

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj

Faculté des Sciences et de la technologie

Département Électronique 'MCIL'

Mémoire

Présenté pour obtenir

LE DIPLOME DE MASTER

Spécialité : Électronique industrielle

Par

➤ **HAMDANE ABDELKADER**

Intitulé

*Optimisation de l'estimation paramétrique optimale du modèle Autorégressif
avec Intelligence Artificielle : Approche Hybride*

Soutenu le : 25 /06/ 2024

Devant le Jury composé de :

<i>Nom & Prénom</i>	<i>Grade</i>	<i>Qualité</i>	<i>Etablissement</i>
<i>Mme. SAAD SAOUD fatma</i>	<i>Dr</i>	<i>Président</i>	<i>Univ-BBA</i>
<i>Mme. BOUDRAA khadidja</i>	<i>Dr</i>	<i>Encadreur</i>	<i>Univ-BBA</i>
<i>M. TALBI Billel</i>	<i>Dr</i>	<i>Examineur</i>	<i>Univ-BBA</i>

Année Universitaire 2023/2024

REMERCIEMENT

Au nom d'Allah le Miséricordieux

Non pas parce que la tradition veut que cette page soit présente dans cet ouvrage, mais parce que les personnes à qui nous remercions la méritent véritablement.

Tout d'abord, nous tenons à remercier notre professeur, **Mme. Boudraa Khadidja**, de nous avoir fait l'honneur de superviser notre travail. Il nous a fait part de ses suggestions et critiques pendant cette période.

Nous exprimons notre profonde gratitude envers tous les enseignants de l'Université Mohamed Elbachir El Ibrahimy, qui nous ont équipé des outils indispensables à la réussite de nos études universitaires tout au long de notre parcours.

Nous tenons également à exprimer nos remerciements et nos expressions d'appréciation et de considération à ma famille et à tous mes amis.

Enfin, je voudrais exprimer ma gratitude à tous ceux qui ont soutenu ou aidé dans ce travail.

Merci à vous tous

Listes des Figures

Chapitre 02

Fig II.1 Structure générale d'un Algorithme Génétique	8
Fig II.2 Exemple d'un chromosome en codage binaire	9
Fig II.3 Croisement uniforme en codage binaire.....	10
Fig II.4 Mutation dans le cas d'un codage binaire	10
Fig II.5 Déplacement d'une particule.....	11
Fig II.6 Organigramme du PSO.....	14

Chapitre 03

Fig III.1 Représentation temporelle du signal modèle	16
Fig III.2 Représentation temporelle du signal modèle 2.	17
Fig III.3 Organigramme de l'utilisation de l'algorithme génétique AG dans la modélisation AR.....	18
Fig III.4 Organigramme de l'utilisation de PSO dans la modélisation AR.....	19
Fig III.5 Densité spectrale de puissance du signal modèle 1 obtenue par AR-Levinson pour différentes valeurs de N (500, 250, 128, 64).....	20
Fig III.6 Densité spectrale de puissance du signal modèle 1 obtenue par AR-Levinson pour différentes valeurs du rapport SNR (100, 60, 45, 15, 0, inf).....	21
Fig III.7 (1, 2, 3,4) : Densité spectrale de puissance du signal modèle 1 obtenue par AR-Levinson pour différentes valeurs de p (3, 4,5,8).....	22
Fig III.8 (1, 2, 3, 4) : Densité spectrale de puissance du signal modèle 2 obtenue par AR-Levinson pour différentes valeurs de N (500, 250, 128, 64)....	23
Fig III.9 (1, 2, 3, 4, 5, 6) : Densité spectrale de puissance du signal modèle 2 obtenue par AR-Levinson pour différentes valeurs du rapport SNR (100, 60, 45, 15, 0, inf)....	24
Fig III.10 (1, 2, 3,4) : Densité spectrale de puissance du signal modèle 2 obtenue par AR-Levinson pour différentes valeurs de p (3, 4 ,5,8)	25
Fig. III.11 Densité spectrale de puissance du signal modèle 1 avant et après l'application de l'AG.....	27
Fig. III.12 La variation de l'erreur quadratique moyenne de l'estimation en fonction des générations.....	27
Fig. III.13 Densité spectrale de puissance du signal modèle 1 avant et après l'application de PSO	29
Fig. III.14 Vue agrandie de la figure III.10.....	29

Liste des Tableaux

Chapitre 01

Tableau I.1 Tableau comparatif entre les différentes techniques d'estimation conventionnelle	5
--	---

Chapitre 03

Tableau III. 1 Paramètres du signal modèle 1 original.....	26
Tableau III. 2 Paramètres AR estimés par Levinson du signal modèle 1	26
Tableau III. 3 Paramètres AR-Levinson optimisés avec l'AG du signal modèle 1.....	26
Tableau III. 4 Paramètres AR estimés par Levinson du signal modèle 1.....	28
Tableau III. 5 Paramètres AR-Levinson optimisés avec PSO du signal modèle 1.....	28
Tableau III. 6 tableau comparatif entre l'optimisation par AG et PSO.....	30

NOMENCLATURE

AR	: Auto-Régressif
MA	: Moyenne mobile (Moving Average)
ARMA	: Auto-Régressif à Moyenne mobile (Auto Regressive Moving Average)
a_k	: Les coefficients de la partie AR
p	: L'ordre de la partie AR
$e(n)$: Bruit blanc centré, gaussien
$H(z)$: La fonction de transfert
DSP	: Densité spectrale de puissance
$S_x(z)$: La transformée en z de la fonction de corrélation pour le modèle ARMA
R_{xx}	: La fonction d'autocorrélation
$\varepsilon(k)$: L'erreur de prédiction commise sur l'estimation
$\hat{\theta}^T$: Les paramètres estimés
N	: Le nombre d'échantillons
R	: La matrice de Toeplitz
J	: La fonction quadratique
FPE	: Erreur de prédiction finale
ρ_p	: La puissance de l'EPL pour une modélisation AR(p)
AIC	: Le critère d'AKAIKE
CAT	: Criterio Autoregressive transfer function
f_c	: Fréquence d'échantillonnage
SNR	: Rapport signal sur bruit (Signal to noise ratio)
K	: Constant de Boltzmann
T	: Température en K
Δv	: Bande de fréquence du système en Hz
r_{dd}	: Un bruit blanc, gaussien
Ab	: Un coefficient proportionnel à la variance du bruit
AG	: Algorithme Génétique
PSO	: Particle swarm optimization
Fit	: Fonction fitness
Pr	: Probabilité de sélection
P_c	: Probabilité de croisement
P_m	: Probabilité de mutation
MSE	: L'erreur quadratique moyenne de l'estimation
EPL	: Erreur de prédiction linéaire

Table des matières

Introduction Générale.....	2
Chapitre I : Analyse spectrale via l'approche paramétrique des modèles autorégressifs AR	4
I.1 Introduction.....	4
I.2 Représentation du modèle rationnel linéaire.....	4
I.3 Densité spectrale de puissance du modèle AR	4
I.4 Les techniques d'estimation conventionnelles.....	5
I.4.1 Algorithme de Burg	5
I.4.2 Algorithme de Levinson	5
I.4.3 Algorithme des moindres carrés	6
I.4.4 Choix de l'algorithme	7
I.5 Sélection de l'ordre d'un modèle ARMA	7
I.6 Conclusion	8
<i>Chapitre II L'Intelligence Artificielle dans l'Optimisation des Modèles</i>	<i>10</i>
II.1 Introduction	10
II.2 Présentation des Algorithmes d'IA pour l'Optimisation	10
II.3 Algorithmes Génétiques (GA).....	10
II.3.1 Définition.....	10
II.3.2 Les principales étapes de l'algorithmes génétique	10
II.4 Algorithme PSO	14
II.4.1 Définition.....	14
II.4.2 Construction de l'Essaim et Principe de Fonctionnement.....	14
II.4.2.1 Construction de l'Essaim.....	14
II.4.2.2 Principe de Fonctionnement	15
II.5 Conclusion	16
<i>Chapitre III : Application et Évaluation de l'Approche Hybride</i>	<i>18</i>
III.1 Introduction	18
III.2 Signaux modèles	18
III.2.1 Bruit blanc	18

III.2.2 Rapport signal sur bruit	18
III.2.3 Signal modèle 1 Somme de deux sinusoides bruitées	19
III.2.4 Signal modèle 2 Un processus transitoire d'ordre quatre(4).....	19
III.3 Les étapes de l'optimisation hybride par l'intelligence artificielle	20
III.3.1 Modèle AR	20
III.3.2 La fonction objective.....	20
III.3.3 Formulation l'optimisation de l'estimation des paramètres du modèle AR en utilisant les algorithmes génétiques AG.....	21
III.3.4 Formulation l'optimisation de l'estimation des paramètres du modèle AR en utilisant PSO.....	22
III.4 Résultats et interprétations	22
III.4.1 Densité spectrale de puissance (DSP) estimée par Levinson	22
III.4.1.1 Signal modèle 1	22
III.4.1.2 Signal modèle 2.....	26
III.4.2 Application des procédures des AG aux signaux modèles	29
III.4.3 Application des procédures des PSO aux signaux modèles	31
III.5 Comparaison entre l'optimisation par Algorithme Génétique (AG) et l'Optimisation par Essaim Particulaire (PSO) dans l'estimation de modèle AR-Levinson.....	33
III.6 Conclusion.....	33
Conclusion Générale	34
Bibliographie	35

Introduction Générale

Les avancées scientifiques et technologiques ont considérablement amélioré notre capacité à prévoir divers phénomènes grâce à l'analyse des séries temporelles, essentielles en physique, finance, médecine, et autres domaines. Une série chronologique, suite de données indexées par le temps, permet de modéliser et d'interpréter des phénomènes physiques complexes. L'analyse spectrale, technique clé pour décrire ces signaux dans le domaine des fréquences, a été renforcée par les travaux de Box et Jenkins en 1970 [1]. Ils ont démontré l'efficacité des modèles autorégressifs (AR), moyenne mobile (MA) et (ARMA) pour le traitement des signaux, particulièrement utile pour la surveillance et le diagnostic des machines dans les centrales énergétiques.

Du point de vue de la modélisation paramétrique, une variété d'algorithmes conventionnels pour l'estimation des paramètres des modèles AR ont été développés. Parmi ces algorithmes figurent les techniques de Burg, Levinson et les Moindres Carrés (LS). Ces méthodes peuvent être coûteuses en calcul et nécessitent l'estimation des coefficients de nombreux modèles AR possibles [2].

Les algorithmes évolutifs, tels que les algorithmes génétiques (GA) et l'optimisation par essaim particulaire (PSO), offrent une alternative puissante pour résoudre les problèmes d'optimisation. Les GA, inspirés par les mécanismes de la sélection naturelle, et le PSO, inspiré par le comportement des essaims, sont capables de trouver des solutions optimales de manière efficace et avec un taux de convergence rapide [3]. Ce mémoire est structuré en trois chapitres :

Chapitre 1 : Étude du modèle rationnel linéaire et estimation des paramètres à l'aide d'algorithmes conventionnels tels que Burg, Levinson et les Moindres Carrés (LS).

Chapitre 2 : Présentation des fondements théoriques des algorithmes génétiques et de l'optimisation par essaim particulaire.

Chapitre 3 : Nous proposons de revoir l'algorithme conventionnel pour l'estimation du modèle AR, puis d'analyser l'impact de divers paramètres sur les résultats obtenus. Ensuite, nous appliquerons les algorithmes génétiques et le PSO pour affiner cette estimation. Nous réaliserons des tests de performance sur des signaux modèles afin de comparer l'efficacité de ces techniques évolutives par rapport aux méthodes conventionnelles.

Chapitre I

Chapitre I : Analyse spectrale via l'approche paramétrique des modèles autorégressifs AR

I.1 Introduction

La méthode de l'analyse spectrale utilisant les modèles AR, MA et ARMA est sans aucun doute la plus réputée parmi les techniques paramétriques à haute résolution en traitement du signal. Elle permet de représenter l'ensemble de l'information spectrale avec un nombre limité de paramètres. De nombreux travaux ont été spécifiquement consacrés au modèle AR [4].

Dans ce chapitre, nous aborderons les concepts d'analyse spectrale basés sur les méthodes paramétriques du modèle AR ainsi que les techniques conventionnelles d'estimation des paramètres de ce modèle.

