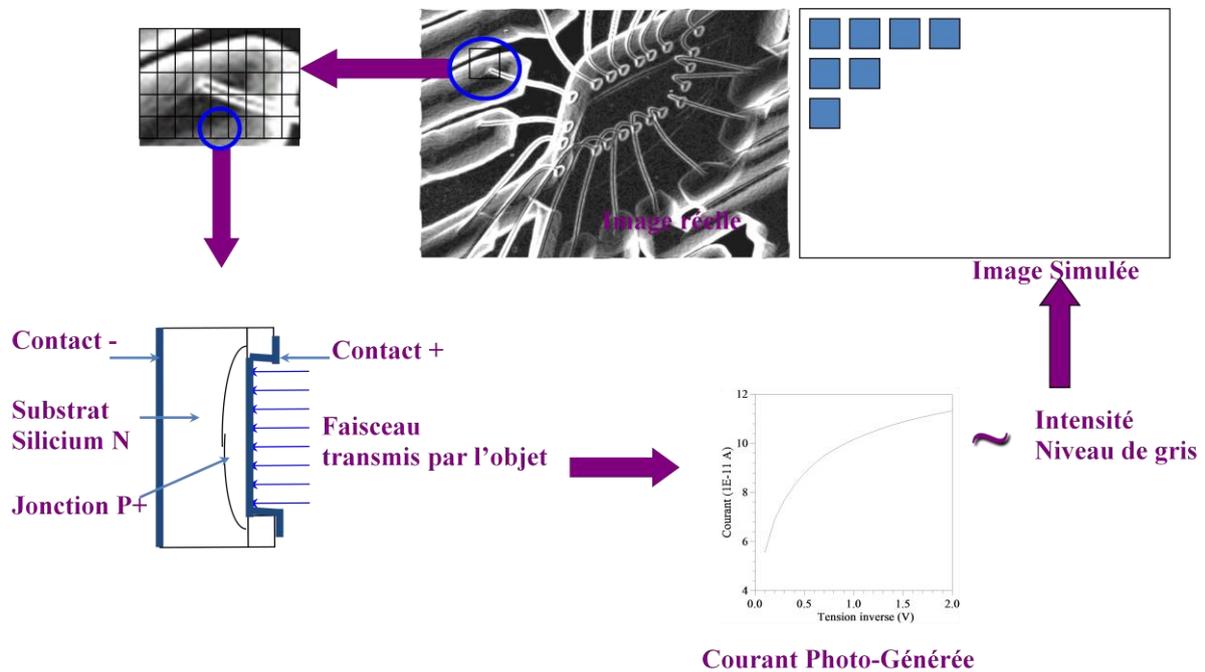
- **Flux des électrons émis par un filament chauffé**
- **Énergie des électrons due à la tension d'accélération**
- **Type de la cible et sa géométrie**
- **Interaction électrons atomes de la cible**
- **Émission des photons X**
- **Formation du spectre**

### II-Objet

- **Géométrie de l'objet et celle du flux de photons**
- **Énergie des photons**
- **Type de l'objet et sa géométrie**
- **Interaction photons et éléments de l'objet**
- **Absorption des photons X**
- **Autres phénomènes autres que l'absorption**

### III-Détecteur

- **Géométrie du détecteur soumis au flux de photons**
- **Décomposition en cellules ponctuelles contenant un détecteur semi-conducteur**
- **Introduction de la génération des porteurs de charges sous l'effet des photons X**
- **Réponse de la matrice des détecteurs et conversion en image à niveau de gris**



## Géométrie d'un Détecteur

### Les applications

#### **L'acquisition d'image:**

- Les objets en métaux, alliages, semi-conducteurs, plastiques, modules finis ou semi-finis.
- Optimisation des paramètres d'acquisition pour une meilleure qualité des informations d'inspections et d'analyse.

#### **Suivi de processus:**

- Détection d'anomalies et de défauts aux cours des processus de cycle de conception de laboratoire ou de l'industrie.
- Aide à l'amélioration qualité de produits.

### I.7.Conclusion

Comme vous l'avez constaté le problème de reconstruction d'image est un problème mal posé. Pour le rendre bien posé il nécessaire d'introduire une régularisation par un critère de pénalisation. Dans la littérature il existe plusieurs proposition nous on propose la régularisation flou. On ce qui concerne la recherche de la solution plusieurs proposition existe. Nous proposons l'algorithme génétique comme outil d'optimisation pour aboutir à la solution globale du problème.

---

# CHAPITRE 2

---

## **Chapitre II**

### **Passage en revue des méthodes de reconstruction d'image**

#### **Résumé**

Les méthodes de reconstruction tomographique peuvent se classer en générale dans deux subdivisions les méthodes analytiques et itératives. Dans ce chapitre on présente les algorithmes les plus utilisés : Filtered Back Projection (FBP), Maximum Likelihood Expectation Maximisation (MLEM), et Maximum A Posteriori Expectation Maximisation (MAPEM). Nos études généralement sont réalisées pour les systèmes à rayons parallèles de projection. Alors que la plus part des tomographes industriels sont conçus avec la technique conique (Fan Beam) pour simplifier la sur conception [20]. Pour les études au contraire c'est la technologie parallèle qui nous facilite la tâche, alors que le passage entre les deux techniques se fait par une simple transformation mathématique.

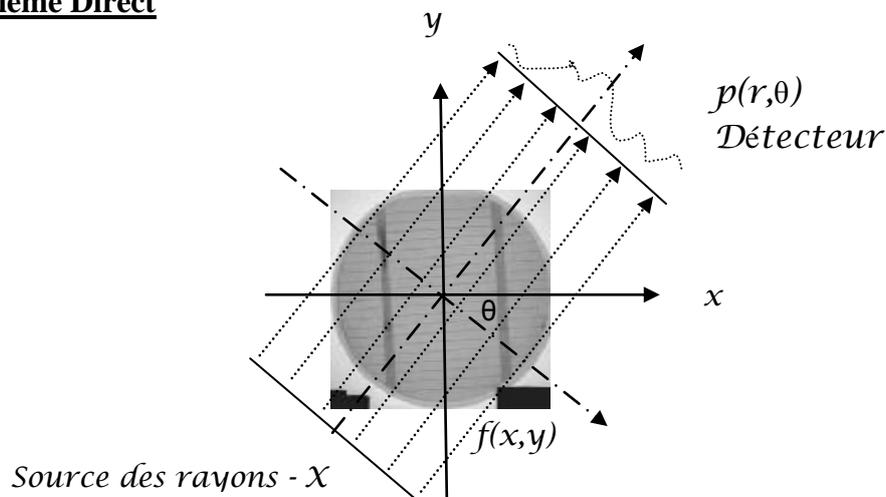
---

## II.1.Méthode Analytique

### II.1.1. Transformée de Radon et Transformée de Radon Inverse

L'opérateur de projection, est connu par la transformée de Radon en 2D qui n'est d'autre que l'intégrale en ligne, cet opérateur est défini comme étant une résolution directe du problème de reconstruction. L'unicité de la solution exige un nombre infini d'angles, alors qu'en pratique seul un nombre fini d'angles peut être mesurés. Pour un nombre fini d'angles, il n'y a pas de fonctions qui peuvent décrire arbitrairement le résultat, donc il est difficile d'obtenir une reconstruction réelle en pratique.

### II.1.2. Problème Direct



*Figure.II-1.Mesures de projections en tomographie à rayon-x.*

$p$  est le vecteur des projections et  $R$  est la matrice de projection entre objet et données figure.II-1, nous pouvons réécrire le problème direct par l'équation:

$$p=R_{r,\theta}f+n \quad (II-1)$$

Où  $n$  est appelé bruit; il représente les erreurs de mesures, les incertitudes du modèle, et les erreurs de discrétisation.

### II.1.3. Projections et Bruit

Le bombardement d'un objet par les rayon-x donne naissance a ce qu'on appelle l'image de projection. Le but de la reconstruction d'image est d'obtenir une image d'une section de l'objet à partir de ces projections. Soit  $\mu(x;y)$  le coefficient d'atténuation de l'objet en un point  $(x;y)$ . Considérons que l'illumination est constituée de rayon parallèles, l'intensité du flux détecté est donnée par l'équation.(I-1) [17].

Une image dégradée par un bruit additive aléatoire  $n(n1;n2)$  [23] est donné par:

$$f(n1;n2) = f_0(n1;n2) + n(n1;n2) \quad (II-2)$$

Où  $f_0(n1; n2)$  est l'image originale.

Le rapport signal sur bruit,  $SNR$  est défini par:

$$SNR = 10 \log_{10} \frac{Var[f_0(n_1, n_2)]}{Var[p(n_1, n_2)]} \quad (II-3)$$

Où  $Var[.]$  représente la variance.

L'erreur quadratique normalisée moyen ( $NMSE$ ) entre l'image originale  $f_0(n_1; n_2)$  et l'image traitée  $p(n_1; n_2)$  est défini par :

$$NMSE [f_0(n_1; n_2); p(n_1; n_2)] = 100 \frac{Var[f_0(n_1, n_2) - p(n_1, n_2)]}{Var[f_0(n_1, n_2)]} \% \quad (II-4)$$

La mesure  $NMSE [f_0(n_1; n_2); f(n_1; n_2)]$  est similairement définie en [23].

Le  $SNR$  dû au traitement est défini par:

$$SNR_{\text{traitement}} = 10 \log_{10} \frac{NMSE[f_0(n_1, n_2), f(n_1, n_2)]}{NMSE[f_0(n_1, n_2), p(n_1, n_2)]} \text{ dB} \quad (II-5)$$

#### **II.1.4. Données de projection**

La méthode illumine un objet par de multiple rayons. Les rayons sont reçues sur un détecteur sur l'autre coté, et la valeur de chaque atténuation est enregistrée. Le résultat de cette opération est une projection de l'objet. Cette lecture est prise en différents angles d'orientations de l'objet.

#### **II.1.5. Rétroprojection Filtrée**

$f(x, y) = IR(p(r, \theta))$  exprimée par l'équation (I-4):

$$f(x, y) = \left( \frac{-1}{2\pi^2} \right) \int_0^\pi \int_{-\infty}^{+\infty} \frac{\frac{\partial}{\partial r} p(r, \theta)}{(r - x \cos \theta - y \sin \theta)} dr d\theta$$

Etapas:

1. Les mesures:  $p(r, \theta)$

2. Dérivation:  $p = \frac{\partial p(r, \theta)}{\partial r}$

3. Transformée de Hilbert

$$p(r', \theta) = \frac{1}{\pi} \int_0^\infty \frac{p(r, \theta)}{r - r'} dr$$

4. Ou TF inverse et Filtrage

5. Rétroprojection:  $f(x, y) = \frac{1}{2\pi} \int_0^\pi p(r' = x \cos \theta + y \sin \theta, \theta) d\theta$

La méthode la plus rapide et la plus simple de la reconstruction d'images est l'approche rétroprojection filtrée. La méthode débute avec une image initiale. Les valeurs de ses projections sont projetées sur le pixel correspondant et additionnées à sa valeur existante.

La rétroprojection filtrée élimine les hautes fréquences de l'image reconstruite c'est pour cela qu'il faut filtrer les projections avant de les rétro-projeter directement. Ensuite il maintient les

---

bases fréquences de l'image réelle à laquelle on va additionner la rétroprojection directe. Après que les projections sont filtrées, on exécute l'algorithme de la rétroprojection pour aboutir à l'image désirée.

## **II.1.6. Résultats et discussion**

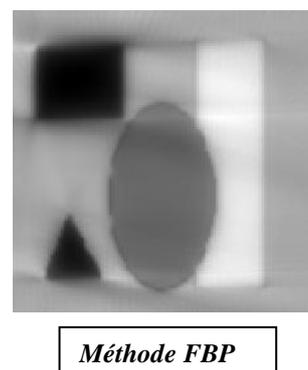
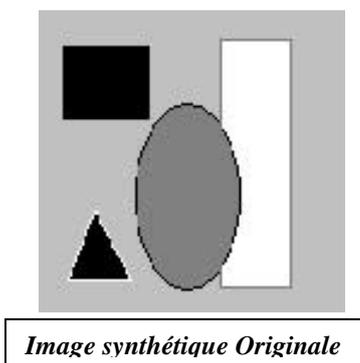
### **II.1.6.1. Description des images**

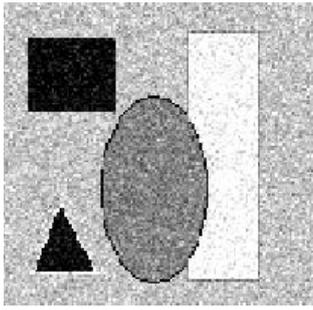
Plusieurs ensembles de données sont utilisés, commençons par l'image synthétique ensuite des images à 256x256 pixels de cellules solaire et finalement un circuit intégré (IC). Le but est d'évaluer l'algorithme en termes de qualité de reconstruction et de robustesse à un bruit Gaussien ou de Salt & Pepper (bruit-impulsion). La dimension de l'image finale reconstruite est 256x256 pixels.

### **II.1.6.2. Résultats de Simulation**

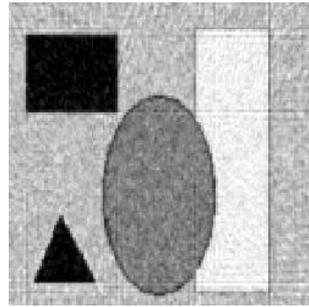
Dans les figures. (II-2), figure. (II-3), figure. (II-4) et figure. (II-5), des images synthétiques et réelles sont reconstruites avec l'algorithme de reconstruction FBP. Les données de projections considérées sont simples puis dégradées par un bruit Gaussien de niveau de variance 0.005 .Ensuite un bruit impulsionnel dit Salt & Pepper avec une valeur additionnée de 3% (ceci est la cause de l'introduction aléatoire de pixels blancs ou noirs dans l'image) [23]. Le nombre d'itération choisie est compris entre 10 et 100 pour éliminer l'accumulation de bruit.

Comme vous pouvez le voir, après le filtrage plusieurs petits détails dans l'image commence à apparaitre. Cependant il restera le problème de la résolution de l'image.

