

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

**UNIVERSITE M'HAMED BOUGARA BOUMERDES**



**Faculté des Sciences de L'Ingénieur**

**Département Génie Mécanique**

## **Mémoire de Master**

En vue de l'obtention du diplôme de **MASTER** en :

**Filière : Génie Mécanique**

**Spécialité : Energies Renouvelables**

### **THEME**

**Prédiction et Optimisation de la production de biogaz par procédé  
de méthanisation**

Présenté par :

BENAMAR Nasma

Promotrice:

Dr. MOUGARI Nour Elislam

**Promotion 2022- 2023**

# Remerciement

Je remercie tout d'abord ma promotrice Dr. Nour Elislam MOUGARI de m'avoir accompagné tout le long de ce travail, elle qui m'a guidé, conseillé et surtout beaucoup rassurer ainsi que Mr. Djamel Eddine GHERSI.

Je remercie également les membres du jury qui me font l'honneur de prendre de leur temps pour évaluer mon travail.

Un grand remerciement pour mes parent qui m'ont soutenu et encourager tout le long de ma vie et a tous mes amis qui m'ont encouragés.

## **Résumé**

La méthanisation est l'une des techniques les plus avantageuses pour la fourniture d'énergie durable et l'élimination des déchets. Cependant, la production de biogaz par une telle pratique peut s'avérer très complexe en raison des changements des paramètres d'exploitation, la non linéarité et de la surveillance minutieuse du processus. Face à ces obstructions, les techniques d'intelligence artificiel (IA) tel que les réseaux de neurones artificiel (RNA) et l'algorithme génétique (GA) se révèlent être une solution efficace, Grâce à l'utilisation de vastes ensembles de données et à l'application d'algorithmes avancés, ces techniques offre la possibilité de prédire et d'optimiser la production de biogaz. L'objectif de ce mémoire est de mettre en œuvre les réseaux de neurones artificiels (RNA) pour développer un modèle robuste, rapide et précis, en utilisant une base de données collectée des travaux publiés dans la littérature. Ce modèle a pour finalité de prédire la production de biogaz résultant de la Co-digestion des déchets alimentaires et des balles de maïs, en prenant en compte le rapport de mélange entre le substrat et l'inoculum, ainsi que le temps de digestion. Par la suite, le modèle basé sur les ARN est associé à l'algorithme génétique (AG), qui est un algorithme d'optimisation, dans le but de déterminer la combinaison optimale du rapport l'inoculum/ substrat et du temps de digestion permettant d'atteindre la production maximale de biogaz. Les résultats globaux de ces études révèlent que le modèle basé sur les réseaux de neurones artificiels combinés à l'algorithme génétique (AG-RNA), est un outil robuste et efficace, permettant une meilleure prédiction et optimisation de la production de biogaz. Ces techniques d'intelligence artificielle permettraient aux opérateurs de processus de digestion anaérobie de contrôler, d'évaluer et de prédire les paramètres opérationnels à l'avance, sans compromettre la stabilité du processus pour une production de biogaz améliorée et efficace. Ceci est important pour la sécurité environnementale future et la prospérité économique des systèmes de méthanisation.

## **Mots clés**

Algorithme génétique ; Biogaz ; Intelligence artificielle ; Méthanisation ; Réseau de neurones artificiels.

## **Abstract**

Anaerobic digestion is one of the most advantageous techniques for the supply of sustainable energy and the elimination of waste. However, the production of biogas by such a practice can be very complex due to changes in operating parameters, nonlinearity and careful monitoring of the process. In the face of these obstructions, artificial intelligence (AI) techniques such as artificial neural networks (ANN) and genetic algorithm (GA) are proving to be an effective solution, thanks to the use of large data sets and With the application of advanced algorithms, these techniques offer the possibility of predicting and optimizing the production of biogas. The objective of this thesis is to implement artificial neural networks (ANN) to develop a robust, fast and accurate model, using a database collected from works published in the literature. The purpose of this model is to predict the production of biogas resulting from the co-digestion of food waste and cornhusks, taking into account the mixing ratio between the substrate and the inoculum, as well as the digestion time. Subsequently, the RNA-based model is associated with the genetic algorithm (GA), which is an optimization algorithm, in order to determine the optimal combination of the inoculum/substrate ratio and the digestion time allowing achieving maximum biogas production. The overall results of these studies reveal that the model based on artificial neural networks combined with the genetic algorithm (AG-RNA) is a robust and efficient tool, allowing better prediction and optimization of biogas production. These artificial intelligence techniques would allow anaerobic digestion process operators to control, assess and predict operational parameters in advance, without compromising process stability for improved and efficient biogas production. This is important for the future environmental safety and economic prosperity of biogas systems.

## **Key words:**

Genetic algorithm; Biogas; Artificial intelligence; Anaerobic digestion; Artificial neural network.

## ملخص

يعتبر الهضم اللاهوائي من أكثر التقنيات فائدة لتوفير الطاقة المستدامة والتخلص من النفايات. ومع ذلك، فإن إنتاج الغاز الحيوي من خلال هذه الممارسة يمكن أن يكون معقدًا للغاية بسبب التغييرات في معلمات التشغيل، وعدم الخطية والمراقبة مثل الشبكات العصبية الاصطناعية الدقيقة للعملية. في مواجهة هذه العوائق، أثبتت تقنيات الذكاء الاصطناعي أنها حل فعال، وذلك بفضل استخدام مجموعات البيانات الكبيرة وتطبيق الخوارزميات المتقدمة، توفر والخوارزمية الجينية هذه التقنيات إمكانية التنبؤ وتحسين إنتاج الغاز الحيوي. الهدف من هذه الرسالة هو تنفيذ الشبكات العصبية الاصطناعية لتطوير نموذج قوي وسريع ودقيق، باستخدام قاعدة بيانات تم جمعها من الأعمال المنشورة في الأدبيات. الغرض (ANN) من هذا النموذج هو التنبؤ بإنتاج الغاز الحيوي الناتج عن الهضم المشترك لمخلفات الطعام وقشور الذرة، مع مراعاة نسبة الخلط بين الركيزة والتلقيح، وكذلك وقت الهضم. بعد ذلك، يرتبط النموذج القائم على الحمض النووي الريبي بالخوارزمية، وهي خوارزمية تحسين، من أجل تحديد التركيبة المثلى لنسبة اللقاح / الركيزة ووقت الهضم الذي يسمح (GA) الجينية بتحقيق أقصى إنتاج للغاز الحيوي. تكشف النتائج الإجمالية لهذه الدراسات أن النموذج المعتمد على الشبكات العصبية هو أداة قوية وفعالة، مما يسمح بالتنبؤ بشكل أفضل (AG-RNA) الاصطناعية جنبًا إلى جنب مع الخوارزمية الجينية وتحسين إنتاج الغاز الحيوي. ستسمح تقنيات الذكاء الاصطناعي هذه لمشغلي عملية الهضم اللاهوائي بالتحكم في المعلمات التشغيلية وتقييمها والتنبؤ بها مقدمًا، دون المساس باستقرار العملية لإنتاج الغاز الحيوي المحسن والفعال. هذا مهم للسلامة البيئية في المستقبل والازدهار الاقتصادي لأنظمة الغاز الحيوي.

## الكلمات الدالة

الخوارزمية الجينية الغاز الحيوي. ذكاء اصطناعي؛ الهضم اللاهوائي؛ تنبؤ؛ شبكة اعصاب صناعية

**Sommaire**

**Nomenclature**

**Liste des figures**

**Liste des tableaux**

**Introduction**

**Chapitre 1 : Généralités sur le processus de méthanisation.**

1.1. Introduction .....	4
1.2. La biomasse.....	4
1.4. La méthanisation .....	6
1.4.1. Définition de la méthanisation.....	6
1.4.2 Les étapes de la méthanisation .....	7
1.4.2.1 L'hydrolyse .....	7
1.4.2.2 L'acidogenèse .....	8
1.4.2.3 L'acétogenèse.....	8
1.4.2.4 La méthanogenèse.....	8
1.4.3 Les produits de la méthanisation .....	9
1.4.3.1 Le biogaz.....	9
1.4.3.2 Le digestat .....	10
1.4.4 Différents paramètres influençant la méthanisation .....	10
1.4.4.1 Température .....	10
1.4.4.2 Le pH .....	11
1.4.4.3 Le rapport carbone/azote (C/N) .....	12
1.4.4.4 Le Taux de charges organiques (TCO).....	12
1.4.4.5 Les Solides totaux (ST) et solides volatils (SV) .....	13
1.4.4.6 Le temps de rétention hydraulique (TRH) .....	13
1.4.4.7 L'inoculum.....	13

1.4.4.8 La Co-digestion.....	14
1.4.4.9 L'absence des inhibiteurs.....	14
1.6 Le système de digestion .....	14
1.6.1 Le digesteur .....	14
1.6.2 Différents systèmes de digesteurs.....	15
1.6.2.1 Le digesteur de type discontinu .....	15
1.6.2.2 Le digesteur de type continu .....	16
1.7 Conclusion.....	16

## **Chapitre 2: Technique d'intelligence artificielle**

2.1. Introduction .....	17
2.2. Définition de l'intelligence artificielle .....	17
2.3. Réseau de neurones artificiels (RNA).....	18
2.3.1. Définition.....	18
2.3.2. Les éléments constitutifs d'un neurone artificiel.....	18
2.3.3. Architecture d'un RNA .....	19
2.3.4. Composants d'un RNA.....	20
2.3.4.1. Neurones .....	20
2.3.4.2. Couches : groupement de neurones .....	20
2.3.4.3. Poids et biais : valeurs numériques .....	20
2.3.4.4. Fonctions d'activation.....	21
2.3.5. Différents types de RNA .....	22
2.3.5.1. Réseau de neurones feed-forward .....	23
2.3.5.1. Les réseaux de neurones récurrents (RNN) .....	23
2.3.6. Apprentissage des RNA.....	24
2.3.6.1. Apprentissage supervisé.....	24
2.3.6.2. Apprentissage non supervisé.....	25
2.4. L'algorithme génétique (AG).....	25

2.4.1. Principes généraux des Algorithmes Génétiques .....	26
2.4.2. Fonctionnement d'un algorithme génétique .....	27
2.4.2.1. Le croisement .....	28
2.4.2.2. La mutation .....	28
2.4.2. 3. La sélection .....	28
2.5. Application des techniques d'intelligence artificielle pour la prédiction et l'optimisation de la production du biogaz .....	29
2.6. Conclusion.....	34

### **Chapitre 3: Prédiction et Optimisation de la production de biogaz**

3.1. Introduction .....	35
3.2. Matériel et méthodes .....	35
3.2.1. Base de données.....	35
3.2.2. Normalisation des données .....	35
3.2.3. Développement du modèle prédictif (RNA) .....	36
3.3. Analyses statistiques .....	37
3.4. Résultats et discussion.....	37
3.4.1. Architecture du réseau de neurone artificiel .....	37
3.4.2. Résultats de la prédiction du volume de biogaz .....	40
3.4.3. Optimisation de la production de biogaz par l'algorithme génétique (AG) .....	44
3.5. Conclusion.....	45
Conclusion générale et perspectives .....	46
Conclusion générale .....	46
Perspectives.....	47

## NOMENCLATURE

<b>Lettres</b>	<b>Significations</b>	<b>Unités</b>
<b>AE</b>	Algorithmes Evolutionnaires	
<b>AG</b>	Algorithme Génétique	
<b>AGV</b>	Acides Gras Volatiles	(%)
<b>AIE</b>	Agence Internationale de l'Energie	
<b>ANFIS</b>	Adaptive Neuro Fuzzy Inference System	
<b>C/N</b>	Rapport Carbone/Azote	
<b>DA</b>	Digestion Anaérobie	
<b>DSM</b>	Déchets Solides Municipaux	
<b>EGM</b>	Equation de Gompertz Modifiée	
<b>GES</b>	Gaz à Effet de Serre	
<b>IA</b>	Intelligence Artificielle	
<b>MLP</b>	Multi Layer Perceptron	
<b>NARX</b>	Nonlinear Autoregressive Exogenous	
<b>R<sup>2</sup></b>	Coefficient de détermination	
<b>MSE</b>	l'erreur moyenne quadratique	
<b>RM</b>	Rapport du Mélange	(%)
<b>RNA</b>	Réseaux de Neurones Artificiels	
<b>ST</b>	Solides totaux	(%)
<b>SV</b>	Solides Volatiles	(%)
<b>TCO</b>	Taux de Charge Organique	(kg.m-3.jour-1)
<b>TD</b>	Temps de Digestion	(Jours)
<b>TRH</b>	Temps de Réention Hydraulique	(Jours)
<b>FW</b>	Déchets alimentaire	
<b>MH</b>	Balles de maïs	

## Liste des figures

<b>Figure 1.1 :</b> Voies de valorisation énergétique de la biomasse.....	5
<b>Figure 1.2 :</b> Processus de méthanisation.....	7
<b>Figure 1.3 :</b> Etapes de la méthanisation. ....	9
<b>Figure 1.4 :</b> Taux de production de biogaz en fonction de la température.....	11
<b>Figure 1.5 :</b> Système de digestion anaérobie. ....	15
<b>Figure 2.1 :</b> Eléments constitutifs d'un neurone artificiel [13].....	19
<b>Figure 2.2 :</b> Architecture d'un réseau de neurones artificiel.....	19
<b>Figure 2.3 :</b> Types de réseaux d neurones artificiels.....	22
<b>Figure 2.4 :</b> Réseau Feed-forward monocouche (a) et multicouches (b). ....	23
<b>Figure 2.5 :</b> Réseau de neurones récurrent. ....	24
<b>Figure 2.6 :</b> Algorithme génétique.....	26
<b>Figure 2.7 :</b> Organigramme de l'algorithme génétique.....	27
<b>Figure 3.1 :</b> Architecture du modèle RNA pour la prédiction du volume de biogaz...	40
<b>Figure 3.2 :</b> Changements de l'erreur quadratique moyenne avec le nombre d'époques au cours du processus d'apprentissage : prédiction du volume de biogaz.....	41
<b>Figure 3.3 :</b> Graphiques de régression du RNA pour la prédiction de biogaz.....	42
<b>Figure 3.5 :</b> Comparaison entre le volume de biogaz produit expérimentalement et prédit par le modèle RNA.....	43

## Liste des tableaux

<b>Tableau 2.1 :</b> Fonctions d'activation couramment utilisées.....	22
<b>Tableau 2.2 :</b> Application des techniques d'intelligence artificielle pour la prédiction et l'optimisation de la production du biogaz. ....	29
<b>Tableau 3.1 :</b> Résultats des essais pour une couche caché.....	38
<b>Tableau 3.2 :</b> Résultats des essais pour deux couches cachées.....	38
<b>Tableau 3.3 :</b> Informations détaillé sur le modèle de prédiction RNA.....	39
<b>Tableau 3.4 :</b> Valeurs de $R^2$ pour la prédiction du volume de biogaz.....	42
<b>Tableau 3.5 :</b> Combinaison optimale des paramètres d'entrée pour une production maximale de biogaz déterminée par AG-RNA.....	44

# **Introduction générale**

### **Introduction générale**

Au cours des dernières décennies, notre planète a été confrontée à deux défis majeurs : le réchauffement climatique et l'augmentation rapide de la population mondiale. Selon les données de l'ONU, la population mondiale a atteint 7,9 milliards de personnes en 2023, ce qui représente une augmentation de près de 1,1 % par rapport à l'année précédente. Cette croissance démographique continue exerce une pression croissante sur les ressources naturelles et les systèmes énergétiques existants.