I.2 Représentation du modèle rationnel linéaire

Un modèle AR (p) (Auto-Regressive) utilise les valeurs passées d'une série temporelle pour prédire ses valeurs futures. L'équation générale d'un modèle AR(p) est [5] :

$$x_t = \sum_{k=1}^p a_k x_{t-k} + e_t \quad (1)$$

Où les a_k sont les coefficients de partie AR, et où e_t est un bruit blanc centré, gaussien, de moyenne nulle et de variance σ_e^2 . La fonction de transfert est donnée par l'expression :

La fonction de transfert $H(z)$ est le rapport de la sortie $X(z)$ à l'entrée $e(z)$:

$$H(z) = \frac{1}{1 - \sum_{k=1}^p a_k z^{-k}} \quad (2)$$

I.3 Densité spectrale de puissance du modèle AR

Pour obtenir la DSP, nous évaluons la fonction de transfert sur le cercle unité en remplaçant z par $e^{j2\pi f}$. Ainsi, la fonction de transfert devient :

$$H(e^{j2\pi f}) = \frac{1}{1 - \sum_{k=1}^p a_k e^{-j2\pi f k}} \quad (3)$$

La DSP du modèle AR(p) se traduit par la formule suivante [4-6] :

$$S_x(f) = \sigma^2 \left| \frac{1}{1 - \sum_{k=1}^p a_k e^{-j2\pi k f}} \right|^2 \quad (4)$$

I.4 Les techniques d'estimation conventionnelles

I.4.1 Algorithme de Burg

C'est un algorithme récursif en ordre qui minimise par rapport aux coefficients de réflexion la puissance des erreurs de prédiction directe et rétrograde. On a [4, 5] :

$$e_k^f(n) = x(n) + \sum_{m=1}^k a_k[m] x(n-m) = e_{k-1}^f(n) + k_k e_{k-1}^b(n-1) \quad (5)$$

$$e_k^b(n) = x(n-k) + \sum_{m=1}^k a_k^*[m] x(n-k+m) = e_{k-1}^b(n-1) + k_k^* e_{k-1}^f(n) \quad (6)$$

On cherche à minimiser :

$$\rho_k = \frac{1}{2}(\rho_k^f + \rho_k^b) = \frac{1}{2} \sum_{n=k}^{N-1} |e_k^f(n)|^2 + |e_k^b(n)|^2 \quad (7)$$

Si l'on suppose connus $\{k_1, k_2, \dots, k_{k-1}\}_{k=0,1,\dots,p}$ alors ρ_k ne dépend que de k_k . On a donc :

$$k_k = \frac{-2 \sum_{n=k}^{N-1} e_{k-1}^f(n) e_{k-1}^{b*}(n-1)}{\sum_{n=k}^{N-1} |e_{k-1}^f(n)|^2 + |e_{k-1}^b(n-1)|^2} \quad (8)$$

On en déduit :

$$\left\{ \begin{array}{l} a_k[k] = k_k \\ a_k[i] = a_{k-1}[i] + a_k[k] a_{k-1}^*[k-i] \quad i = 1, 2, \dots, k-1 \\ \rho_k = [1 - |a_k[k]|^2] \rho_{k-1} \end{array} \right. \quad (9)$$

I.4.2 Algorithme de Levinson

C'est un algorithme qui permet de résoudre en général tout système du type $Ax = B$ avec A Toeplitz, donc en particulier les équations normales de Yule-Walker [5,6]:

$$\begin{pmatrix} r_{xx}(0) & r_{xx}(-1) & \dots & r_{xx}(-p) \\ r_{xx}(1) & r_{xx}(0) & \dots & r_{xx}(-p+1) \\ \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \dots & \vdots \\ r_{xx}(p) & r_{xx}(p-1) & \dots & r_{xx}(0) \end{pmatrix} \begin{pmatrix} 1 \\ a_1 \\ \vdots \\ a_p \end{pmatrix} = \begin{pmatrix} \rho_p \\ 0 \\ \vdots \\ 0 \end{pmatrix} \quad (10)$$

Algorithme :

Initialisation :

$$\begin{aligned} a_1[1] &= -\frac{r_{xx}(1)}{r_{xx}(0)} \\ \rho_1 &= (1 - |a_1[1]|^2) r_{xx}(0) \end{aligned} \quad (11)$$

Récursion :

$$\left\{ \begin{array}{l} a_k[k] = -\frac{r_{xx}(k) + \sum_{i=1}^{k-1} a_{k-1}[i] r_{xx}(k-i)}{\rho_{k-1}} = k_k \\ a_k[i] = a_{k-1}[i] + a_k[k] a_{k-1}^*[k-i] \quad i = 1, 2, \dots, k-1 \\ \rho_k = [1 - |a_k[k]|^2] \rho_{k-1} \end{array} \right. \quad (12)$$

I.4.3 Algorithme des moindres carrés

La méthode des moindres carrés a été introduite par Karl Gauss en 1809. Elle a été à la base de toutes les méthodes d'identification et d'estimation des paramètres. Cette méthode est basée sur la minimisation d'une fonction quadratique \mathbf{J} définie comme [5] :

$$J = \sum_{t=1}^N [\varepsilon(t)]^2 \quad (13)$$

Où $\varepsilon(k)$ représente l'erreur de prédiction commise sur l'estimation.

On définit l'erreur de prédiction comme étant la différence entre la sortie du système et la sortie du modèle :

$$\varepsilon(t) = y(t) - \hat{y}(t) \quad (14)$$

Sachant que :

$$\hat{y}(t) = \hat{\theta}^T \varphi(t) \quad (15)$$

Où $\hat{\theta}^T$ représentent les paramètres estimés.

La méthode des moindres carrés est basée sur la détermination des meilleurs paramètres, c'est-à-dire ceux qui minimiseront un certain critère d'optimalité. Il représente la somme des carrés des erreurs de prédictions:

$$J_N(\theta) = \frac{1}{N} \sum_{t=1}^N [\varepsilon(t)]^2 \quad (16)$$

Avec N le nombre d'échantillons.

La minimisation du critère $J_N(\theta)$ consiste à trouver un optimum, en cherchant les valeurs de θ qui annulent sa dérivée :

$$\left[\frac{\delta J_N(\theta)}{\delta \theta} \right]_{\theta=\hat{\theta}(N)} = 0 \quad (17)$$

$$\frac{\delta J_N(\theta)}{\delta \theta} = \frac{2}{N} \left\{ \sum_{t=1}^N \varphi(t) [y(t) - \theta^T \varphi(t)] \right\}_{\theta=\hat{\theta}(N)} \quad (18)$$

On déduit la solution optimale au sens des moindres carrés de la forme suivante :

$$\hat{\theta}(N) = \left[\sum_{t=1}^N \varphi(t) \varphi^T(t) \right]^{-1} \sum_{t=1}^N \varphi(t) y(t) \quad (19)$$

Nous constatons que la matrice $(\varphi(t)\varphi^T(t))$ est grande si le nombre d'échantillons N est important. D'où le calcul de son inverse n'est pas conseillé ; pour cela on utilise l'estimation récursive des moindres carrés.

I.4.4 Choix de l'algorithme

Le Tableau I.1 montre la comparaison entre les différentes techniques d'estimations conventionnelles dont nous avons rappelé les principes ci-dessus [5, 6, 7].

Tableau I.1 Tableau comparatif entre les différentes techniques d'estimations conventionnelles

<i>Algorithmes d'estimations conventionnelles</i>	<i>Avantages</i>	<i>Inconvénients</i>
Burg	- Bonne résolution fréquentielle; réduit les erreurs à courte distance; plus robuste aux valeurs aberrantes	- Peut être plus complexe à implémenter
Levinson	- Rapide et efficace; stable; gère efficacement les modèles AR de grande dimension	- Moins robuste en présence de bruit; nécessite des hypothèses de stationnarité
moindres carrés	Simple à comprendre et implémenter; estimation sans biais si les erreurs sont gaussiennes	Sensible aux valeurs aberrantes; coûteux computationnellement pour grandes séries temporelles

- ➡ Notre choix s'est porté vers l'algorithme de Levinson pour extraire les paramètres d'un modèle AR.

I.5 Sélection de l'ordre d'un modèle ARMA

Plusieurs méthodes ont été proposées qui consistent à minimiser un critère : l'ordre choisi est celui qui minimise le critère. Ce dernier dépend en général de la puissance de l'erreur de prédiction aux différents ordres. Si l'on note $\hat{\rho}_p$ la puissance de l'EPL pour une modélisation AR(p), le premier critère utilisé est un critère d'erreur de prédiction finale FPE qui est donné par [5, 6] :

$$FPE(p) = \hat{\rho}_p \frac{N + p + 1}{N - p - 1} \quad (20)$$

Où N est le nombre d'échantillons.

Le deuxième critère est basé sur la minimisation d'une fonction d'information, noté AIC (AKAIKE information criterion).

$$AIC(p) = N \ln(\hat{\rho}_p) + 2p \quad (21)$$

Pour des enregistrements longs, le critère AIC est le plus convenable, mais pour des enregistrements courts, les critères d'AKAIKE sont identiques.

Perzen a aussi proposé un critère de sélection de l'ordre qui est noté CAT (criterio Autoregressive transfer function) exprime par [5, 6] :

$$CAT(p) = \frac{1}{N} \left(\sum_{i=1}^p \frac{1}{\hat{\rho}_i} - \frac{1}{\hat{\rho}_p} \right) \quad (22)$$

I.6 Conclusion

Il existe de nombreuses méthodes d'analyse spectrale, et le choix de la méthode dépend souvent de l'application spécifique. En général, les méthodes non paramétriques sont préférées pour les signaux longs et stationnaires, tandis que les méthodes paramétriques sont plus adaptées aux signaux courts et non stationnaires. De plus, les méthodes de modélisation AR peuvent être adaptées pour permettre une analyse de la densité spectrale de puissance du signal observé.

Chapitre II

Chapitre II L'Intelligence Artificielle dans l'Optimisation des Modèles

II.1 Introduction

L'intelligence artificielle (IA) joue un rôle crucial dans l'optimisation des modèles à travers diverses techniques et algorithmes. Parmi les méthodes les plus remarquables, on trouve les Algorithmes Génétiques (GA) et l'Optimisation par Essaim Particulaire (PSO). Ces approches d'optimisation inspirées de la nature offrent des solutions puissantes pour résoudre des problèmes complexes qui seraient difficiles, voire impossibles, à résoudre par des méthodes traditionnelles. Les fondements des algorithmes génétiques (GA) et de l'Optimisation par Essaim Particulaire (PSO) ainsi que leurs principes seront décrits en détail dans ce chapitre. [8 ,9].

II.2 Présentation des Algorithmes d'IA pour l'Optimisation

Les algorithmes d'intelligence artificielle pour l'optimisation, tels que les Algorithmes Génétiques (GA) et l'Optimisation par Essaim Particulaire (PSO), sont des outils puissants pour résoudre des problèmes complexes d'optimisation. Ces méthodes s'inspirent de processus naturels et biologiques pour explorer efficacement l'espace de solution et trouver des solutions optimales.

II.3 Algorithmes Génétiques (GA)

II.3.1 Définition

Les algorithmes génétiques (AG) appartiennent à la famille des algorithmes évolutionnaires. Introduits initialement par John Holland en 1975, ils ont été largement explorés et développés grâce aux travaux de Goldberg et De Jong. Ces algorithmes d'optimisation s'inspirent du concept de l'évolution naturelle proposé par Charles Darwin, qui consiste à « appliquer à une population des transformations afin de produire une population mieux adaptée »[10].

II.3.2 Les principales étapes de l'algorithmes génétique

Le fonctionnement d'un algorithme génétique est basé sur les étapes suivantes (Fig.1) [10,11] :

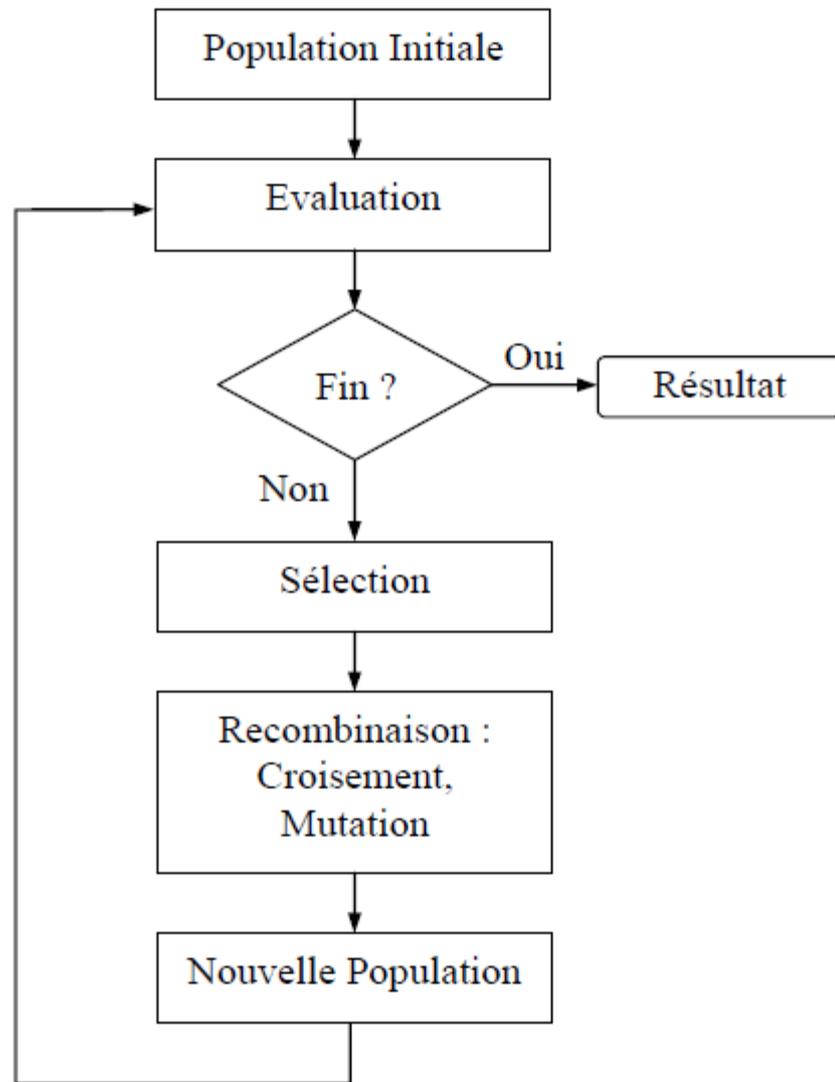


Fig.1 : Structure générale d'un Algorithme Génétique [11].

1. Création de la Population et Codage

L'algorithme génétique nécessite une représentation des individus, solutions potentielles du problème à résoudre, dont le choix est crucial. Le codage des individus, souvent en binaire, détermine la qualité de la recherche, et le choix de la taille de la population est essentiel pour éviter une recherche exhaustive ou une solution sous-optimale. La distinction entre l'espace phénotypique (où le problème est posé) et l'espace génotypique (où opèrent les opérateurs génétiques) est également fondamentale pour le succès de l'algorithme.