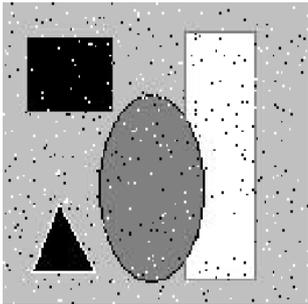




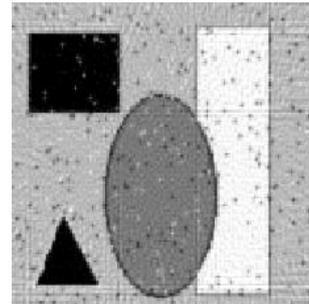
*Image avec un bruit Gaussien*



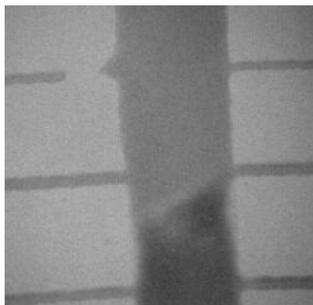
*Méthode FBP*



*Image avec un bruit Salt & pepper*



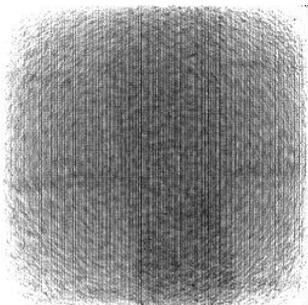
*Méthode FBP*



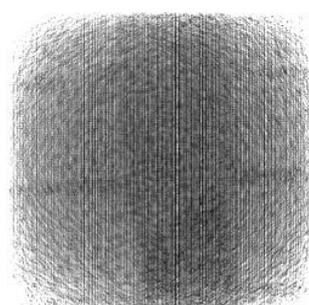
*Image Originale de la cellule*



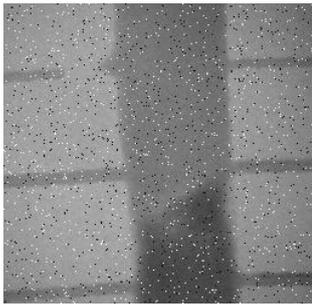
*Méthode FBP*



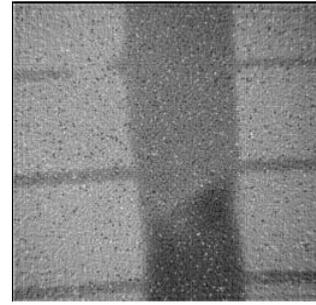
*Image avec un bruit Gaussien*



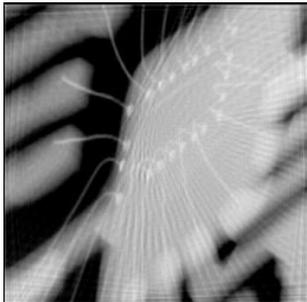
*FBP bruité*



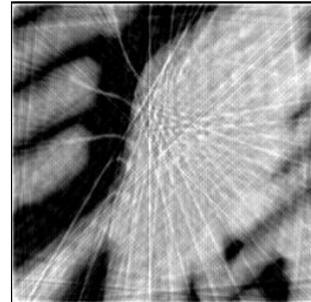
*Image avec un bruit Salt & pepper*



*FBP bruité*



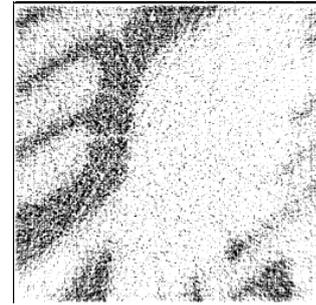
*Image Originale du Circuit intégré*



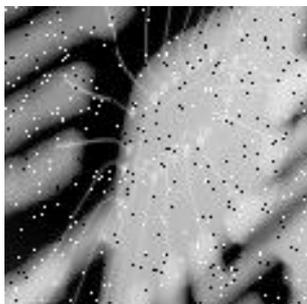
*Méthode FBP*



*Image avec un bruit Gaussien*



*FBP bruité*

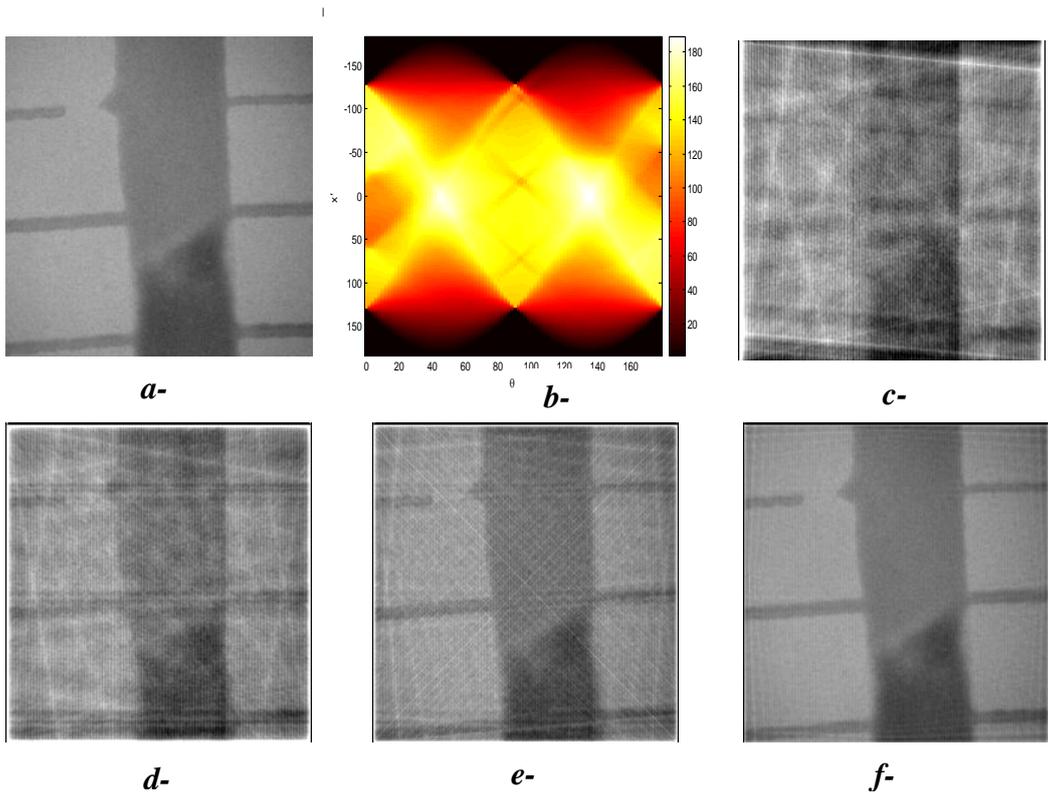


*Image avec un bruit Salt & pepper*

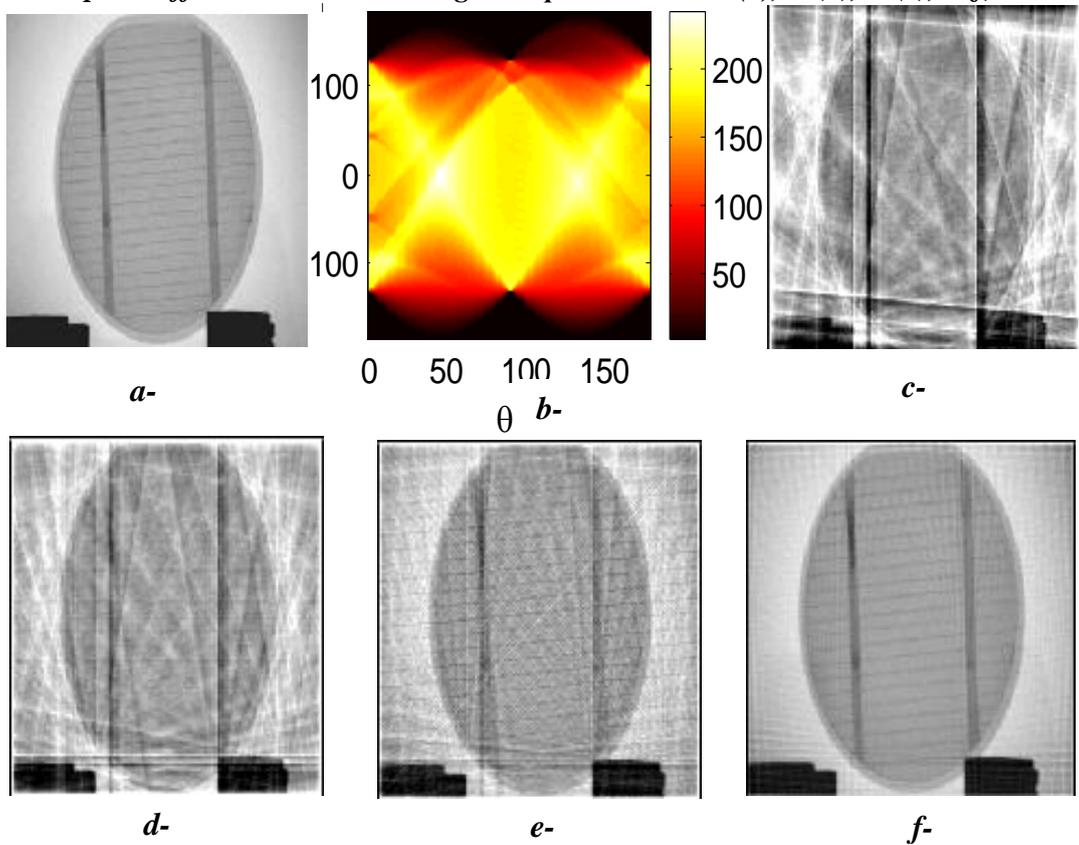


*FBP bruité*

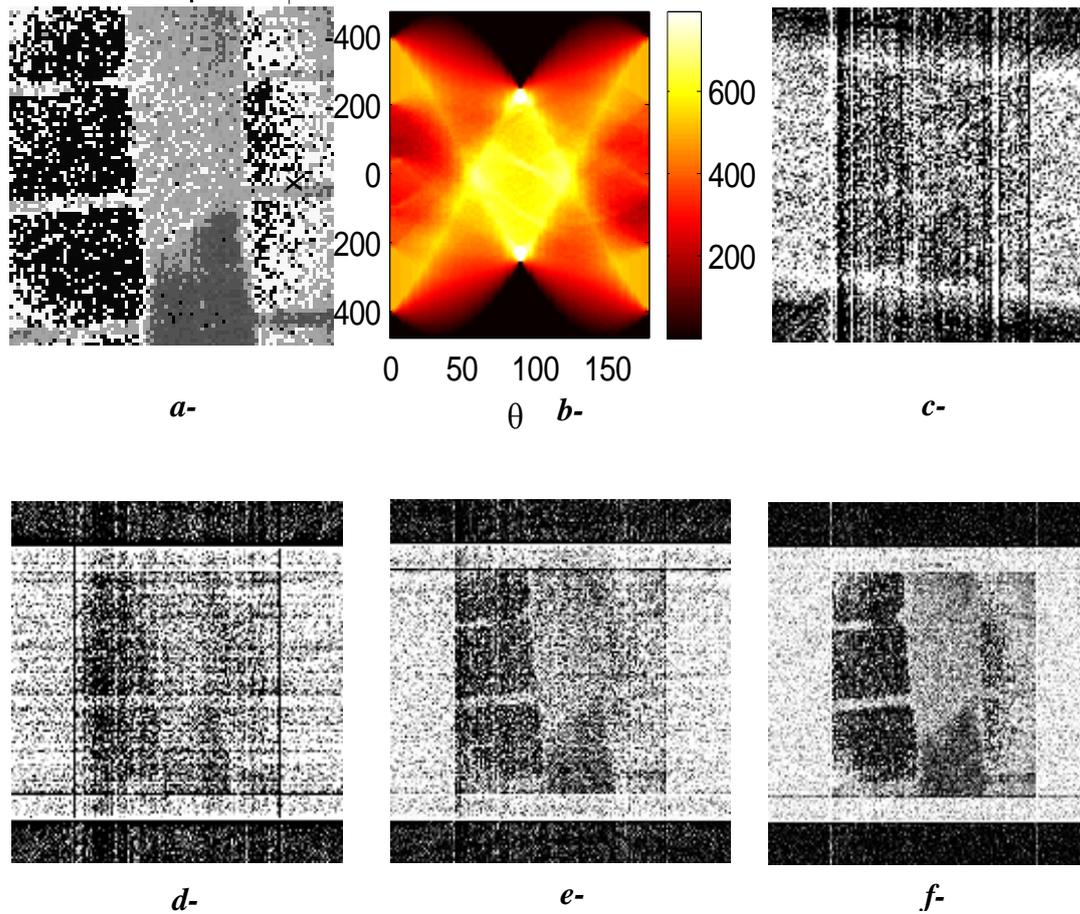
*Figure II-2: Image originale et image rétro projetée pour différents types de bruits.*



**Figure II-3: Image originale(a), sinogramme de projections(b), et images rétro projetées pour différentes nombres d'angles respectivement: 11(c), 18(d), 36(e),90(f).**



**Figure II-4: Image original(a), sinogramme de projections(b), et images rétro projetées pour différentes nombres d'angles respectivement : 11(c), 18(d), 36(e),90(f).**



**Figure II-5: Image original bruitée(a), sinogramme de projections(b), et images rétroprojetées pour différents nombres d'angles respectivement : 11(c), 18(d), 36(e), 90(f).**

### **II.1.7. Conclusion**

Parmi les problèmes de la reconstruction analytique, le calcul de la dérivée des projections par rapport à  $r$  et l'intégration par rapport à  $r$ . Malgré cela il existe pas mal de travaux basés sur cette méthode, où l'opération de dérivation est approximée par un filtre passe haut et l'opération d'intégration par rapport à  $r$  est effectuée dans le domaine de Fourier. Alors que l'intégration par rapport à  $\theta$  est reconnue comme une rétroprojection. le problème majeur c'est le nombre limité de projection.

Face à une dégradation des projections par le bruit de Gauss ou Salt & Pepper, l'algorithme analytique ne résiste pas au bruit dans l'image et demande un plus grand nombre de projections. malgré ça cette méthode ne demande pas beaucoup de calculs mais les images résultantes n'auront pas une très bonne résolution.

---

## **II.2.METHODES ALGEBRIQUES**

### **II.2.1. Discrétisation du problème**

Pour introduire les informations a priori afin de compenser le manque de données, nous utiliserons les méthodes algébriques. La première étape c'est la discrétisation du problème direct qui transforme l'équation linéaire continue de la transformée de radon (RT) en un système d'équations finies et linéaires. L'objet se partage alors en une grille de  $n$  pixel ( $f_1, f_2 \dots f_n$ ) l'expression de la TR devient.

$$P_{\theta}(r) = \sum_{j=1}^n r_j(r, \theta) f_j \quad (II-6)$$

Où  $f = [f_1, f_2, \dots, f_n]^t$

$r_j(r, \theta)$  représente l'intersection entre le  $j^{ieme}$  pixel et la ligne du rayon  $L_{\theta, r}$  les projections  $p_{\theta k}$  peuvent s'écrire sous forme matricielle par :

$$p_{\theta}(r) = R.f \quad (II-7)$$

Où:  $p_{\theta}(r)$  est le vecteur qui représente la projection de l'objet et  $R$  la matrice de projection de dimension  $M \times N$ .  $R$  est définie par  $m$  blocs  $R_1, \dots, R_m$  de matrice  $r \times n$ . Le bloc  $R_k$  correspond à la  $k^{ieme}$  projection. On considère seulement le cas du faible nombre de projections. Le système est alors sous-déterminé et le problème a une infinité de solutions. Le vecteur  $f$  désigne l'intensité du pixel de l'image  $f(x, y)$  et le vecteur  $p$  la valeurs de chaque  $m$  projections  $p(r, \theta)$  le long des différents angle  $\theta$ , on peut alors notée les projections par:  $p_1, \dots, p_m$ . et les matrices du système  $R$  par:  $R_1, R_2, \dots, R_m$  on a donc:

$$p_1 = R_1.f \quad \dots \quad p_m = R_m.f \quad p = R.f = R_1 \dots R_m.f \quad (II-8)$$

Finalement On, modélise le problème direct par:

$$p = R.f(:) \quad (II-9)$$

Arrivant a se stade là nous cherchons a modélisé le problème inverse c.à.d. pour  $p$  donnée, il faut trouver le  $f$ . ce problème inverse est sous-déterminé et il a une infinité de solutions.

### **II.2.2. Rétroprojection et matrice transposée**

$\hat{f} = R^t.p$  est une image obtenue par rétroprojection on peut voir que:  $R^t = \begin{bmatrix} R_1^t & R_2^t & \dots & R_m^t \end{bmatrix}$  Le calcul de cette solution est:  $f = R^t.p$

Notons que:  $\hat{f} = R_1^t.p_1 + R_2^t.p_2 + \dots + R_m^t.p_m$  est l'addition d'images chacune étant la rétroprojection d'une projection.

---

### **II.2.3. Moindre Carrée (MC) et Inversion Généralisée (IG)**

Soit les deux matrices symétriques  $R^t R$  et  $R.R^t$  leurs décompositions en valeurs singulières sont  $SVD(R.R^t)$  et  $SVD(R^t R)$  les deux matrices sont singulières, la solution aux sens des Moindre Carrée (MC) est:

$$\hat{f} = \arg \min_f \left\{ \|p - Rf\|^2 \right\} \quad (II-10)$$

-Le problème inverse mal posé désigné par le système d'équation.(II-8), n'a pas de solution exacte. Cependant on peut lui attribuer une solution approchée sous la forme de minimisation d'un critère de type distance dans l'espace de Hilbert. Si la distance choisie est une distance euclidienne, on parle de solution au sens des moindres carrés[2].

Et si  $R^t R$  est réversible, nous avons la solution inverse généralisée:

$$\hat{f} = (R^t .R)^{-1} R^t p \quad (II-11)$$

Si  $RR^t$  est réversible, on a : 
$$\hat{f} = R^t (R.R^t)^{-1} p \quad (II-12)$$

### **Algorithme Itératif**

Nous pouvons aussi avoir la solution a l'aide de l'algorithme itératif suivant:

$$f = f + .1 * R^t (p - R * f(:)) \quad (II-13)$$

Où  $f$  est une image arbitraire, cela peut être utilisé pour obtenir toutes les solutions possibles de  $p = R.f$  par addition de cette image arbitraire à la solution IG parmi les algorithmes existant nous pouvons cités.

- Méthode de Bialy: Un algorithme itératif qui se base sur une suite d'itérations (équation. II-13)[4].
- Méthode de Landweber: Nous aboutissons a cet algorithme si au critère des moindres carrés MC on applique un algorithme de minimisation du type gradient [3].
- Méthode de Van-Cittert: Si on ajoute des contraintes à la suite des itérations [4].
- Méthode de Kaczmar: L'idée est d'utiliser les donnés de projections une par une[3].

### **II.2.4. Régularisation**

Rendre un problème mal-posé en un problème bien posé, ce qui veut dire trouvé une solution unique pour toutes les mesures possibles, et assurer la stabilité de cette solution par rapport aux erreurs sur ces mesures[2].

### **Contraintes de Positivité**

les niveaux de gris de la solution image en reconstruction d'image doit être toujours positive [24].

---

## **II.2.5. Inversion Généralisée et Décomposition en Valeurs Singulières (SVD)**

La reconstruction de la forme inconnu de l'objet passe par la résolution du système d'équation linéaire

$$p = Rf \quad (II-14)$$

$R$  est rectangulaire (non carrée) la solution de l'équation (I-5) est équivalente à la solution de l'équation suivante.

$$R^t Rf = R^t p \quad (II-15)$$

Où  $R^t R$  est une matrice carrée de dimension  $n \times n$ .

On sait que le nombre de projections est petit, alors  $M < n$  et  $R^t R$  n'est pas réversible et le système a une infinité de solutions. La solution inverse généralisée à l'aide de la méthode des moindres carrés est:

$$f_{MC} = \arg \min \|p - Rf\|^2 \quad (II-16)$$

Ce qu'est revient à résoudre l'équation:  $R^t Rf = R^t p$

Le début de la solution commence par la décomposition de la matrice du système en valeurs singulière.

$$R = U \cdot \text{diag}[\lambda_1, \dots, \lambda_n] V^t \quad (II-17)$$

Où  $U = [u_1, \dots, u_n]$  et  $V = [v_1, \dots, v_n]$  sont des matrices de dimension:  $M \times N$  et  $N \times N$ .

Les  $\lambda_i$  sont les valeurs propres de  $R$ .

Les vecteurs  $v_i$  sont les vecteurs propres de  $R^t R$  associés aux valeurs propres  $\lambda_i^2$ .  $u_i$  sont les seules à vérifier l'égalité  $R \cdot v_i = \lambda_i u_i$  La solution inverse généralisée est:

$$f_{IG} = \sum_{i=1}^{rg(R)} \frac{u_i^t \cdot d}{\lambda_i} v_i \quad (II-18)$$

## **II.2.6 Résultats et discussion**

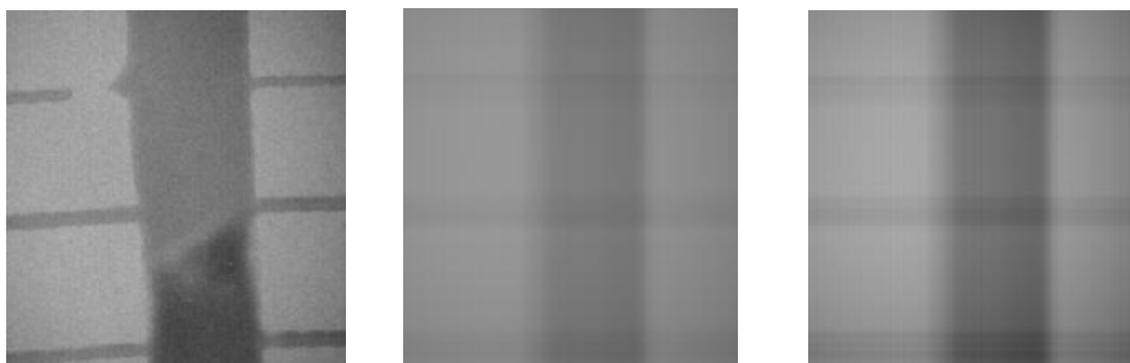
### **II.2.6.1. Description des images**

L'image utilisée est la cellule solaire à 256x256 pixels. Le but est d'évaluer l'algorithme en termes de qualité de reconstruction et de robustesse à un bruit Gaussien. La dimension de l'image finale reconstruite est 256x256 pixels.

### **II.2.6.2. Résultats de simulation**

Une comparaison est faite pour les données de projections simples et dégradées par, premièrement un bruit Gaussien de niveau de variance 0.005 [23]. Dans la figure. II-6, des

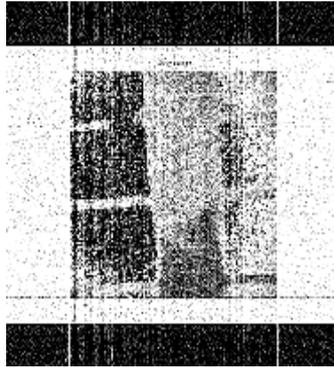
images réelles sont reconstruites avec l'algorithme algébrique des moindres carrés. Le nombre d'itérations choisies est compris entre 2 et 100 pour éliminer l'accumulation de bruit. On observe que le problème est vraiment mal-conditionné à cause de l'important manque on informations (un petit nombre de données). On doit chercher à obtenir d'autre données comme par exemple d'autres projections dans d'autre directions. La figure.II.6 montre différentes résultats obtenu pour plusieurs cas de reconstructions d'images.



*a-Image originale    b-image reconstruite avec MC à deux projections    c-Image reconstruite avec MC régularisée*



*d-Image reconstruite avec MC Régularisée à 36 projections    e-Image reconstruite avec MC Régularisée à 90 projections    f-Image originale bruitée*



*g-Image reconstruite avec MC  
Régularisée à 90 projections.*

*Figure.II.6: Images originale et images bruitées reconstruites avec différentes algorithmes algébriques.*

### II.2.7.Conclusion

Les méthodes de reconstruction algébriques se basent sur l'idée de limitation des données tomographique de projections, ces algorithmes produisent de mauvais résultats. Même les régularisations introduites par SVD ou celles des moindres carrées améliorent très peu la solution. Un autre problème c'est que cette limitation d'angle affaiblit la qualité de la matrice du système  $R$ . L'un des avantages c'est que ces méthodes algébriques exigent moins de projections que les méthodes analytiques. Mais malgré ça ces méthodes restent très sensibles aux erreurs des bruits. Il faut donc chercher une méthode qui introduit les informations a priori sur la solution et sur les erreurs de mesures.

---

## **II.3: Méthode Itérative et Inférence Bayésienne**

### **II.3.1.Introduction**

Le principe de base des méthodes itératives est simple il début par la création d'une image initiale, pour laquelle on calcul les projections. Ensuite, les erreurs sont calculé, ils représentent la différence entre les nouvelles projections et les projections originales. La matrice erreur doit être de même dimension que la matrice projection. Cette matrice erreur est ensuite rétro projetée dans l'image initiale. L'opération est répété avec cette nouvelle image jusqu'à ce que le nombre d'itérations soit atteint.

### **II.3.1. Régularisation Itérative**

La régularisation d'un problème mal-posé est de le ramener à un problème bien-posé on définissons une solution unique pour toutes les mesures, et stable vis a vie des erreurs [25].

#### **Méthode Itérative**

La solution régularisée est définie comme un argument qui minimise un critère  $J(f)$ :

$$f = \operatorname{argmin}_f \{ \| J(f) = L(f) + \lambda U(f) \| \}$$

On peut utiliser les algorithmes local comme l'algorithme du gradient pour trouver la solution[26].

$$\nabla J(f) = \frac{\partial J(f)}{\partial f} = \frac{\partial L(f)}{\partial f} + \frac{\partial U(f)}{\partial f} \quad (II-19)$$

Toutes les méthodes locales d'optimisation cherchent itérativement la solution:

$$f_{k+1} = f_k - \alpha_k D_k \nabla J(f_k)$$

Suivant le choix de  $\alpha_k$  et  $D_k$  on déterminent le type d'algorithme de gradient.

---

### II.3.3.L'Algorithme Du Maximum Likelihood Expectation Maximisation MLEM

#### II.3.3. 1. Implémentation de l'algorithme

Pour aboutir a une solution la plus proche au problème inverse il faut:

- Prendre en compte explicitement les erreurs de discrétisation, de mesures et de modélisation.
- Prendre en compte les informations a priori.
- Enfin caractériser l'incertitude qui reste dans la solution.

Pour cela il faut utilisé la théorie des probabilités [27]. Où on représente ces incertitudes sur une grandeur par une loi de probabilité conditionnelle ensuite on utilise la notion d'estimation pour déterminer les grandeurs inconnues. Cette loi est prise comme une fonction de la grandeur inconnue appelée fonction de vraisemblance que nous allons maximisé pour arrivé a la solution.

Pour notre problème mal posé  $f = \text{argmin}(J(f))$  est la quasi solution en minimisant le critère  $J(f)$  choisit comme une fonction 'likelihood' dans l'estimation probabiliste. Si on ajoute les contraintes au critère comme le lissage, on introduit la violation des contraintes comme une lourde pénalisation dans le critère [5]:

$$J(f) = L(f) + P(f) \quad (II-20)$$

La solution est définie comme le minimiseur de ce critère dite approche de vraisemblance pénalisée. Où  $L(f)$  est la fonction likelihood  $l(f)$  égale à la probabilité conditionnelle  $\text{prob}(p/f)$  d'observer le vecteur  $p$  quand l'émission ou la transmission est l'image  $f$  (variable de Poisson) [1].

$P(f)$  est l'information a priori qui veut dire: comment doit être l'image reconstruite? Qui doit être bien choisie pour refléter nos connaissances a priori sur le bruit et l'image.

On introduit le modèle de Poisson qui est généralement accepté comme modèle mathématique valide pour le processus de reconstruction. Donnons la remarque que même le modèle gaussien est applicable.

Soit le vecteur de mesures  $p = \{p_i; i = 1, \dots, m\}$ , la fonction log-likelihood à maximiser, sachant  $f = \{f_j; j = 1, \dots, n\}$  est:

Et: 
$$L(f) = -1^T (Rf + n) + p^T \log(Rf + n) \quad (II-21)$$

$$L(f) = (p \log p^T(f) - p^T(f)) \quad (II-22)$$

Où

$$p^T(f) = Rf + n$$
$$l(f) = \sum_{i=1}^n \left( -\sum_{j=1}^m r_{ij} f_j + p_i \ln \left( \sum_{j=1}^m r_{ij} f_j \right) - \ln(p_i!) \right) \quad (II-23)$$

$r_{ij}$  est un facteur de pondération représentant la contribution du pixel  $j$  au nombre de comptes détecté dans le récepteur  $i$ . Les  $r_{ij}$  sont aussi les éléments de la matrice  $R$  de probabilité du système et ils représentent la probabilité qu'une particule émise du pixel  $j$  soit détecté par le détecteur  $i$ .  $n_i$  désigne le bruit contenu dans la  $i^{\text{ième}}$  mesure. Le but de la reconstruction est d'estimer le vecteur image  $f$  du vecteur de données  $p$ .

L'optimisation de la fonction  $J(f)$  peut être réalisée par l'algorithme de descente de gradient comme elle peut être réalisée par l'algorithme d'expectation maximisation EM.