Le réchauffement climatique est un autre problème urgent auquel nous sommes confrontés. Les activités humaines, telles que la combustion des combustibles fossiles, ont entraîné une augmentation des émissions de gaz à effet de serre, conduisant à une élévation de la température moyenne de la planète. Selon le Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC), depuis le début de l'ère industrielle, la température mondiale moyenne a augmenté d'environ 1,1°C, et les conséquences de ce réchauffement se font déjà sentir dans le monde entier.

L'augmentation de la population mondiale et la croissance économique ont un impact significatif sur l'augmentation de la production de déchets. Avec une population en constante expansion, les besoins en ressources augmentent, entraînant une augmentation de la consommation et de la production de déchets. Les activités industrielles et commerciales génèrent également une quantité considérable de déchets. Cette surproduction de déchets pose des défis majeurs en termes de gestion et de traitement.

Face à ces défis, la production de biogaz par méthanisation offre une solution prometteuse qui permet de répondre à la demande croissante en énergie et aux enjeux environnementaux. Le biogaz est un mélange de gaz principalement composé de méthane et de dioxyde de carbone, produit par la décomposition anaérobie. Les déchets organiques peuvent donc être transformés en biogaz, une source d'énergie renouvelable. L'utilisation du biogaz permet une double optimisation : d'une part, elle offre une alternative énergétique durable en réduisant la dépendance aux combustibles fossiles, et d'autre part, elle permet une valorisation efficace des déchets organiques.

Le processus de méthanisation est complexe et non linéaire. Cela est dû à l'interaction des différents paramètres physico chimiques qui permettent d'avoir une production de biogaz stable et efficace. Il est important de surveiller et contrôler ces divers paramètres, pour

l'obtention d'une conception efficace et par voie de conséquence, une production optimale de biogaz.

L'utilisation de l'intelligence artificielle (IA) se révèle être une solution efficace. En exploitant des ensembles de données massives et en appliquant des algorithmes avancés, l'IA permet d'analyser les facteurs qui influencent la production de biogaz telle que le PH, la température, le temps de digestion, le rapport inoculum/substrat etc...

Grâce à l'analyse des facteurs cités précédemment, les modèles d'IA peuvent prédire avec précision la production de biogaz et identifier les paramètres optimaux pour maximiser les rendements, sans recourir aux tests longs et très coûteux de laboratoire.

L'objectif de notre travail est d'appliquer les réseaux de neurones artificiels (RNA) pour développer un modèle robuste, rapide et précis, en utilisant une base de données collectée à partir des travaux publiés dans la littérature. Ce modèle a pour but de prédire la production de biogaz à partir de la Co digestion des déchets alimentaires et balles de maïs, en prenant en considération le rapport du mélange du substrat avec l'inoculum et le temps de digestion. Le modèle basé sur le RNA est couplé par la suite avec l'algorithme génétique (AG), qui est un algorithme d'optimisation, dans le but de déterminer la combinaison optimale entre l'inoculum et le substrat, et le temps de digestion qui permettent d'avoir le maximum de biogaz. Les résultats de la modélisation permettent ensuite une conception et un contrôle efficaces des procédés de biogaz.

Le présent travail est réparti en trois chapitres :

Chapitre 1 : ce chapitre présente un aperçu sur le principe de méthanisation. Les définitions de la biomasse, de la méthanisation et du système de digestion (digesteur) sont abordées en premier lieu. Par la suite, les étapes de la méthanisation et les différents paramètres qui influent sur ce processus sont examinés.

Chapitre 2 : ce chapitre vise à donner un aperçu des techniques d'intelligence artificielle qui sont utilisées dans ce travail. Une description des réseaux de neurones artificielle et de l'algorithme génétique est présentée, y compris leur concept de base. A la fin du chapitre, un aperçu des travaux les plus importants relatifs à l'application des techniques d'intelligence artificielle pour la prédiction et l'optimisation de production de biogaz est présenté.

Chapitre 3 : ce chapitre présente les étapes suivies pour le développement du modèle basé sur les réseaux de neurones artificiels couplé à l'algorithme génétique pour la prédiction et l'optimisation de la production de biogaz, ainsi que les résultats et discussion. Ce modèle prend en compte deux variables clés : le rapport substrat/inoculum et le temps de digestion (en jours). L'efficacité de cette approche est évaluée à l'aide des indicateurs de performances statistiques tels que le coefficient de détermination ( $R$ ) et l'erreur moyenne (MSE).

# **Chapitre 01**

Généralités sur le processus de méthanisation.

### 1.1. Introduction

Au cours des dix dernières années, la méthanisation s'est développée de façon soutenue. Elle apparaît dorénavant comme une des technologies clés de l'économie circulaire et de la croissance verte. En produisant du biogaz, composé majoritairement de méthane et de dioxyde de carbone, et du digestat, à partir d'effluents et de résidus agricoles et de déchets organiques, elle constitue à la fois une solution pour leur valorisation et une source d'énergie renouvelable.

La méthanisation est également un procédé de plus en plus utilisé pour développer le traitement des déchets urbains, des effluents industriels ou des boues de stations d'épuration.

Dans ce chapitre, nous explorerons les notions clés de la biomasse, de la méthanisation et des digesteurs, ainsi que les différents types de digesteurs disponibles. De plus, nous examinerons en détail les étapes du processus de méthanisation et les différents paramètres qui influent sur son efficacité.

### 1.2. La biomasse

Grâce à l'énergie solaire, à l'eau et aux éléments minéraux contenus dans le sol, les plantes absorbent le gaz carbonique et renouvellent le stock d'oxygène de notre atmosphère. Par le mécanisme de la photosynthèse, elles fabriquent des hydrates de carbone constituant principal des matières végétales. Au sens large, « la biomasse » désigne l'ensemble de la matière vivante. Depuis le choc pétrolier de 1973, cette terminologie s'applique aux produits organiques végétaux ou animaux utilisés à des fins énergétiques ou agronomiques, que l'on classe couramment, selon leur taux d'humidité, en deux grandes familles :

- **La « biomasse sèche »** : qui comprend la « biomasse ligneuse » (bûches, rémanents forestiers et petits bois de haie, produits connexes de la transformation du bois, élagages urbains et des bords de routes, bois de rebut, ainsi que les pailles et autres résidus de récoltes ;
- **La « biomasse humide »** : qui regroupe les flux de déchets organiques issus de l'activité agricole (déjections animales), des industries agroalimentaires (abattoirs, laiteries, cidreries, distilleries, etc.) et des collectivités (déchets verts, boues d'épuration, fraction fermentescible des ordures ménagères, graisses organiques et produits résiduels). Selon une autre définition, la biomasse est toute matière

provenant du vivant. Elle a la propriété d'être une source soit d'énergie soit de matière première [1].

### 1.3. La valorisation énergétique de la biomasse

La biomasse peut apporter une contribution significative à l'offre énergétique. L'utilisation de cette dernière comme source d'énergie participe au cycle naturel du carbone, la quantité de dioxyde de carbone (CO<sub>2</sub>) rejetée dans l'atmosphère lors de la combustion correspondant sensiblement à celle absorbée par la biomasse par photosynthèse. Les filières ne nécessitant pas une importante consommation d'énergie pour cultiver et transformer la biomasse brute présentent un bilan CO<sub>2</sub> favorable.

La biomasse est susceptible de fournir de l'énergie sous diverses formes : chaleur, électricité, combustibles et/ou carburants gazeux, liquides et solides.

Les filières de bioénergies reposent essentiellement sur trois "familles" de procédés de conversion, comme illustré dans la figure 1.1 :

- **voies thermochimiques** : combustion, pyrolyse et gazéification ;
- **voies biologiques** : méthanisation (digestion anaérobie), compostage...
- **voies oléo chimiques** : raffinage d'huiles et graisses végétales et animales.

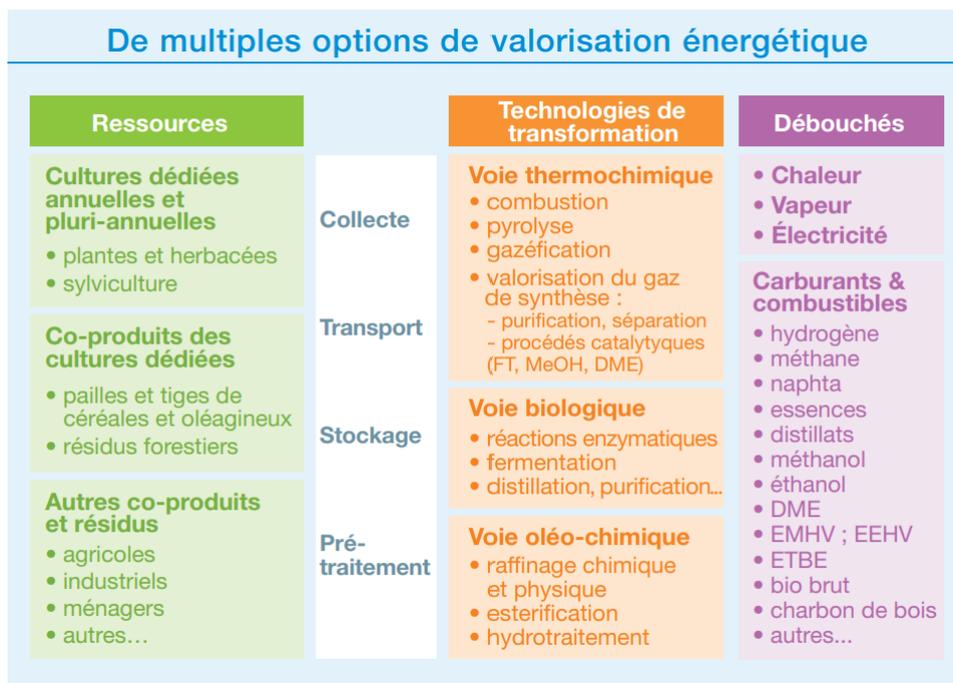


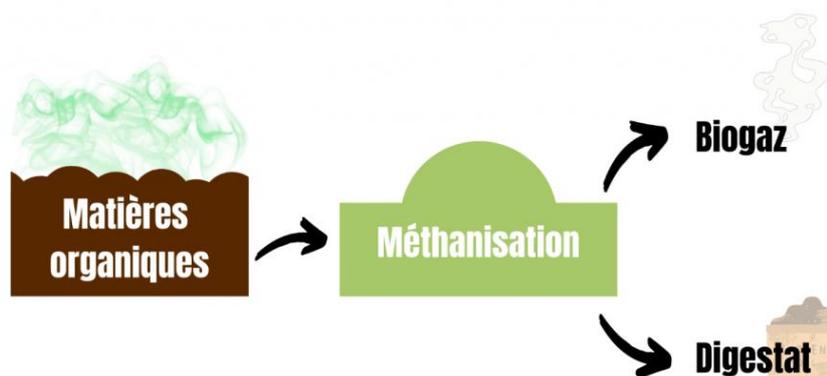
Figure 1.1 : Voies de valorisation énergétique de la biomasse.

La méthanisation est l'un des meilleurs candidats biotechnologiques pour produire de l'énergie grâce à sa capacité de traiter différents types de déchets. En effet, elle permet la production de biogaz, source d'énergie renouvelable valorisable sous différentes formes (électricité, chaleur, injection dans le réseau de gaz naturel). Par ailleurs, le digestat, produit solide de la méthanisation, offre également une alternative aux engrais minéraux [2]. En fait, l'utilisation mondiale des technologies de méthanisation pour la production de biogaz peut devenir l'un des principaux contributeurs à la réduction planifiée des émissions de gaz à effet de serre (GES), elles permettent une bonne réduction des équivalents de CO<sub>2</sub> par unité d'énergie produite. Le méthane est un puissant GES dont le potentiel de réchauffement planétaire est 25 fois supérieur à celui du dioxyde de carbone. Ainsi, lorsque le biogaz capté est brûlé, le méthane est transformé en CO<sub>2</sub> et en eau, ce qui évite ses émissions fugitives dans l'atmosphère et réduit son impact environnemental négatif.