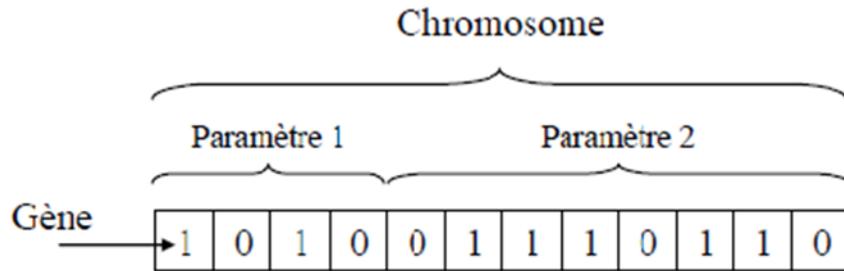


Fig.2 Exemple d'un chromosome en codage binaire

2. Évaluation de la population

L'évaluation des individus consiste à mesurer leur performance via une fonction de fitness liée à la fonction objective, maximisée par l'algorithme génétique. Pour les problèmes de maximisation, la fonction mérite peut être égale à la fonction objective, tandis que pour les problèmes de minimisation, la fonction fitness est souvent la réciproque de la fonction objective. Les algorithmes génétiques n'exigent aucune condition de dérivabilité ou de continuité, rendant cette méthode attractive pour des problèmes aux propriétés mathématiques complexes.

3. Sélection

La sélection, basée sur le principe darwinien d'évolution, vise à choisir les parents pour la reproduction en favorisant les individus les mieux adaptés. Cet opérateur identifie les individus sur la base de leur fonction de fitness, en sélectionnant les meilleurs et écartant les moins adaptés. Les méthodes de sélection les plus connues incluent la roulette et le tournoi, qui augmentent la probabilité des meilleurs individus de contribuer à la génération suivante.

4. Les Opérateurs Génétiques

Les opérateurs génétiques, principalement le croisement et la mutation, introduisent des modifications aléatoires dans la population sans garantir la génération des individus les plus adaptés. La taille de la population peut être maintenue constante ou modifiée selon la complexité du problème.

a. Croisement

Le croisement permet à un couple d'individus, parmi ceux qui sont sélectionnés, d'échanger leurs informations génétiques c-à-d leurs gènes. Son principe est simple : deux individus sont pris au hasard et sont appelés parents ; ensuite, on tire aléatoirement un nombre P dans l'intervalle $[0, 1]$ qu'on compare à une certaine probabilité de croisement P_c [10,11].

- Si $P > P_c$: Le croisement n'a pas lieu et les parents sont copiés dans la nouvelle génération.
- Si $P \leq P_c$: Le croisement se produit et les chromosomes des parents sont combinés pour créer deux enfants.

Les principaux types de croisement sont :

Croisement multipoints : Plusieurs positions de croisement sont choisies aléatoirement. Les gènes entre deux points de croisement successifs sont échangés entre les parents.

Croisement uniforme : Chaque gène peut constituer un point de croisement. Un masque aléatoire détermine de quel parent chaque gène sera hérité par l'enfant.

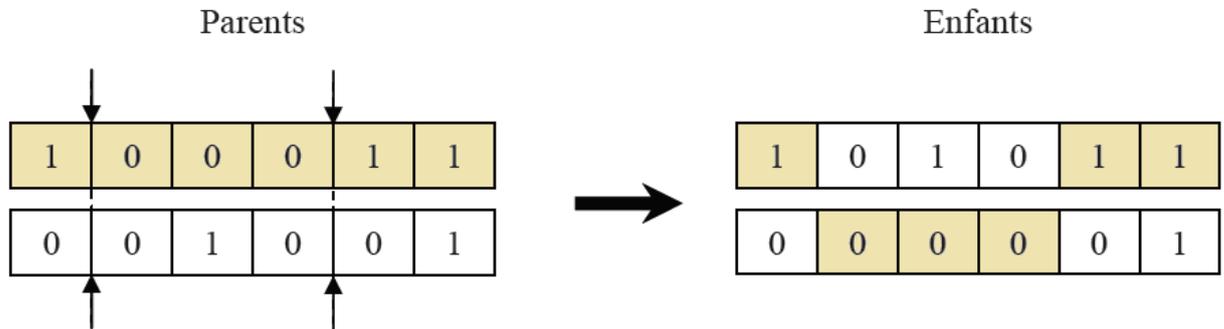


Fig .3 Croisement multipoints (P=2) en codage binaire.

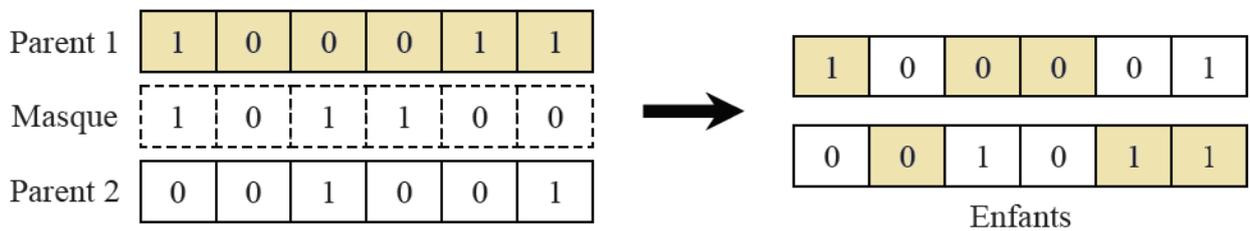


Fig . 4 Croisement uniforme en codage binaire [11].

b. Mutation

La mutation consiste à substituer aléatoirement un gène dans un chromosome par un autre, contrôlée par une probabilité de mutation assignée à chaque gène. Dans un codage binaire, la mutation change un bit aléatoirement, tandis que dans un codage réel, elle ajoute de petites valeurs aléatoires aux individus. La mutation maintient la diversité génétique, empêchant la stagnation de la recherche et assurant une exploration globale.

Mutation à valeurs réelles : Ajout de petites valeurs réelles aléatoires aux individus.

Mutation binaire : Inversion aléatoire d'un bit dans un chromosome (0 devient 1 et vice versa).

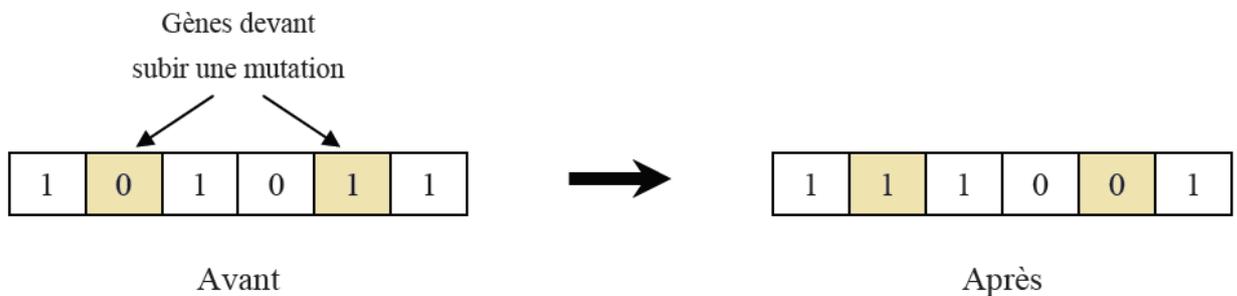


Fig .5 Mutation dans le cas d'un codage binaire [11].

5. **Répétition des étapes** : Ce processus de sélection, croisement et mutation se répète sur plusieurs générations jusqu'à atteindre un critère d'arrêt, tel qu'un nombre maximal de générations ou une convergence de la population vers une solution optimale.

II.4 Algorithme PSO

II.4.1 Définition

L'optimisation par essaim particulaire (OEP), ou Particle Swarm Optimization (PSO) en anglais, est un algorithme évolutionnaire qui exploite une population de solutions candidates pour trouver une solution optimale à un problème. Cet algorithme, proposé par Russel Eberhart (ingénieur en électricité) et James Kennedy (socio-psychologue) en 1995, s'inspire du comportement social des animaux vivant en essaim, tels que les bancs de poissons et les vols d'oiseaux. Ces animaux démontrent des dynamiques de déplacement complexes, bien que chaque individu ait une intelligence limitée et une connaissance locale de sa position dans l'essaim [12].

Chaque individu utilise son information locale et sa mémoire pour décider de ses déplacements. Des règles simples comme « rester proche des autres », « se déplacer dans la même direction » ou « aller à la même vitesse » permettent de maintenir la cohésion de l'essaim et d'aboutir à des comportements collectifs complexes et adaptatifs [12].

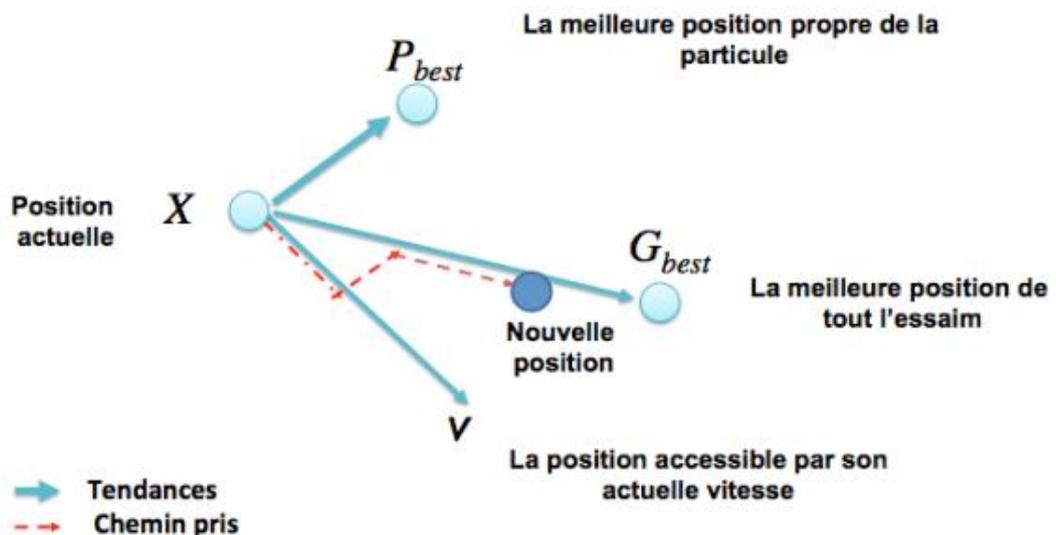


Fig II.6 Déplacement d'une particule

II.4.2 Construction de l'Essaim et Principe de Fonctionnement

II.4.2.1 Construction de l'Essaim

La première étape de l'optimisation par essaim particulaire (PSO) est la construction de l'essaim. Cette construction implique les étapes suivantes[13,14] :

a. Initialisation des Particules :

- **Population Initiale** : Une population de particules est générée avec des positions et des vitesses aléatoires dans l'espace de recherche.

- **Position** (\vec{x}_i) : Chaque particule i est placée aléatoirement dans l'espace de recherche.
 - **Vitesse** (\vec{v}_i) : Chaque particule reçoit une vitesse initiale aléatoire.
- b. Évaluation Initiale :**
- **Fonction de Fitness** (f) : La position initiale de chaque particule est évaluée à l'aide d'une fonction de fitness qui mesure la qualité de la solution représentée par la position de la particule.

II.4.2.2 Principe de Fonctionnement

Le fonctionnement du PSO repose sur l'interaction et la mise à jour continue des positions et des vitesses des particules. Le processus peut être décrit par les étapes suivantes : [13,14]

- 1. Évaluation de la Population :**
 - Chaque particule est évaluée en utilisant la fonction de fitness pour déterminer la qualité de sa position actuelle.
- 2. Mise à Jour des Meilleures Positions :**
 - **Meilleure Position Individuelle** (\vec{P}_{besti}) : Chaque particule garde en mémoire la meilleure position qu'elle a atteinte jusqu'à présent.
 - **Meilleure Position Globale** (\vec{G}_{besti}) : L'ensemble de l'essaim détermine la meilleure position trouvée par n'importe quelle particule.
- 3. Mise à Jour des Vitesses :**
 - Les vitesses des particules sont ajustées en fonction de leur position actuelle, de leur meilleure position individuelle (\vec{P}_{besti}), et de la meilleure position globale (\vec{G}_{besti}).
 - **Équation de Mise à Jour :**

$$\vec{v}_i(t+1) = \omega \cdot \vec{v}_i(t) + c_1 r_1 (\vec{P}_{besti} - \vec{x}_i(t)) + c_2 r_2 (\vec{G}_{besti} - \vec{x}_i(t)) \quad (1)$$

Où ω est le facteur d'inertie, c_1 et c_2 sont les coefficients d'accélération, et r_1 et r_2 sont des variables aléatoires.

- 4. Mise à Jour des Positions :**
 - Les positions des particules sont mises à jour en fonction de leurs nouvelles vitesses.
 - **Équation de Mise à Jour :** $\vec{x}_i(t+1) = \vec{x}_i(t) + \vec{v}_i(t+1)$ (2)
- 5. Itération :**
 - Le processus de mise à jour des vitesses et des positions se répète jusqu'à ce qu'un critère d'arrêt soit atteint (par exemple, un nombre maximal d'itérations ou la convergence de l'essaim vers une solution optimale).