La dérivée partielle du premier ordre de  $J(f)$  pour chaque pixel  $f_j$  est:

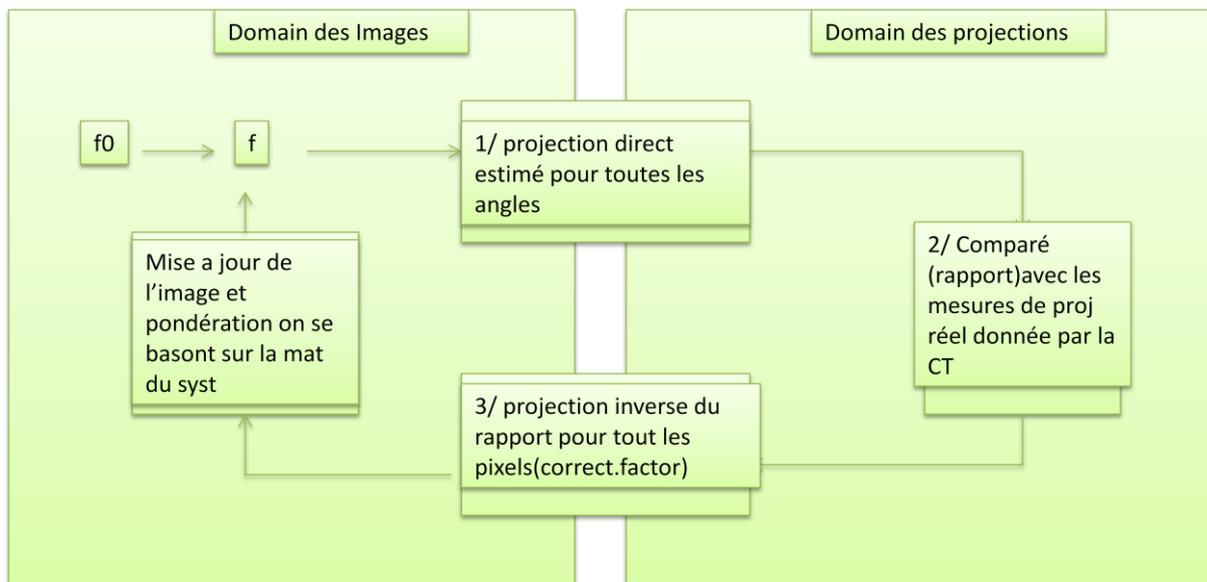
$$\hat{f} = \arg \max \{l(f)\} \Rightarrow \frac{\partial l(f)}{\partial f} = 0 \quad (II-24)$$

Finalement, nous aboutissant a la relation itérative suivante pour le calcul des images estimées  $f$ .

$$f_j^{k+1} = \frac{f_j^k}{\sum_{i=1}^n r_{ij}} \sum_{i=1}^n r_{ij} \frac{p_i}{\sum_{j=1}^m r_{ij} f_j^k} \quad (II-25)$$

Où  $k$  est le nombre d'itérations.

L'algorithme itératif d'expectation maximisation (EM) démarre avec un vecteur strictement positive  $f(0)$  pour estimer une image par maximisation de la fonction log-likelihood.



**Le schéma itératif produit du ML-EM (d'après Carson)**

L'Algorithme EM se compose de deux étapes:

1-L'Expectation Etape où on définit la fonction à optimiser en se basant sur le principe du M-V. Généralement c'est une fonction likelihood  $L(f)$ , basée sur le concept de probabilité conditionnelle.

---

Le phénomène de projection est vue comme une variable de Poisson. La probabilité de détection de la projection  $p_i$  ( $p_i$  variable de Poisson) est:  $prob(p_i) = \frac{e^{-P_i} P_i^{-P_i}}{P_i!}$

Les  $i$ -variables de Poisson sont indépendantes, alors la probabilité conditionnelle  $prob(p \setminus f)$  d'observer le vecteur  $p$  quand l'émission est l'image  $f$ , est le produit des probabilités individuelles les  $prob(p_i)$  et la fonction L-H est:  $L(f) = prob(p \setminus f) = \prod_{i=1}^n prob(p_i)$

2-La Maximisation de la fonction L-H, veut dire trouvé la plus grande valeur de  $L(f)$ . Celle ci est obtenue en annulant sa dérivée.

Dans le ML-EM Pour Maximiser la fonction L-H on considère  $l(f) = \ln L(f)$  et nous obtenons le critère du MLEM équation.II-23.

La fonction de Likelihood en ML-EM c'est la prob d'observer n'importe quelle image  $f$ .

On cherche l'image  $f$  avec un max de prob de réalisation de  $p$  qui est donnée par l'équation.II-

24. Le schéma itératif produit du ML-EM (d'après Carson) est donné par l'équation.II-25:

Les remarques qu'ont peut faire ici sont:

- ❖ L'algorithme EM peut être vu comme un ensemble successif de projection et rétroprojection.
- ❖ le rapport est entre celle mesuré et les estimés dans le bin  $i$ .
- ❖ La rétroprojection est fait pour le pixel  $j$ .
- ❖ D'une autre manière on peut schématiser l'algorithme du MLEM par le bloc suivant où on commence par:
- ❖ Une image initiale  $f_0$ ...
- ❖ A laquelle on calcul les projections (somme  $r_f$ ).
- ❖ Projection inverse retour a l'image(correction factor).
- ❖ Mise a jour de l'image et pondération avec matrice du systeme.
- ❖ L'idée de base de MLEM est que itérativement les mesures de projection estimés vont être proche des projections réelles mesurées.
- ❖ Le problème de MLEM c'est que a cause du bruit dans l'image les mesures de projection estimé vont être proche a des mesure de projection bruité donc loin du réel.
- ❖ Donc le but ne sera pas seulement de minimisé l'écart, mais aussi de minimisé le bruit là où on le trouve.par la régularisation(l'introduction de l'a priori) basé sur la question comment doit être l'image réelle.

---

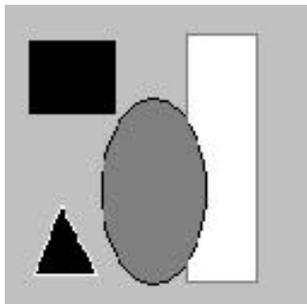
### II.3.3.2 Résultats et discussion

#### II.3.3.2.1 Description des images

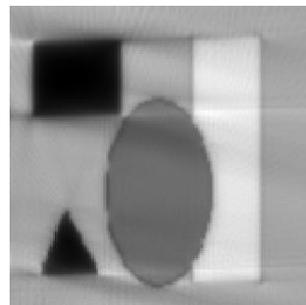
Nous avons utilisés un ensemble de donnés, l'image synthétique ensuite des images à 256x256 pixels de cellules solaire et finalement un circuit intégré (IC), pour évaluer l'algorithme en terme de qualité de reconstruction et de robustesse au bruit de Gauss ou Salt & Pepper (bruit-impulsion). La dimension de l'image finale reconstruite est 256x256 pixels.

#### II.3.3.2.2.Résultats de Simulation

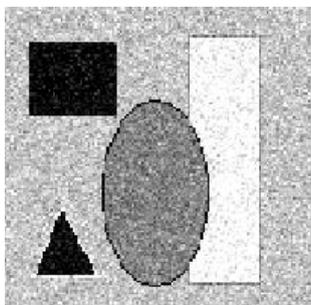
Nous avons utilisés des données de projections simples et dégradées par, premièrement un bruit Gaussien de niveau de variance 0.005 et ensuite un bruit impulsionnel dit Salt & Pepper avec une valeur additionnée de 3% .Dans la figure. II-7, et la figure. II-8, des images synthétiques et réelles sont reconstruites avec l'algorithme du Maximum Likelihood-Expectation Maximisation (MLEM). Le nombre d'itérations choisies est compris entre 10 et 100 pour éliminer l'accumulation de bruit. Les performances de l'algorithme ont été évaluées pour le critère objectif la fonction Log-likelihood .Puisque l'algorithme proposé calcule itérativement l'estimée de la pénalisation likelihood, la fonction log-likelihood est une mesure qualitative appropriée pour caractériser les performances de l'algorithme. La fonction log-likelihood est donnée par l'Equation. II-24 l'inconvénient de la méthode c'est le bruit qui croît avec l'augmentation du nombre d'itérations.



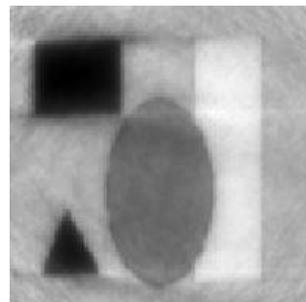
*Image synthétique Originale*



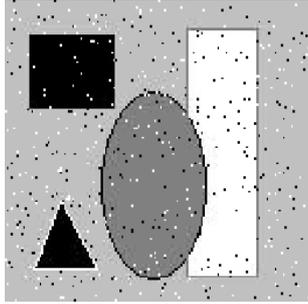
*MLEM*



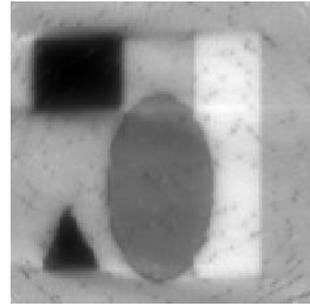
*Image avec un bruit Gaussien*



*MLEM*



*Image avec un bruit Salt & pepper*



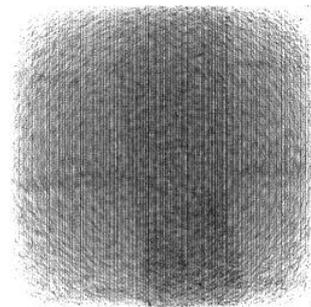
*MLEM*



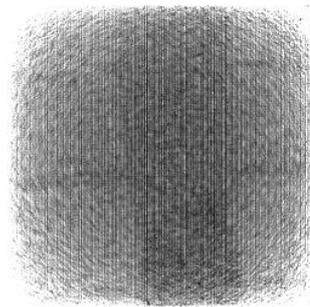
*Image Originale de la cellule*



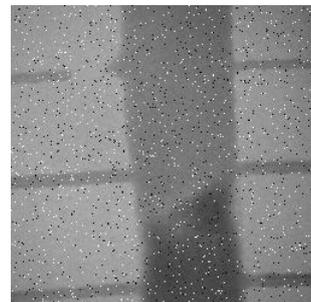
*MLEM*



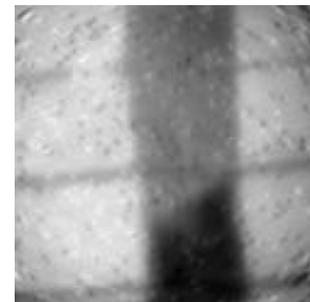
*Image avec un bruit Gaussien*



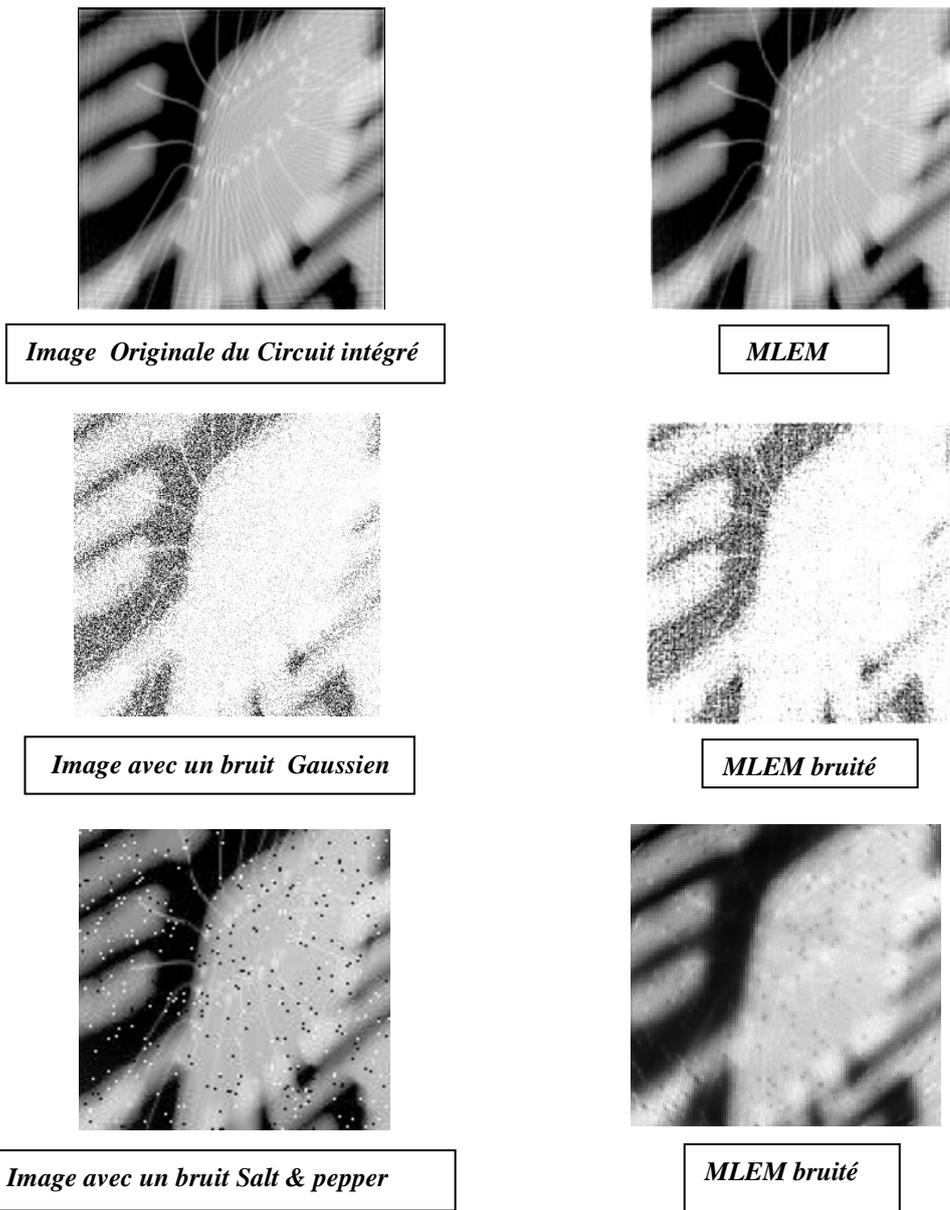
*MLEM bruité*



*Image avec un bruit Salt & pepper*



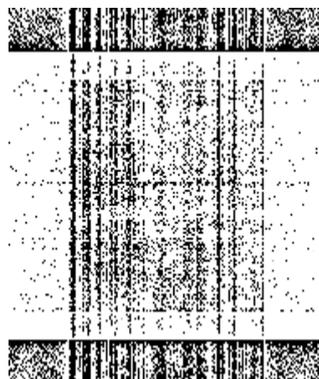
*MLEM bruité*



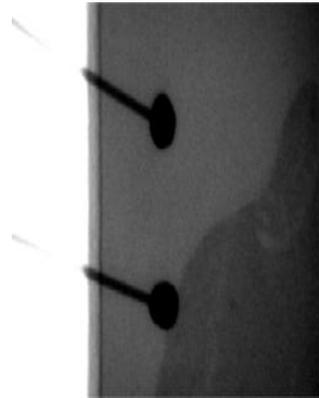
*Figure II-7: Images originales et images rétro projetées pour différents types de bruits.*



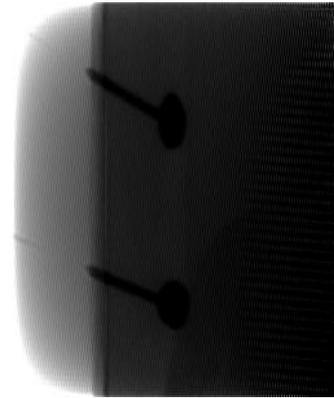
*a-Image originale bruitée*



*b-Image reconstruite régularisée avec MLEM pour 10 projections*



*c- Image originale*



*d-Image reconstruite régularisée avec  
MLEM pour 50 projections*

**Figure. II-8: Images originales et images bruitées reconstruites avec l'algorithme MLEM. pour différents nombres d'angles respectivement : 10(b), 50(d).**

### **II.3.3.3.Conclusion**

En présence de bruits d'artifacts la reconstruction par l'algorithme itérative MLEM commence à se dégrader quand le nombre d'itérations atteint une certaine valeur. Dans notre cas c'est au voisinage de 100 itérations que l'image reconstruite par l'algorithme du MLEM commence à perdre ses caractéristiques. Un autre problème de la méthode MLEM, est qu'elle peut affecter la matrice du système. La reconstruction d'images par l'algorithme MLEM à plusieurs avantages par rapport à la FBP. Cependant l'algorithme du MLEM demande plus de calcul, donc nous aurons besoin de plus de mémoire pour stocker l'image, les projections et la matrice de probabilité du système.

---

## **II.3.4.L'Algorithme Du Maximum A Posteriori MAPEM**

### **III.3.4.1.Introduction à la Régularisation (inférence Bayésienne)**

Après discrétisation a priori on peut estimé l'objet inconnu, la tâche est un problème mal-posé. Une possibilité est de régulariser par formulation Bayésienne on intégrant les informations a priori sur l'objet à estimer. Ce modèle prend en considération l'information a priori sur les paramètres de l'objet inconnu  $f$  et sur les données  $p$  à travers les quantités stochastique qui sont respectivement:  $J(f)=K(f)+\lambda.Q(f)$

- 1- La Loi a priori: Terme de Régularisation.  $Q(f) \propto -\log J(f)$  qui prend en considération l'information a priori sur l'objet.
- 2- La fonction likelihood (Vraisemblance): Terme d'attache aux données.

$$K(f) = \|p - R.f\|^2$$

Le compromis entre ces deux termes est réalisé à l'aide du paramètre de régularisation  $\lambda$ .

La résolution de l'équation de  $J$  donne un minimum mais l'unicité de ce minimum n'est pas garanti quand le  $J$  n'est pas convexe. L'algorithme génétique résout le problème par recherche du minimum global.

La définition de la loi a posteriori sur  $f$  est donnée par:

1-La distribution a priori  $J(f)$ : se sont les informations initiales sur les paramètres de l'objet estimé  $f$ . Pour le CND (Contrôle non destructive) on n'a pas d'informations précises sur la forme de  $f$ .

2-La distribution de la loi de Vraisemblance  $J(p/f)$  : Nos connaissances sur les données mesurées .

3-Une distribution a posteriori  $J(f/p)$ : Obtenue par fusion des deux informations précédentes avec la loi Bayésienne .

4-Choix de l'estimateur des paramètres  $\hat{f}$  des distribution a posteriori  $J(f/p)$ .

$J(f)$  dépend du type de modélisation choisie (poisson ou gauss).

La loi Bayes est énoncée par :

$$J(f/p) = \frac{J(p/f).J(f)}{J(p)} \quad (II-26)$$

$J(p)$ : facteur de normalisation indépendant de l'objet inconnu  $f$  définie par :

$$J(p) = \int_f J(p/f).J(f).df \quad (II-27)$$

$J$  : critère de probabilité conditionnelle.

---

### II.3.4.2. Implémentation de l'algorithme

Le problème des méthodes itératives basées sur la fonction likelihood c'est l'accumulation de bruit dans la solution estimée. La méthode MAP résout ce problème par l'inclusion d'une fonction pénalité pour diminuer l'accumulation de bruit dans l'image reconstruite. Cette méthode est basée sur le théorème de Bayes qui combine la fonction likelihood de Poisson et l'information a priori sur l'image. Notre contribution prend l'information a priori comme une pénalité floue et optimise le nouveau critère avec l'algorithme génétique. L'a priori le plus utilisé est celui de Gibbs définie par [6]:

$$P(f) = Ce^{-\beta U(f)} \quad (II-28)$$

Où  $U(f)$  est la fonction potentielle définie par le champ de Markov,  $\beta$  et  $C$  sont choisies pour modéliser l'importance de la valeur de l'a priori :

$$U(f) = |f - f_0| \Rightarrow \frac{\partial}{\partial f_j^k} U(f_j^k) = \sum_{b \in N} w_{jb} (f_j^k - f_b^k) \quad (II-29)$$

$k$  nombre d'itérations,  $w_{jb}$  la pondération du pixel  $j \in N$  l'ensemble des voisins proches du pixel,  $f_0$  l'image information. La dérivé de  $J(f)$  est prise égale à zéro pour trouver l'image  $f$  (de la formule de green) [29]:

$$f_j^{k+1} = \frac{f_j^k}{\sum_{i=1}^n r_{ij} + \beta \frac{\partial}{\partial f_j^k} U(f_j^k)} \frac{\sum_{i=1}^n p_i}{\sum_{j=1}^m r_{ij} f_j^k r_{ij}} \quad (II-30)$$

La valeur de l'a priori dans le dénominateur du MAP fait la différence avec le MLEM, cette correction est parfois négligeable et son calcul est une perte de temps [4].

On utilise le raisonnement intelligent pour juste savoir si la valeur est small ou large. On va l'exprimer par un modèle flou dans la méthode FPEM (fuzzy penalty expectation maximization).

❖ Cette valeur de l'a priori au dénominateur du MAP EM, fait la différence avec le MLEM. Cette correction est parfois négligeable et son calcul est une perte de temps.

Ce qu'on peut remarqué dans cette formule c'est:

1. Le terme a priori est la dérivée de la fonction  $U$  dite fonction potentiel.
2. Il est choisie pour enforcie le lissage de l'image et éliminé le bruit.
3. Si cette valeur est petite; ça ne sert a rien de faire toutes les calculs pour revenir à MLEM.
4. Et ça veut dire aussi que l'image est lisse dans le voisinage du pixel(i,j).

5. L'inconvénient le plus important c'est que la méthode avec cet a priori force par pénalisation l'image à devenir lisse aux bords, ce qui cause la perte des détails de l'image.
6. Pour remédier à ce problème, on suppose que: si la différence de potentiel entre pixel est large on est dans un bord(contour-Edge).Et donc on pénalise pas ce pixel et c'est ce que fait notre contribution par la méthode FPPEM.

Si on prend  $J(f)$  comme une fonction fitness à optimiser par l'algorithme GA on va exprimer la valeur du terme a priori dans le critère du MAP avec un modèle flou dans la méthode FPGA (fuzzy penalty genetic algorithm).

$$J(f) = \sum_{i=1}^n \left( - \sum_{j=1}^m r_{ij} f_j + p_i \ln \left( \sum_{j=1}^m r_{ij} f_j \right) - \ln(p_i!) \right) - \beta U(f_j) + c \quad (II-31)$$

Où  $c$ : constante d'intégration. Donc premièrement on doit construire un modèle flou pour évaluer cette correction.