### 1.4. La méthanisation

#### 1.4.1. Définition de la méthanisation

La méthanisation est une technologie basée sur la dégradation par des micro-organismes de la matière organique (biomasse) (figure 1.2). Parmi les plus courants se trouvent des matières agricoles telles que le fumier ou le lisier, des bio déchets des ménages et déchets des collectivités, des entreprises ou encore des boues de station d'épuration, en conditions contrôlées et en l'absence d'oxygène, donc en milieu anaérobie, contrairement au compostage qui est une réaction aérobie [2]. Cette dégradation provoque en premier lieu du biogaz, mélange gazeux saturé en eau à la sortie du digesteur et composé de méthane (CH<sub>4</sub>), de gaz carbonique (CO<sub>2</sub>) et de quelques gaz traces (NH<sub>3</sub>, N<sub>2</sub>, H<sub>2</sub>S). Cette énergie renouvelable peut être utilisée sous forme combattive pour la production d'électricité et de chaleur, de production d'un carburant, ou d'injection dans le réseau de gaz naturel après épuration. En second lieu un produit humide, riche en matière organique partiellement stabilisée, appelé digestat.



**Figure 1.2 :** Processus de méthanisation.

### 1.4.2 Les étapes de la méthanisation

On peut distinguer quatre phases dans la dégradation anaérobie : l'hydrolyse, l'acidogénèse, l'acétogénèse et la méthanogénèse (figure 1.3) [2].

#### 1.4.2.1 L'hydrolyse

C'est l'étape où les macromolécules organiques (polysaccharides, protéines, composés lipidiques) sont hydrolysées en éléments plus simples, tels que sucres simples, acides aminés, acides gras à courtes chaînes, glycérol. Les produits solubles issus des dépolymérisations s'ajoutent à la fraction déjà soluble de la matière organique. La taille des particules et leur mise en solution permet leur assimilation par les micro-organismes. Selon le substrat utilisé, les produits d'hydrolyse sont différents. L'hydrolyse des lipides (lipolyse) libère du glycérol, des acides gras volatils (AGV) et des acides gras à longues chaînes (AGLC). Le glycérol est rapidement assimilé par les microorganismes. L'hydrolyse des protéines, libère des polypeptides et des acides aminés. La cellulose et les hémicelluloses sont hydrolysées en leurs monosaccharides constitutifs (glucose, fructose, arabinose, ...). La lignine est non ou très faiblement consommée en digestion anaérobie. Or, dans les composés d'origine végétale, la lignine incruste plus ou moins la cellulose et les hémicelluloses ce qui peut limiter d'autant leur hydrolyse. Les vitesses de dépolymérisation des macromolécules sont particulièrement faibles pour les protéines, les lipides et la cellulose [3].

### 1.4.2.2 L'acidogenèse

L'acidogenèse correspond à la conversion intracellulaire des produits solubles d'hydrolyse en composés tels que l'eau, le dihydrogène, le dioxyde de carbone et les acides gras volatils, alcools, ammoniac. Les AGV sont des molécules simples avec un squelette de 1 à 6 atomes de carbone. Les sept principales espèces d'AGV sont les acides formique, acétique, propionique, butyrique et isobutyrique, valérique et iso-valérique. Le biogaz produit au cours de cette phase, tout comme lors de l'hydrolyse, est principalement composé de CO<sub>2</sub> (80%) et de H<sub>2</sub> (20%). La production des différentes espèces d'AGV est conditionnée par le substrat et par la pression en H<sub>2</sub>. Les micro-organismes impliqués dans l'acidogenèse sont généralement des mêmes genres que ceux de la phase d'hydrolyse [4].

### 1.4.2.3 L'acétogenèse

L'acétogenèse est l'ensemble des réactions qui conduit à la production d'acétate. Cette étape est réalisée par deux groupes microbiens consommant respectivement le CO<sub>2</sub> et les AGV. Les bactéries homoacétogènes ou acétogènes strictes produisent de l'acétate par la réduction du dioxyde de carbone [2].

### 1.4.2.4 La méthanogenèse

Au cours de cette dernière étape de minéralisation de la matière organique, les molécules à un ou deux atomes de carbone sont converties en méthane. Deux voies métaboliques permettent la production de méthane, à partir de l'acétate et du couple CO<sub>2</sub>/H<sub>2</sub>. Les microorganismes responsables sont anaérobies stricts et appartiennent au domaine des Archées. Les méthanogènes acétotrophes convertissent l'acétate en dioxyde de carbone et en méthane. La décarboxylation de l'acétate fait intervenir deux réactions couplées, dont le bilan d'enthalpie libre rend thermodynamiquement possible la production de méthane.

Les méthanogènes hydrogénotrophes réduisent le dioxyde de carbone, les carbonates et les bicarbonates avec le dihydrogène pour former du méthane et de l'eau [2].

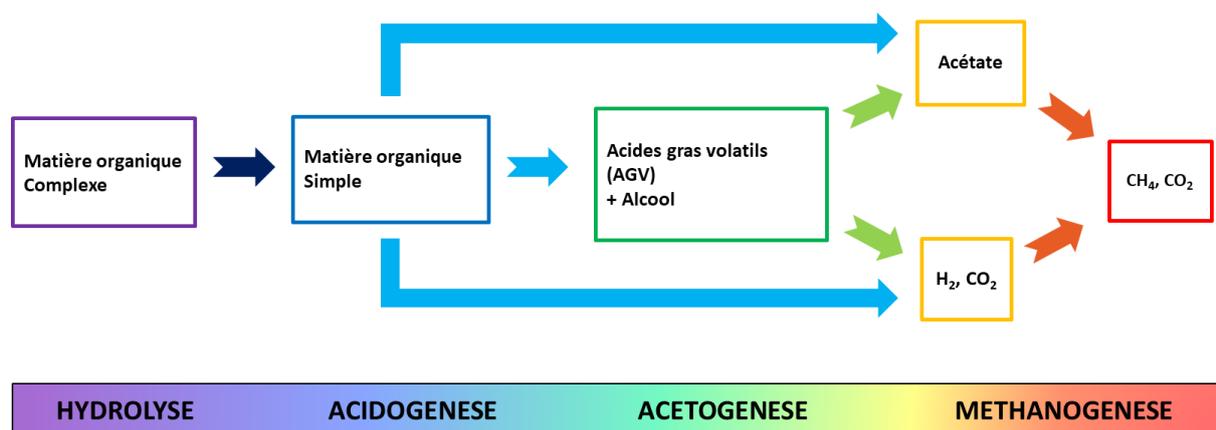


Figure 1.3 : Etapes de la méthanisation.

### 1.4.3 Les produits de la méthanisation

#### 1.4.3.1 Le biogaz

Le biogaz est un mélange gazeux saturé en eau, composé d'environ 50 % à 70 % de méthane (CH<sub>4</sub>), de 20 % à 50 % de gaz carbonique (CO<sub>2</sub>) et de quelques gaz traces (NH<sub>3</sub>, N<sub>2</sub>, H<sub>2</sub>S). Le biogaz a un pouvoir calorifique inférieur (PCI) de 5 à 7 kWh/Nm<sup>3</sup>. Sa valorisation permet d'éviter l'utilisation d'énergie fossile et de réduire les émissions de méthane – gaz à fort impact sur l'effet de serre - dans l'atmosphère lors du stockage de la biomasse à l'air libre.

La valorisation énergétique du biogaz se fait aujourd'hui majoritairement par deux grandes voies technologiques :

- **La cogénération** : le biogaz est envoyé dans un moteur de cogénération ou une turbine qui le transforme en électricité et chaleur ; L'électricité produite est injectée sur le réseau d'électricité.
- **L'épuration** : le biogaz est épuré pour atteindre un taux de méthane de 97% ou plus et devenir du bio méthane. Il est alors injecté dans les réseaux de gaz naturels classiques. Il est ensuite utilisé comme gaz naturel dans des processus industriels, pour le chauffage des habitations ou pour servir de carburant aux véhicules roulant au Gaz Naturel Véhicule (GNV).

D'autres applications existent : combustion direct du biogaz dans une chaudière, valorisation mixte du biogaz en cogénération et en bio-GNV directement sans injection dans les réseaux.

### 1.4.3.2 Le digestat

Le digestat, qui représente environ 90 % du tonnage des substrats entrants, est quant à lui un fertilisant organique qui contient l'ensemble des éléments des matières entrantes fertilisants (azote, phosphore et potassium - N, P, K) tout en ne présentant quasi aucune nuisance olfactive. De par sa texture et les formes chimiques du N, P, K, ce nouveau fertilisant peut nécessiter des adaptations de pratiques pour son épandage aux champs.

Utilisé comme **fertilisant**, ce sous-produit riche en matière organique peut être utilisé pour :

- l'épandage ;
- la valorisation (après traitement physique) ;
- l'incinération.

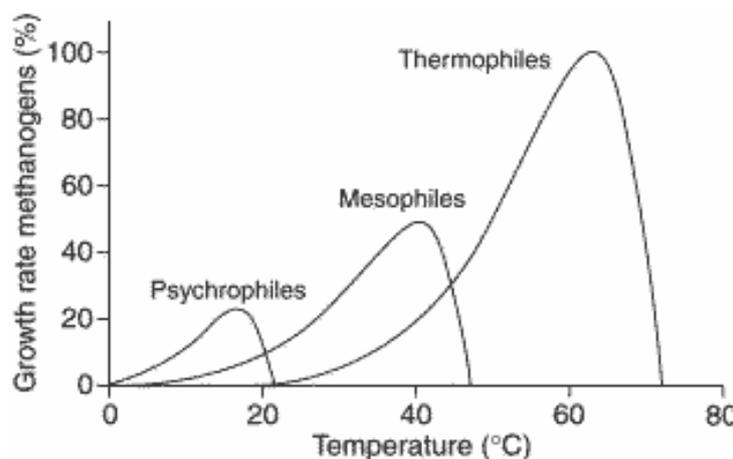
### 1.4.4 Différents paramètres influençant la méthanisation

#### 1.4.1.1 Température

La digestion anaérobie peut se réaliser sous trois gammes de température :

- **de 15 à 25°C** : méthanisation psychrophile ;
- **de 25 à 45°C** : méthanisation mésophile ;
- **de 55 à 65°C** : méthanisation thermophile.

La méthanisation mésophile est la plus utilisée (à 38 °C) dans les zones tempérées. La figure suivante (figure 1.4) présente le taux de production de biogaz en fonction de la température et du temps de séjour.



**Figure 1.4 :** Taux de production de biogaz en fonction de la température.

La stabilité de la température est essentielle pour un bon déroulement de la fermentation méthanique ; or les marges de fluctuations tolérables sont plus étroites en zone thermophile qu'en zone mésophile ( $\pm 2.8^{\circ}\text{C}$  à  $38^{\circ}\text{C}$  ;  $\pm 0.8^{\circ}\text{C}$  à  $49^{\circ}\text{C}$  et seulement  $\pm 0.3^{\circ}\text{C}$  à  $52^{\circ}\text{C}$ ). Ceci implique qu'en zone thermophile, la température de fermentation doit être rigoureusement contrôlée et homogène dans tout le réacteur. Cet équilibre thermique, facilement réalisable au stade pilote, mais beaucoup plus difficile à obtenir dans les grandes unités. Dans l'écart des températures mésophiles, pour une hausse de  $1^{\circ}\text{C}$  la production de gaz augmente de 5%. Toutefois de fréquentes chutes de température peuvent déséquilibrer les populations microbiennes. Les variations de température peuvent être contraignantes pour la digestion mésophile ( $35^{\circ}\text{C}$ ) ou thermophile ( $55^{\circ}\text{C}$ ) [5].

### 1.4.4.2 Le pH

La digestion anaérobie se déroule normalement pour des pH compris entre 6 et 8 la plupart se développent de façon optimale conditions de pH neutre car les milieux acides ou basiques altèrent l'équilibre chimique des réactions enzymatiques ou détruisent les enzymes, en dessous de 6, l'activité des bactéries méthanogènes diminue rapidement et peut être complètement stoppée à partir de 5,5. Alors que les bactéries acidogènes continuent à produire des acides gras volatiles (AGV) jusqu'à des pH voisins de 4,5, une acidification du milieu provoque une accumulation des acides gras volatils, qui en trop grande quantité, bloque la production du méthane, et sa peut traduire un dysfonctionnement de la syntrophie entre les microorganismes de la méthanisation. D'autre part les bactéries impliquées dans la production et la consommation de l'hydrogène, pouvant entraîner une accumulation de

propionate. Les surcharges organiques peuvent également engendrer une accumulation des AGV car l'apport de substrat dépasse les capacités de dégradation de l'écosystème microbien. Pour une digestion anaérobie des boues d'épuration le pH est autorégulé dans le digesteur avec des valeurs optimales comprises entre 6,8 et 7,4 car l'alcalinité produite par les méthanogènes sous forme de CO<sub>2</sub>, d'ammonium et de bicarbonate, permet de maintenir le pH dans la gamme de neutralité [6].

### 1.4.4.3 Le rapport carbone/azote (C/N)

Le rapport carbone/azote (C/N) est une mesure de la quantité relative de l'azote et du carbone organique présent dans la charge du digesteur. Si le rapport C/N est très élevé, les déchets utilisés comme substrat auront une carence en azote, ce qui est pourtant nécessaire pour développer des communautés bactériennes. En conséquence, la production de gaz sera faible. Si le rapport C / N est très faible, l'azote est libéré et s'accumule sous forme d'ammoniac. Cela permettra d'accroître la valeur du pH de la matière et un pH supérieur à 8,5 sera toxique sur les communautés bactériennes méthanogènes. Ainsi un rapport C/N de 20-30 est considéré comme optimal pour un digesteur anaérobie [7].

### 1.4.4.4 Le Taux de charges organiques (TCO)

La quantité de matière organique, telle que les déchets de papier, alimentaires et de jardin, disponibles pour des micro-organismes qui produisent le méthane, est le facteur le plus significatif pour la génération du méthane dans un déchet. La capacité de production du méthane dans un déchet est directement proportionnelle à la quantité des matières organiques.

Il varie de 1 à 5 kg. m<sup>-3</sup>.jour<sup>-1</sup>. Ces valeurs sont choisies inférieures aux capacités maximums de digesteurs pour éviter l'instabilité du processus [8]. Un excès de charge organique se produit lorsque la quantité de matière organique entrante dépasse la capacité de dégradation de la communauté microbienne. Cela entraînera à une accumulation d'AGV, et donc une diminution des rendements de méthane. Le TCO est pris en compte pour décider du temps de rétention hydraulique (TRH) d'un digesteur.