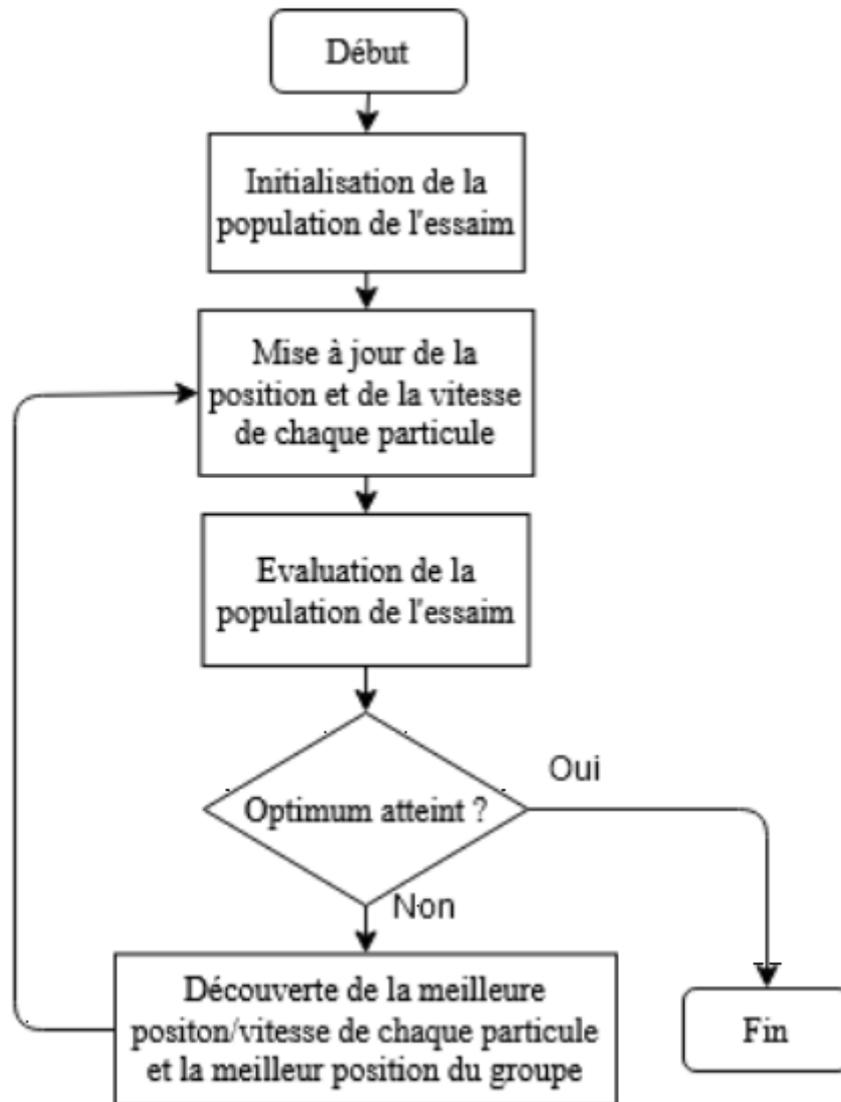


Fig II.7 Organigramme du PSO[13,14].

II.5 Conclusion

Dans ce chapitre, nous avons introduit les principes fondamentaux des algorithmes génétiques (GA) et de l'optimisation par essaim particulaire (PSO) pour résoudre des problèmes d'optimisation. Les GA utilisent des opérateurs tels que la sélection, le croisement et la mutation, et sont efficaces pour une large gamme de problèmes, même ceux sans continuité ou dérivabilité. PSO, inspiré du comportement social des essaims, met à jour les positions et vitesses des particules pour explorer l'espace de recherche de manière globale. Dans le prochain chapitre, nous appliquerons les GA et PSO pour optimiser l'estimation des paramètres d'un modèle AR, démontrant leur efficacité pratique.

Chapitre III

Chapitre III : Application et Évaluation de l'Approche Hybride

III.1 Introduction

L'objectif de ce chapitre est d'appliquer et de tester l'efficacité et les performances l'algorithme conventionnel (Levinson) pour l'estimation du modèle AR. Nous analyserons l'influence de divers paramètres tels que le rapport signal sur bruit (SNR), le nombre de points, et l'ordre (p, q) du modèle AR sur les résultats obtenus. Les tests et applications seront réalisés à l'aide d'un programme écrit sous Matlab 8.1 (R2018a), permettant l'étude et l'analyse de modèle AR ainsi que le traitement des signaux stationnaires et non stationnaires. En complément des méthodes conventionnelles, nous explorerons également l'utilisation des algorithmes génétiques (GA) et de l'optimisation par essaim particulaire (PSO) pour optimiser l'estimation des paramètres du modèle AR[15]. Ces techniques évolutives sont reconnues pour leur capacité à résoudre efficacement les problèmes d'optimisation complexes, offrant des solutions optimales avec un taux de convergence rapide. Les performances des GA et PSO seront examinés sur deux signaux modèles, permettant ainsi de comparer leur efficacité à celle des méthodes conventionnelles.

III.2 Signaux modèles

III.2.1 Bruit blanc

Le bruit blanc est un signal de valeur moyenne nulle. Son spectre en amplitude est constant. La densité spectrale du bruit blanc est constante dans la bande de fréquence $\Delta\nu$ considérée [16].

$$B(\nu) = B_0 = \frac{1}{2} kT \quad (1)$$

Avec $\left\{ \begin{array}{l} k \\ T \\ \Delta\nu \end{array} \right.$ La constante de Boltzmann
La température (en K°)
La bande de fréquence du système (en Hz)

La fonction d'autocorrélation temporelle du bruit blanc est une impulsion de Dirac :

$$C_{bb}(\tau) = B_0 \delta(\tau) \quad (2)$$

Dans notre travail, le bruit utilisé est un bruit additif généré par Matlab ; sa formule est donnée par l'expression suivante [17]:

$$e(i) = Ab \times r_{dd} \quad (3)$$

r_{dd} : Un bruit blanc gaussien.

Ab : Un coefficient proportionnel à la variance du bruit.

III.2.2 Rapport signal sur bruit

Le rapport signal sur bruit (SNR=Signal to noise ratio) est le rapport des puissances du signal P_s et du bruit P_b [16,17] :

$$SNR = \frac{P_S}{P_B} \quad (4)$$

Ou, en dB :

$$SNR_{dB} = 10 \log \left(\frac{P_S}{P_B} \right) = 10 \log \left(\frac{\sum_{i=1}^n y^2(i)}{\sum_{i=1}^n e^2(i)} \right) \quad (5)$$

$y(i)$: un signal qui sera additionné à un bruit blanc $e(i)$.

Le rapport SNR mesure donc la qualité du signal.

III.2.3 Signal modèle 1 Somme de deux sinusoïdes bruitées

Le premier modèle est un signal périodique composé de deux sinusoïdes de même amplitude et de fréquences $f_1 = 200Hz$, $f_2 = 220Hz$, $f_e = 1000Hz$ et d'un bruit blanc additif $e(t)$ [17].

$$Y(t) = \sin(2\pi 200t) + \sin(2\pi 220t) + e(t) \quad (6)$$

Le processus discret est :

$$Y(i) = \sin \left(2\pi \left(\frac{200}{f_e} \right) i \right) + \sin \left(2\pi \left(\frac{220}{f_e} \right) i \right) + e(i) \quad (7)$$

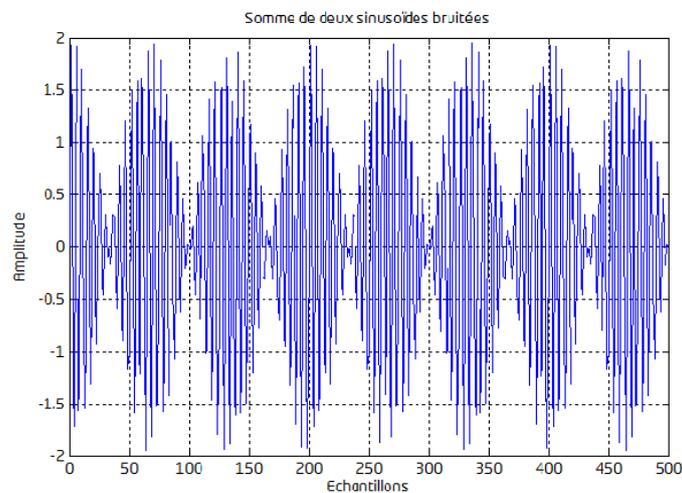


Fig III.1 : Représentation temporelle du signal modèle 1.

III.2.4 Signal modèle 2 Un processus transitoire d'ordre quatre(4)

Le deuxième modèle est un signal aperiodique, transitoire et harmonique qui se présente sous forme de battements causés par deux fréquences légèrement différentes avec la fréquence de battement égale à $f = f_1 - f_2$ [17].

$$y(i) = 2.7607y(i-1) - 3.818y(i-2) + 2.6535y(i-3) - 0.9238y(i-4) + e(i)$$

(8)

Les pôles de ce processus sont :

$$Z_1 = 0.9806e^{j0.8583} = 0.9806e^{j2\pi(0.140)}$$

$$Z_3 = 0.9802e^{j0.7163} = 0.9802e^{j2\pi(0.114)}$$

$$Z_2 = Z_1^*$$

$$Z_4 = Z_3^*$$

$$f_e = 1000, \text{ SNR} = \text{inf}, N_e = 500$$

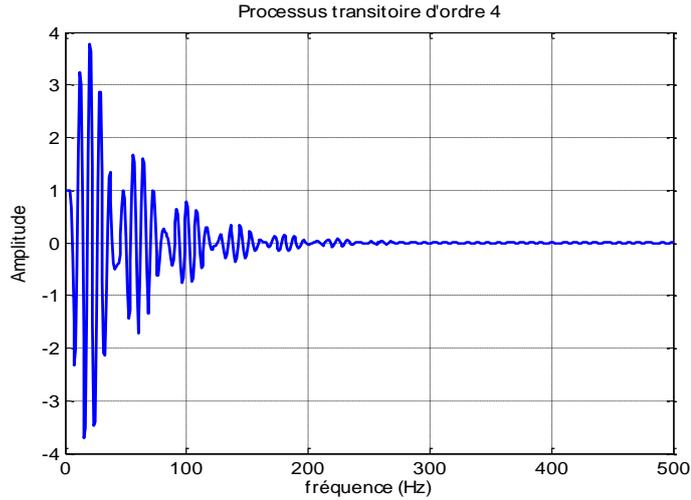


Fig III.2 : Représentation temporelle du signal modèle 2.

III.3 Les étapes de l'optimisation hybride par l'intelligence artificielle

III.3.1 Modèle AR

Considérons le processus récursif général invariant dans le temps pour le signal $y(n)$, dénommé AR (p), qui est régi par l'équation suivante :

$$y(n) = \sum_{i=1}^p a_i y(n-i) + e(n) \quad (9)$$

Où :

$y(n)$ est un signal aléatoire échantillonné.

$e(n)$ est un bruit blanc centré, gaussien, de moyenne nulle et de variance σ_e^2 .

a_i , avec $a_0 = 1$, sont les coefficients autorégressifs (AR).

p est l'ordre de modèle (AR)

III.3.2 La fonction objective

La fonction fitness est essentielle pour la convergence rapide des algorithmes d'optimisation, guidant la recherche vers la meilleure solution. Une fonction fitness mal informée ralentit la convergence, retardant la découverte de la solution optimale. En général, la fonction de fitness est conçue pour minimiser l'erreur entre les données réelles et les données modélisées

par le modèle AR. Une forme courante de la fonction de fitness est l'erreur quadratique moyenne (MSE), qui calcule la moyenne des carrés des différences entre les valeurs mesurée et les valeurs estimée par le modèle AR, peut être défini comme suit [8,11,15] :

$$MSE = \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2 \quad (10)$$

Où : $y(t)$ La réponse mesurée ; $\hat{y}(t)$ La réponse estimée.

III.3.3 Formulation l'optimisation de l'estimation des paramètres du modèle AR en utilisant les algorithmes génétiques AG

Pour estimer les paramètres du modèle AR présentée par l'équation(9), on peut utiliser l'algorithme génétique représenté sur la figure III.3 [15,18].

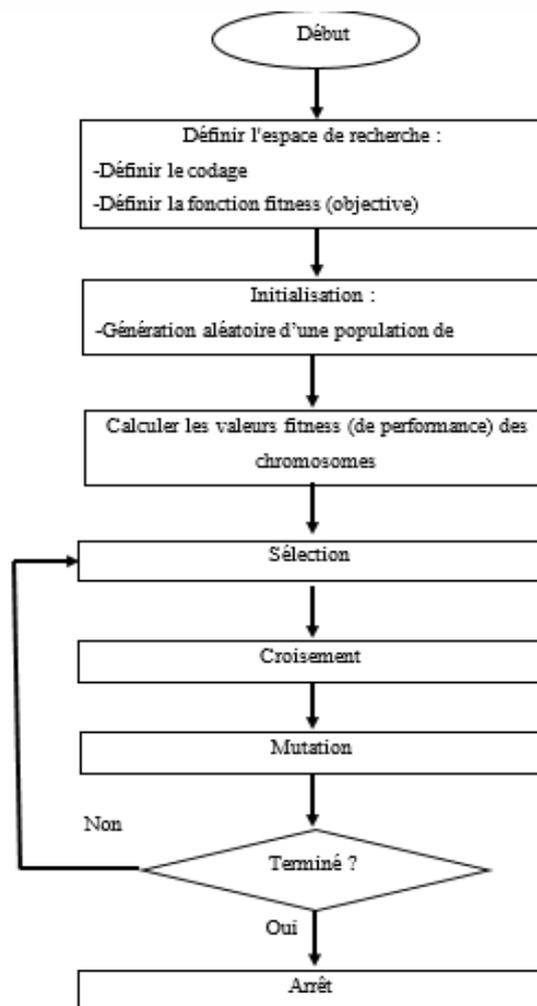


Fig III.3 Organigramme de l'utilisation de l'algorithme génétique AG dans la modélisation AR.

III.3.4 Formulation l'optimisation de l'estimation des paramètres du modèle AR en utilisant PSO

Pour estimer les paramètres du modèle AR présentée par l'équation (9), on peut utiliser le PSO représenté sur la figure III.4 [19].