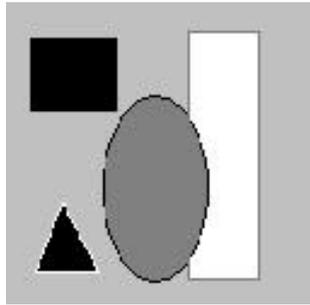
### **II.3.5.3. Résultats et discussion**

#### **II.3.5.3.1. Description des images**

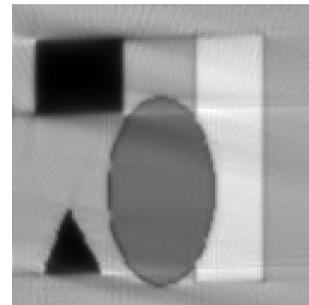
Un ensemble de données synthétique et des images réelles à 256x256 pixels de cellules solaire et finalement un circuit intégré (IC) est utilisé pour évaluer l'algorithme du MLEM en termes de qualité de reconstruction et de robustesse au bruit de Gauss ou Salt & Pepper (bruit-impulsion). La dimension de l'image finale reconstruite est 256x256 pixels.

#### **II.3.5.3.2. Résultats de Simulation**

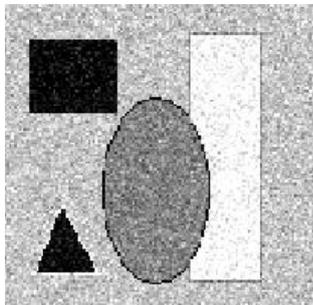
Une comparaison est faite pour les données de projections simples et dégradées par, premièrement un bruit Gaussien de niveau de variance 0.005 et ensuite un bruit impulsionnel dit Salt & Pepper avec une valeur additionnée de 3%. Dans la figure. II-9, et la figure. II-10, des images synthétiques et réelles sont reconstruites avec l'algorithme du Maximum a Posteriori reconstruction MAPPEM. Le nombre d'itération choisie est compris entre 10 et 100 pour éliminer l'accumulation de bruit. L'a priori est basé sur l'idée de savoir comment doit être l'image? Et il est choisi pour pénaliser le bruit de l'image. Pour comprendre comment l'algorithme du MAP favorise le lissage de l'image, on choisit une loi a priori qui va aider à la régularisation et à la suppression du bruit. C'est la fonction quadratique de Gibbs donnée par l'équation. II-29



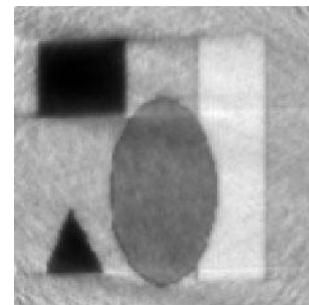
*Image synthétique Originale*



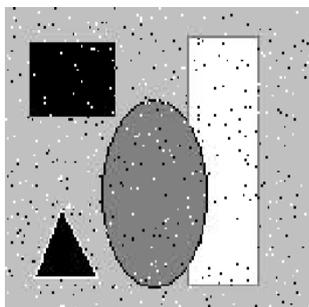
*MAPEM*



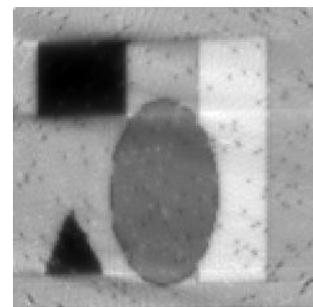
*Image avec un bruit Gaussien*



*MAPEM*



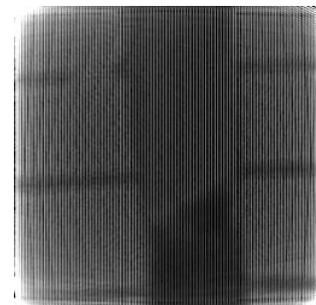
*Image avec un bruit Salt & pepper*



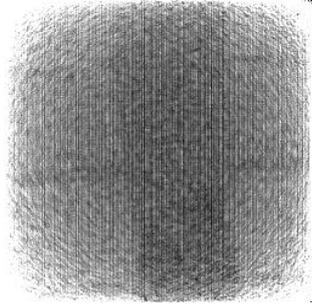
*MAP EM*



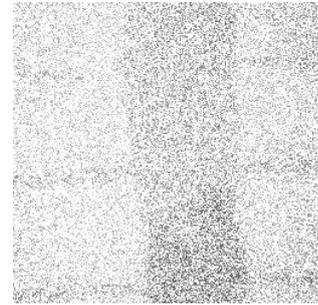
*Image Originale de la cellule*



*MAPEM*



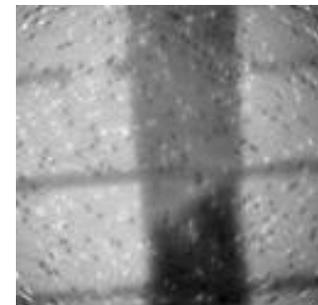
*Image avec un bruit Gaussien*



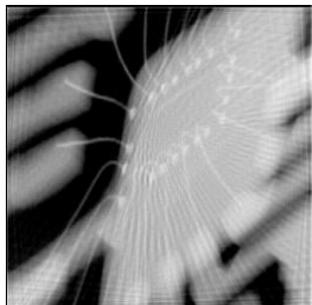
*MAPEM bruité*



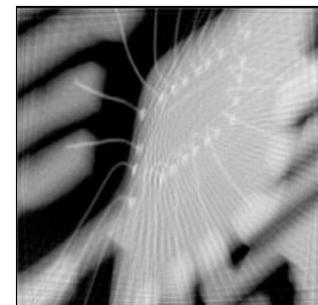
*Image avec un bruit Salt & pepper*



*MAPEM bruité*



*Image Originale du Circuit intégré*



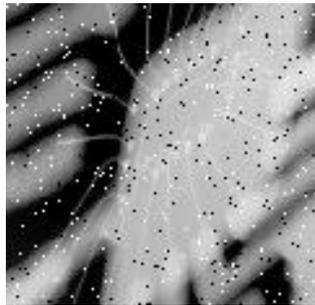
*MAPEM*



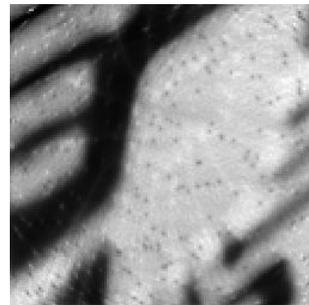
*Image avec un bruit Gaussien*



*MAPEM bruité*



*Image avec un bruit Salt & pepper*

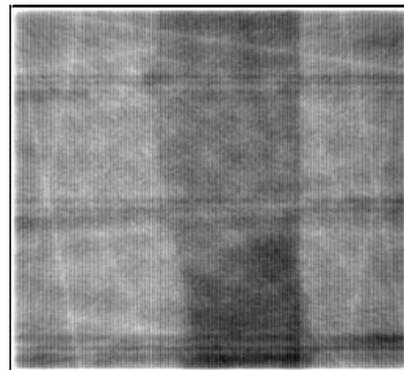


*MAPEM bruité*

*Figure. II-9: Images originales et images rétro projetées pour différents types de bruits.*



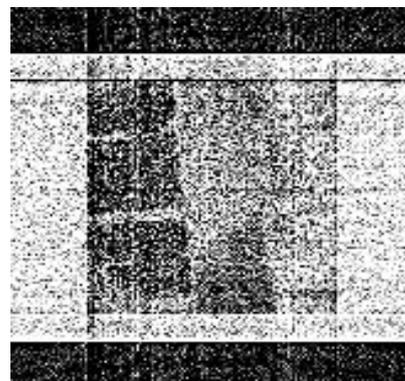
*a-Image originale*



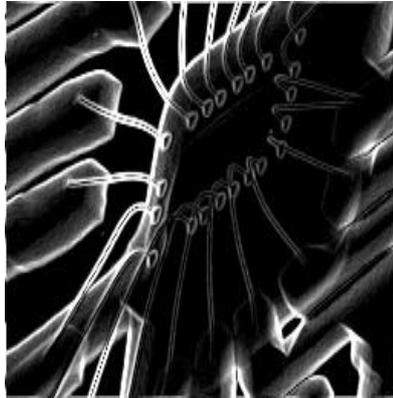
*b-Image reconstruite régularisée avec  
MAPEM pour 10 projections*



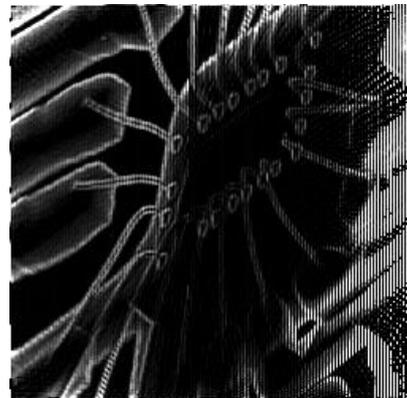
*c-Image bruitée originale*



*d-Image reconstruite régularisée avec  
MAPEM pour 10 projections*



*e- Image originale*



*f-Image reconstruite régularisée avec  
MAPEM pour 50 projections*

**Figure. II-10: Images originales et images bruitées reconstruites avec la méthode MAPEM.**

#### **II.3.5.4.Conclusion**

La méthode bayésienne est capable de reconstruire des images avec moins de bruit et une bonne résolution meilleurs que celle de la méthode MLEM. L'approche bayésienne permet de prendre en compte les informations a priori sur la solution et les données simultanément. L'algorithme du MAP a une propriété de rapidité de convergence pour la reconstruction d'images en tomographie à données limitées. Mais ces résultats restent dépendants de la qualité des informations apportées par la loi a priori qui ne se présente pas généralement sous une forme de loi probabiliste.

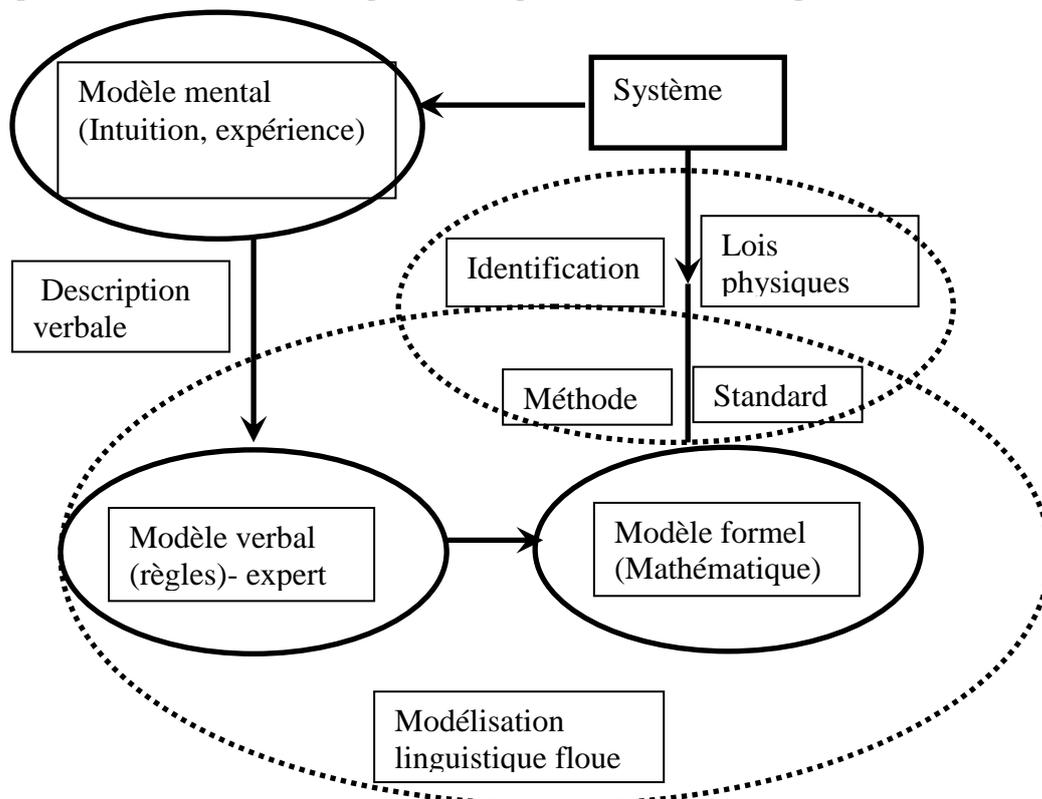
---

## II.4 : INFERENCE FLOUE

### II.4.1 Modélisation floue

Construire un modèle de la réalité est un but principal dans les différentes disciplines de l'ingénierie et la science. Le modèle peut être utilisé pour la simulation, l'analyse du comportement des systèmes et pour mieux comprendre le mécanisme de fonctionnement des systèmes. Dans l'ingénierie le modèle d'un système peut être utilisé pour désigner un contrôleur en retour ou pour prédire l'allure et le comportement futur du système, dans le but de calculer les actions de contrôle optimales. Trois genres de modèles sont montrés dans la figure. II-11. De l'expérience, et en utilisant l'intuition, les gens construisent des modèles mentaux dans leur cerveaux. Des modèles mentaux, un expert peut essayer de formuler un modèle verbal en utilisant les règles (si ... alors) ; qui sont des sens communs des descriptions de la vie quotidienne.

Pour les utilisations en ingénierie, les modèles mathématiques sont toujours construit, pour l'instant, en se basant sur les équations différentielles ou aux différences dérivées des lois physiques et avec estimation des paramètres par l'identification expérimentale.



*Figure.II-11: Modélisation linguistique floue pour la construction des modèles.*

Pour les systèmes bien définis, cet outil mathématique standard mène au bon modèle. Sinon le modèle du processus est ennuyeux. Il existe plusieurs systèmes dont le mécanisme physique

---

est inconnu ou compliqué donc le modèle mathématique est difficile à obtenir, par contre le modèle verbal de tel sujet peut être relativement simple.

Les outils mathématiques standards sont incapables d'incorporer le modèle verbal. C'est là où la modélisation floue linguistique peut être appliquée. Mais cette méthode ne peut pas être une restriction seulement pour formaliser le modèle verbal.

Dans tout système générant des données, l'ingénieur chargé de la modélisation peut utiliser ces données pour construire le modèle du système.

La modélisation floue peut être vue comme un travail structurel pour mélanger les informations de différentes natures, comme les règles verbales et les données numériques. Le terme modélisation floue comporte plusieurs genres de modèles qui emploient une variété de concepts de la théorie des ensembles flous. [17]

Typiquement les ensembles flous sont utilisés pour partitionner le domaine continu des variables I/O du système dans de petites régions adressées par des termes linguistiques comme Grand, Petit ... etc.

Le modèle flou décrit le système par l'établissement des relations entre les labels d'entrées et de sorties. Ces relations peuvent être exprimées sous la forme de règles (if... then). Chaque règle schématise une région floue de l'espace prémise (partie antécédente) à une autre région floue dans l'espace des conséquences. Par exemple, la règle :

« Si la tension est haute alors la vitesse est grande »

Relie haute tension dans un moteur électrique à la grande vitesse de son rotor. Les ensembles flous des termes linguistiques haut sont définis dans leurs domaines respectifs de : tension et rotation par minute.

Le mécanisme d'inférence floue assure l'interpolation entre les règles, donnant la réponse aux entrées ; qui ne sont pas définies dans les prémisses des règles. Cette idée de modélisation linguistique floue a été introduite dans les travaux de recherche par Zadeh et appliquée ensuite par Mamdani [5] au contrôle flou des systèmes dynamiques. En plus de la description explicite par règle, la planification peut être définie par des relations floues.

La construction de tel modèle dit : modèle relationnel flou est basée sur la théorie des relations floues et des équations relationnelles. L'ensemble flou de sortie  $y$  est calculé à partir de l'ensemble flou d'entrée  $x$  par la composition relationnelle  $y = x * R$ .

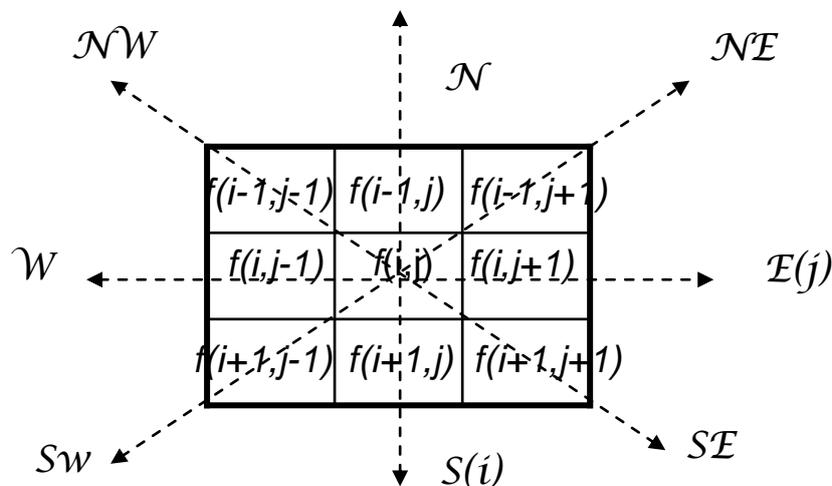
Les modèles linguistiques standards ont été étendus par Sugéno et Takagi aux règles avec conséquence de la forme (non floue) fonction des variables prémises, donc :

$$\text{Si } x \text{ est petit alors } y = a.x + b$$

Il est intéressant d'étudier la différence entre la description du sujet par le modèle linguistique de Mamdani et le modèle de Sugéno [12]. Conceptuellement différent de l'approche précédente c'est l'idée de régression linéaire floue où les nombres flous sont utilisés pour représenter les paramètres incertains dans un modèle de régression linéaire flou:

$$y = \hat{a}_1 x_1 + \dots + \hat{a}_0.$$

#### II.4.2 Bases Théoriques et implémentation de l'algorithme d'inférence floue



**Figure.II.12: voisinage 3 × 3 du pixel central (Il montre les différentes directions dérivatives le long de W).**

Le critère  $J$  est basée sur la probabilité conditionnelle, où  $p$  est la donnée mesurée, et  $f$  est l'image estimé. La solution est:

$$\hat{f} = \arg \max(J(f)) \quad (II-32)$$

Avec  $J(f) = L(f) + \beta U(f) \quad (II-33)$

Où  $\beta$  est le facteur de régularisation qui exprime un compromis entre la bonne convergence à l'image originale et la lourde pénalisation imposée à l'image originale [30].

$L(\cdot)$  est la fonction log-likelihood et  $U(\cdot)$  est la fonction pénalité.  $J(f)$  représente la probabilité a posteriori et  $U(\cdot)$  est le terme a priori. L'a priori le plus utilisé est la distribution de Gibbs.

$$\text{prob}(f/p) \propto [\text{prob}(p/f) \text{prob}(p)] \quad (II-34)$$

On doit calculer l'estimation de likelihood pénalisée par le remplacement de la fonction  $U(\cdot)$  dans l'équation.(II-34) par une fonction de pénalisation floue. L'estimée est ensuite obtenue par maximisation de l'équation (II-34).

La fonction log-likelihood  $L(f)$  peut être écrite comme:

$$L(f) = -1^T (Rf + n) + p^T \log(Rf + n) \quad (II-35)$$

La dérivée partielle du premier ordre de  $J(x)$  pour chaque pixel  $f$  est:

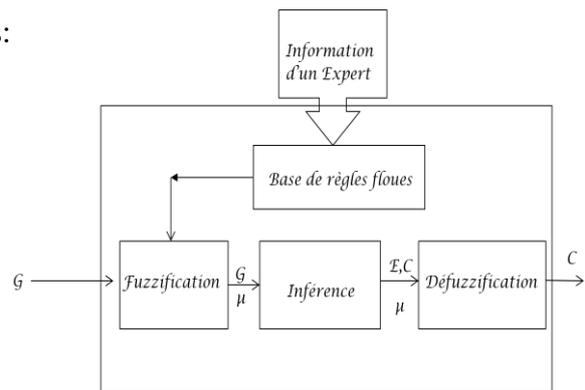
$$\frac{\partial J(f)}{\partial f} = \frac{\partial L(f)}{\partial f} + \frac{\partial U(f)}{\partial f} \quad (II-36)$$

Pour que  $f$  soit la solution optimale du problème d'optimisation non linéaire, l'optimisation de la fonction  $J(f)$  peut être réalisée par l'algorithme d'expectation maximisation.

#### **II.4.2.1. La fonction potentielle floue**

Le modèle flou FIS est constitué de quatre blocs:

- 1-Base de règles floues(BRF)
- 2-Fuzzification
- 3-Inférence
- 4-Defuzzification



*Le modèle flou(FIS)*

Le but de ce paragraphe est de calculer une estimation pénalisée-likelihood. Pour cela on remplace la fonction  $U(f)$  dans l'équation.II-30, par la fonction pénalité floue.  $U(f)$  une loi d'a priori de pénalité, choisie comme distribution floue définie comme la première dérivé de la valeur du pixel  $(i,j)$ :

$$U(f) = G_N = |f_{i,j-1} - f_{i,j}| \vec{N} \quad (II-37)$$

$U(f)$  représente le potentiel d'interaction du pixel  $i$  et de ses voisinages dans la direction  $N$ .

Où  $f_{i,j-1}$  représente le pixel du voisinage dans la direction  $N(North)$ .

Pour calculer un edge  $E$  (frontière ou contour) le long d'une direction, trois dérivés doivent être calculées et sommées [7]:

$$E_w^k(i, j) = G_w^k(i, j) + G_w^k(i-1, j) + G_w^k(i+1, j) \quad (II-38)$$

Pour exprimer le degré de 'smallest' de la dérivée floue  $E_N$  dans une direction, on utilise l'ensemble flou 'small' à la place du grand calcul dans la formule du MAPEM [31].

Maintenant nous devons trouver le modèle flou de la fonction a priori de Gibbs, à l'aide des deux étapes suivante : étape détection de l'edge et l'étape de pénalisation [32] et [33].