### 1.4.4.5 Les Solides totaux (ST) et solides volatils (SV)

ST et SV sont des paramètres incontournables pour la caractérisation des substrats organiques. Le ST décrit la matière sèche d'un substrat en pourcentage du poids total. La concentration en SV est définie comme la fraction organique du ST et est généralement mesurée en pourcentage de ST. Les concentrations en ST et SV des substrats ainsi que du digestat fournissent des informations utiles sur le rendement en biogaz attendu et l'efficacité du procédé. La concentration en SV est couramment utilisée pour évaluer l'efficacité du processus de DA. Non seulement le potentiel de biogaz d'un substrat peut être estimé en fonction de sa teneur en SV, mais aussi le degré de dégradation atteint par le procédé de DA en comparant l'entrée de SV au digesteur et la sortie de SV. De plus, les composants mécaniques d'une installation de DA, tels que les pompes et les agitateurs, ne peuvent traiter en toute sécurité que des matériaux ayant une certaine concentration en ST. Deux catégories principales sont identifiées : le procédé humide, travaillant à un ST < 15 % et le procédé sec fonctionnant à un ST > 15 % [9].

### 1.4.4.6 Le temps de rétention hydraulique (TRH)

Le TRH représente le temps de séjour moyen du substrat dans le digesteur. Il est calculé en fonction du volume du digesteur [ $m^3$ ] et de l'apport journalier de substrat [ $m^3$ /jour].

Le TRH doit être suffisamment long pour permettre l'établissement de la communauté microbienne, et éviter les surcharges hydrauliques. Un TRH trop court entraînera un lessivage des méthanogènes, dont le temps de doublement de la population est d'environ 30 jours et par la suite une accumulation d'AGV. Le TRH minimale dépend des substrats à valoriser. Il est généralement court avec des substrats facilement biodégradables (15 - 30 jours), et peut atteindre 100 jours pour des substrats qui ne sont pas facilement biodégradables [10].

### 1.4.4.7 L'inoculum

Il est nécessaire d'inaugurer les bactéries d'ensemencement enrichies dans un digesteur pour démarrer le processus de digestion anaérobie. Normalement, les boues de digesteur provenant d'une usine de biogaz en fonctionnement ou d'une usine municipale provenant d'une fosse à fumier bien décomposée ou de lisier de vache sont utilisées comme semences. En général, l'inoculum ajouté a tendance à améliorer le rendement en biogaz et la formation de  $CH_4$  dans

le biogaz. Il a le potentiel d'améliorer le rendement en biogaz et de raccourcir la période de rétention.

### 1.4.4.8 La Co-digestion

La Co-digestion consiste à méthaniser simultanément plusieurs substrats d'origines différentes, et de valoriser certains substrats impossibles à méthaniser en mono-digestion, qui peut être une association des coproduits liquides/liquides, solides/solides ou liquides/solides. Le mélange se fait généralement, par une répartition en fonction de l'apport de MO des substrats respectifs, il peut toutefois être réalisé en fonction d'autres paramètres, tels que le rapport C/N ou la MS. la Co-digestion est généralement un moyen de produire des quantités de biogaz supérieures grâce à des réactions plus stables ou des charges organiques plus élevées à cause de l'équilibre de nutriments des coproduits.

### 1.4.4.9 L'absence des inhibiteurs

La méthanisation est réputée pour sa sensibilité aux matières toxiques et particulièrement la phase méthanogène, qui est encore plus sensible. Ces éléments inhibiteurs sont présents dans le substrat lui-même, ou produits lors de la digestion, parmi eux on peut citer : l'ammoniac, les acides gras volatils (AGV), les composés sulfurés et les métaux lourds.

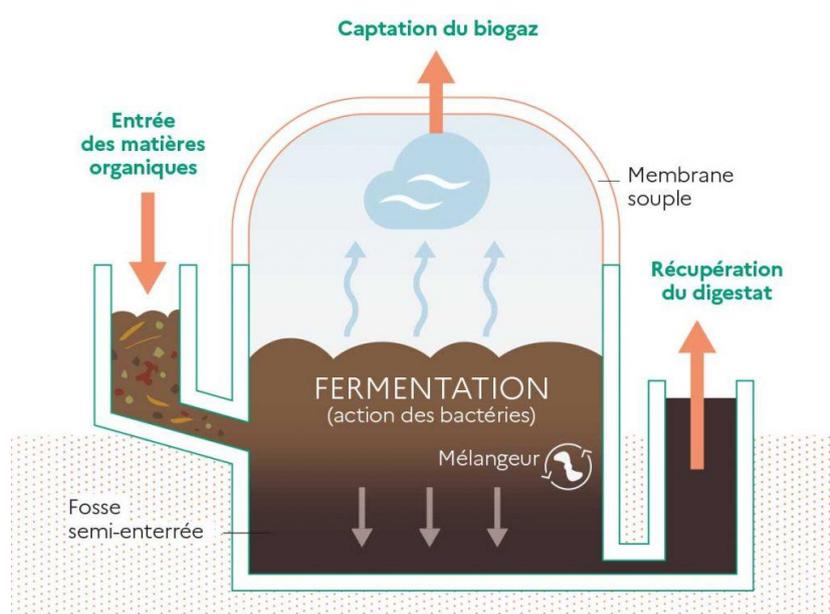
## 1.6 Le système de digestion

### 1.6.1 Le digesteur

L'élément principal d'un procédé de méthanisation est le digesteur. D'une manière générale, la structure du digesteur est à base de béton ou d'acier. Elle doit présenter une résistance mécanique et chimique. C'est pourquoi elle est souvent protégée par une paroi ou une membrane interne qui isole le matériau de construction de la matière à digérer.

Le digesteur est constitué d'une cuve fermée (figure 1.5), étanche à l'air et de préférence isolée thermiquement de l'extérieur dans laquelle les microorganismes se côtoient pour dégrader chimiquement et biologiquement les effluents organiques. Il peut être équipé d'un système de chauffage, d'un système d'agitation, d'un système de prélèvement et d'un système de mesure de teneur en gaz, de dispositifs permettant le contrôle de différents paramètres : la température, le pH, la pression ...etc.

Il est dimensionné à partir du volume utile calculé à partir du taux de charge, notamment du taux de charge organique (quantité de matière organique introduite par m<sup>3</sup> de réacteur et par jour), et du temps de séjour. Le dimensionnement sera établi en tenant compte des valorisations aval de biogaz et de digestat mais également en fonction de la présence ou non d'un post-digesteur. Il faut également prendre en compte l'évolution potentielle des substrats (comportement, potentiel méthanogène variables) au cours de la vie de l'installation pour lui autoriser une certaine flexibilité.



**Figure 1.5 :** Système de digestion anaérobie.

### 1.6.2 Différents systèmes de digesteurs

Le choix du digesteur varie en fonction du type de déchets à traiter et de l'application visée. On peut classer les digesteurs en deux grandes catégories selon le mode d'alimentation : les digesteurs de type continu et les digesteurs de type discontinu.

#### 1.6.2.1 Le digesteur de type discontinu

Il a l'avantage d'être d'une construction simple. Le mode opératoire consiste à remplir le digesteur avec les substances organiques et laisser digérer, le temps de rétention est en fonction de la température et d'autres facteurs. A la fin de la digestion, le digestat est évacué et le processus peut recommencer. Ces systèmes, rustiques et d'une grande simplicité technique, sont avantageux pour traiter les déchets solides comme les fumiers, les résidus

agricoles ou les ordures ménagères. La production de biogaz n'est pas régulière : au début du cycle, la fermentation du substrat ne venant que de commencer, la production de biogaz est lente. Elle s'accélère, et atteint un taux maximal au milieu du processus de dégradation et chute en fin de cycle lorsque seuls les éléments difficilement digestibles restent dans le digesteur.

### 1.6.2.2 Le digesteur de type continu

Dans un digesteur continu, le substrat introduit de manière continue est digéré et déplacé soit mécaniquement, soit sous la pression des nouveaux entrants vers la sortie sous forme de digestat. Le fonctionnement en continu, est bien adapté aux installations de grande taille. Il existe trois principaux types de digesteurs continus : système à cuve verticale, système à cuve horizontale et système à cuves multiples.

## 1.7 Conclusion

La méthanisation apparaît donc comme un moyen technologique très efficace qui permet une valorisation de la matière organique et de l'énergie ; c'est son intérêt spécifique par rapport aux autres filières. Elle participe à la diminution de la quantité de déchets organiques et à la diminution des émissions de gaz à effet de serre par substitution à l'usage d'énergies fossiles. Le problème posé ici est la difficulté de stabilisation de ces paramètres en raison de la complexité associée au processus de méthanisation.

Les digesteurs anaérobies sont conçus en fonction de conditions de fonctionnement stables. Il est important de comprendre la cinétique du processus de méthanisation, ce qui nous permet de prédire le fonctionnement du digesteur. La sélection et la surveillance des paramètres qui influencent la production de biogaz jouent un rôle essentiel dans l'optimisation du processus, car ils fournissent des informations sur l'état et le fonctionnement du système.

La modélisation peut être une approche intéressante qui va permettre de développer une relation entre les paramètres physico-chimiques et opérationnels, et l'efficacité du processus, mais aussi de contrôler et prédire le comportement du processus à l'échelle réelle

L'intelligence artificielle pourrait s'avérer une solution adéquate pour la prédiction et l'optimisation de la production de biogaz par le procédé de méthanisation, et fera l'objet du deuxième chapitre.

## **Chapitre 02**

Techniques d'intelligence artificielle.

### 2.1. Introduction

L'intelligence artificielle est une technologie en constante évolution. Son objectif principale étant d'être une machine intelligente capable d'imiter l'homme dans ses tâches intellectuelles les plus complexes c'est pour cela qu'elle peut être une solution à notre problème.

Ce chapitre va être un aperçu des techniques d'intelligence artificielle, au cours de lequel on mettra une définition du terme « intelligence artificielle » puis on développera les techniques utilisées au cours de ce mémoire qui sont les réseaux de neurones artificiels et l'algorithme génétique.

### 2.2. Définition de l'intelligence artificielle

L'intelligence Artificielle correspond à un ensemble de technologies « mises en œuvre en vue de réaliser des machines capables de simuler l'intelligence humaine », comme le raisonnement ou l'apprentissage. Le principal champ d'étude en Intelligence Artificielle s'appelle le Machine Learning. Il consiste à faire apprendre aux ordinateurs à exécuter trois types d'actions : prédire, classifier et regrouper. Les algorithmes ou modèles effectuant ces tâches sont appelés respectivement : réseaux de neurones, machine à vecteurs de support, algorithmes de partitionnement de données

Ces modèles peuvent être utilisés seuls ou en combinaison avec d'autres méthodes comme des méthodes d'optimisation pour mettre en œuvre des applications plus complexes. Une des principales valeurs ajoutées des algorithmes de Machine Learning par rapport aux méthodes classiques réside dans la prise en compte de plusieurs dizaines voire centaines de variables, en se basant sur des données de tous types (bits, nombres, textes, images, sons, vidéos). Ces données doivent être collectées, traitées et homogénéisées de manière à ce qu'elles puissent être interprétées par le modèle : l'algorithme « apprend » ensuite sur quelle combinaison de critères baser sa décision

La quantité et qualité des données sur lesquelles les modèles de Machine Learning sont entraînés sont déterminantes pour leurs performances : par exemple, entraîner un classificateur contrôlant la qualité de produits sur des images floues ou sur un jeu de données restreint réduira fortement ses performances [11].

## 2.3. Réseau de neurones artificiels (RNA)

### 2.3.1. Définition

Un RNA est une inspiration du cerveau humain ; de ses capacités de traitement et de stockage des connaissances pratiques en vue d'utilisation ultérieure si besoin. L'aspect fondamental de cette technique est la nouvelle conception composée d'unités de traitement simples pour stocker les connaissances pratiques et les rendre disponibles pour une utilisation en cas de besoin [12].

Les unités de traitement dans un RNA imitent le cerveau sous deux aspects : la connaissance est obtenue par le réseau via un processus d'apprentissage incorporant des neurones artificiels, et les forces de connexion des neurones artificiels appelés « poids » qui forment la base de l'apprentissage du réseau, sont utilisées pour le stockage des connaissances acquises.

Le fonctionnement d'un RNA ne nécessite pas la connaissance des informations détaillées sur un système. Il apprend la relation entre les paramètres d'entrée et de sortie en analysant les données précédemment collectées.

### 2.3.2. Les éléments constitutifs d'un neurone artificiel

Un neurone artificiel fonctionne d'une manière inspirée de celle d'un neurone biologique : un nœud d'un réseau de plusieurs neurones reçoit généralement plusieurs valeurs d'entrée et génère une valeur de sortie [13].

Les éléments qui constituent un neurone artificiel sont présentés dans la figure 2.1 et sont définis comme :

- Les entrées "E" du neurone proviennent soit d'autres éléments "processeurs", soit de l'environnement.
- Les poids "W" indiquent l'influence de chaque entrée.
- Entrée de biais : une unité fictive dont le poids permet d'ajuster le seuil de déclenchement du neurone.
- La Fonction d'activation "f" détermine l'état du neurone en sortie "S".

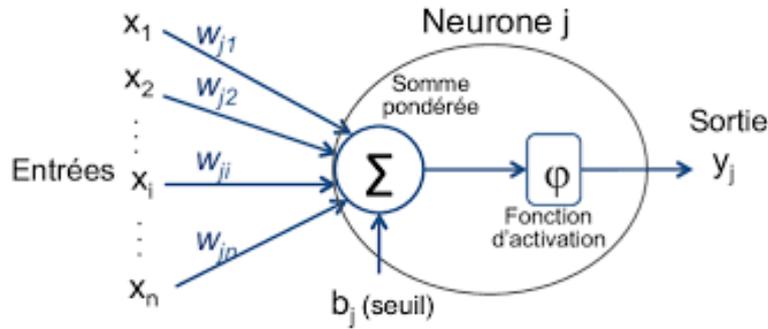


Figure 2.1 : Eléments constitutifs d'un neurone artificiel [13].