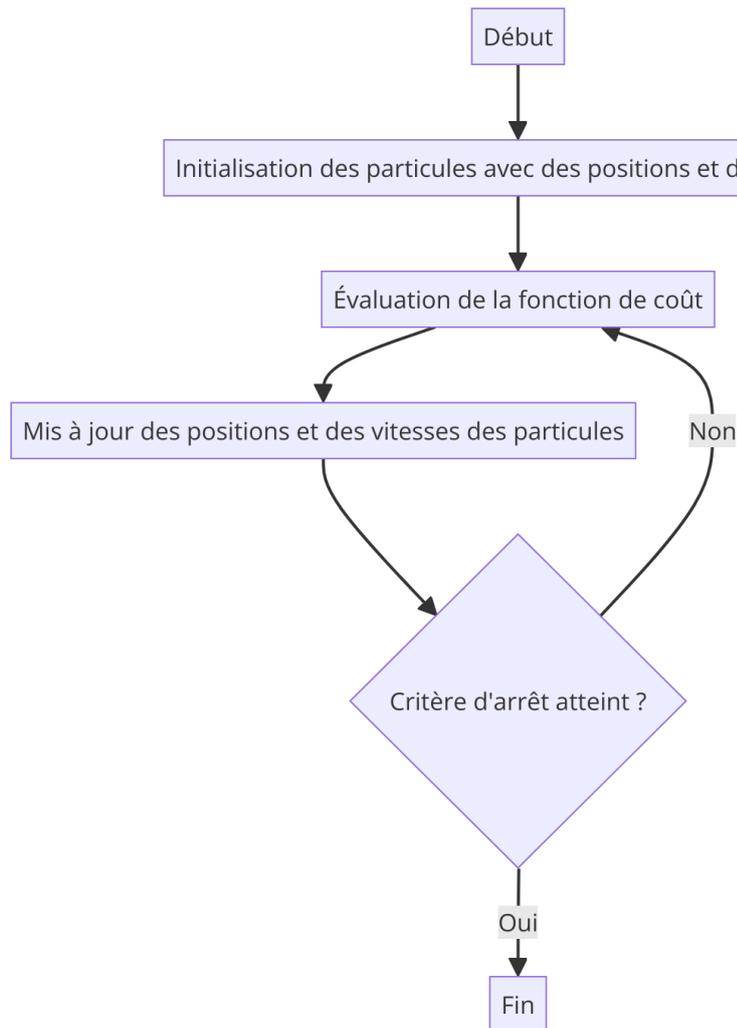


Fig III.4 Organigramme de l'utilisation de PSO dans la modélisation AR.

III.4 Résultats et interprétations

III.4.1 Densité spectrale de puissance (DSP) estimée par Levinson

III.4.1.1 Signal modèle 1

Cas 1 : Influence du nombre de points

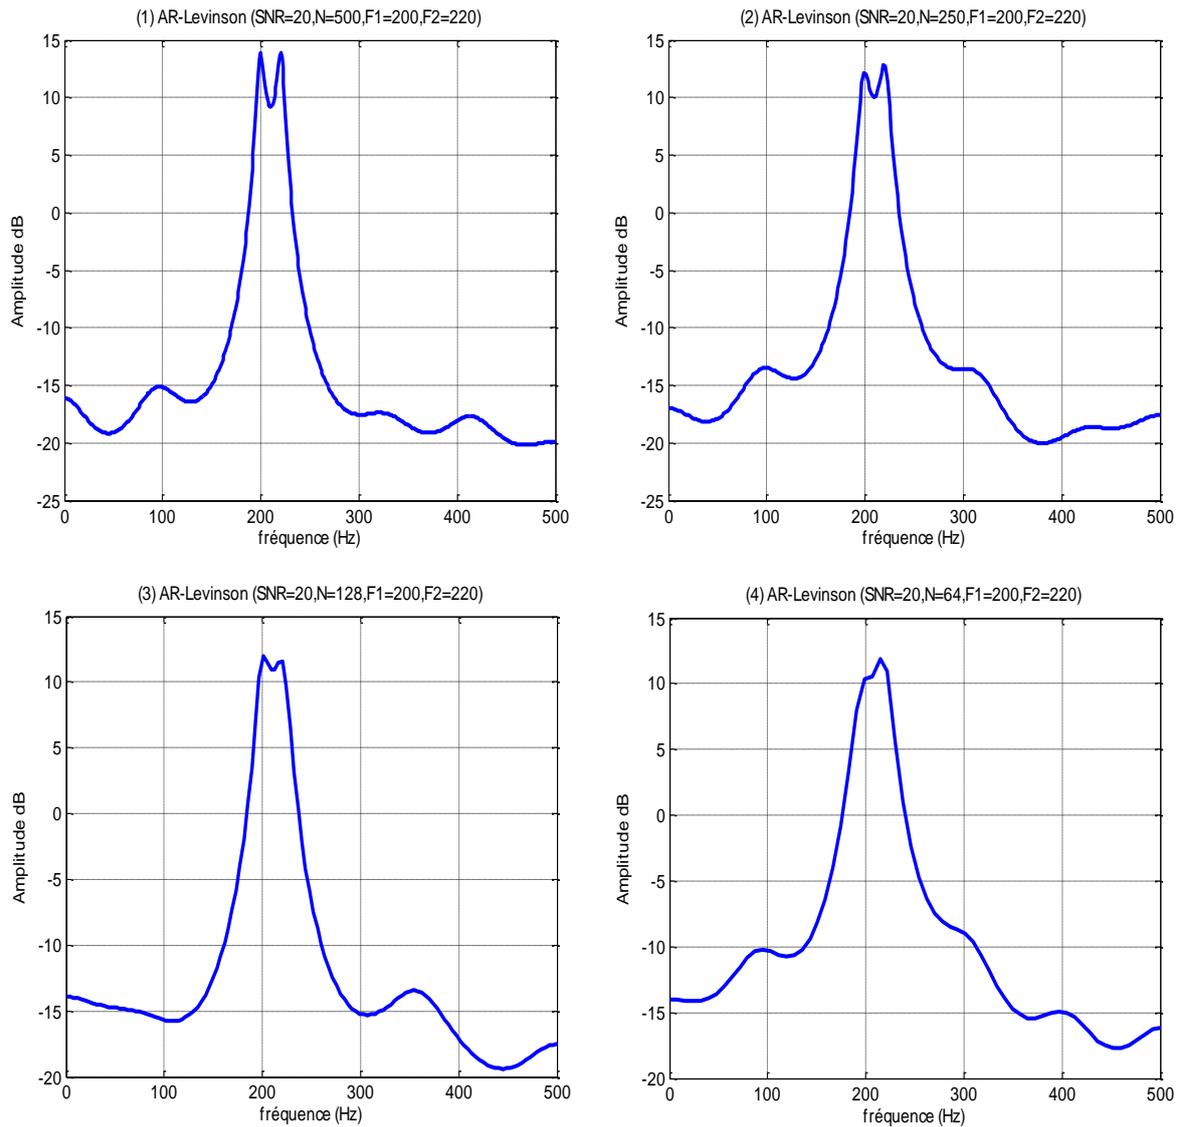


Fig III.5 (1, 2, 3, 4) : Densité spectrale de puissance du signal modèle 1 obtenue par AR-Levinson pour différentes valeurs de N (500, 250, 128, 64).

Interprétation :

La figure II.5 représente la densité spectrale de puissance du processus AR associé au signal modèle 1 obtenue par l'algorithme de Levinson. Cette figure montre l'influence du nombre de points pour l'apparition de deux pics qui correspondent aux deux fréquences f_1 et f_2 . Nous observons, d'après cette figure, que l'augmentation de nombre de points à partir de 128 peut séparer les deux pics.

Cas 2 : Influence du rapport SNR

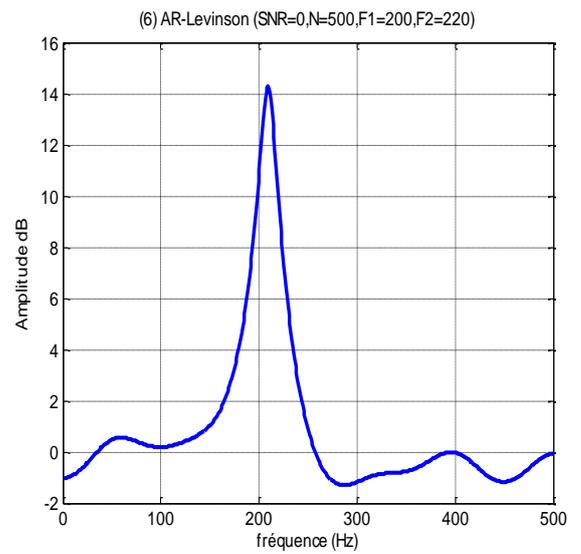
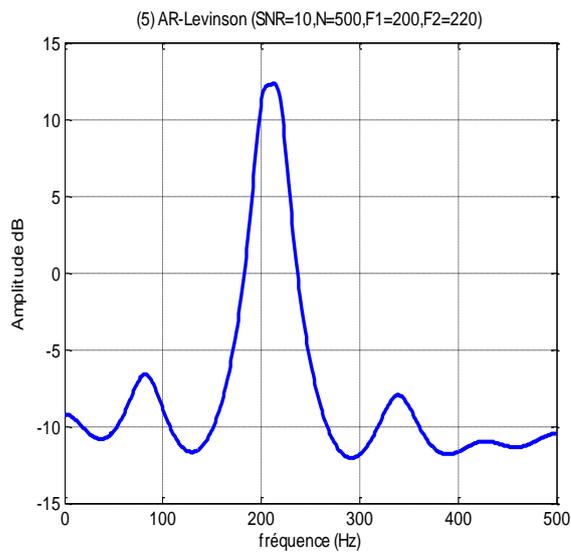
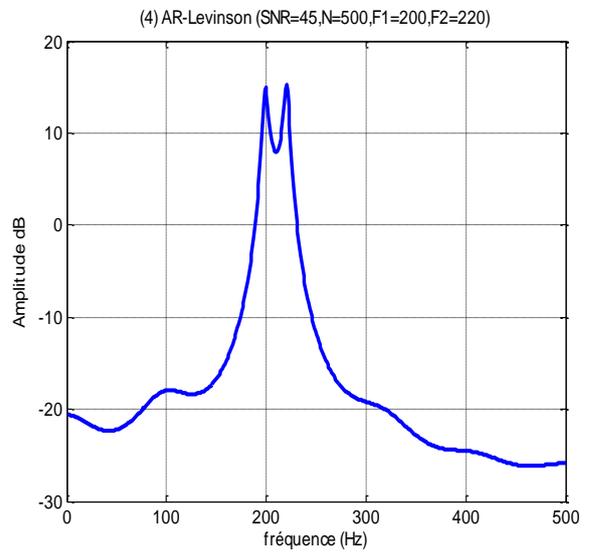
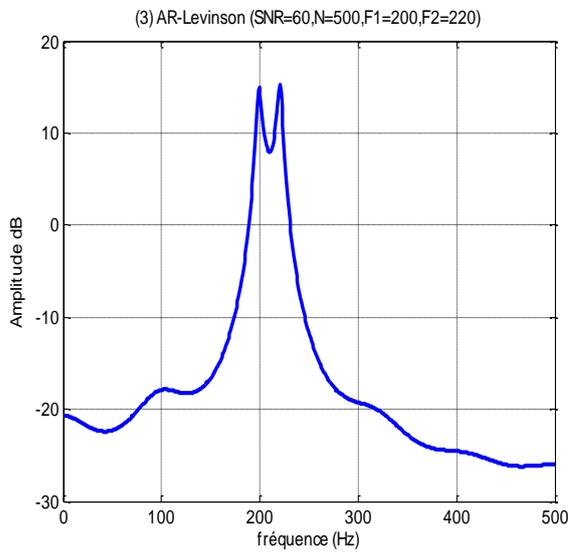
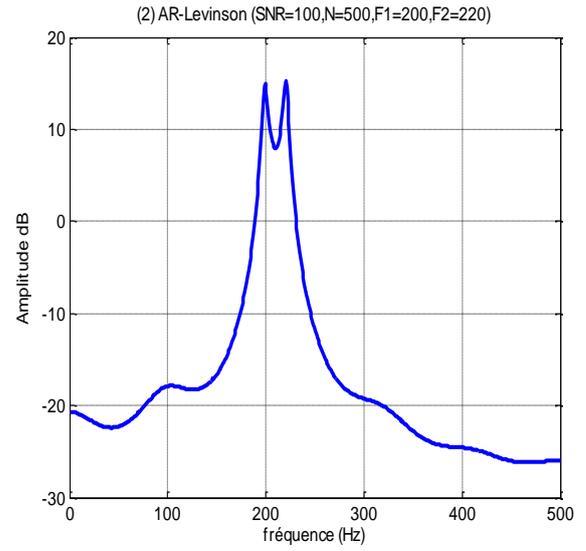
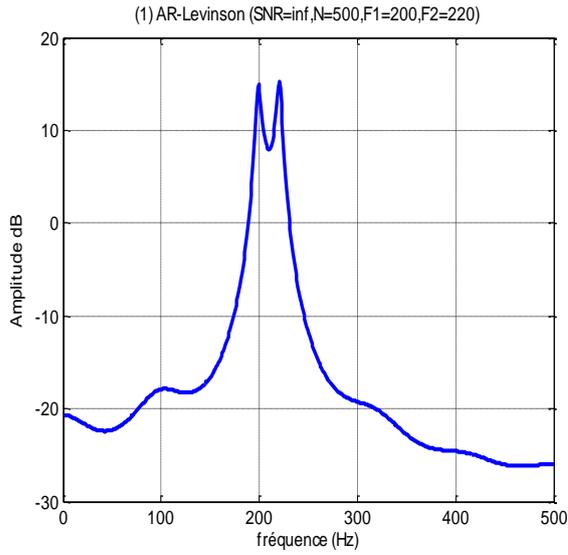


Fig III.6 (1, 2, 3, 4, 5, 6) : Densité spectrale de puissance du signal modèle 1 obtenue par AR-Levinson pour différentes valeurs du rapport SNR (100, 60, 45, 15, 0, inf).

Interprétation :

La figure III.6 montre que la séparation des deux pics se fait avec des forts SNR (inf, 100, 60, 45), et pour des faibles SNR (15, 0) il n'y a pas de détection de deux fréquences.