##### **II.4.2.1.1 Etape Détection**

Si la différence  $G_N$  entre le niveau de gris du pixel est large, alors il ya un edge, si non la région est lisse et la valeur de l'edge  $E_N$  est small.

### a. Fuzzification

Les conditions pour la détection d'edge sont:

- Pour détecter un contour le long d'une direction N trois dérivées G sont utilisées.
- Les valeurs des dérivées seront larges dans une direction, s'il y a détection de contour.
- Si deux des trois dérivées sont small, c'est qu'il n'y a pas de contour dans cette direction (règle des 2\*1/3).
- Les termes linguistiques small et large sont définis par des fonctions d'appartenances qui représentent le degré d'appartenance des variables linguistiques  $G_N$  et  $E_N$  aux ensembles flous small et large figure. II-11.

$$\mu_{E,G} = \begin{cases} \left[ \frac{E_N - \min(E_N)}{\max(E_N) - \min(E_N)} \right]^2 & \text{for } \min(E_N) \leq E_N \leq \max(E_N) \\ 0 & \text{otherwise} \end{cases} \quad (II-39)$$

-Pour calculer la valeur de la variable floue détection de contour E dans une direction N on utilise le FIS (fuzzy inference system) correspondent EDGE w.

### b. Base de règles

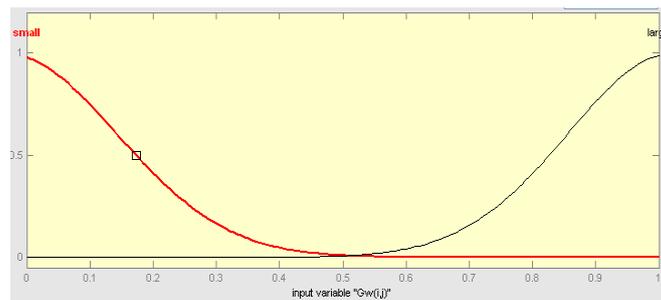
Si  $G_W^k(i, j)$  est small et  $G_W^k(i-1, j)$  est small alors  $E_W^k(i, j)$  est small

Si  $G_W^k(i, j)$  est small et  $G_W^k(i+1, j)$  est small alors  $E_W^k(i, j)$  est small

Si  $G_W^k(i-1, j)$  est small et  $G_W^k(i+1, j)$  est small alors  $E_W^k(i, j)$  est small

Si  $G_W^k(i, j)$  est large et  $G_W^k(i+1, j)$  est large et  $G_W^k(i-1, j)$  est large alors  $E_W^k(i, j)$  est large

-Similairement la détection de contour dans les huit directions  $\{E, NE, N, NW, W, SW, S, SE\}$  est calculée. Figure. II-13.



G, E

Figure.II-13- Fonction d'appartenance Gaussienne.

L'idée de base est de s'échapper à l'effet de la valeur d'une seule dérivative qui va être grand a cause du bruit. Cependant si deux des trois valeurs des dérivatives sont petites (small), il est sûr de supposé qu'il n'ya pas détection de contour dans cette direction.

---

### **II.4.2.1.2. Etape Pénalisation**

L'étape suivante est la pénalisation des pixels pour lesquels on a pas détecté de contour (lissage de la région). Huit règles floues du système d'inférence *FIS* penalty-w sont utilisées pour indiquer la correction en pénalisation des huit directions adjacentes au pixel (i,j).

Si  $E_F^k(i, j)$  est small alors  $C^k(i, j) = E_F^k(i, j)$  sinon  $C^k(i, j) = 0$

$C^k(i, j)\vec{N}$  est la correction au site (i, j) due aux pixels adjacents dans la direction N. la correction totale est:

$$C_T^k(i, j) = \frac{1}{8} \sum_N C^k(i, j)\vec{N} \quad (II-40)$$

On remplace le terme erreur (II-44) dans (II-35) on obtient le critère à optimiser par l'AG pour résoudre le problème inverse.

Nous allons exprimer cet a priori défini par:  $\frac{\partial}{\partial f_j^k} U(f_j^k) = \sum_{b \in N} w_{jb} (f_j^k - f_b^k)$   
avec un modèle flou dans la méthode FP EM.

Où:  $U(f) = G_N = |f_{i,j-1} - f_{i,j}|^N$  et dit aussi Dérivée floue, elle est la mieux adaptée pour accomplir la tâche de détection de contour.

Donc le but de FPEM est:

- Préservé les contours des images.
- Éliminé le bruit dans l'image (le lissage).

### **II.4.2.2. Algorithme de la méthode FPEM**

L'algorithme mène à la simple équation itérative Equation. II-34. Où  $f_j^{k+1}$  est l'estimée suivante du pixel j basé sur l'estimée actuelle  $f_j^k$ .

#### **Etape 1 :**

Débuter par une image initiale supposée,  $f^0$ , cette supposition initiale est généralement l'image entière multipliée par une valeur constante, ou généralement une image de la rétroprojection filtrée FBP (filtered back projection).

#### **Etape 2 :**

Projection directe de cette image dans le domaine des projections  $\sum_{j=1}^m r_{ij} f_j^k$ .

#### **Etape 3 :**

Ces projections sont comparées avec les projections mesurées  $p_i$ ; dans  $\frac{p_i}{\sum_{j=1}^m r_{ij} f_j^k}$ . Ceci

forme un facteur de correction multiplicative pour chaque projection.

---

**Etape 4 :**

Ce facteur est ensuite reprojété dans le domaine des images  $\sum_{i=1}^n \frac{p_i}{\sum_{j=1}^m r_{ij} f_j^k} r_{ij}$  pour obtenir un facteur de correction pour l'image estimée initialement.

**Etape 5 :**

Ce facteur de correction du domaine image est ensuite multiplier par l'image estimée actuelle. Ensuite divisée par un terme de pondération  $\sum_{i=1}^n r_{ij} + \beta \frac{\partial}{\partial f_j} U(f_j^k)$  basé sur le modèle du système  $\sum_{i=1}^n r_{ij}$  pour appliquer le facteur de correction désiré pour chaque image, en ajoutant la correction  $\beta \frac{\partial}{\partial f_j} U(f_j^k)$  résultante de l'application du model flou dans ses deux étapes détection et pénalisation. C'est ici ou réside la différence de l'algorithme FPEM par rapport à la méthode MAPEM.

**Etape 6 :**

La nouvelle image estimée est maintenant réinjectée dans l'algorithme comme une image suivante.

**Etape 7 :**

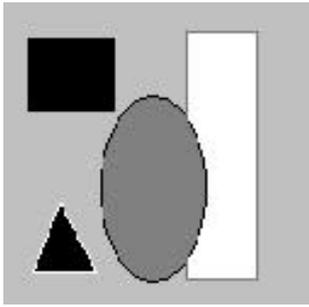
L'algorithme se répète jusqu'à ce que l'estimée approche la solution du maximum likelihood.

**II.4.3. Résultats et discussion****II.4.3.1. Description des images**

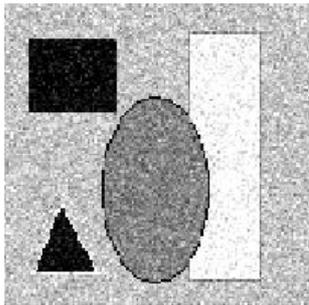
Un ensemble de données synthétique ensuite des images réelles à 256x256 pixels de cellules solaire et finalement un circuit intégré (IC) sont utilisés pour évaluer l'algorithme en termes de qualité de reconstruction et de robustesse au bruit de Gauss ou Salt & Pepper (bruit-impulsion). La dimension de l'image finale reconstruite est 256x256 pixels.

**II.4.3.2. Résultats de Simulation**

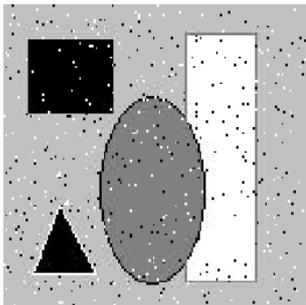
Une comparaison est faite pour les données de projections simples et dégradées par, premièrement un bruit Gaussien de niveau de variance 0.005 et ensuite un bruit impulsionnel dit Salt & Pepper avec une valeur additionnée de 3% .Dans la figure. II-14, des images synthétiques et réelles sont reconstruites avec l'algorithme du Maximum a Posteriori reconstruction avec un a priori flou FPEM. Le nombre d'itérations choisies est compris entre 10 et 100 pour éliminer l'accumulation de bruit.



*Image synthétique Originale*



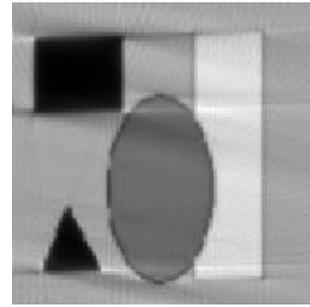
*Image avec un bruit Gaussien*



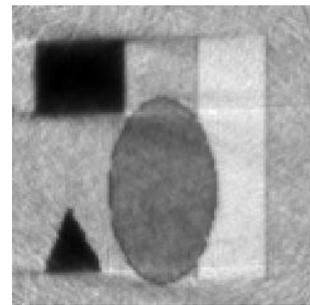
*Image avec un bruit Salt & pepper*



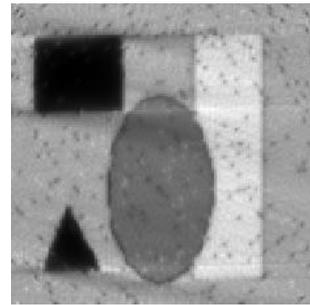
*Image Originale de la cellule*



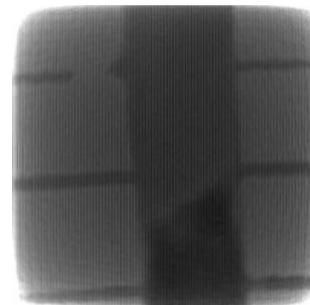
*FPEM*



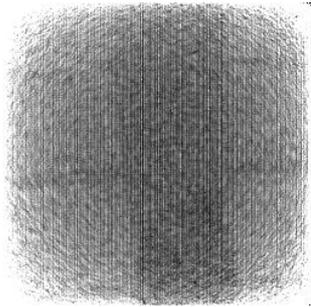
*FPEM*



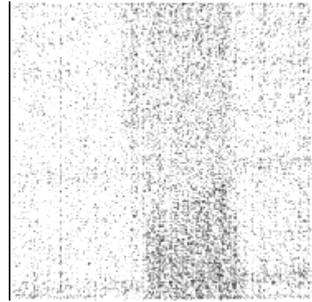
*FPEM*



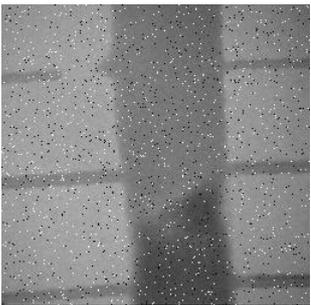
*FPEM*



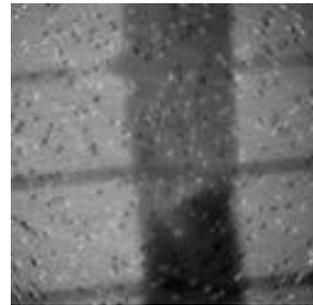
*Image avec un bruit Gaussien*



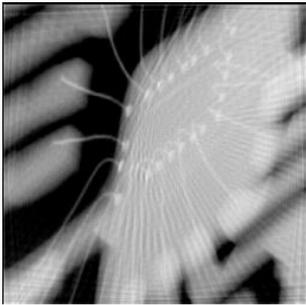
*FPEM bruité*



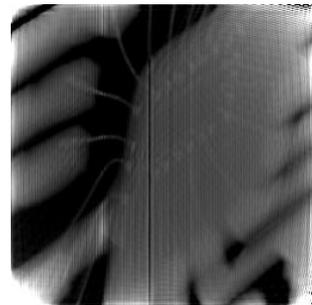
*Image avec un bruit Salt & pepper*



*FPEM bruité*



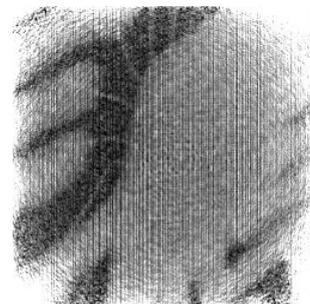
*Image Originale du Circuit intégré*



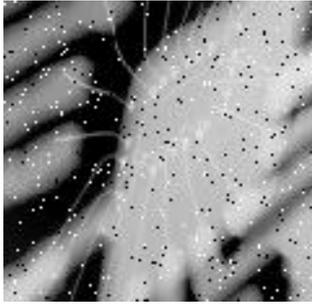
*FPEM*



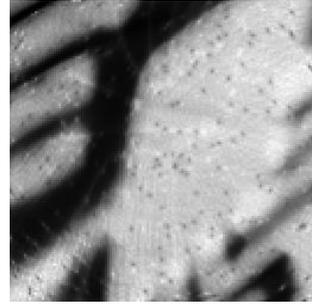
*Image avec un bruit Gaussien*



*FPEM bruité*



*Image avec un bruit Salt & pepper*



*FPEM bruité*

*Figure II-14. Images Réelles reconstruites avec différents algorithmes.*

#### **II.4.4. Conclusion**

Toutes les méthodes de reconstruction tomographique qu'on a vue présentent des handicaps. L'issue est généralement les méthodes statistiques (probabilistes), surtout l'a priori réalisé par l'inférence bayésienne. Mais le problème qui se pose c'est le choix du modèle mathématique de ce a priori. C'est pour ça qu'on a opté pour le raisonnement flou (inférence floue) pour essaie d'approximer l'inférence bayésienne ou le model de l'a priori par un model flou plus facile et plus adéquat.

---

# CHAPITRE 3

---

## **Chapitre III**

### **Approche Génétique pour la Détermination des Paramètres d'un Objet à partir de Projections en tomographie-X**

#### **Résumé**

L'optimisation par algorithme génétique est l'une des nouvelles méthodes aléatoires stochastiques qui peut être utilisé même pour les problèmes non analytiques, pour remédier au problème principale d'optimum local du quel soufre la plupart des méthodes de reconstruction tomographique [35]. L'implémentation de cette méthode dans les domaines médicaux et industriels a connu un grand succès ces dernières années. Dans cette méthode il est nécessaire de définir une fonction fitness qui peut être utilisée pour exprimer l'optimalité dans une forme explicite en utilisant a titre d'exemple, l'ensemble des carrés des erreurs entre les sorties du modèle flou mesurées et estimées. Il a été montré que les systèmes régies par la logique floue et qui ont été optimisés par un algorithme génétique produisent de meilleur résultat [36].

---

### **III.1.Introduction**

L'AG est inspiré du mécanisme de sélection naturel. Il présume que la solution potentielle d'un problème est un individu qui peut être représenté par un ensemble de paramètres.

Ces paramètres sont vus comme des gènes des chromosomes et peuvent être structurés à l'aide d'une file (une chaîne) de valeurs sous une forme binaire ou réelle. Des valeurs positives généralement comme des valeurs fitness, sont utilisées pour refléter le degré de fitness du chromosome pour résoudre le problème d'optimisation, et cette valeur est vraiment liée à sa valeur objective.

A travers une évolution génétique, un chromosome a tendance de produire un chromosome de bon qualité, ce qui veut dire une bonne solution au problème. Dans une application pratique des AG, une population de chromosomes doit être initialisée. La largeur de cette population varie d'un problème à un autre. Un groupe de ces chromosomes généralement appelés parents sont sélectionnés à travers une routine spécifique de sélection.

Les gènes des parents sont à mixer et à recombinaison pour la production de nouveaux chromosomes dans la prochaine génération. Il a été prouvé que les bons chromosomes vont produire une génération avec une grande chance de survie, en simulant le mécanisme de survie naturel.

Une des meilleurs techniques utilisées dans un tel mécanisme de sélection est la roue de la loterie (roulette wheel)[19]. Le cycle d'évolution est répété jusqu'à ce qu'un critère de terminaison est atteint.

Pour faciliter le cycle d'évolution de l'AG, deux opérateurs fondamentaux sont utilisés le croisement et la mutation, aussi la routine de sélection peut être prise comme un autre opérateur.

#### **I-Le codage:**

Les codages réels sont désormais largement utilisés, notamment dans les domaines applicatifs pour l'optimisation de problèmes à variables réelles [37]. Chaque variable (information) représente alors un gène et toutes les valeurs que peuvent prendre cette caractéristique représentent les allèles possibles pour ce gène, et en concaténant tous ces gènes pour obtenir un chromosome qui lui représente une solution dans son intégralité.

Il y a trois principaux types de codage:

- le codage binaire: c'est le plus utilisé. Chaque gène dispose du même alphabet binaire {0, 1}.
- le codage réel: utile lorsque on recherche le maximum d'une fonction réelle.
- le codage de Gray: le codage de Gray est un codage qui a comme propriété qu'entre un élément  $n$  et un élément  $n + 1$ , donc voisin dans l'espace de recherche, un seul bit diffère.

---

L'algorithme génétique:

- 1) Initialiser P.
- 2) Evaluer P.
- 3) TantQue Pas Convergence faire :
  - a) Sélection de  $P_1$  éléments a partir des Parents P
  - b) Croisement sur  $P_1$
  - c) Mutation sur  $P_1$
  - d) Remplacer les Anciens de P par leurs Descendants de  $P_1$
  - e) Evaluer P
- 4) FinTantQue

### **II-L'opérateur de sélection:**

Cet opérateur définit quels seront les individus de P qui vont être dupliqués dans la nouvelle population  $P_1$  et vont servir de parents [38]. Cet opérateur est important puisqu'il permet aux individus de survivre. La probabilité de survie d'un individu sera directement reliée à son efficacité dans la population.

Il ya quatre types de méthodes de sélection différentes :

- La méthode de la "loterie biaisée" (roulette wheel) de Goldberg [35], la plus célèbre où chaque individu a une chance d'être sélectionné proportionnelle à sa performance cette dernière est désigné par un secteur dans la roue[20].
- La méthode "élitiste".
- La sélection par tournois.
- La sélection universelle stochastique.

### **La fonction (Fitness) de Sélection**

La fonction de sélection est utilisée pour créer une pression évolutive. Chromosomes à haute performance ont une grande chance de survivre. La méthode de sélection de la roue de loterie est utilisé pour sélectionner les chromosomes des parents. Un chromosome peut être bien choisi qu'un autre. Tout dépend de la chance dans la roue de la roulette, qui est adaptative.

### **III- L'opérateur de croisement:**

Le croisement permet la production de chromosomes qui héritent partiellement des caractéristiques des parents [43]. Son rôle fondamental est de permettre la recombinaison des informations présentes dans la population. Cet opérateur est appliqué après application de la sélection sur la population P, on peut noter que le nombre de points de croisements et la

---

probabilité de croisement  $p_c$  permettent d'introduire plus ou moins de diversité. L'opérateur de croisement favorise l'exploration de l'espace de recherche.

#### **IV- L'opérateur de mutation:**

Cet opérateur change la valeur allélique d'un gène avec une probabilité  $p_m$  très faible. Une mutation consiste simplement en l'inversion d'un bit (ou de plusieurs bits)[22].

L'opérateur de mutation modifie donc de manière complètement aléatoire les caractéristiques d'une solution, ce qui permet d'introduire et de maintenir la diversité au sein de notre population de solutions. Cet opérateur introduit du bruit dans la population.

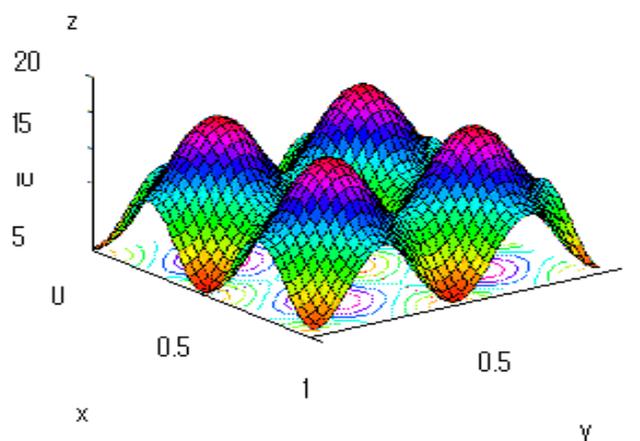
#### **b. Exemple d'optimisation par AG**

Pour chercher le maximum de la fonction objective de la figure. III-1. Fonction de Rastrigin, avec :  $Z = f(x, y)$  où  $x, y \in [0, 1]$ .

Le chromosome est formé de 16 bits binaire. Une chaîne représente les coordonnées  $x, y$  avec 8 bits pour chacun. La simulation est faite à l'aide du Matlab (Toolbox génétique). Nous montrons les opérations typiques de la génétique et le changement de la population de la première génération à la seconde.

- La probabilité de l'opérateur de croisement est notée  $P_c$  avec une valeur, typique de 0,6 à 1,0.
- Cependant la mutation est appliquée à chaque chromosome individuellement. L'opération touche aléatoirement un chromosome avec une probabilité  $P_m$  dont la valeur typique (empirique) est 0,1.

Le choix de  $P_c, P_m$ , dépend de la complexité du problème d'optimisation et leur mise à jour dépend de la fonction objective.