### 2.3.3. Architecture d'un RNA

Un RNA comprend quelques dizaines, centaines, milliers, voire millions de neurones artificiels appelés unités, disposés en une série de couches, chacune d'entre elles étant reliée aux couches de chaque cote. Certaines d'entre elles, appelées unités d'entrée, sont conçues pour recevoir du monde extérieur diverses formes d'informations que le réseau tentera d'apprendre, de reconnaître ou de traiter d'une autre manière. D'autres unités se trouvent de l'autre cote du réseau et signalent comment il réagit aux informations qu'il a apprises, ce sont les unités de sortie. Entre les unités d'entrée et les unités de sortie se trouvent une ou plusieurs couches d'unités cachées, qui ensemble, forment la majorité du cerveau artificiel. La plupart des réseaux de neurones sont entièrement connectés, ce qui signifie que chaque unité cachée et chaque unité de sortie est connectée à chaque unité des couches de part et d'autre. Les connexions entre une unité et une autre sont représentées par un nombre appelé poids, qui peut être soit positif ou négatif. Plus le poids est élevé, plus une unité a d'influence sur une autre (Voir figure 2.2) [13].

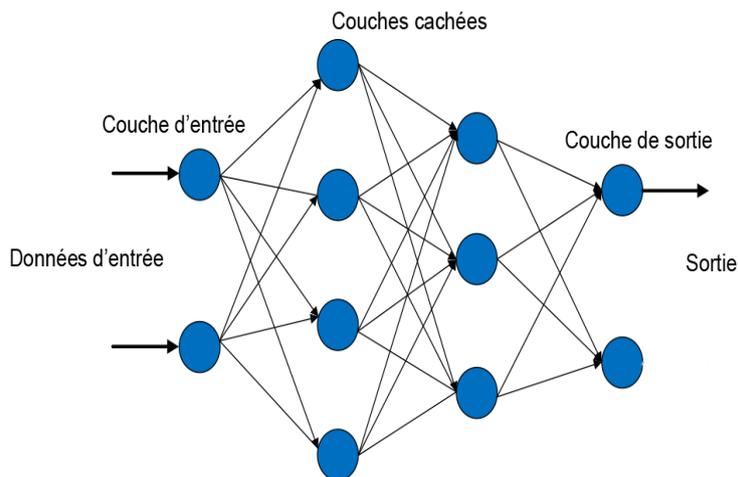


Figure 2.2 : Architecture d'un réseau de neurones artificiels.

### 2.3.4. Composants d'un RNA

Le RNA est constitué des composants principaux suivants :

#### 2.3.4.1. Neurones

Ils prennent une donnée d'entrée et produisent une donnée de sortie. Un certain nombre de neurones sont groupés en couches (ou layers). Tous les neurones du même groupe remplissent un type de fonction similaire.

Les neurones d'entrée reçoivent des données d'entrée, les traitent et les transmettent aux neurones dans la couche suivante. Les neurones cachés prennent les données de sortie des précédents neurones en entrée, calculent de nouvelles données de sortie et les transmettent à des couches successives.

Dans un réseau de neurones à plus de 3 couches, les neurones de la dernière couche cachée (hidden layer) transmettent les données de sortie en entrée des neurones de la couche de sortie (output layer). A partir de cela les neurones de la couche de sortie produisent les données de sortie finales.

#### 2.3.4.2. Couches : groupement de neurones

Les couches (ou layers) contiennent des neurones et aident à faire circuler l'information. Il existe au moins deux couches dans un réseau de neurones : la couche d'entrée (input layer) et la couche de sortie (output layer).

Il est tout à fait possible d'avoir un (très) grand nombre de couches dans un réseau de neurones complexe. Plus il y aura de couches, plus le réseau sera profond (deep learning).

Les couches, autres que les couches d'entrée et de sortie, sont appelées les couches cachées (ou hidden layers).

#### 2.3.4.3. Poids et biais : valeurs numériques

Les poids et biais sont des variables du modèle qui sont mises à jour pour améliorer la précision du réseau. Un poids est appliqué à l'entrée de chacun des neurones pour calculer une donnée de sortie. Les réseaux de neurones mettent à jour ces poids de manière continue. Il existe donc une boucle de rétroaction mise en œuvre dans la plupart des réseaux de neurones.

Les biais sont également des valeurs numériques qui sont ajoutées une fois que les poids sont appliqués aux valeurs d'entrée. Les poids et les biais sont donc en quelque sorte des valeurs d'auto-apprentissage de nos réseaux de neurones.

### 2.3.4.4. Fonctions d'activation

Comme son nom l'indique, la fonction d'activation est une formule mathématique (algorithme) activée dans certaines circonstances. Elle lisse ou normalise la donnée de sortie avant qu'elle ne soit transmise aux neurones suivants. Ces fonctions aident les réseaux de neurones à apprendre et à s'améliorer.

Lorsque les neurones calculent la somme pondérée des valeurs d'entrée + le biais, elles sont transmises à la fonction d'activation, qui vérifie si la valeur calculée est supérieure au seuil requis. Si la valeur calculée est supérieure au seuil requis, la fonction d'activation est activée et une valeur de sortie est calculée. Cette valeur de sortie est ensuite transmise aux couches suivantes ou précédentes (en fonction de la complexité du réseau), ce qui peut aider les réseaux de neurones à modifier le poids de leurs neurones.

Les fonctions d'activation introduisent la non-linéarité dans les RNAs, nécessaire pour résoudre des problèmes complexes.

Si nous traçons les sorties non linéaires produites par les fonctions d'activation, nous obtiendrons une courbure. La pente de la courbe est utilisée pour calculer le gradient. Et le gradient nous aide à comprendre le taux de changement et les relations entre les variables. À partir des relations, les algorithmes sont optimisés et les poids sont mis à jour.

Il existe un grand nombre de fonctions d'activation. Certaines des fonctions d'activation couramment utilisées sont résumées dans le Tableau.2.1.

Tableau 2.1 : Fonctions d'activation couramment utilisées.

Fonction d'activation	Equation	Plage d'entrée et de sortie	Représentation graphique
Linéaire	$f(x) = x$ (2.2)	$R_{input} = [-\infty, +\infty]$ $R_{output} = [0,1]$	
Log-sigmoïde	$f(x) = \frac{1}{1 + e^x}$ (2.3)	$R_{input} = [-\infty, +\infty]$ $R_{output} = [0,1]$	
Tangente hyperbolique	$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$ (2.4)	$R_{input} = [-\infty, +\infty]$ $R_{output} = [-1,1]$	

### 2.3.5. Différents types de RNA

Selon le modèle de connexions entre les neurones et de la propagation des données entre les divers tiers des neurones, les RNAs peuvent être classés en deux catégories, les réseaux feed-forward et les réseaux récurrents ou à retour d'informations [14] (Figure 2.3).

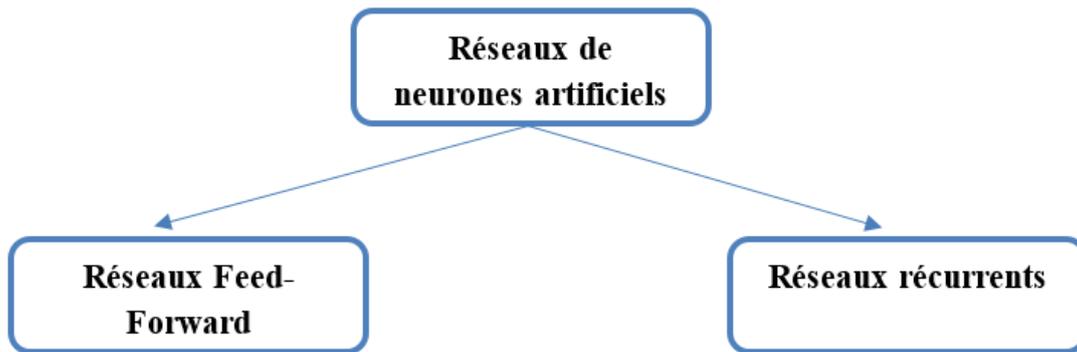


Figure 2.3 : Types de réseaux d neurones artificiels.

### 2.3.5.1. Réseau de neurones feed-forward

Dans ce type de réseaux, les informations passent directement de l'entrée aux nœuds de traitement puis aux sorties. La matrice d'interconnexion est restreinte à un seul sens.

Ils peuvent être constitués que de deux couches (Réseaux Feed-forward monocouches) (voir figure 2.4 a), une couche d'entrée où aucun calcul n'est effectué et une couche de sortie qui est chargée d'effectuer les calculs. Les signaux d'entrée sont directement connectés aux signaux de sortie via les poids. Comme leur architecture peut être constituée d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie (Réseaux Feed-forward multicouches) (voir figure 2.4 b). Dans ce cas, les couches cachées et la couche de sortie effectuent les calculs. Le réseau représenté est entièrement connecté, ce qui signifie qu'un neurone dans n'importe quelle couche doit être lié à tous les neurones de la couche précédente.

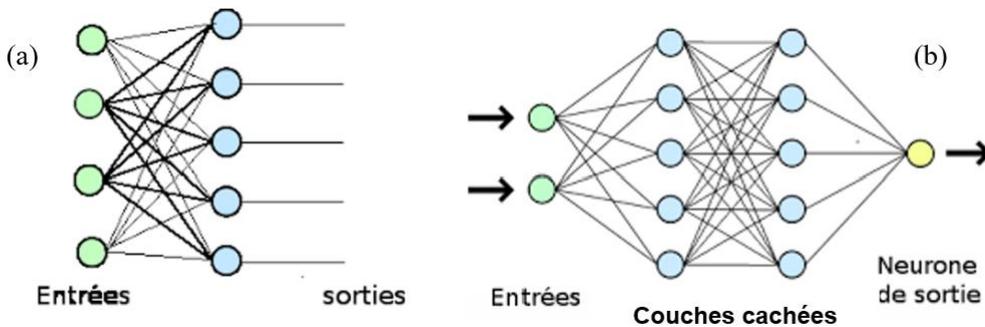


Figure 2.4 : Réseau Feed-forward monocouche (a) et multicouches (b).

### 2.3.5.1. Les réseaux de neurones récurrents (RNN)

Ce sont des réseaux de neurones dans lesquels l'information peut se transmettre dans les deux sens, ils incluent des couches profondes aux premières couches. Ils ont la structure d'un réseau multicouche mais ils ont au moins une connexion de retour et des retards, où la sortie d'un neurone retourne à l'entrée de la couche cachée actuelle (voir figure 2.5). Ils sont plus proches du mécanisme réel de fonctionnement du système nerveux, qui n'est pas à sens unique.

Ainsi, les RNN conviennent aux applications où les informations historiques sont importantes. Ces réseaux aident à prévoir les séries chronologiques dans les applications commerciales et à prévoir les mots dans les applications de type chatbot. Ils peuvent fonctionner avec différentes longueurs d'entrée et de sortie et nécessitent une grande quantité de données [15].

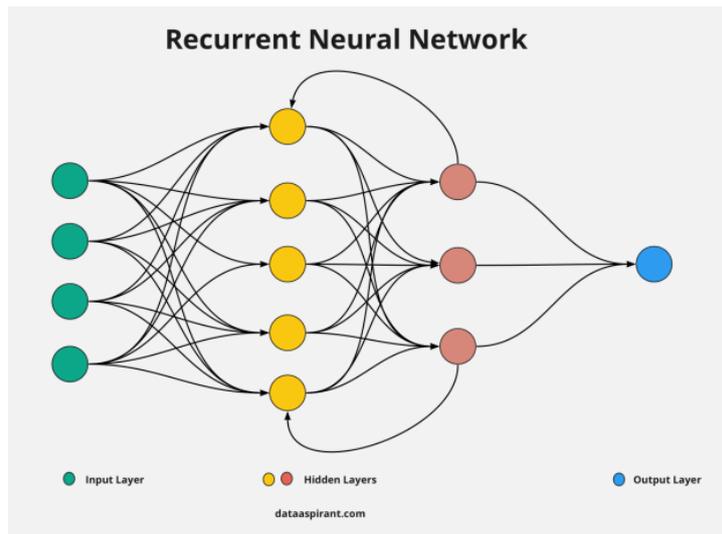


Figure 2.5 : Réseau de neurones récurrent.

### 2.3.6. Apprentissage des RNA

L'apprentissage appelé aussi l'entraînement est une phase de développement d'un réseau de neurone. Elle consiste à estimer les paramètres des neurones du réseau, à fin que celui-ci remplisse au mieux sa tâche qui lui est affectée. Durant ce processus, les poids et les biais de connexion sont modifiés à l'aide de différents algorithmes d'apprentissage [16]. Ces algorithmes d'apprentissage peuvent être classés comme suit :

#### 2.3.6.1. Apprentissage supervisé

Dans l'apprentissage supervisé, les entrées et les sorties sont fournies pour former le réseau. Les entrées sont traitées, les sorties prédites sont comparées aux sorties désirées, puis les poids des connexions sont ajustés pour minimiser la différence entre les deux [16].

Le processus est répété plusieurs fois car les poids sont continuellement ajustés jusqu'à ce que l'erreur soit minimisée. Il existe de nombreux algorithmes d'apprentissage supervisé, notamment la descente de gradient, la rétro propagation, Widrow-Hoff, ...etc. L'algorithme largement utilisé est la rétro-propagation.

- **Algorithme d'apprentissage rétro-propagation :**

Le concept de rétro-propagation (back propagation) aide les réseaux de neurones à améliorer leur précision et permet aux algorithmes d'auto apprendre.

Lorsque les réseaux de neurones sont formés, une gamme de valeurs d'entrée est transmise avec la valeur de sortie attendue correspondante. Les fonctions d'activation produisent alors une sortie à partir de l'ensemble des entrées. Lorsque le résultat réel est différent du résultat attendu, les poids appliqués aux neurones sont mis à jour. Parfois, les résultats attendus et réels se situent dans les limites du seuil d'erreur et le réseau de neurones est considéré comme optimal. Cependant, la sortie attendue est parfois différente de la sortie réelle. En conséquence, les informations sont renvoyées dans le réseau et les poids et biais sont améliorés. Ce processus est de nature récursive et est appelé rétro-propagation.