Cas 3 : Influence de l'ordre p

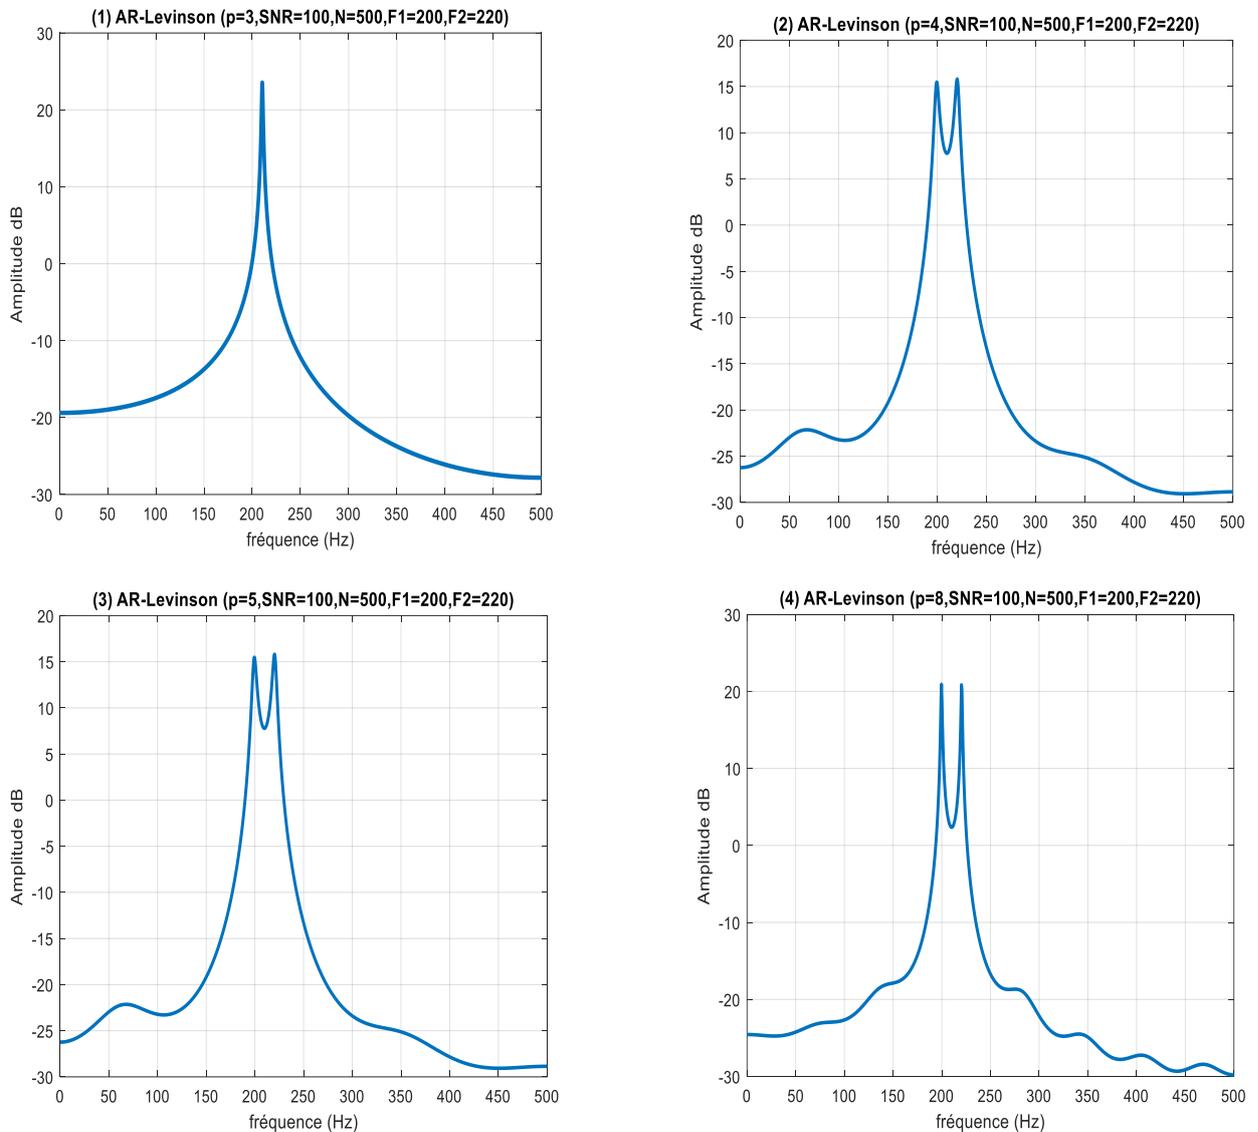


Fig III.7 (1, 2, 3,4) : Densité spectrale de puissance du signal modèle 1 obtenue par AR-Levinson pour différentes valeurs de p (3, 4, 5,8).

Interprétation :

Nous remarquons, d'après la figure III.7, que l'augmentation de l'ordre p (AR) avec un nombre de points fixe $N=500$ peut faire apparaître les deux pics principaux à partir de $p=4$. Nous observons également l'apparition de pics parasites à $p=8$.

III.4.1.2 Signal modèle 2

Cas 1 : Influence du nombre de points

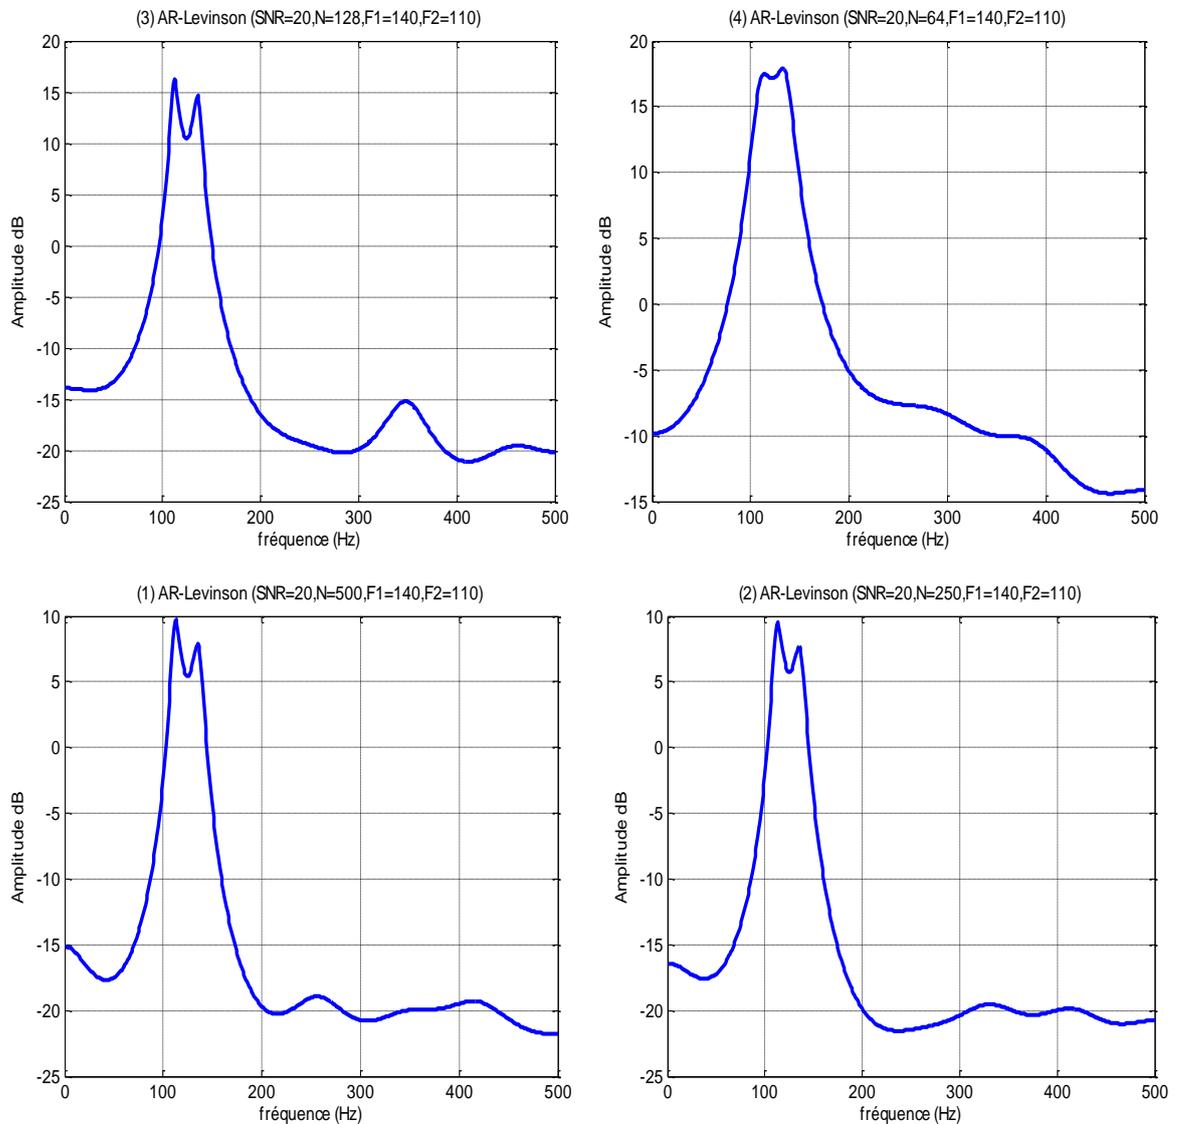


Fig III.8 (1, 2, 3, 4) : Densité spectrale de puissance du signal modèle 2 obtenue par AR-Levinson pour différentes valeurs de N (500, 250, 128, 64).

Interprétation :

Nous observons, d'après la figure II.8, que les deux pics apparaissent à partir de N=128.

Cas 2 : Influence du rapport SNR

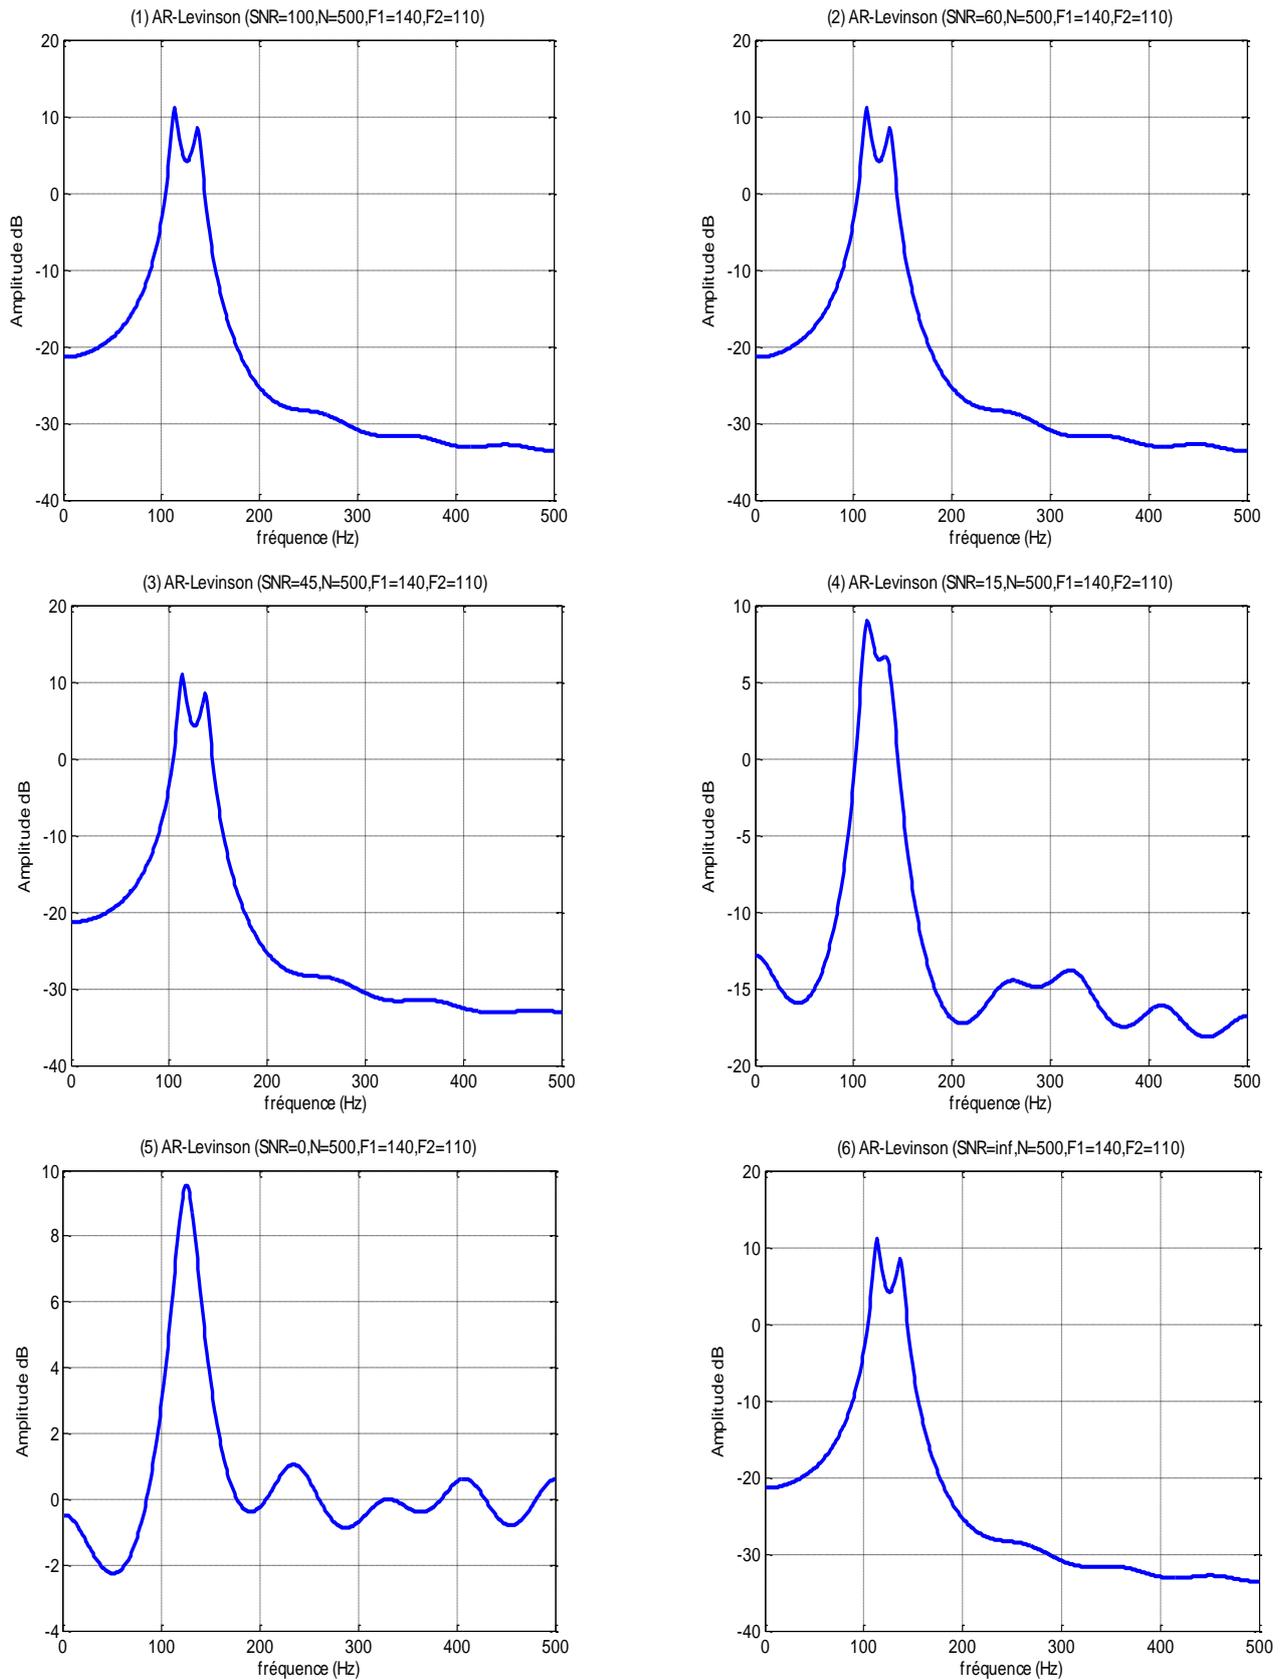


Fig III.9 (1, 2, 3, 4, 5, 6) : Densité spectrale de puissance du signal modèle 2 obtenue par AR-Levinson pour différentes valeurs du rapport SNR (100, 60, 45, 15, 0, inf).