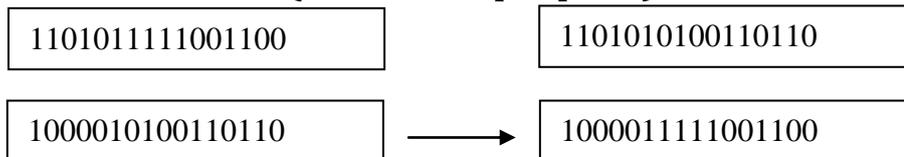
*figure.III.1. Opérateurs de la génétique d'une génération vers une autre génération.*

---

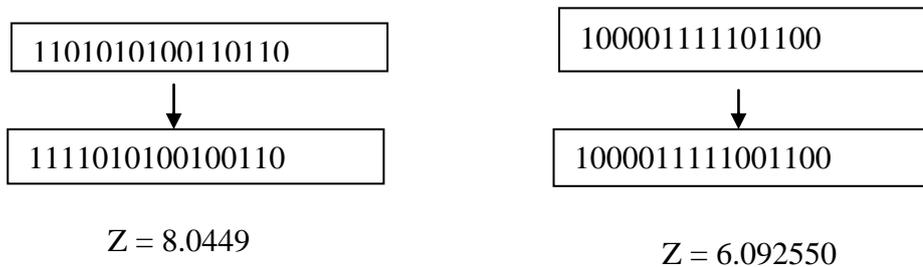
### ETAPE 1 : SELECTION DES PARENTS

Première population	Valeur Objective $z = f(x, y)$
1100110110101000	3.481746
0101010110110101	3.668023
1000010100110110	6.261380
1101011111001100	12.864222

### ETAPE 2 : CROISEMENT (Croisement par point)



### ETAPE 3: MUTATION



### ETAPE 4: REINSERTION

Seconde population	Valeur Objective $z = f(x, y)$
1111010100100110	8.044649
1000011111001100	6.092550
1000010100110110	6.261380
1101011111001100	12.864222

Pour résumer:

L'AG recherche les extrêmes d'une fonction définie sur un espace de données. Pour cela on doit disposer de cinq éléments :

- 1) Un principe de codages des éléments des populations.
- 2) Un mécanisme de génération de la population initiale.
- 3) Une fonction à optimiser (dans R).
- 4) Des opérateurs permettant de diversifier la population (croisement, mutation).
- 5) Des paramètres pour dimensionner le problème (taille de la population, nombre de génération, probabilité de croisement et mutation).

---

## **III.2. Opérateurs de l’algorithme génétique**

Les opérateurs utilisés dans l’AG emploient les paramètres suivant:

$r \in [0, 1]$  un nombre aléatoire,  $t = 0, 1, \dots, T$  le nombre de générations,  $V$  et  $W \in \{1, 2, \dots, L\}$  indiquent les chromosomes sélectionnés, pour les opérateurs.

$k \in \{1, 2, \dots, m\}$  donne la position d’un élément dans le chromosome et  $V_k^{\max}$  et  $V_k^{\min}$  sont les bornes minimale et maximale, respectivement dans les variables encodées par élément  $k$ .

### **-Opérateur de croisement**

Les chromosomes sont sélectionnés en paire pour le croisement.

#### **-Croisement arithmétique simple**

$S_g^t$  et  $S_w^t$  sont croisés à la position  $k$ , le nouveau né (offspring) résultant est:

$$S_v^{t+1} = (V_1, \dots, V_k, W_{k+1}, \dots, W_m) \quad \text{et} \quad S_v^{t+1} = (W_1, \dots, W_k, V_{k+1}, \dots, V_m)$$

Où  $k$  est un entier aléatoire dans  $\{1, \dots, m-1\}$ .

### **-Opérateur de mutation**

Un seul chromosome est sélectionné.

#### **-Mutation uniforme**

Un élément aléatoire  $V_k$ ,  $k \in [1, m]$  est remplacé par  $V_k^1$  qui est un nombre aléatoire du rang  $V_k^{\min}, V_k^{\max}$  le chromosome résultant est  $S_v^{t+1} = (V_1, \dots, V_m)$ .

### **-Fonction de sélection**

La fonction de sélection est utilisée pour créer une pression évolutive. Les chromosomes à grande performance ont une grande chance de survivre. La méthode de sélection de la roue de loterie est utilisée pour sélectionner les chromosomes des opérateurs.

Un chromosome peut être sélectionné mieux qu’un autre. Tout dépend de la chance dans la roue de roulette, qui est adaptative et donnée par:

$$J_i^{tel} = \frac{1}{\sqrt{J_i - \max(j)}}, \quad i \in \{1, \dots, m\} .$$

Où  $J$  est la performance du modèle mesurée par la technique de l’erreur des moindres carrées (mean square error)

$$MSE = \frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2$$

Où  $y$  est la valeur calculée et  $\hat{y}_k$  est la valeur mesurée du modèle.

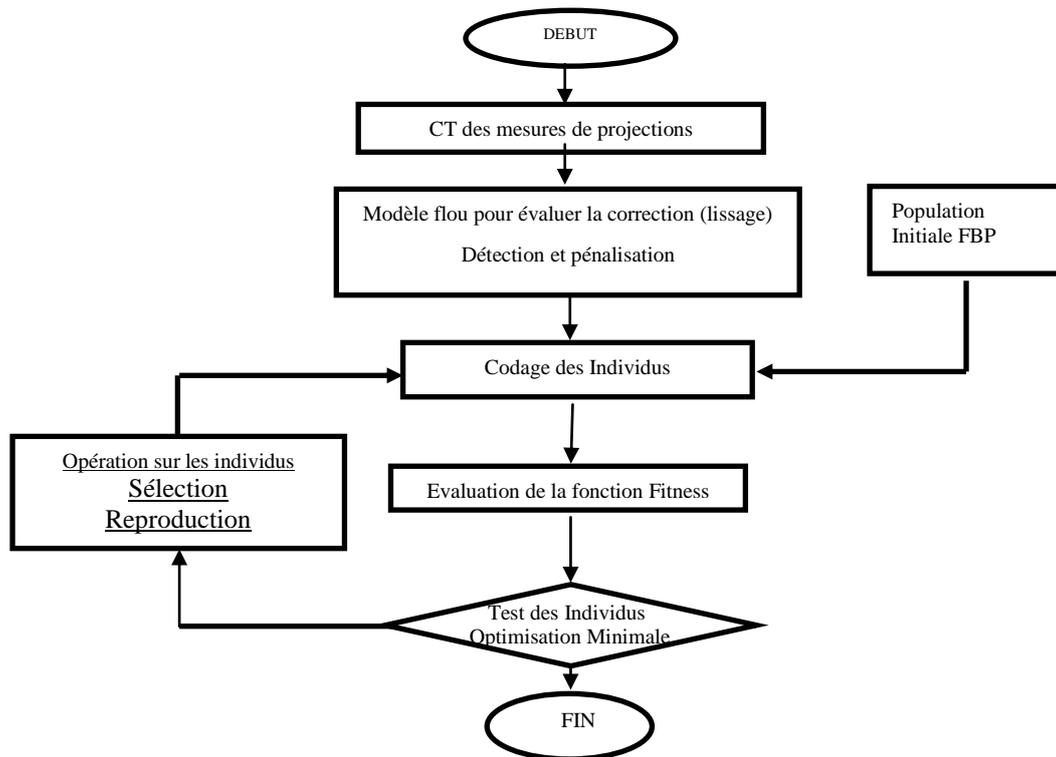
La chance du croisement est  $\zeta_c$  (90%) et la chance de mutation est  $\zeta_m$  (5%).

---

➤ Les bons chromosomes sont toujours préservés par réinsertion après l'opération.

### III.3.Optimisation à l'aide de l'algorithme génétique

On donne dans la figure.III-2, l'organigramme de notre méthode combinée dans lequel vous voyez premièrement le modèle flou pour lequel on doit calculer la correction en lissage en deux étapes détection et pénalisation et deuxièmement la solution optimale résultante de l'algorithme génétique.



*Figure. III-2. cycle d'évolution employé dans l'AG.*

Les données de projections sont utilisées avec l'algorithme génétique de base pour la détermination des paramètres de l'objet [46], [47], [13], [48].

#### **1. Initialisation**

La population initiale la plus efficace est la FBP (filtered back projection).

#### **2. Sélection**

La méthode qu'on a utilisée est le schéma de la roue de loterie (RWS) pour plus de détails [46] et [49].

#### **3. Reproduction**

---

Exige une mémoire héréditaire sous forme de gènes, les modifications sont croisement et mutation qui permettent de diversifier l'AG.

#### 4. Croisement

On a utilisé le croisement à un point. Il est appliqué avec une probabilité  $P_c$  élevée.

#### 5. Mutation

On a utilisé la mutation uniforme. Elle est appliquée avec une probabilité  $P_m$ .

#### 6. Evaluation de la fonction fitness

La fonction fitness choisie pour la rendre maximale est basée sur l'erreur entre les projections calculées et celles mesurées pour différents angles de projections ( $m$  angles  $\theta$ ) et donc un nombre  $m$  de projections. Une variété de critères de mesures d'erreurs existent parmi lesquels on peut citer: RMSE (root mean squared error), MSE, MAE, RSE. Nous avons opté pour le choix suivant:

$$E = J(f) = L(f) + \beta U(f)$$

$$l(f) = \sum_{i=1}^n (-\sum_{j=1}^m r_{ij} f_j + p_i \ln(\sum_{j=1}^m r_{ij} f_j) - \ln(p_i!)) - \beta U(f) + c \quad (III-1)$$

$$\frac{\partial}{\partial f_j^k} U(f_j^k) = C_T(i, j) \Rightarrow \beta U(f_j^k) = f_j \cdot C_T(i, j)$$

$C_T$ : Valeur du terme a priori dans le critère du MAP.

Nous allons l'exprimer avec un modèle flou dans la méthode FPGA en prenant  $J(f)$  comme une fonction fitness à optimiser. La fin de l'algorithme génétique est terminée quand un nombre fixe de générations est surpassé, ou un niveau de convergence est atteint.

#### III.4.L'algorithme Global de la méthode FPGA

L'algorithme conduit à la simple équation.III-1. qui doit être optimisée par l'AG.

##### Etape 1:

Débuté par un choix initial d'image (population initiale)  $f(0)$ . Ce choix initial est généralement l'image FBP (filtered back projection) ou une image blanche ou noire.

##### Etape 2:

L'application du modèle flou dans ces deux étapes détection et pénalisation donne la valeur de la correction  $\beta \frac{\partial}{\partial f_j} U(f_j^k)$  et suivant l'équation.III-1. On calcule le terme

$\beta U(f_j^k) = f_j \cdot C_T(i, j)$  à injecter dans la fonction globale pour l'optimiser par l'équation III-1.

##### Etape 3:

---

On introduit l'AG par le codage individuel on commençant par la population initiale choisie dans l'étape.1.

**Etape 4:**

L'application de l'algorithme génétique à l'aide de trois étapes:

-Reproduction: (croisement et mutation).

-Evaluation: (fitness function)

-Sélection:

**Etape 5:**

Finalement la fin de l'algorithme génétique est obtenue quand un nombre fixe de générations est surpassé, ou un niveau de convergence est atteint.

**III.5. Résultats et discussion**

**III.5.1. Description des images**

Nous avons utilisé plusieurs ensembles de données, premièrement l'image synthétique ensuite des images à 256x256 pixels de cellules solaire et finalement un circuit intégré (IC). Ces deux dernières données sont obtenues à l'aide du tomographe Fein-focus pour évaluer l'algorithme en termes de qualité de reconstruction et de robustesse au bruit de Poisson, Gaussien ou Salt & Pepper (bruit-impulsion). La dimension de l'image finale reconstruite est 256x256 pixels.

Les caractéristiques principales du Tomographe sont: Radioscope type FXS160.50; Source: X-rays poly chromatique, trajectoire Molybdène, Detector : H641VR02 (Fein-Focus) + Convertisseur en RS170; Acquisition : Matrox Support MVP+Software FIP400 v4.0, Image Niveau de gris en 8 bits 512\*512 pixel. Accélération du flux d'électron 10 - 160 Kv sous un courant avec 1 mA max. Tache de focalisation micrométrique: 4 -1000 µ.

Le contrôle par la technique de la radioscopie à micro-foyer donne une idée sur la qualité de fabrication des objets, spécialement dans le stade qui exige un examen. Le but principal de ce système d'inspection est l'examen en temps réel des objets. Il est ainsi possible de contrôler les défauts sous différents angles. Les tests de radioscopie à micro-foyer montrent l'intérêt de l'équipement de contrôle pour obtenir de résultats satisfaisants dans l'examen des objets de différentes compositions, et structures. Mais aussi l'intérêt de détecter des défauts dans les applications de soudage qui vont jusqu'à moins de 10mm d'épaisseur.

**III.5.2 Résultats de Simulation**

Une comparaison similaire est faite pour les données de projections simples et dégradées par, premièrement un bruit Gaussien de niveau de variance 0.005 et ensuite un bruit impulsionnel dit Salt & Pepper avec une valeur additionnée de 3% (ceci est la cause de l'introduction

aléatoire de pixels blancs ou noirs dans l'image) [23]. Dans la figure. III-3, et la figure. III-4, des images synthétiques et réelles sont reconstruites avec différents algorithmes ; l'algorithme du Maximum Likelihood-Expectation Maximisation (MLEM), l'algorithme du Maximum a Posteriori reconstruction MAPEM, l'algorithme du Maximum a Posteriori reconstruction avec un a priori FPEM et le FPGA. Les performances des algorithmes sont évaluées pour les différents critères objectifs [50]. On mesure le rapport de convergence en calculant le rapport signal sur bruit (SNR) et ensuite l'erreur carrée moyenne (MSE) entre les valeurs mesurées et celles estimées comme une fonction du nombre d'itération/génération  $k$ .

Les équations des SNR et du MSE utilisées sont:

$$SNR = -10 * \log_{10} \left[ \frac{\sum (f_{result}(:) - f_{original}(:))^2}{\sum (f_{original}(:))^2} \right] \quad (III-2)$$

$$MSE = \frac{1}{n * m} (\sum ((f_{result}(:) - f_{original}(:))^2)) \quad (III-3)$$

Ces équations expriment la dispersion entre l'image reconstruite et l'image originale. Les SNR et MSE résultant pour le MLEM, MAPEM, FPEM et FPGA sont donnés dans la figure.(III-5). Le nombre d'itérations/génération choisie est compris entre 10 et 100 pour éliminer l'accumulation de bruit. On voit la stabilité de l'algorithme FPGA et FPEM en comparaison avec l'algorithme MLEM qui converge vers une solution bruitée quand le nombre d'itérations augmente. Ceci n'est pas le cas pour l'algorithme FPGA. Le FPEM est plus coûteux en termes de temps de calcul Tableau. (III-2). Pour l'opérateur de croisement les chromosomes sont sélectionnés par paire (croisement arithmétique) [51]. Pour l'opérateur de mutation un chromosome est sélectionné (Mutation uniforme). La fonction sélection est utilisée pour créer une pression évolutive. Les chromosomes avec de grandes performances ont une grande chance de survie. La chance du croisement est  $\zeta_c$  90% et la chance de la mutation est  $\zeta_m$  5%. Les meilleurs chromosomes sont toujours retenus par réinsertion après les opérations. Le Tableau. (III-2) indique le temps CPU en second après N itérations pour les méthodes MLEM, MAPEM, FPEM et FPGA. La taille de l'image est 256\*256, on peut voir la réduction en temps du CPU donné par l'algorithme combiné. On note que le CPU utilisé est un Pentium 4 avec 3.4 GHZ et 496 MO de RAM.

### **III.5.3.Limites de l'algorithme FPGA**

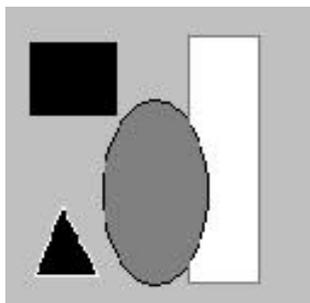
L'utilisateur du FPGA doit choisir un certain nombre de paramètres de l'AG pour converger vers la solution image globale. Le choix des paramètres a une grande influence sur la vitesse de convergence comme sur le succès de l'optimisation. En particulier, dans cette étude la population initiale, le croisement et la mutation et les critères d'arrêt vont recevoir une

---

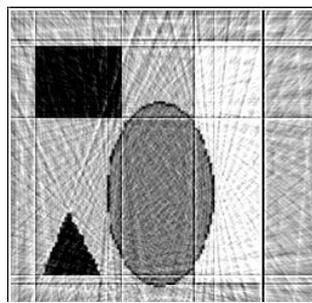
attention spéciale, dans le but d'atteindre une combinaison efficace et fiable des paramètres. Dans les documents consultés, la mutation est typiquement inférieure à 5%, mais dans des cas exceptionnels on considère des cas plus élevés [13]. On a trouvé une grande variation en termes du nombre d'individus par population, même pour des problèmes similaires.

Le rôle principal de l'opérateur de mutation est de restaurer la diversité dans les gènes des chromosomes, c'est un des points de nos futurs travaux. De ce fait, le croisement peut perdre son rôle quand la grande partie de la population est centrée autour d'un minimum local de la fonction fitness. Dans ce cas, un nombre croissant d'individus devient génétiquement identique et à ce moment le croisement, ne modifie pas le chromosome, c'est dans ce cas où on converge dans un minimum local. Ceci est appelé le dérapage génétique. Dans ce cas la on doit changer la stratégie de mutation. Le principal point noir de l'AG est le risque prématuré de convergence vers un extremum local, quelque fois due au mauvais choix de l'initialisation de l'espace de recherche; c'est pour quoi on démarre généralement par une FBP comme solution initiale.

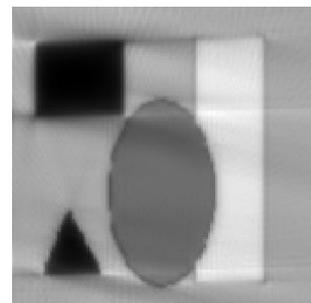
Finalement, il est important de noter que plusieurs exécutions de l'AG avec les mêmes conditions initiales et le même choix de paramètres peuvent potentiellement converger vers différents optimaux voisins due à leur nature stochastique. Donc la répétition n'est pas toujours efficace.