Ainsi, la rétro-propagation rend les réseaux de neurones intelligents en s'améliorant automatiquement [17].

### **2.3.6.2. Apprentissage non supervisé**

Dans l'apprentissage non supervisé, le RNA ne dispose que des entrées et ne reçoit pas les sorties souhaitées. Le système doit alors trouver un moyen de découvrir les caractéristiques significatives de la population d'entrée à l'aide des algorithmes non supervisés. À l'heure actuelle, l'apprentissage non supervisé n'est pas bien compris et fait toujours l'objet de recherches.

### **2.4. L'algorithme génétique (AG)**

L'algorithme génétique (AG) est un algorithme d'optimisation basé sur les mécanismes de la sélection naturelle et de la génétique. Il combine une stratégie de "survie des plus forts" avec un échange d'information aléatoire mais structuré. Pour un problème pour lequel une solution est inconnue, un ensemble de solutions possibles est créé aléatoirement. On appelle cet ensemble la population. Les caractéristiques (ou variables à déterminer) sont alors utilisées dans des séquences de gènes qui seront combinées avec d'autres gènes pour former des chromosomes et par après des individus. Chaque solution est associée à un individu, et cet individu est évalué et classifié selon sa ressemblance avec la meilleure, mais encore inconnue, solution au problème (figure 2.6). Il peut être démontré qu'en utilisant un processus de sélection naturelle inspiré de Darwin, cette méthode convergera graduellement à une solution [18].

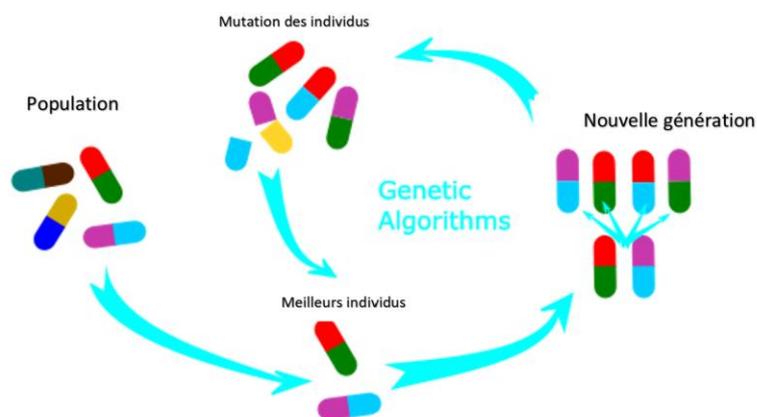


Figure 2.6 : Algorithme génétique.

### 2.4.1. Principes généraux des Algorithmes Génétiques

Pour utiliser un Algorithme Génétique pour un problème particulier, on doit donc disposer des cinq éléments suivants :

- **Le codage des solutions (individus) :** associe à chacun des points de l'espace d'états une structure de données. Elle vient généralement après une phase de modélisation mathématique du problème traité. La qualité du codage conditionne le succès de l'algorithme.
- **Une méthode de génération de la population initiale :** la population d'individus produite initialement qui servira de base pour les générations futures doit être non homogène.
- **Une fonction à optimiser :** ou fonction d'évaluation de l'individu. Cette fonction retourne une valeur réelle appelée fitness, qui va permettre de déterminer la probabilité de sélection d'un individu.
- **Les opérateurs génétiques :** permettent de diversifier la population au cours des générations et d'explorer l'espace d'états. Le croisement recompose les gènes d'individus de la population. La mutation entraîne des altérations minimales sur les individus pour éviter la convergence rapide de la population. La sélection favorise les meilleurs individus.
- **Les paramètres de dimensionnement :** taille de la population, nombre total de générations ou critère d'arrêt, probabilités d'application des opérateurs de croisement et de mutation.

### 2.4.2. Fonctionnement d'un algorithme génétique

L'AG effectue plusieurs opérations pour obtenir une solution optimale. Ces opérations sont présentées sur l'organigramme de la figure 2.7.

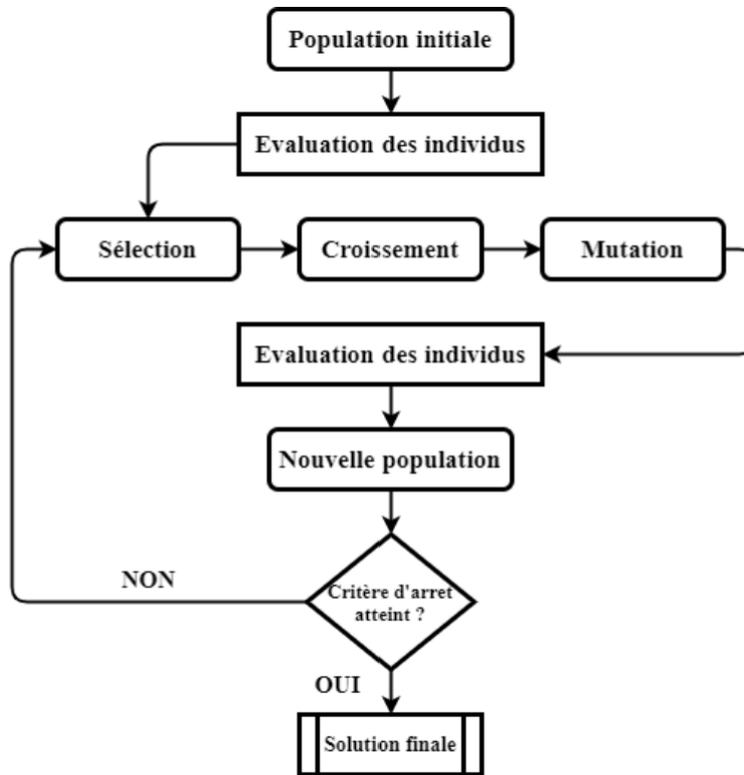


Figure 2.7 : Organigramme de l'algorithme génétique.

Une population initiale est générée aléatoirement, chaque variable de la solution possible connue sous le nom de solution candidate ou individu est désignée par une chaîne binaire constituée d'un chromosome. La population de chromosomes forme une génération qui est manipulée en fonction de la règle évolutive de survie. L'objectif principal de l'étape d'initialisation est de répartir les solutions autour de l'espace de recherche aussi uniformément que possible pour augmenter la diversité de la population et avoir une meilleure chance de trouver des régions prometteuses. Une fonction de fitness est utilisée pour évaluer les valeurs de fitness de ces chromosomes.

### 2.4.2.1. Le croisement

Le croisement utilisé par les algorithmes génétiques est la transposition informatique du mécanisme qui permet, dans la nature, la production de chromosomes qui héritent partiellement des caractéristiques des parents. Son rôle fondamental est de permettre la recombinaison des informations présentes dans le patrimoine génétique de la population. En effet, plus le nombre de points de croisements sera grand et plus la probabilité de croisement sera élevée plus il y aura d'échange de segments, donc d'échange de paramètres, d'information, et plus le nombre de points de croisements sera petit et plus la probabilité de croisement sera faible, moins le croisement apportera de diversité.

### 2.4.2.2. La mutation

L'opérateur de mutation, assure le brassage et la recombinaison des gènes parentaux, permettant de diversifier la future population afin d'éviter une convergence rapide vers une solution optimale localement.

Étant aléatoire, cet opérateur agit selon une probabilité  $P_c$  fixée par l'utilisateur en fonction du problème à optimiser.

On trouve plusieurs stratégies de mutation :

- **La mutation uni-point** : ce type de mutation se fait par altération d'une seule valeur sur le chromosome.
- **La mutation bipoints et multipoints** : cette mutation se fait par altération de plusieurs valeurs sur le chromosome.
- **La mutation par valeurs** : la mutation par valeur se fait par transformation d'une valeur donnée en une autre valeur déterminée, sur tous les gènes du chromosome.

### 2.4.2. 3. La sélection

La sélection permet aux individus d'une population de survivre, de se reproduire ou de mourir, selon leur adaptation. En règle générale, la probabilité de survie d'un individu dépendra directement de son efficacité relative dans la population.

Il s'agira donc de privilégier les individus ayant un "score" d'adaptation le plus élevé ; et de pénaliser ceux avec une faible adaptation. On note que cette adaptation est liée directement à la fonction objective

**2.5. Application des techniques d'intelligence artificielle pour la prédiction et l'optimisation de la production du biogaz**

Plusieurs travaux ont appliqué l'approche des réseaux de neurones artificiels (RNA) et l'algorithme génétique (AG) comme outil efficace pour la prédiction et l'optimisation de la production de biogaz par méthanisation. Quelques exemples de ces travaux sont résumés dans le tableau 2.2.

Type de substrat	Paramètres D'entrée	Paramètre de sortie	Fonction d'activation	Résultat	Réf
Déchets organiques des décharges (2010)	ST, TVS PH Température	volume du méthane	Sigmoïde	Les RNA ont prouvé leur robustesse dans la prédiction de la production de biogaz avec un $R^2 = 0.87$ .	[19]
Mixte de sciure de bois ; Bouse de vache ; Tige de bananier ; Huiles de cuisson ; Déchet de papier ;  (2012)	Type de substrats	Volume de biogaz	Sigmoïde	L'intelligence artificielle a permis de trouver une combinaison de substrat performante pour une production de biogaz optimal	[20]
Eaux usées (2013)	Fractions de boues industrielles des industries papetière,	Rendement de méthane	Linéaire	La modélisation du traitement des boues industrielles par les RNA a donné l'impact de chaque boue en Co digestion sur la	[21]

	chimique, pétrochimique, automobile et agro- alimentaire			quantité de méthane produite	
Déchets de bétail (2014)	Le débit Matière sèche Solide volatile PH Température	Production de biogaz	Linéaire	Ce travail démontre l'utilisation du réseau NARX pour modéliser la dynamique d'un digesteur anaérobie de grande taille. Avec une prédiction de taux de production quotidienne de biogaz avec un écart de $\pm 8\%$	[22]
Graines de Karanja et bouse de bétail (2015)	PH Tempe de digestion Rapport C/N	Rendement du biogaz.	Linéaire	Un RNA a été utilisé pour effectuer la prédiction de la meilleure combinaison de paramètres et le GA a été utilisé pour optimiser les paramètres opérationnels qui affectent la quantité de biogaz.	[23]
Déchets solides municipaux (2016)	PH Teneur en humidité TVS Acide gras volatile	La teneur en méthane dans un rendement de biogaz.	Linéaire	Les performances des ensembles de données d'apprentissage et de validation ont montré un coefficient de corrélation de 0,915 et 0,884, indiquant respectivement une bonne capacité de généralisation du modèle.	[24]
Déchets alimentaire (2017)	Solides totaux PH Température Rapport C/A	Quantité de Biogaz	Linéaire	La méthode d'intelligence artificielle ont prouvé leur efficacité en atteignent leur objectif de biogaz	[25]

	Prétraitement				
Composte de champignons usés (2018)	Rapport C/A Température Tempe de rétention	Volume de biogaz	Linéaire	Les RNA et l'ANFIS doivent être employé dans les cas où une précision élevée est requise ; ANFIS a prédit avec précision les valeurs de sortie des situations thermophiles et mésophiles.	[26]
Déchets de Gombo (2019)	Température Temps de rétention	Rendement de bio méthane	Sigmoïde	Le prétraitement des déchets de gombo avec des alcalins (NaOH) a amélioré la biodégradabilité anaérobie des déchets de gombo de 45,87 %.  Les RNA ont prouvé leur robustesse dans la prédiction de la production de biogaz	[27]
déchets solides agricoles (2020)	Température Composition du substrat Temps de rétention hydraulique Doses de traitement chimique	Production cumulé de méthane	/	Cette étude confirme la capacité du modèle RNA à prédire le comportement de la digestion anaérobie et identifier les conditions optimales dans un court instant.	[28]
Bouse de vache et déchets de fleurs. (2021)	Demande chimique en oxygène Réduction d'oxydation AGV Taux de	Rendement de biogaz	Sigmoïde	Les modèles RNA pour la prédiction du rendement de biogaz ont montré une excellente capacité à représenter les interrelations entre les variables d'entrée et de sortie.	[29]

	charge Organique PH NH <sub>4</sub>				
Déchets alimentaires, de fruits et de légumes. (2021)	Réacteur/alimentation Solide volatil pH Réacteur à charge organique Temps de rétention Température Volume du réacteur	Volume de Biogaz ;	Log-sigmoïde Tan-sigmoïde	Les surfaces de réponse du modèle RNN se sont avérées utiles pour définir la région optimale pour la production de biogaz ; lorsqu'il est appliqué aux ensembles de données d'entraînement, de test et de validation, le modèle a montré des valeurs acceptables de coefficient de détermination de 0,9929.	[30]
Mixture de déchets organiques. (2021)	Temps de rétention hydraulique ; Rapport C/N ; Solide Volatile ;	Volume de Biogaz ; Pourcentage du Méthane.	Log-sigmoïde Tan-sigmoïde	Les modèles basés sur les RNA couplé à l'algorithme génétique (AG) ont prouvé leur robustesse et leur précision de prédiction de la production de biogaz et du volume de méthane élevée avec des coefficients de détermination de 0.99.	[31]
Effluent de moulin à huile de palme. (2022)	pH ; Demande chimique en oxygène ; Demande biochimique en oxygène (DBO) ; Charge	Pureté du méthane ; Rendement en méthane ; Elimination de la demande chimique en oxygène	Sigmoïde	Les modèles basés sur les réseaux de neurones artificiels (RNA) développés ont réussi à prédire avec précision les propriétés des effluents de l'usine de digestion anaérobie avec un minimum d'erreurs.	[32]

	organique du réacteur (ORL).	(DCO).			
Eaux usées de manioc. (2023)	Temps de digestion ; pH ; Concentration de calcium à base de coquille d'œuf.	Volume de biogaz.	Tan-Sigmoïde	Sept algorithmes de formation différents ont été utilisés pour former le modèle, et un algorithme génétique (GA) a également été mis en œuvre pour optimiser l'architecture ANN, ce qui a entraîné un apprentissage plus rapide et des performances de prédiction plus élevées. Compte tenu de l'ensemble de données, l'algorithme de Levenberg-Marquardt avec une tangente hyperbolique comme fonction de transfert vers les couches cachée et de sortie était le modèle le plus efficace pour prédire le biogaz produit avec une valeur R de 0,9999.	[33]

## **2.6. Conclusion**

En raison de la complexité, la non linéarité et l'incertitude liée au processus de méthanisation ; la modélisation et l'optimisation d'un système de production de biogaz et une tâche complexe c'est pour cela qu'une approche plus développée a été nécessaire.