Interprétation :

La figure III.9 montre que la séparation des deux pics se fait avec des forts SNR (inf, 100, 60, 45), et pour des faibles SNR (15, 0) il n'y a pas de détection de deux fréquences.

Cas 3 : Influence de l'ordre p

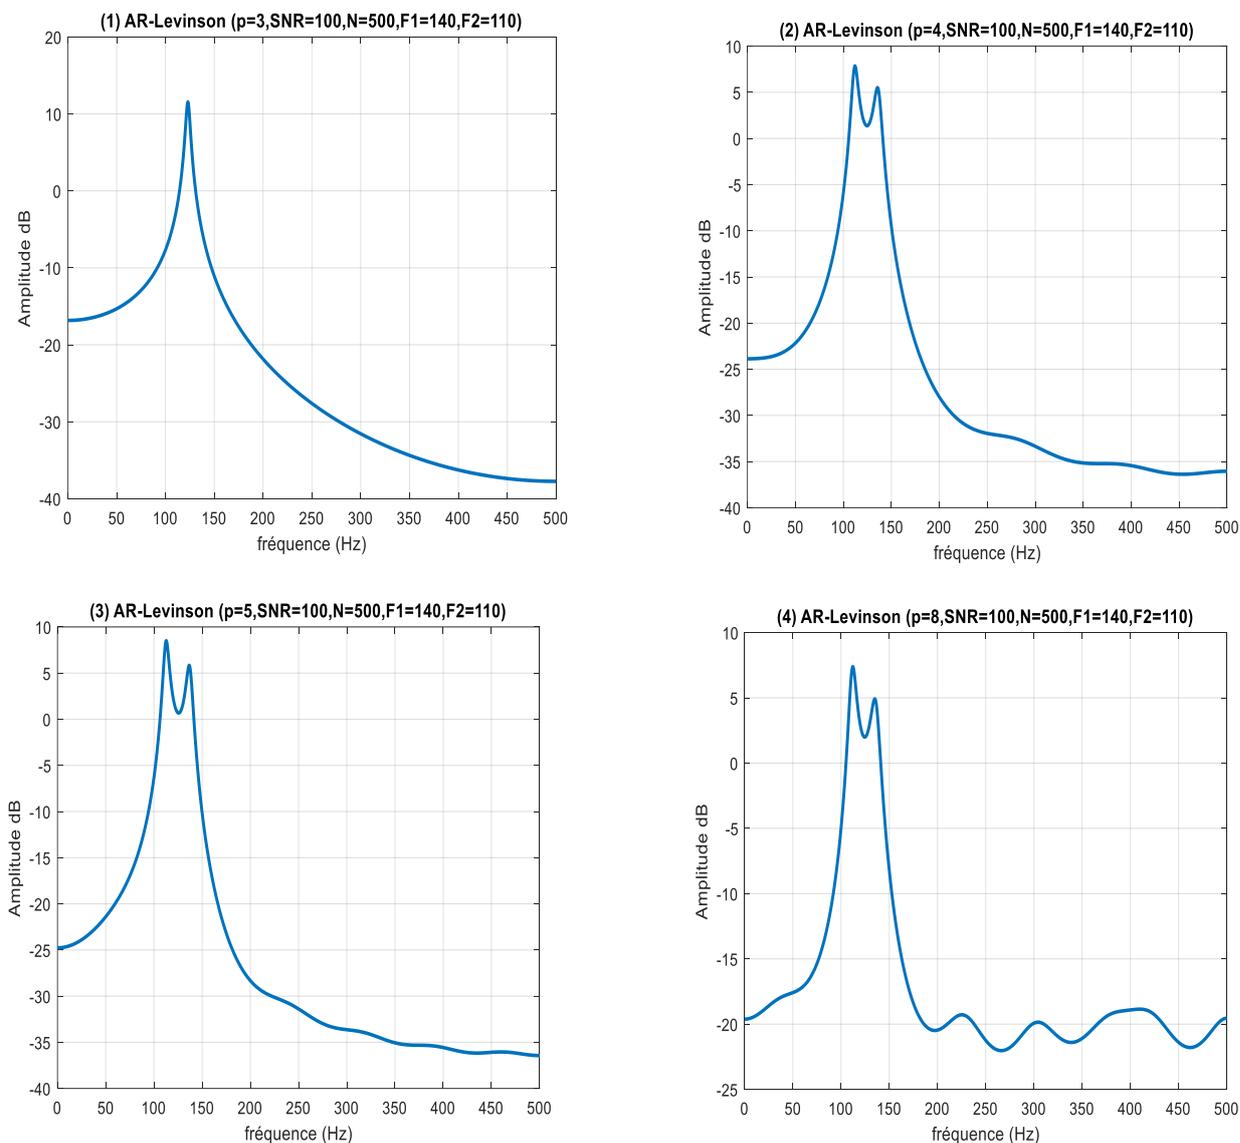


Fig III.10 (1, 2, 3,4) : Densité spectrale de puissance du signal modèle 2 obtenue par AR-Levinson pour différentes valeurs de p (3, 4, 5,8).

Interprétation :

D'après la figure III.10, on y observe que, pour un nombre fixe de points de données (N = 500), l'augmentation de l'ordre du modèle AR (p) permet de faire apparaître les deux pics principaux à partir de p = 4 (ordre optimal). Cependant, il est important de noter l'apparition de pics parasites à p = 8.

III.4.2 Application des procédures des AG aux signaux modèles

Le tableau III .1 montre les paramètres du signal modèle 1.

Tableau III. 1 Paramètres du signal modèle 1 original.

Paramètres	N	f_1	f_2	SNR	p (ordre optimal)
Valeurs	500	200Hz	220Hz	100	4

Après l'utilisation de l'algorithme d'estimation AR-Levinson, nous avons obtenu les paramètres du modèle AR $a(p)$ du signal modèle 1 qui sont indiqués dans le tableau III. 2 :

Tableau III. 2 Paramètres AR estimés par Levinson du signal modèle 1.

Paramètres a et b	a_1	a_2	a_3	a_4
Valeurs	-0.9947	2.2324	-0.9947	1.0000

➡ L'erreur moyenne de l'estimation MSE=20.8235

Après l'application de l'algorithme génétique pour affiner l'estimation des paramètres AR-Levinson, nous avons obtenu les paramètres $a(p)$ du signal modèle 1, qui sont indiqués dans le tableau III. 3:

Tableau III. 3 Paramètres AR-Levinson optimisés avec l'AG du signal modèle 1

Paramètres a et b	a_1	a_2	a_3	a_4
Valeurs	-1.0019	2.2390	-1.0006	0.9989

➡ L'erreur moyenne de l'estimation après l'utilisation de l'AG : MSE= 0.0646

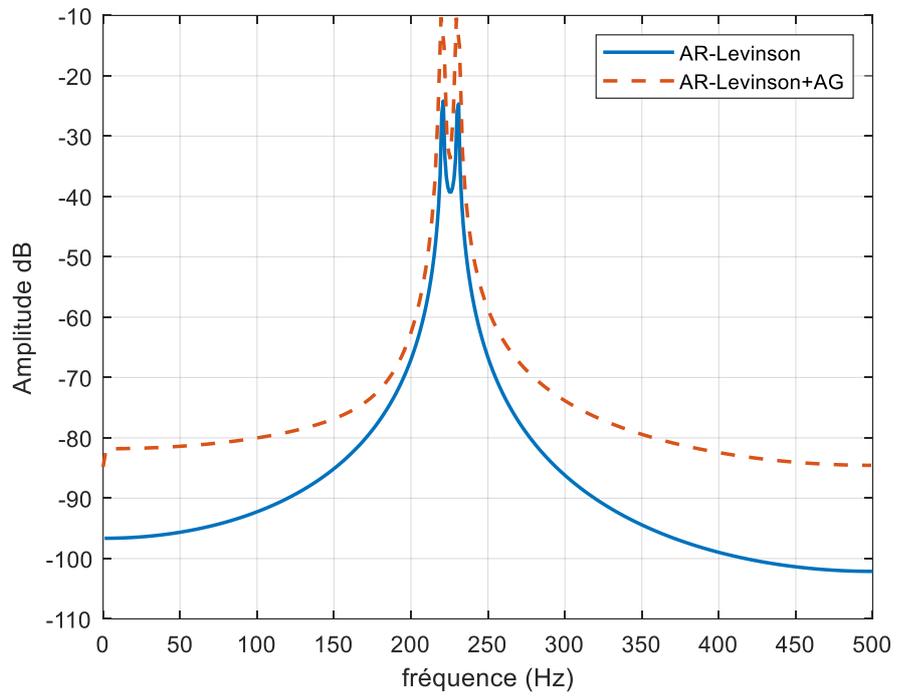


Fig. III.11 Densité spectrale de puissance du signal modèle 1 avant et après l'application de l'AG.

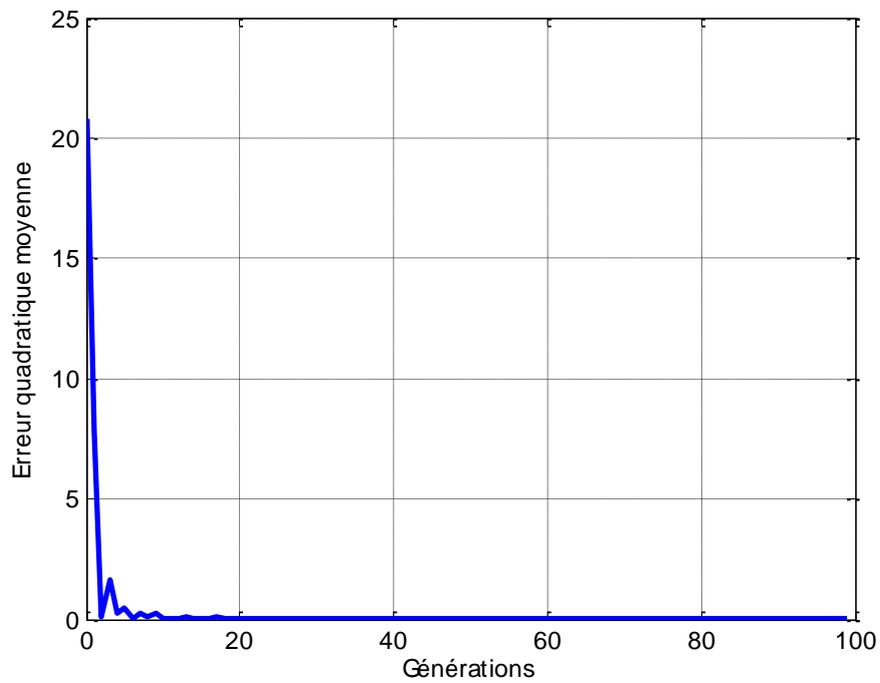


Fig. III.12 La variation de l'erreur quadratique moyenne de l'estimation en fonction des générations.

Interprétation :

D'après la figure (III.11) et pour un ordre optimal, nous n'observons que le signal généré après l'application de l'AG est mieux que le signal avant, et il y a une amélioration de la DSP, c-à-d, augmentation de l'amplitude est dans certain points. La courbe rouge (- -) est presque la même que la courbe bleu du signal réel avec une erreur moyenne de l'estimation (avant AG) $MSE=20.8235$, et L'erreur après l'utilisation de l'AG : $MSE= 0.0646$. Donc, il y a une diminution de l'erreur moyenne comme nous pouvons l'observer sur la figure (III.12).

III.4.3 Application des procédures des PSO aux signaux modèles

Pour même paramètres du signal modèle 1(tableau III .1), et après l'utilisation de l'algorithme d'estimation AR-Levinson, nous avons obtenu les paramètres du modèle AR $a(p)$ du signal modèle 1 qui sont indiqués dans le tableau III. 4 :

Tableau III. 4 Paramètres AR estimés par Levinson du signal modèle 1.