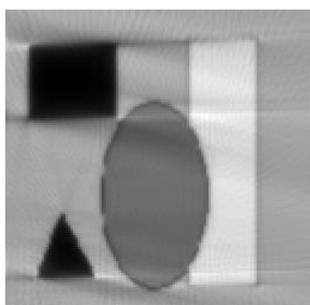
*Image synthétique Originale*



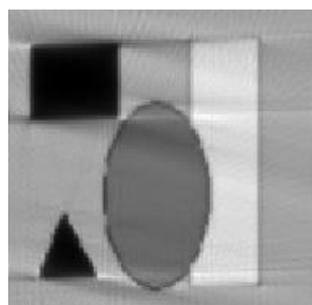
*Méthode FBP*



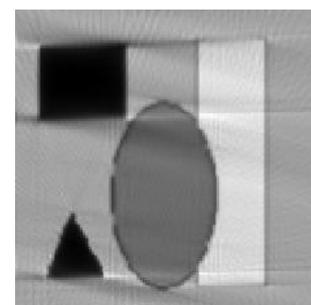
*MLEM*



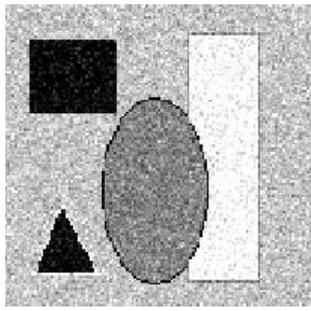
*MAPEM*



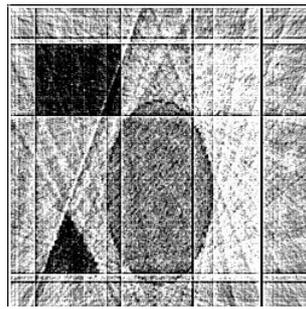
*FPEM*



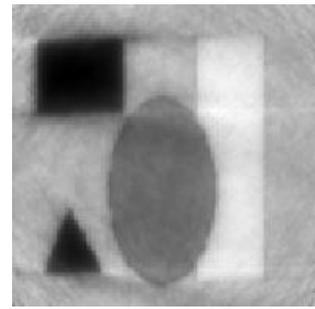
*FPGA*



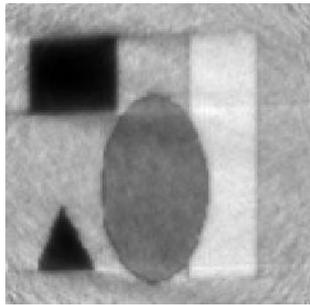
*Image avec un bruit Gaussien*



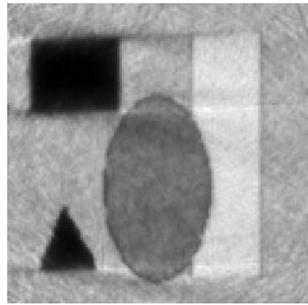
*Méthode FBP*



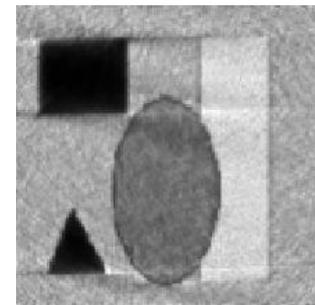
*MLEM*



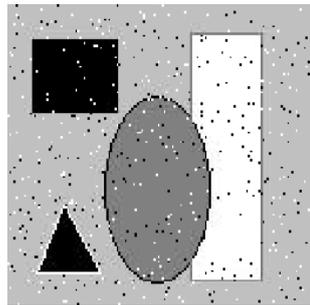
*MAPEM*



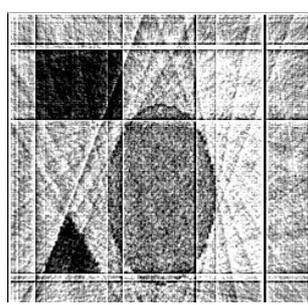
*FPEM*



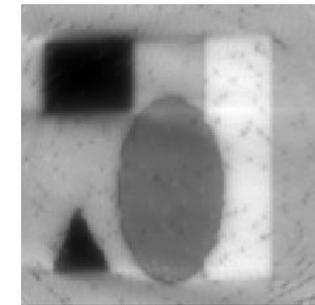
*FPGA*



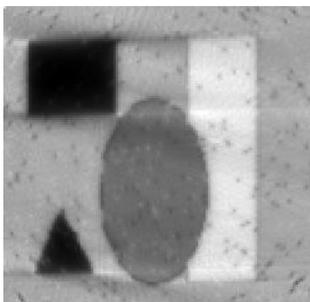
*Image avec un bruit Salt & pepper*



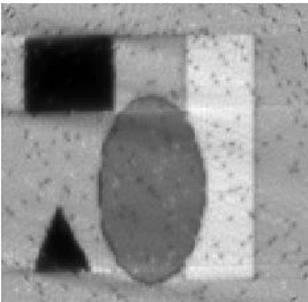
*Méthode FBP*



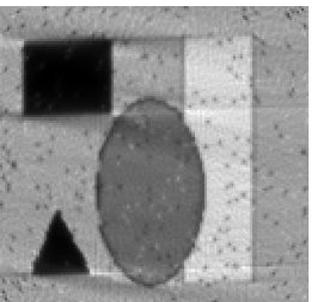
*MLEM*



*MAPEM*

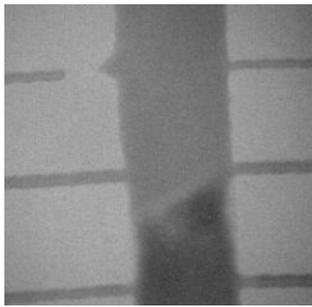


*FPEM*

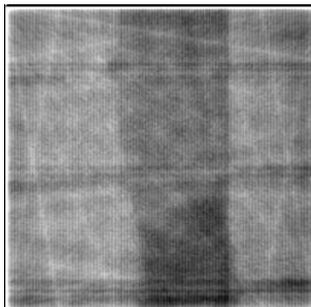


*FPGA*

*Figure.III-3. Image Synthétique reconstruite avec différents algorithmes.*



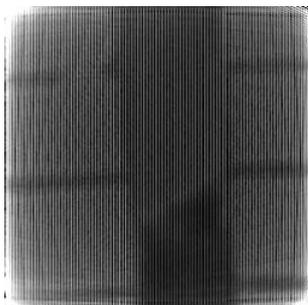
*Image Originale de la cellule*



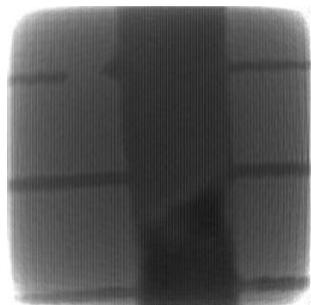
*Méthode FBP*



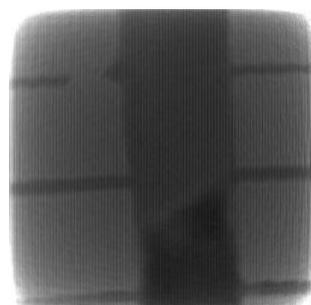
*MLEM*



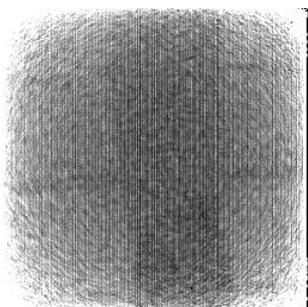
*MAPEM*



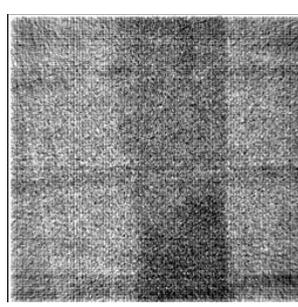
*FPEM*



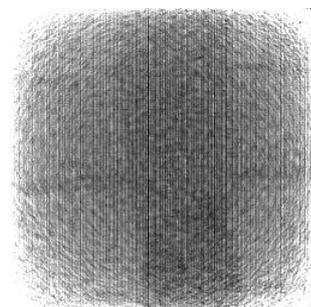
*FPGA*



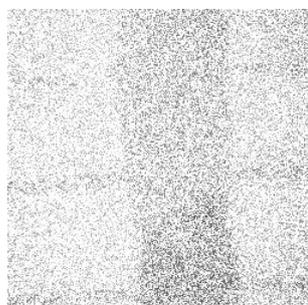
*Image avec un bruit Gaussien*



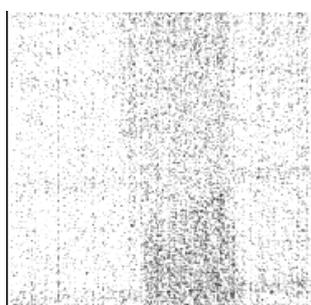
*FBP bruité*



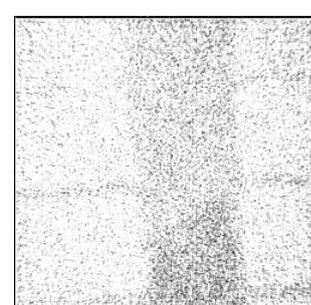
*MLEM bruité*



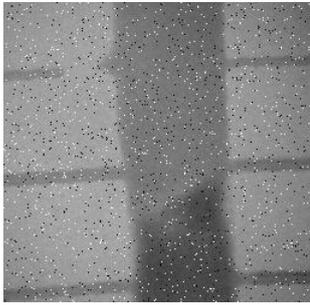
*MAPEM bruité*



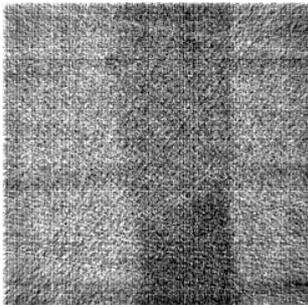
*FPEM bruité*



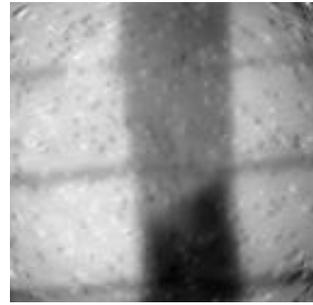
*FPGA bruité*



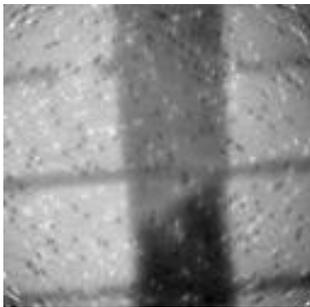
*Image avec un bruit Salt & pepper*



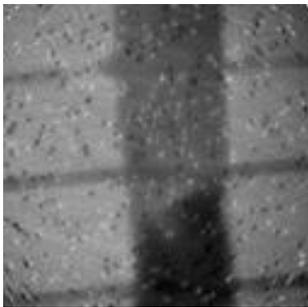
*FBP bruité*



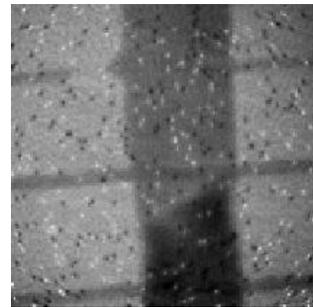
*MLEM bruité*



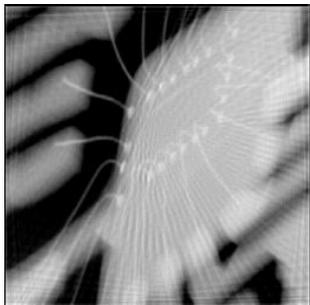
*MAPEM bruité*



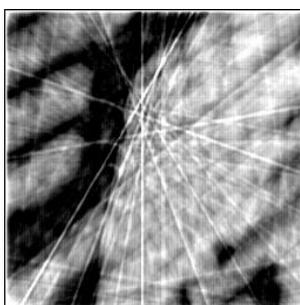
*FPEM bruité*



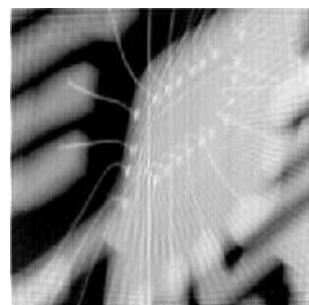
*FPGA bruité*



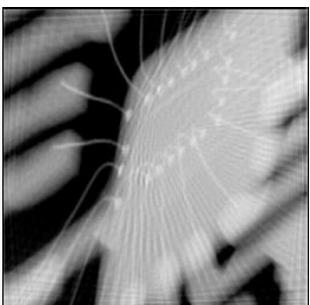
*Image Originale du Circuit intégré*



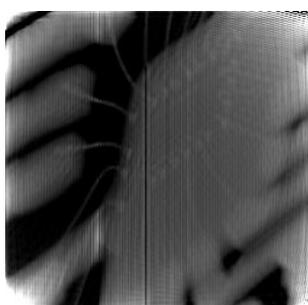
*Méthode FBP*



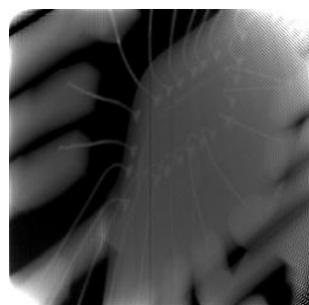
*MLEM*



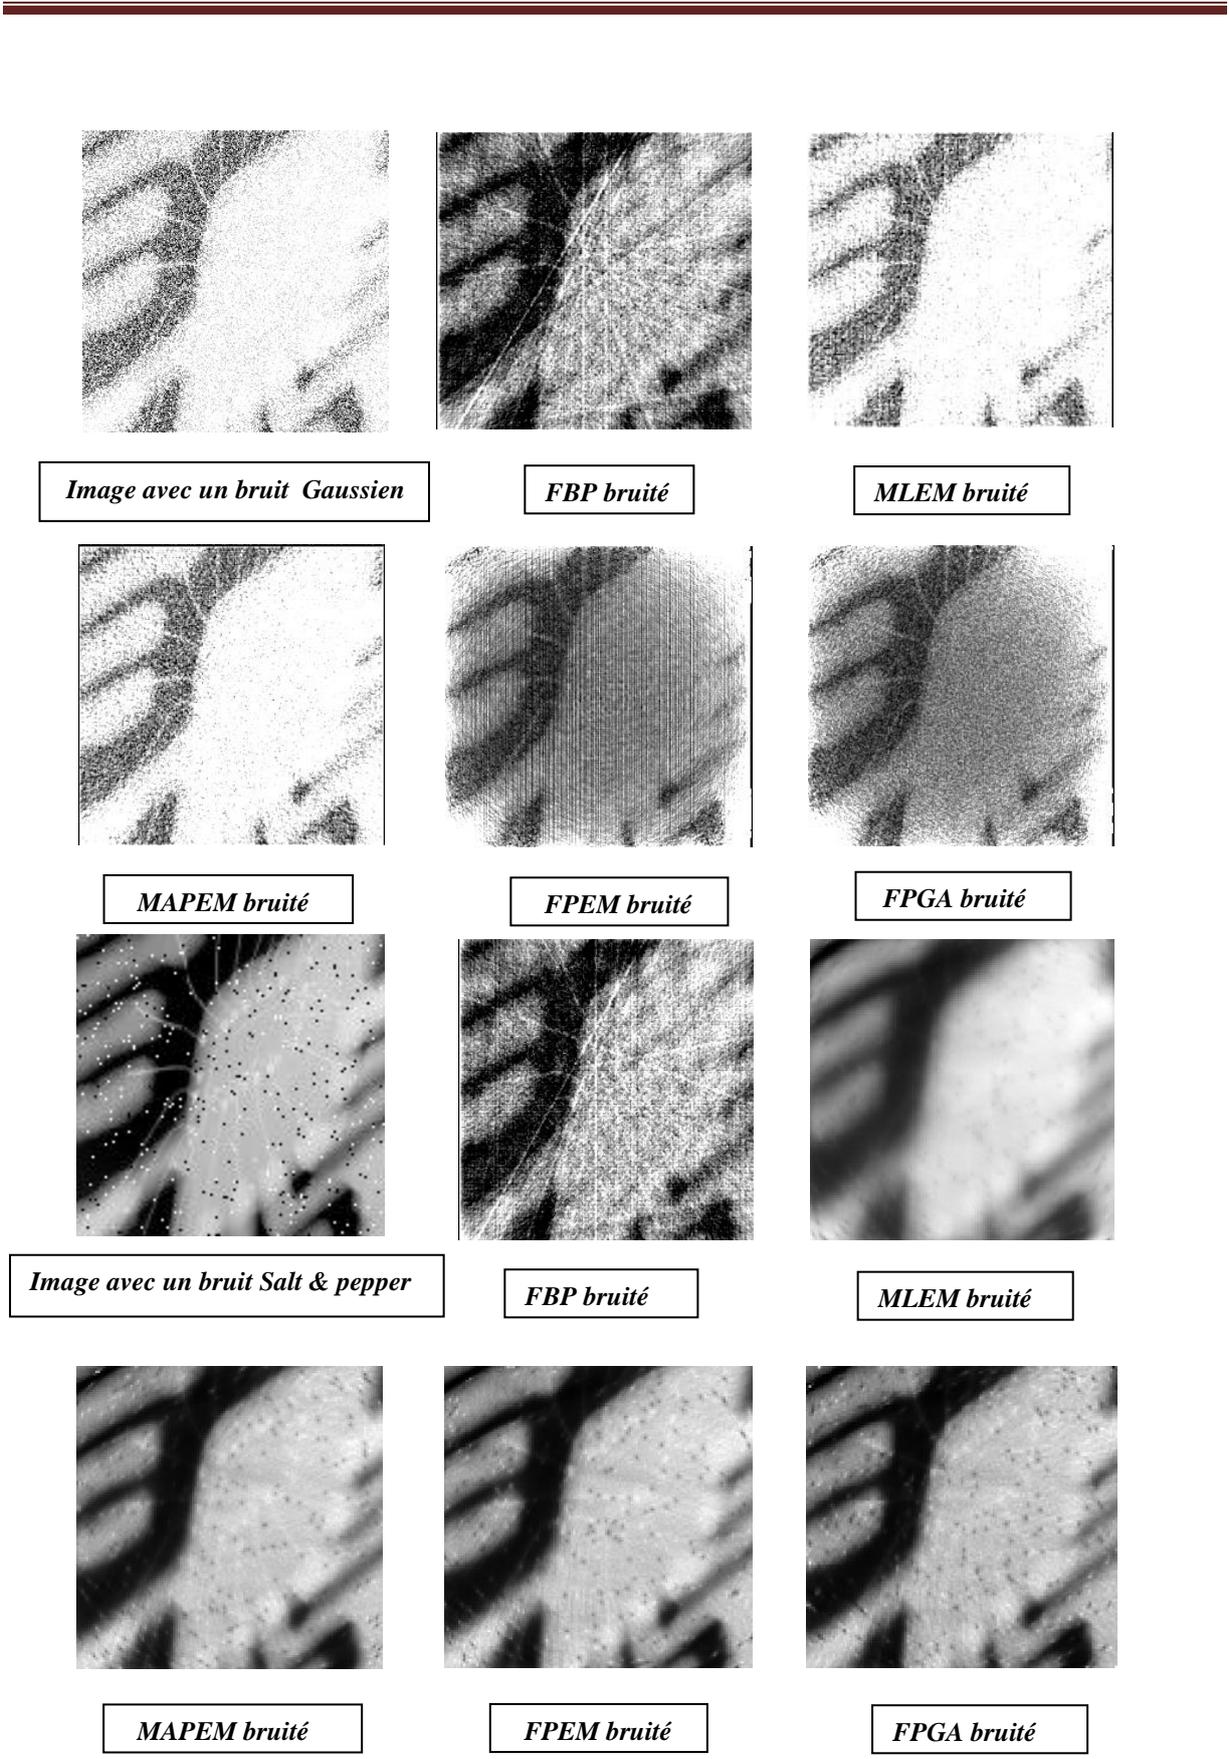
*MAPEM*



*FPEM*



*FPGA*



*Figure.III-4. Images Réelles reconstruites avec différents algorithmes.*

Itération	MLEM		MAPEM		FPEM		FPGA	
	SNR	MSE	SNR	MSE	SNR	MSE	SNR	MSE
20	22.949	0.0029	25.314	0.0022	27.013	0.0019	29.605	0.0015
40	24.395	0.0024	26.501	0.0020	29.314	0.0015	32.106	0.0010
60	25.411	0.0022	26.893	0.0020	29.904	0.0014	33.754	0.0008
80	26.311	0.0020	27.293	0.0018	30.805	0.0012	34.107	0.0007
100	27.070	0.0018	28.697	0.0016	31.761	0.0010	35.894	0.0005

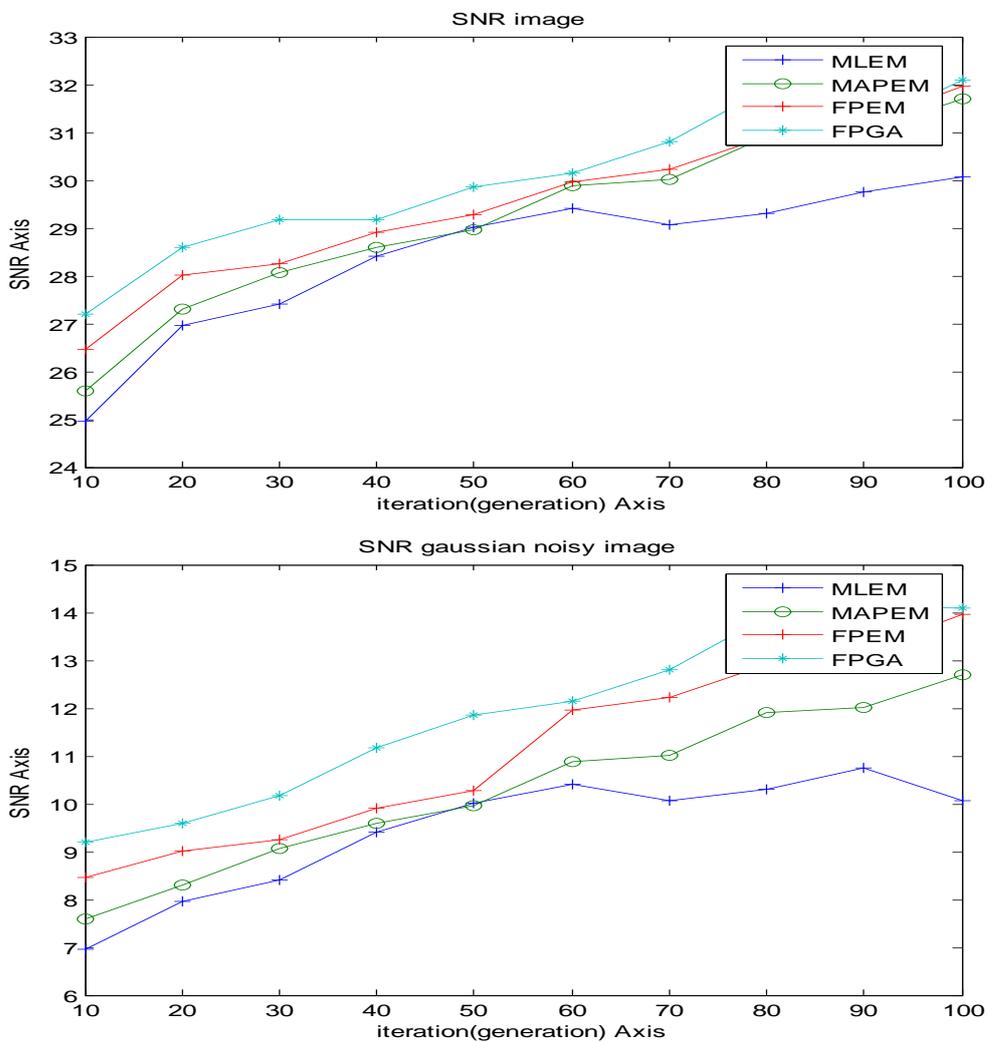
*Tableau récapitulatif des résultats quantitative de simulation pour l'images Réelles de cellule solaire*

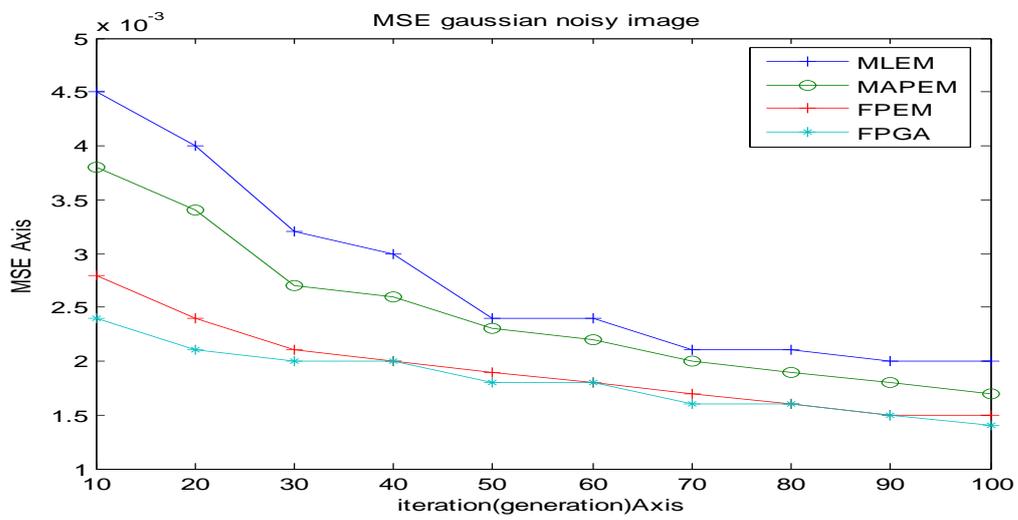
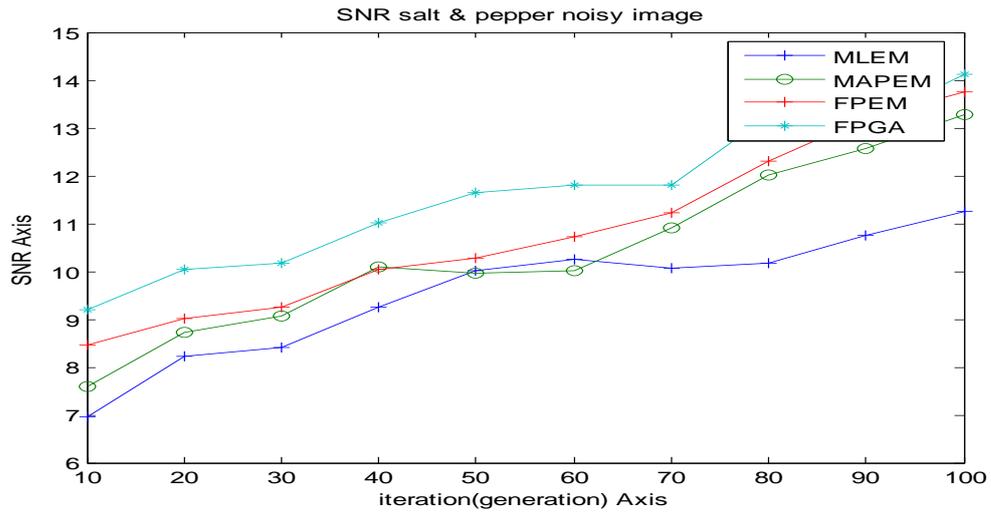
Itération	MLEM		MAPEM		FPEM		FPGA	
	SNR	MSE	SNR	MSE	SNR	MSE	SNR	MSE
20	8.062	0.0040	8.907	0.0034	9.349	0.0024	12.413	0.0021
40	9.171	0.0030	9.475	0.0026	13.007	0.0020	13.519	0.0020
60	9.810	0.0024	10.915	0.0022	14.341	0.0018	14.961	0.0018
80	9.008	0.0029	11.767	0.0021	15.637	0.0017	16.719	0.0016
100	8.854	0.0034	12.851	0.0020	16.345	0.0016	18.347	0.0014