Ce chapitre nous a démontré que l'intelligence artificielle est l'outil le plus adapté à cette tâche en vue de sa rapidité, sa précision et sa capacité à résoudre plusieurs problèmes simultanément.

## **Chapitre 3**

Prédiction et optimisation de la production de  
biogaz

### 3.1. Introduction

Ce chapitre va présenter la création d'un modèle de réseau de neurones artificiels couplé à l'algorithme génétique (AG) qui permettra de prédire et d'optimiser la production de biogaz par méthanisation. Ce modèle prendra en compte le rapport substrat/inoculum ainsi que le temps de digestion (en jours) comme paramètres d'entrée. Pour mesurer l'efficacité de l'approche développée, le modèle proposé sera évalués en utilisant les indicateurs de performance statistiques tels que le coefficient de corrélation linéaire (R) et l'erreur moyenne (MSE).

### 3.2. Matériel et méthodes

#### 3.2.1. Base de données

Pour le développement du réseau de neurone artificiel qui servira à la prédiction de la production de biogaz par méthanisation, les données expérimentales ont été collectées à partir du travail publie OWAMAHA, H. I., KPESANI, S. C., ALFA, M. I., *et al* [34] où six digesteurs ont été alimentés d'un rapport inoculum / substrat, le substrat étant composé de déchets alimentaire (FW) et de bal de maïs (MH).

Chaque un de ces digesteurs (D-0.25, D-0.5, D-1, D-2, D-4, D-0) à un rapport inoculum/substrat différent. L'objectif de ce travail était de trouver le meilleur rapport I/S pour une production de biogaz optimum. La sélection du meilleur rapport est basée sur le rendement et la linéarité de la production de biogaz.

#### 3.2.2. Normalisation des données

Avant d'analyser une base de données, il est important de normaliser les données pour obtenir des résultats précis. Cette normalisation doit être effectuée sur les variables d'entrée et de sortie. Pour garantir une normalisation adéquate, toutes les données ont été mises à l'échelle dans une plage de [0-1], en se basant sur les valeurs minimales et maximales de chaque catégorie. Pour adapter les données normalisées à la fonction d'activation dans la couche cachée et la couche de sortie du RNA, l'équation (3.1) a été utilisée.

$$X = (X - X_{min}) / (X_{max} - X_{min}) \quad (3.1)$$

$X$  : Valeur normalisée ;

$X_{min}$  : Valeurs minimales de  $X$  ;

$X_{max}$  : Valeurs maximales de X ;

### 3.2.3. Développement du modèle prédictif (RNA)

Un modèle RNA est développé sur Matlab à l'aide de l'outil NN-Toolbox pour prédire la production de biogaz. Le rapport I/S et le temps de digestion (en jours) sont considérés comme paramètres d'entrée. Et le volume de biogaz produit est considéré comme paramètre de sortie.

Les données expérimentales collectées sont séparées en trois ensembles distincts pour entraîner, valider et tester le modèle. Le premier ensemble représente 70% des données et est utilisé pour l'entraînement, tandis que le deuxième ensemble (15%) est utilisé pour la validation et le dernier ensemble (15%), qui est indépendant de l'ensemble d'entraînement, est utilisé pour tester le modèle.

La performance des RNA dépend de plusieurs paramètres, tels que le nombre de couches cachées, le nombre de neurones par couche cachée, la fonction d'activation et l'algorithme d'entraînement. Un faible nombre de neurones peut entraîner une approximation insuffisante, tandis qu'une structure compliquée avec un nombre excessif de neurones et de couches cachées peut prendre plus de temps et ne pas améliorer l'approximation, voire même conduire à un sur ajustement. Ainsi, la précision des RNA dépend de la sélection de paramètres appropriés. Pour trouver le nombre optimal de couches cachées, le nombre optimal de neurones par couche cachée et la fonction d'activation idéale pour une meilleure prédiction des paramètres de fonctionnement et de caractéristiques d'émissions, on utilise la méthode «Essais et erreurs».

Le nombre de neurones est varié de 2 à 10 neurones, le nombre de couches cachées est varié de 1 à 2, et les fonctions d'activations testées pour la couche cachée sont Log-sigmoïde et Tan-sigmoïde. La fonction d'activation utilisée pour la couche de sortie est la fonction linéaire Pure-line. L'algorithme « Back-propagation » a été utilisé pour entraîner les deux modèles. Et l'algorithme d'apprentissage « Levenberg Marquadt » a été utilisé pour construire la structure des réseaux.

### 3.3. Analyses statistiques

Afin d'évaluer les performances et de valider les modèles développés, l'erreur moyenne quadratique (Mean Square Error MSE) qui donne la moyenne de la différence quadratique entre la prévision du modèle et la valeur expérimentale, ainsi que le coefficient de corrélation linéaire R qui quantifie la force du lien linéaire entre les valeurs prédites et les valeurs expérimentales sont utilisés, comme décrit dans l'Eq. (3.2) et l'Eq. (3.3)

$$MSE_{\text{err}}^f = \frac{\sum(E_i - P_i)^2}{N \sum E_i^2} \quad (3.2)$$

$$R = 1 - \frac{\sum_{i=1}^n (E_i - P_i)}{\sum_{i=1}^n (E_i - P_i)} \quad (3.3)$$

$E_i$  : Valeur expérimentale ;

$P_i$  : Valeur prédite ;

$P_{\bar{}}$  : Moyenne des données observées ;

N : Nombre de données ;

Le critère d'ajustement important dans le cas où le but du modèle est la prédiction est le MSE, qui mesure la précision des modèles. Il indique à quel point les données expérimentales se rapprochent des valeurs prédites. Un faible MSE indique un meilleur ajustement. En ce qui concerne le coefficient de corrélation linéaire, R est utilisé pour évaluer l'ajustement des modèles en déterminant la dispersion des données le long de la droite de régression ajustée.

### 3.4. Résultats et discussion

#### 3.4.1. Architecture du réseau de neurone artificiel

Les résultats des essais menés par la méthode Essais et Erreurs (Trial and Error) pour la détermination de l'architecture optimale du RNA pour la prédiction du volume de biogaz, sont illustrés dans les tableaux 3.1 et 3.2, respectivement.

**Tableau 3.1 : Résultats des essais pour une couche caché.**

N° de couches	N° de neurones	Fonction d'activation	MSE	R
1 couche	2	Log-sigmoïde	0.0050212	0.9468
1 couche	4	Log-sigmoïde	0.0049054	0.98226
1 couche	6	Log-sigmoïde	0.0031979	0.98511
1 couche	8	Log-sigmoïde	0.00096257	0.99182
1 couche	10	Log-sigmoïde	$1.8995 \cdot 10^{-5}$	0.99992
1 couche	2	Tan-sigmoïde	0.0041923	0.97561
1 couche	4	Tan-sigmoïde	0.0037538	0.98506
1 couche	6	Tan-sigmoïde	0.0052477	0.97714
1 couche	8	Tan-sigmoïde	0.0012134	0.99125
1 couche	10	Tan-sigmoïde	0.0013724	0.98599

**Tableau 3.2 : Résultats des essais pour deux couches cachées.**

N couches	N° de neurones 1 <sup>ere</sup> couche	N° de neurones 2 <sup>eme</sup> couche	Fonction d'activation	MSE	R
2 couches	2	4	Log-sigmoïde	0.0023224	0.98766
2 couches	2	4	Tan-sigmoïde	0.00014751	0.99935
2 couches	4	6	Log-sigmoïde	3.3082e-05	0.99986
2 couches	4	6	Tan-sigmoïde	0.010245	0.94854

D'après les valeurs des indicateurs de performance MSE et R, l'architecture optimale du réseau de neurones artificiels qui présente une prédiction précise du volume de biogaz se compose d'une couche cachée, qui comprend 10 neurones avec une fonction d'activation log-sigmoïde. Les paramètres détaillés de cette architecture sont présentés dans le tableau 3.3 et illustrés dans la figure 3.1.

**Tableau 3.3 :** Informations détaillé sur le modèle de prédiction RNA.

<b>Paramètres</b>	<b>RNA</b>
<b>N° de couches cachées</b>	1
<b>N° de neurones dans les couches cachées</b>	10
<b>Fonction d'activation</b>	Log-sigmoïde
<b>Algorithme d'entraînement</b>	Trainlm
<b>N° de données d'entraînement</b>	92
<b>N° de données de validation</b>	20
<b>N° de données de test</b>	20
<b>Performance goal</b>	$10^{-10}$
<b>Nombre d'époques</b>	92

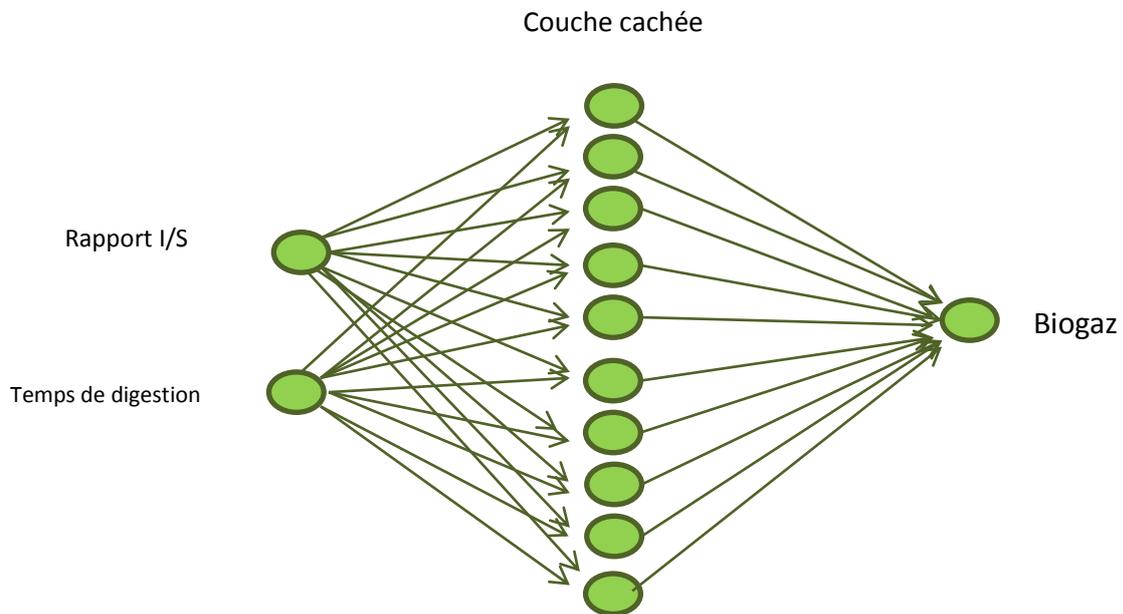
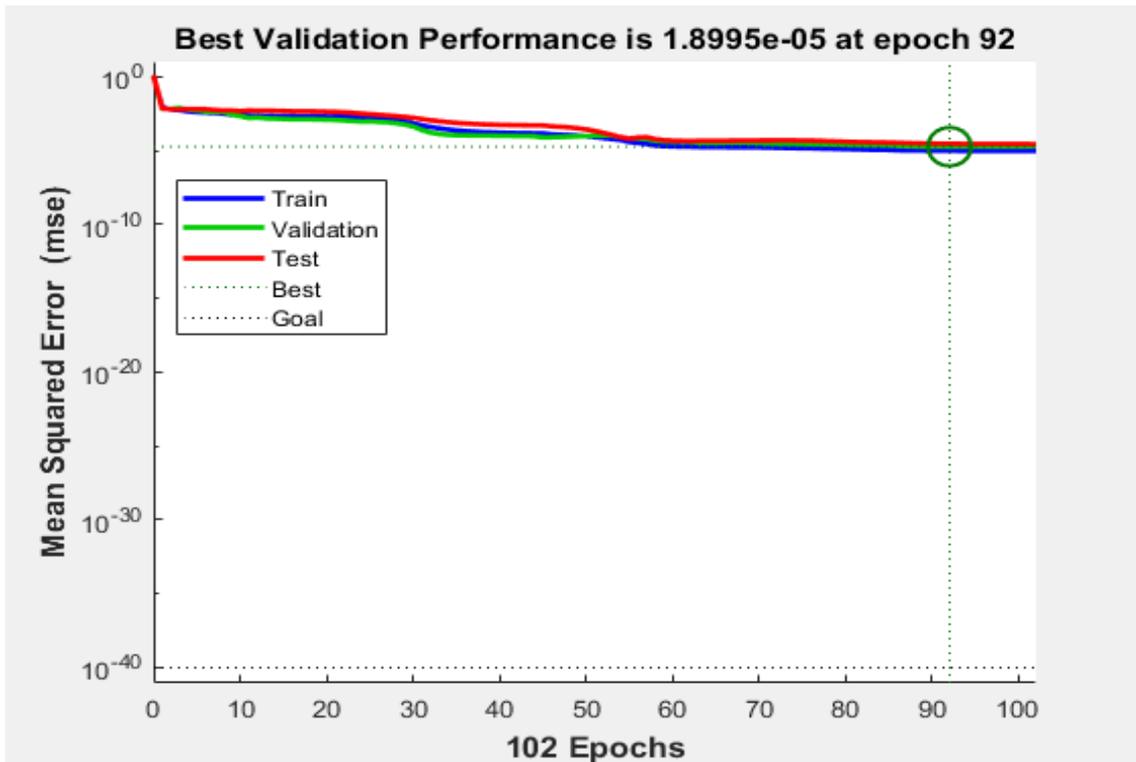


Figure 3.1 : Architecture du modèle RNA pour la prédiction du volume de biogaz.