Paramètres a et b	a_1	a_2	a_3	a_4
Valeurs	-0.9947	2.2324	-0.9947	1.0000

➡ L'erreur moyenne de l'estimation $MSE=20.8235$

Après l'application de l'algorithme PSO pour affiner l'estimation des paramètres AR-Levinson, nous avons obtenu les paramètres $a(p)$ du signal modèle 1, qui sont indiqués dans le tableau III. 5:

Tableau III. 5 Paramètres AR-Levinson optimisés avec PSO du signal modèle 1

Paramètres a et b	a_1	a_2	a_3	a_4
Valeurs	-0.9922	2.2314	-0.9923	1.0001

➡ L'erreur moyenne de l'estimation après l'utilisation de PSO : $MSE= 0.00252$

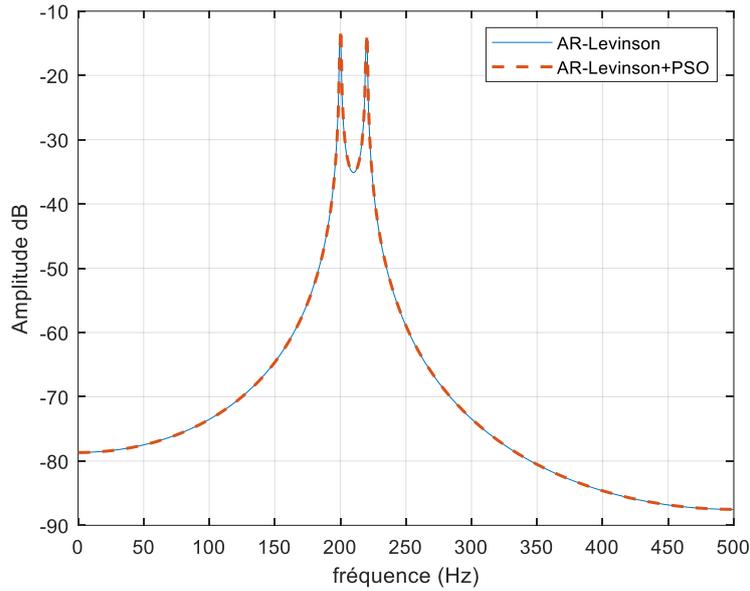


Fig. III.13 Densité spectrale de puissance du signal modèle 1 avant et après l'application de PSO.

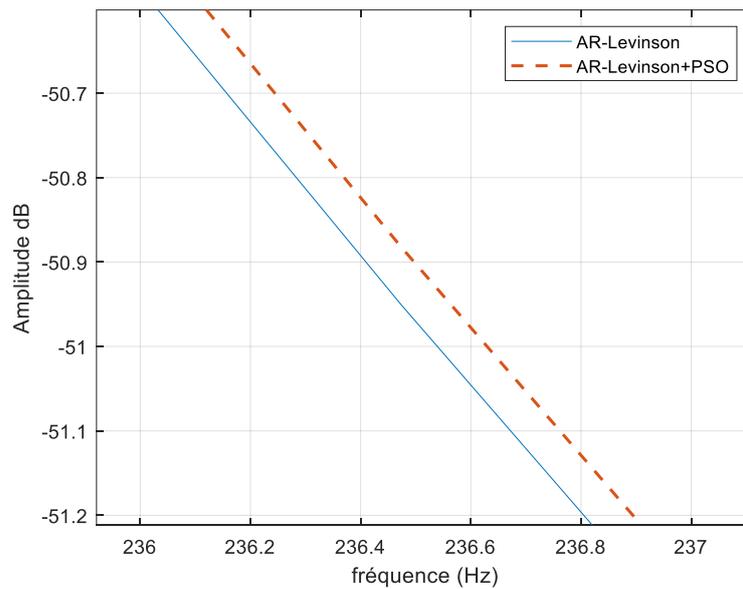


Fig. III.14 Vue agrandie de la figure III.10

Interprétation :

L'optimisation par PSO du modèle AR-Levinson ne semble pas apporter une amélioration significative par rapport à la méthode AR-Levinson classique pour ce cas particulier, étant donné que les spectres de puissance sont presque identiques. Cependant, l'optimisation par PSO pourrait être bénéfique dans d'autres scénarios ou pour d'autres types de signaux où l'ajustement des paramètres AR est plus critique.

III.5 Comparaison entre l'optimisation par Algorithme Génétique (AG) et l'Optimisation par Essaim Particulaire (PSO) dans l'estimation de modèle AR-Levinson

Le tableau III.6 présente une comparaison entre l'optimisation par Algorithme Génétique (AG) et l'Optimisation par Essaim Particulaire (PSO) dans l'estimation de modèle AR-Levinson.

Tableau III. 6 tableau comparatif entre l'optimisation par AG et PSO.

Critère	AG	PSO
Complexité	Plus complexe à implémenter, temps de calcul plus long en raison des opérations de croisement et de mutation.	Moins complexe, généralement plus rapide grâce à des mises à jour simples des positions et vitesses.
Temps de Calcul	Plus long, surtout pour de grandes populations et de nombreux cycles de génération.	Plus court, converge généralement plus rapidement.
Robustesse	Très robuste grâce à la diversité des solutions générées par croisement et mutation.	Moins robuste face aux minima locaux, mais efficace pour des solutions proches de l'optimum global.
MSE (Erreur Quadratique Moyenne)	Efficace pour minimiser la MSE, peut nécessiter plus de générations pour converger.	Efficace également, souvent avec une convergence plus rapide mais dépend des paramètres de l'algorithme.

Les deux méthodes d'optimisation, AG et PSO, présentent des avantages pour l'estimation des modèles AR-Levinson. Le choix entre elles dépendra des exigences spécifiques de l'application, telles que la précision requise, le temps de calcul disponible et la robustesse nécessaire face aux divers problèmes de minimisation.

III.6 Conclusion

Les résultats de ce chapitre démontrent que, bien que l'algorithme de Levinson soit une méthode efficace et fiable pour l'estimation des modèles AR, l'utilisation des techniques évolutives comme les algorithmes génétiques et l'optimisation par essaim particulaire peut apporter des améliorations significatives, notamment en termes de précision et de convergence rapide vers des solutions optimales. Ces techniques sont particulièrement avantageuses dans des scénarios d'optimisation complexes où les méthodes conventionnelles peuvent atteindre leurs limites.

Conclusion Générale

L'étude présentée dans ce mémoire porte sur le développement des méthodes d'estimation des paramètres du modèle AR par l'hybridation d'approches évolutives telles que les algorithmes génétiques et le PSO avec une technique d'estimation conventionnelle. Afin d'atteindre cet objectif, nous sommes passés par plusieurs étapes : Dans un premier temps, nous avons examiné le modèle rationnel linéaire et les techniques d'estimation conventionnelles telles que Burg, Levinson et les Moindres Carrés (LS). Nous avons constaté que ces méthodes offrent une base solide pour l'estimation des paramètres, mais peuvent être limitées en termes de complexité de modélisation.

Ensuite, nous avons présenté les fondements théoriques des algorithmes génétiques et de l'optimisation par essaim particulaire. Ces approches évolutives offrent des avantages pour l'optimisation de paramètres complexes, en particulier dans des espaces de recherche vastes et non linéaires.

Enfin, nous avons proposé une méthode pour améliorer l'estimation des paramètres du modèle AR en combinant l'algorithme conventionnel avec des approches évolutives telles que les algorithmes génétiques et le PSO. Nos résultats montrent que cette approche permet d'obtenir des estimations plus précises et robustes, en particulier pour des signaux complexes.

En conclusion, ce travail souligne l'importance de combiner des approches conventionnelles et évolutives pour l'estimation des paramètres des modèles AR. Ces techniques peuvent être appliquées à une variété de domaines, notamment la détection de défauts dans des machines tournantes ou d'autres systèmes dynamiques. Des travaux futurs pourraient explorer davantage ces méthodes et les adapter à d'autres types de modèles et de problèmes d'estimation.

Bibliographie

- [1] R. Mechoug, "La prédiction des séries temporelles utilisant les paradigmes de soft computing," Thèse de doctorat, Option : Électronique, Université Mohamed Khider – Biskra, 2013.
- [2] A. Kizilkay and A. H. Kayran, "Estimation of the ARMA model parameters based on the equivalent MA approach," *Digital Signal Processing*, vol. 16, pp. 670-681, 2006.
- [3] N. Rahmani, "Application des algorithmes évolutionnaires au calcul numérique et au finance," Thèse de doctorat, Université de Mohamed Kheider Biskra, 2021.
- [4] E.K. BDIRINA «Diagnostic de défauts d'engrenage par analyse spectrale», mémoire de magister, option : électronique, université Mohamed Boudiaf de M'SILA, 2006.
- [5] O. BESSON «Analyse spectrale paramétrique», cours 3ème année, département avionique et systèmes assure, 2009.
- [6] S.BELAROUCI, M.H.KHELIF, «Analyse spectrale paramétrique et non-paramétrique du signal de précession libre en RMN», *Afrique science*, vol 04, pp 64 – 86, 2008.
- [7] A. KADERLI, A.S. KAYHAN, «Spectral estimation of ARMA processes using ARMA-Cepstrum Recursion», *IEEE signal processing letters*, vol. 7, no. 9, September 2000.
- [8] S. BELKACEM, «Optimisation topologique de structures par algorithmes génétiques», thèse de doctorat, école doctorale science pour l'ingénieur et microtechniques, université de technologie de Belfort-Montbéliard, 2006.
- [9] M. Zemzami, N. Elhami, A. Makhloufi et al., "Application d'un modèle parallèle de la méthode PSO au problème de transport d'électricité," *OpenScience-ISTE Science Publishing*, 2016.
- [10] D. FÉLIXEKE, «Méthode d'identification en virgule fixe d'un modèle non linéaire basé sur les algorithmes génétiques », Mémoire présenté à l'université du Québec à Trois-Rivières, 2008.
- [11] J.S.LACROIX, S.TENADE, « Algorithmes génétiques », Ecole Polytechnique de Montréal, 2004 .
- [12] Y. Cooren, "Perfectionnement d'un algorithme adaptatif d'Optimisation par Essaim Particulaire: application en génie médical et en électronique," Thèse de doctorat, Université Paris-Est, 2008.
- [13] Abdul-Mateen, H. Hameed, et al. "Optimum sizing of hybrid WT/PV systems via open-space particle swarm optimization." 2012 Second Iranian Conference on Renewable Energy and Distributed Generation. IEEE, 2012.

- [14] M. N. Alam, "Particle swarm optimization: Algorithm and its codes in MATLAB," ResearchGate, vol. 8, no. 1, p. 10, 2016.
- [15] S. Abo-Hammoura, Othman M.K. Alsmadib , Adnan M. Al-Smadic , Maha I. Zaqoutc and Mohammad S. Sarairehd , «ARMA model order and parameter estimation using genetic algorithms», Taylor & Francis mathematical and computer modelling of dynamical systems vol. 18, pp 201–221, April 2012.
- [16] M. KAVEH, « High resolution spectral estimation for noisy signals », acoustics, speech, and signal processing, vol. assp-21, no. 3, June 1979.
- [17] E.K. BDIRINA «Diagnostic de défauts d'engrenage par analyse spectrale», mémoire de magister, option : électronique, université Mohamed Boudiaf de M'SILA,2006.
- [18] Q. Chena, K. Wordenb, P. Penga, A.Y.T. Leungc, « Genetic algorithm with an improved fitness function for(N)ARX modelling », science Direct Elsevier mechanical systems and signal processing ,vol 21, pp 994–1007, 2007.
- [19] M. Habibeche, "Une étude de la modélisation et comparative entre Réseau de neurones artificiels, Algorithmes génétiques et Box-Jenkins en prévision de série chronologique chaotique," Ph.D. dissertation, 2020.

Résumé

L'objectif principal de ce travail de Master concerne l'étude des techniques conventionnelles, comme l'algorithme de Levinson, pour l'estimation des paramètres du modèle autorégressif (AR). Ensuite, nous visons à introduire les techniques d'optimisation à base des Algorithmes Génétiques (AG) et de l'Optimisation par Essaims Particules (PSO) pour améliorer l'estimation des paramètres du modèle AR. La procédure AR-Levinson avec les algorithmes de l'intelligence artificielle (IA) a été appliquée et testée sur deux signaux modèles. Elle permet d'obtenir une bonne estimation de la densité spectrale de puissance (DSP) et d'affiner l'estimation des paramètres d'un modèle AR. Les résultats des tests montrent l'importance et l'intérêt des AG et PSO dans l'amélioration des performances d'estimation des paramètres du modèle AR par ajustement.

Mots clés : estimation, analyse spectrale, AR, MSE, DSP, Algorithmes génétiques (AG), Optimisation par essaims particules (PSO).

ملخص

الهدف الرئيسي لهذا العمل هو دراسة التقنيات التقليدية، مثل خوارزمية Levinson، لتقدير المعلمات في النموذج الذاتي التراجعي (AR). ثم، نهدف إلى إدخال تقنيات التحسين القائمة على خوارزميات الجينات (GA) والتحسين بواسطة أجسام الجزيئات (PSO) لتحسين تقدير المعلمات في النموذج AR. تم تطبيق واختبار إجراء AR-Levinson باستخدام خوارزميات الذكاء الاصطناعي (AI) على اثنين من إشارات النموذج. يسمح بالحصول على تقدير جيد لكثافة الطاقة الطيفية (PSD) وتنقيح تقدير المعلمات لنموذج AR. تظهر نتائج الاختبارات أهمية وفائدة GA و PSO في تحسين أداء تقدير المعلمات لنموذج AR من خلال التناسق.

كلمات البحث: التقدير، التحليل الطيفي، AR، MA، MSE، DSP، الخوارزميات الجينية. استمثال عناصر السرب.

Abstract

The main objective of this Master's work is to study conventional techniques, such as the Levinson algorithm, for estimating parameters of the autoregressive (AR) model. Then, we aim to introduce optimization techniques based on Genetic Algorithms (GA) and Particle Swarm Optimization (PSO) to improve parameter estimation of the AR model. The AR-Levinson procedure with artificial intelligence (AI) algorithms was applied and tested on two model signals. It allows for a good estimation of the power spectral density (PSD) and refines the estimation of AR model parameters. The test results demonstrate the importance and interest of GA and PSO in improving the estimation performance of AR model parameters through fitting.

Keywords: estimation, spectral analysis, AR, MSE, DSP, Genetic Algorithms, Particle Swarm Optimization (PSO).