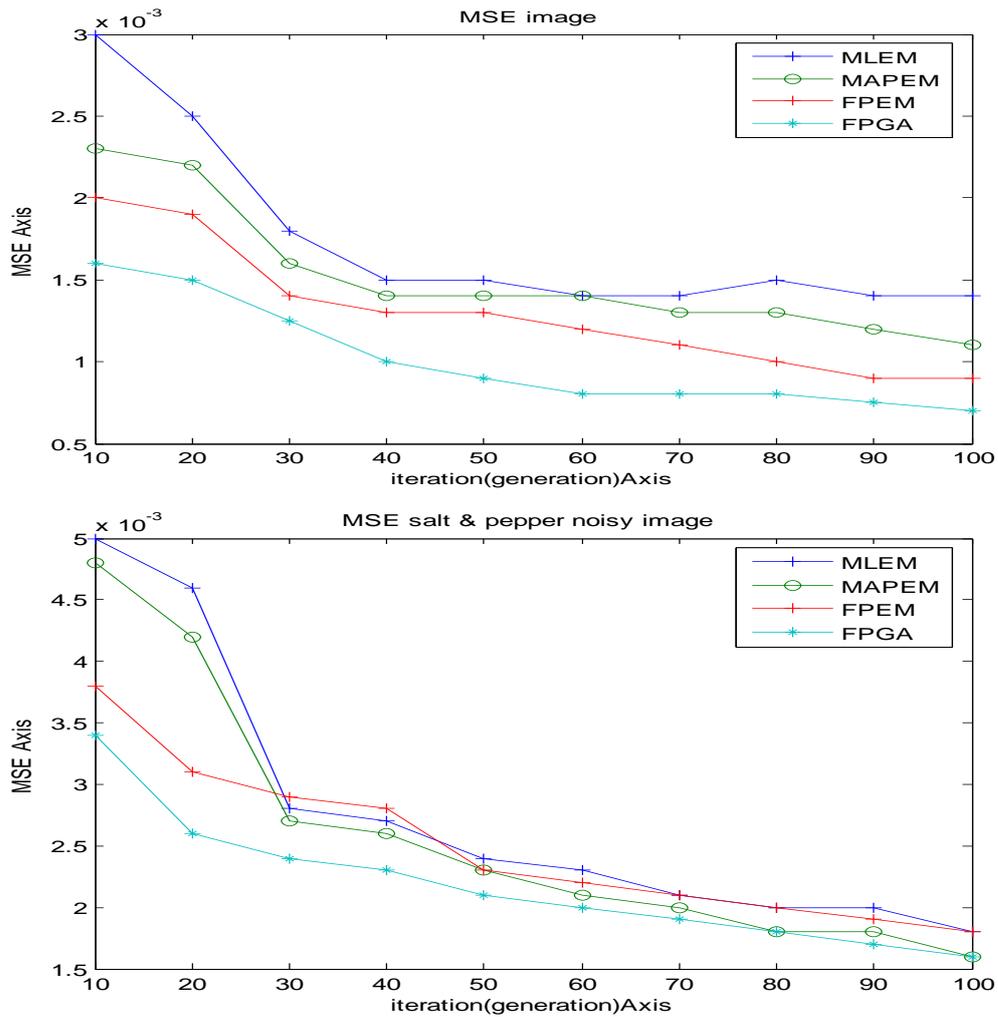
*Tableau récapitulatif des résultats quantitative de simulation pour l'images Réelles de cellule avec un bruit gaussien*

Itération	MLEM		MAPEM		FPEM		FPGA	
	SNR	MSE	SNR	MSE	SNR	MSE	SNR	MSE
20	7.212	0.0055	8.734	0.0042	9.008	0.0031	11.034	0.0026
40	10.213	0.0027	10.092	0.0026	10.050	0.0028	13.007	0.0023
60	10548	0.0023	11.913	0.0021	10.718	0.0022	13.607	0.0020
80	12.163	0.0020	13.569	0.0018	12.304	0.0020	14.253	0.0018
100	13.260	0.0018	14.264	0.0016	13.750	0.0018	15.109	0.0015

*Tableau récapitulatif des résultats quantitative de simulation pour l'images Réelles de cellule solaire avec un bruit de salt & Pepper*







**Figure.III-5. SNR et MSE pour MLEM, MAPEM, FPEM ET FPGA pour l'image de cellule et l'image de cellule bruitée.**

Iteration(generation)	MLEM	MAPEM	FPEM	FPGA
20	67.22	258.75	293.76	53.54
40	139.08	577.68	612.45	109.23
60	221.10	893.92	936.00	166.55
80	289.37	1195.62	1275.21	210.82
100	<b>346.39</b>	<b>1467.52</b>	<b>1580.80</b>	<b>264.33</b>

**Tableau . III-2. Temps CPU en second après N itérations pour MLEM, MAPEM, FPEM et FPGA, taille de l'image 256x256.**

---

### **III.5.4. Conclusion**

Nous avons introduit un nouvel algorithme itératif combiné qui exploite le raisonnement flou pour régulariser en termes de pénalité le bruit dans l'image du problème des appareils de mesures et aux problèmes d'échantillonnage, et qui s'accumule pour les méthodes itératives régularisées (MLEM, OSEM...) quand le nombre d'itérations augmente.

L'introduction de l'optimisation génétique minimise le coût en calcul des méthodes itératives en général algébrique ou statistique. En plus elle donne une solution globale et non locale au problème inverse. Les résultats de la combinaison de ces deux méthodes intelligentes sont encourageant spécialement quand le nombre et les angles des projections sont limités.

---

# Conclusions et perspectives

---

## **CONCLUSION ET PERSPECTIVE**

### **Conclusion**

Nous avons utilisé, deux outils, l'inférence floue et l'optimisation par l'algorithme génétique pour résoudre le problème inverse de reconstruction en imagerie. Il reste cependant quelques difficultés pour l'utilisation de cet algorithme qui sont à la fois d'ordre pratique (le choix de l'a priori dans un problème réel) et algorithmique (type de croisement et de mutation), et qui doivent être résolues pour une utilisation courante de la méthode. Cependant, dans des situations où les méthodes classiques ne peuvent qu'échouer, notre méthode fournit des résultats très intéressants.

Les informations apportées par l'inférence floue sont meilleures que celles apportées par l'inférence bayassienne car elle élimine le bruit et préserve les bords de l'image. Les algorithmes évolutionnaires convergent rapidement vers le minimum global et évitent les minimas locaux pièges des méthodes classiques et donc donnent de bons résultats et un faible coût en calculs.

Le modèle d'inférence flou approxime réellement la correction nécessaire pour le lissage de l'image, néanmoins il ne peut pas garantir l'obtention de la solution optimale. Les techniques évolutionnaire peuvent atteindre rapidement une bonne solution globale sans avoir besoin d'une grande mémoire ou des capacités de calculs élevées.

Le logiciel Matlab comme outil de programmation est très performant pour réaliser ces fonctions.

Enfin, les résultats présentés dans ce travail confirment nos hypothèses théoriques et on a montré que l'implémentation de l'algorithme FPGA avec un a priori flou est vraiment efficace dans le cas de données tomographiques limitées. Ceci peut être considéré comme un nouveau et important apport pour l'utilisation et l'implémentation de l'algorithme FPGA (au delà de sa propriété de convergence rapide) pour la reconstruction d'images dans le cas de données tomographiques limitées.

Les résultats simulés sont vraiment encourageants spécialement quand le nombre et les angles des projections sont limités. Quelques comparaisons avec les méthodes classiques ont montré les performances des méthodes proposées.

---

## **Perspectives**

La Perspective de ce travail reste l'optimisation par essaim de particule (PSO)- particle swarm- de la pénalité floue pour la reconstruction d'images à partir de projections dans la tomographie intelligent à rayon-x (FPPSO) ainsi que la reconstruction 3D d'images. Le regroupement Flou (Fuzzy Means Clustering) FCM/ et le regroupement PSO appliqué a la méthode OSEM.

---

# REFERENCES

# BIBLIOGRAPHIQUES

---

## **Publications de l'auteur**

### **Journal International (1)**

\*A.M.T.Gouicem, khier benmahammed, Radouane Draï, Mostapha Yahï, Abdelmalik Taleb-Ahmed "Multi-objective G-A Optimization of Fuzzy Penalty for Image Reconstruction from Projections in X-Ray Tomography", Digital Signal Processing Elsevier, vol 22 No 3 pp 486-596, 2012.

### **Conférences Internationales (2)**

\* A.M.T.GOUICEM, R. DRAI, M.YAHI. "Optimisation par algorithme génétique de la pénalité floue pour la reconstruction d'image en tomographie -X ", Première conférence internationale sur les systèmes électroniques ' ICKDD 11-14, Décembre 2008, ORAN WITH IOWA INSTITUTE USA.

\*A.M.T.GOUICEM , R.DRAI, M.YAHI, "MULTIOBJECTIF GA OPTIMIZATION OF THE FUZZY PENALTY FOR IMAGE RECONSTRUCTION FROM PROJECTION IN XRAY TOMOGRAPHY", "The 9<sup>th</sup> European Conference For IEEE en MIC medical image conference", du 25-29 February 2008, DRESDEN (GERMANY).

### **Conférences Nationales (2)**

\*A.M.T.GOUICEM, R. DRAI, M.YAHI. "JOURNEE D'ETUDE SUR LES PROBLEME INVERSE", LE CENTRE DE RECHERCHE CSC EN COOPERATION AVEC LE LABO DES MATHS APPLIQUEE UNIV D'ANNABA. MARS 2009

\*A.M.T.GOUICEM, R. DRAÏ, M.YAHI."Reconstruction d'Image 3D en Tomography ", 5th Nuclear and Particle Physics conference NUPPAC'05". BEJAIA-23 octobre 2008.

---

## BIBLIOGRAPHIE

- [1] A.M.Djafari, "A full Bayesian approach for Inverse problems", Kluwer Academic Publishers, New Mexico, USA, 135–143(1996).
- [2] A.M.Djafari, "Joint Estimation of parameters and hyperparameters in a Bayesian approach of solving Inverse problems ", in proceedings of the international conference on image processing, Lausanne, Suisse, Vol.II, 473–477(1996).
- [3] J.A.Fessler, "Statistical image reconstruction methods for transmission tomography", Handbook of Medical Imaging, Volume 2. Medical Image Processing and Analysis, SPIE, Bellingham, pp. 1-70, 2000.
- [5] Z.Zhou, R.M.Leahy, J. Qi, "Approximate maximum likelihood hyperparameter estimation for Gibbs prior ", IEEE Trans. on Image Proc. Vol.6, No.6, pp.844-861, June, 1997.
- [6] J.Besag, "Spatial interaction and the statistical analysis of lattice systems ", J.I. of Royal Stat. Soc. B, Vol.36, pp. 192-236, 1974.
- [7] D.Ville, M.Nachtegael, D.V.D.Weken, E.E.Kerre, W.Philips, I.Lemahieu, "Noise reduction by fuzzy image filtering", IEEE Trans Fuzzy Syst, 11:429-435, 2003.
- [8] X.Duan, Li.Zhang, Y.Xing, Z.Chen, J.Cheng, "Few-View Projection Reconstruction With an Iterative Reconstruction-Reprojection Algorithm and TV Constraint", IEEE transaction on nuclear science, vol 56.no3,june2009.
- [9] W.Li and L.Wang, "Predictor-Corrector Method for Total Variation Based Image Denoising", Journal of Information and Computing Science Vol. 1, No. 1, pp. 29-36, 2006.
- [10] M.a Jianhua, Q.Feng, Y.Feng, J.Huang, W.Chen "Generalized Gibbs priors based positron emission tomography reconstruction", Elsevier Computers in Biology and Medicine, 2010.
- [11] J.M.M.Anderson, R.Srinivasan, B.A.Mair, J.R.Votaw "Accelerated penalized weighted least-squares and maximum likelihood algorithms for reconstructing transmission images from PET transmission data", IEEE Trans Med Imag 24:337-351, 2005.
- [12] P.P.Mondal, K.Rajan, "Iterative image reconstruction for emission tomography using fuzzy potential", IEEE trans Image and signal process 0-7803-8700-7, 2004.
- [13] S.A.Qureshi, SM.Mirza and M.Arif, "Determination of Optimal Number of Projections for Parallel-Ray Transmission Tomography using Hybrid Continuous Genetic Algorithm", International Journal of Imaging Systems and Technology, in Process, 2006.
- [14] T. Günel and S. Kent, "Genetic approach for the determination of object parameters from x ray projections," Elektrik. 6, 277-286, 1996.

- 
- [15] R.Salomon, "Evolutionary Algorithms and Gradient Search: Similarities and Differences", IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION, VOL. 2, NO. 2, JULY 1998.
- [16] R.J.Murphy, "Pose Estimation of Known Objects during Transmission Tomographic Image Reconstruction", IEEE TRANSACTIONS ON MEDICAL IMAGING, VOL. 25, NO. 10, OCTOBER 2006.
- [17] L.A.Zadeh, "Fuzzy sets. Information and Control", 8:338-353, 1965.
- [18] J.H.Holland, Adaptation in natural and artificial systems, University of Michigan Press, Ann Arbor, MI,1975.
- [19] J.H.Holland, "Outline for logical theory of adaptive systems", J. ACM. No.3, 297-314, 1962.
- [20] H.Kudo, T.Rodet, F.Noo, M.Defrise,"Exact and approximate algorithms for helical cone-beam CT", COMPUTATIONAL METHODS IN SCIENCE AND TECHNOLOGY, 67-77, April 27, 2004.
- [21] A.van den bos, "PARAMETER ESTIMATION FOR SCIENTISTS AND ENGINEERS Evolution", John Wiley & Sons Ltd, 2007.
- [22] P.Siarry, "Optimization in Signal and Image Processing", John Wiley & Sons Ltd, 2009.
- [23] C.Solomon, T.Breckon, "Fundamentals of Digital Image Processing", first published, by John Wiley & Sons, Ltd, 2011.
- [24] J.Ma, "Applied Bayesian Modeling and Causal Inference from Incomplete-Data Perspectives", John Wiley & Sons Ltd, 2010.
- [25] R.Zdunek, "Multigrid Regularized Image Reconstruction for Limited-Data Tomography" Computational Methods in Science and Technology 13(1), 67-77, 2007.
- [26] J.Ma, "On Iterative Bayes Algorithms for Emission Tomography", IEEE TRANSACTIONS ON NUCLEAR SCIENCE, VOL. 55, NO. 3, JUNE 2008
- [27] L.Shepp, "Statistical thinking: From Tukey to Vardi and beyond", IMS Lecture Notes-Complex Datasets and Inverse Problems: Tomography, Networks and Beyond Vol. 54 268–273, 2007.
- [28] J.Qi,"Maximum-Likelihood Estimation of Detector Response for PET Image Reconstruction", Proceedings of the 28th IEEE EMBS Annual International Conference New York City, USA, Aug 30-Sept 3, 2006.
- [29] P.J.Green, "Bayesian reconstruction from emission tomography data using a modified EM algorithm", IEEE Trans. on Med. Img., vol.9, No.1, March 1990.

- 
- [30] J.Ma, "AN ITERATIVE BAYES ALGORITHM FOR EMISSION TOMOGRAPHY USING A SMOOTHED SINOGRAM", IEEE 0-7803-9577-8/06, 2006.
- [31] F.Russo, "Fuzzy Filtering of Noisy Sensor Data" In Proc. of the IEEE Instrumentation and Measurement Technology Conference, Brussels,Belgium, 4-6 June 1996, pp. 1281-1285
- [32] F.Russo, "Recent Advances in Fuzzy Techniques for Image Enhancement" IEEE Transactions on Instrumentation and Measurement, Vol. 47, No. 6, Dec. 1998, pp. 1428-1434
- [33] J.J. Buckley, "Fuzzy Probabilities", Springer-Verlag Berlin Heidelberg, 2005, Printed in Germany
- [34] W.A.Deabes, M.A.Abdelrahman", A nonlinear fuzzy assisted image reconstruction algorithm for electrical capacitance tomography ", ISA Transactions, Elsevier, 2010.
- [35] D.E.Goldberg, "Genetic algorithms in search, optimization and machine learning", Addison-Wesley, Reading Massachusetts, 1989.
- [36] B.M.Wilamowski, J.d.Irwin, "Intelligent systems", Taylor and Francis Group, LLC, CRC press, 2011.
- [37] J.P.Papa, L.M.G. Fonseca, A.S .L.de Carvalho, "Projections Onto Convex Sets through Particle Swarm Optimization and its application for remote sensing image restoration", Pattern Recognition, Elsevier, 2010.
- [38] S.N.Sivanandam, S.N.Deepa, "Introduction to Genetic Algorithms", ISBN 978-3-540-73189-4 Springer Berlin Heidelberg New York, 2008.
- [39] P.A.Engelbrecht, "Computational Intelligence an Introduction", ISBN 978-0-470-03561-0 Wiley, University of Pretoria South Africa, 2007.
- [40] R.Sarker, M.Mohammadian, X.Yao, "Evolutionary Optimization", Kluwer Academic Publishers, 2003.
- [41] E.M.Montes, "Constraint-Handling in Evolutionary Optimization", Springer-Verlag Berlin Heidelberg Mexico, 2009.
- [42] S.Sumathi, T.Hamsapriya, P.Surekha, "Evolutionary Intelligence an Introduction to Theory and Applications with Matlab ", Springer-Verlag Berlin Heidelberg India, 2008.
- [43] P.J.Angeline, "Evolutionary optimization versus Particle Swarm Optimization: Philosophy and performance differences", Springer, pp. 601–610, 1998.
- [44] J.Kennedy and C.E.Russell, "Swarm Intelligence ", Academic Press, 2001.
- [45] M.Clerc, "Particle swarm optimization ", ISTE Ltd, 2006.
- [46] J.Koza, " Genetic programming: On the programming of computers by means of natural selection", MIT press, Cambridge, Massachusetts, 1992.

- 
- [47] M.Mitchell, "An introduction to genetic algorithms", MIT Press, Cambridge, Massachusetts, 1999.
- [48] S.N.Sivanandam, S.N.Deepa, "Introduction to Genetic Algorithms", ISBN 978-3-540-73189-4 Springer Berlin Heidelberg New York, 2008.
- [49] D.V.Arnold, "Local Performance of Evolution Strategies in the Presence of Noise", Ph.D thesis, Department of Computer Science, University of Dortmund, Germany, 2001.
- [50] M.Chukalinaa, B.Golosiob, A.Simionovicib, H.Funke, "X-ray tomography: how to evaluate the reconstruction quality? ", Spectrochimica Acta Part B 59 1755– 1758, 2004.
- [51] S.A.Qureshi, S.M.Mirza, M.Arif, "Fitness function evaluation for image reconstruction using GA for parallel ray transmission tomography", IJCSNS International Journal of Computer Science and Network Security, VOL.7 No.1, January2007.

---

## ملخص

الطرق التقليدية لإعادة بناء الصورة اصبحت شبه مستحيلة بسبب العدد المحدود للاسقاطات . من مثل هذه الطرق التقليدي نذكر الطريقة التحليلية و طريقة الاحتمالات البيزية. لهذا اقترحنا طريقة تعوض هذه الاخيرة بطريقة اتخاذ القرارات للمنطق الغامض. ثم نستخدم طريقة الخوارزميات الوراثية للحصول على الحل المثالي للإشكالية العكسية. من اجل هذا اقترحنا إدماج الطرق الذكية - المنطق الغامض معدل بطريقة ذكية أخرى والتي هي البرامج الجينية مفاتيح النص : لإعادة بناء الصورة ، المنطق الغامض ، طريقة الاحتمالات البيزية ، الطريقة التحليلية ، البرامج الجينية

## ABSTRACT

This work concerns X-ray tomography image reconstruction of an object function from few projections in Computed Tomography CT. The problem is so ill posed that no classical method can give satisfactory result. We have investigated a new combined method for penalized-likelihood image reconstruction that combines the fuzzy penalty function (FP) and GA (genetic algorithm) optimization. The proposed algorithm does not suffer from the same problem as that of ML-EM (maximum likelihood expectation maximization) algorithm, and it converges rapidly to a low noisy solution even if the iteration number is high, and gives global estimation not a local one like in classical algorithm such as gradient, to the problem of determining object parameters. The method was tested and validated on a datasets of synthetic and real image.

**Keywords:** Computed Tomography; Non Destructive Testing; Analytic estimation; Bayesian Inference and Estimation; Fuzzy Inference; Genetic Optimization.