### 3.4.2. Résultats de la prédiction du volume de biogaz

Un entraînement a été effectué plusieurs fois avec différentes époques, pour atteindre l'objectif de performance souhaité de  $10^{-10}$ . Le changement d'erreur quadratique moyenne (MSE) avec le nombre d'époques au cours du processus d'apprentissage des RNA, pour la prédiction du volume de biogaz est présenté sur la figure 3.2. Comme le montrent la figure, la valeur du MSE a diminué et est restée constante lorsque les époques ont atteint 92 avec une valeur de  $1.8995 \times 10^{-5}$  pour la prédiction du volume de biogaz, les époques sont utilisées pour figer les modèles.



**Figure 3.2 :** Changements de l'erreur quadratique moyenne avec le nombre d'époques au cours du processus d'apprentissage : prédiction du volume de biogaz.

Figure 3.3 présente les courbes de régression des valeurs du volume de biogaz expérimentales par rapport aux valeurs prédites pendant le processus d'entraînement, de validation, de test et de tout l'ensemble de données, respectivement. Les valeurs des R sont présentées dans le Tableau 3.4.

Les valeurs expérimentales du volume de biogaz sont indiquées par T (cible), tandis que les valeurs prédites du volume de biogaz sont indiquées par Y (sortie). La régression linéaire entre T et Y est l'ajustement linéaire et sa forme idéale serait  $Y = T$ . Comme il est observé sur la figure, les données dispersées sont très proches de la ligne  $Y = T$  inclinée à  $45^\circ$  et montrent une forte corrélation entre les valeurs expérimentales et prédites normalisées. D'après les valeurs de R présentées dans le tableau 3.4, on peut observer que toutes les valeurs de R pour le processus d'entraînement, de validation et de test sont supérieures à 0,99. L'ensemble de données a montré une valeur de R maximale de 0.99992 pour la prédiction du volume de biogaz. Les valeurs de R indiquent que 99,99 % de la variation totale a été identifiée et expliquée par les modèles RNA, et correspond aux données expérimentales. La proximité des valeurs R à 1 désignent l'efficacité et la précision de prédiction très élevée du modèle développé. Il reflète que ce modèle donne des performances adaptées et adéquates.

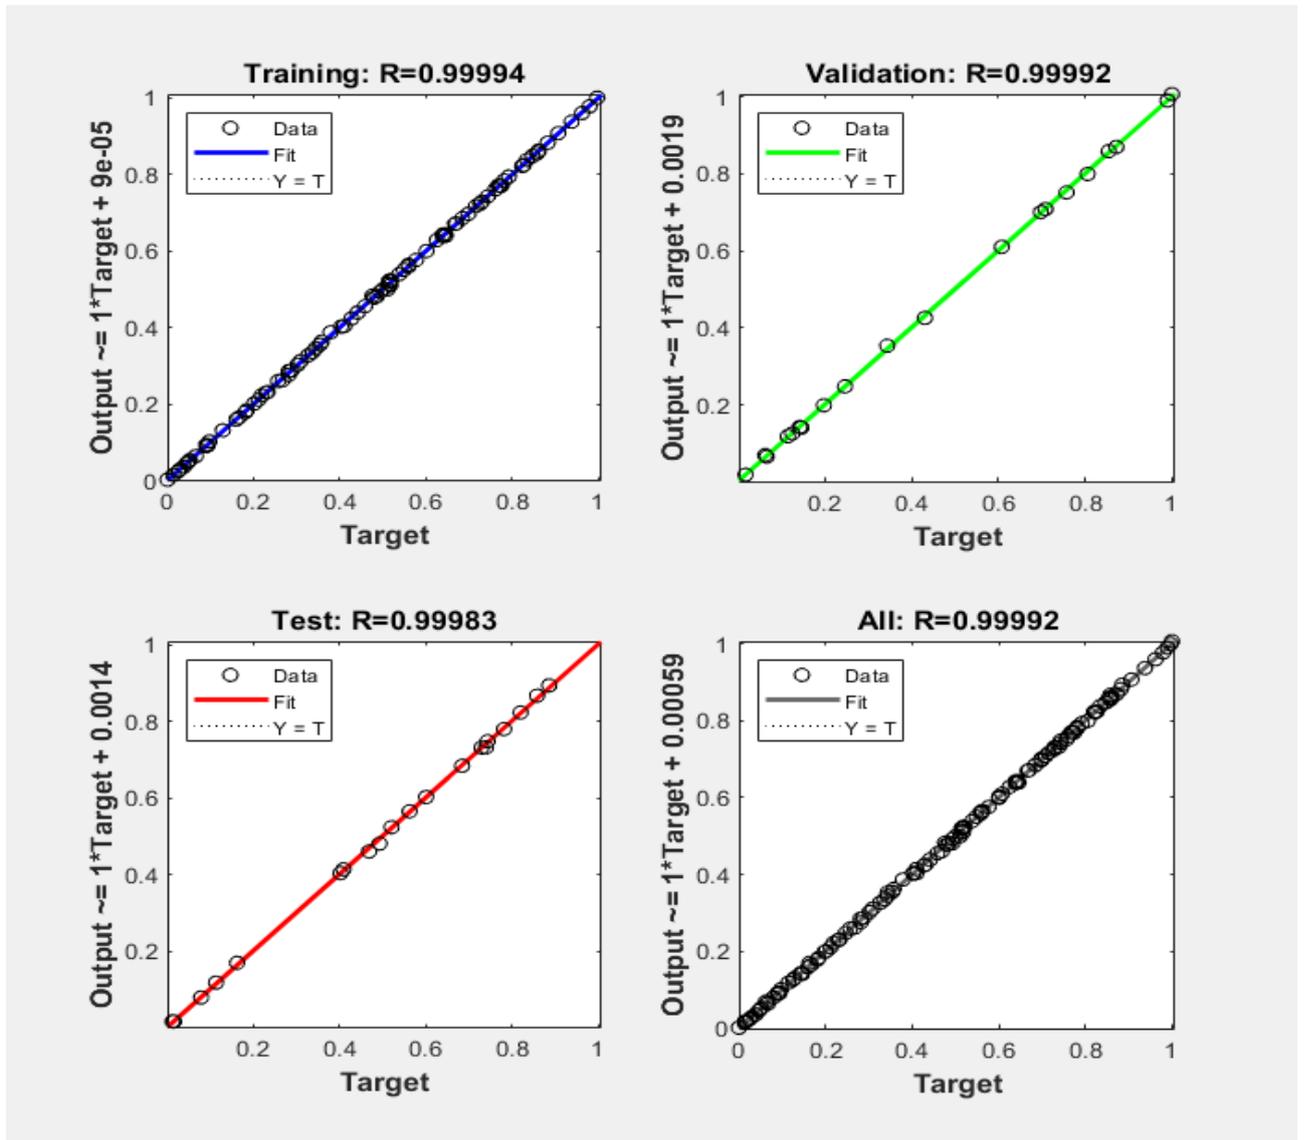
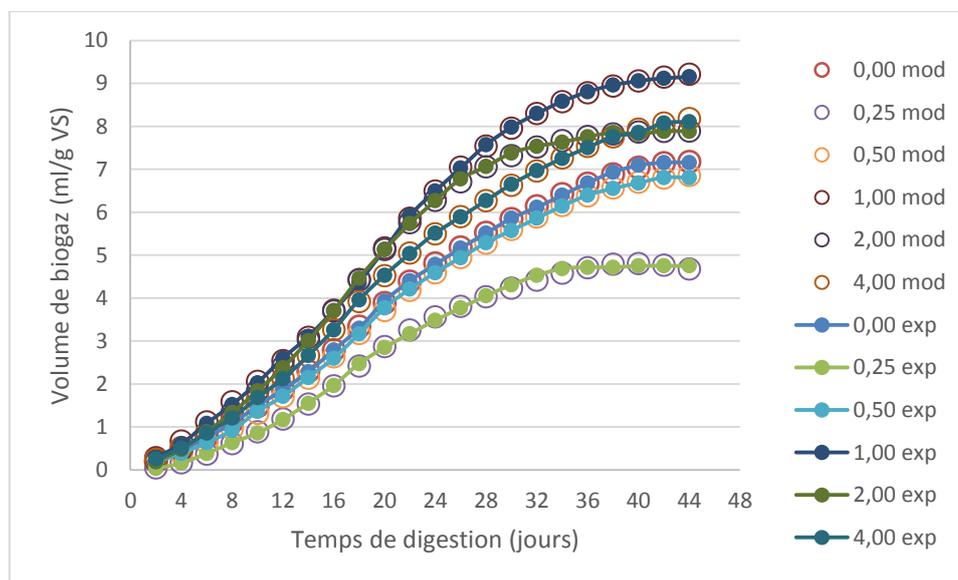


Figure 3.3 : Graphiques de régression du RNA pour la prédiction de biogaz.

Tableau 3.4 : Valeurs de  $R^2$  pour la prédiction du volume de biogaz.

RNA	Processus	R
	Entraînement	0.99994
Volume de biogaz	Validation	0.99992
	Test	0.99983
	Tout l'ensemble de données	0.99992

Figure 3.5 présente les résultats dé-normalisés du volume de biogaz produit expérimentalement par rapports aux résultats prédites par le RNA. On observe que les valeurs prédites sont relativement proches des valeurs expérimentales, voir superposées. Le modèle s'est bien adapté aux données expérimentales présentant un écart inférieur à  $\pm 1\%$ , ce qui est très satisfaisant, et indique une précision de prédiction très élevée. Cela indique l'adéquation de l'approche développée basée sur les réseaux de neurones artificiels, pour la prédiction du volume de biogaz à partir de la Co digestion de déchets alimentaire (FW) et de bal de maïs (MH).



**Figure 3.5 :** Comparaison entre le volume de biogaz produit expérimentalement et prédit par le modèle RNA.

### 3.4.3. Optimisation de la production de biogaz par l’algorithme génétique (AG)

Dans le but de maximiser la production de biogaz à partir de la Co digestion de déchets alimentaire (FW) et de bal de maïs (MH), l’AG est intégrée au modèle basés sur les RNA, afin de déterminer la combinaison optimale du rapport substrat / inoculum et de temps de digestion. Le modèle RNA obtenu précédemment, est intégré en tant que fonction de fitness dans l'AG. Le nombre de générations a été sélectionné pour être 50 et une taille de population de 100. La sortie du modèle qui est le volume de biogaz a été fixé comme un chromosome. Chaque chromosome était composé de deux gènes qui représentent les entrées (le rapport S/I et temps de digestion). La première population est générée et évaluée sur la base de la fonction de fitness. Les opérateurs de sélection, de croisement et de mutation sont appliqués et la combinaison optimale des paramètres d'entrée pour une production maximale de biogaz est déterminée. Les résultats de l'optimisation AG-RNA sont résumés dans le tableau 4.6. Selon le tableau, la quantité maximale de méthane déterminée par AG-RNA était de 9,22 ml/g (VS) avec un rapport de substrat/inoculum de 1,3 et un temps de digestion de 44 jours. Ces résultats ont été comparés à la valeur maximale du biogaz obtenue expérimentalement. OWAMA, H. I. et al [34] ont atteint une production maximale de biogaz 9,15 ml/g (VS), avec une combinaison de rapport de substrat/inoculum de 1 et un nombre de jours de digestion de 44. Les paramètres optimisés n’ont pas été testés expérimentalement, ils peuvent être validés expérimentalement et utilisés après validation pour l'application de la Co digestion de déchets alimentaire (FW) et de bal de maïs (MH) à grande échelle.

**Tableau 3.5 :** Combinaison optimale des paramètres d’entrée pour une production maximale de biogaz déterminée par AG-RNA.

<b>Modèle</b>	<b>Rapport Substrat/inoculum</b>	<b>Temps de digestion (Jours)</b>	<b>Volume du CH<sub>4</sub> (ml/g (VS))</b>
<b>AG-RNA</b>	1,3	44	9,22
<b>EXP</b>	1	44	9.15

### 3.5. Conclusion

Le résultat obtenus à partir des modèles basés sur les réseaux de neurones artificiels ont montré que cette approche se révèle robuste, offrant une capacité prédictive élevée pour l'estimation de la production de biogaz par méthanisation. Ceci est dû à sa rapidité et à sa capacité d'apprentissage.

## **Conclusion générale et perspectives**

### Conclusion générale

Les techniques des réseaux de neurones artificiels (RNA) et l'algorithme génétique (AG) ont été combinés, pour développer un modèle global multiparamétrique, permettant la prédiction de la production de biogaz par méthanisation à partir de la Co-digestion de déchets alimentaire (FW) et de bal de maïs (MH). L'effet du rapport substrat/ inoculum, et du temps de digestion a été pris en compte. Une architecture de réseaux de neurones, a été déterminée à l'aide de la technique Essais et Erreurs.

Le modèle développé était capable de prédire le volume de biogaz avec une précision élevée montrant des valeurs de l'erreur moyenne quadratique très proche de 0 et des valeurs de coefficient de corrélation linéaire (R) très proche de 1. Ces résultats ont prouvé que cette approche se révèle robuste et performante, offrant une capacité prédictive élevée pour la prédiction de la production de biogaz par méthanisation à partir de la Co-digestion de déchets alimentaire (FW) et de bal de maïs (MH). Ceci est dû à sa rapidité et à sa capacité d'apprentissage.

La combinaison du modèle développé basé sur les réseaux de neurones artificiels, à l'algorithme d'optimisation « Algorithme génétique » a permis la détermination de la combinaison optimale des paramètres d'entrée qui sont le rapport substrat/inoculum et le temps de digestion, pour une production maximale de biogaz par méthanisation à partir de la Co-digestion de déchets alimentaire (FW) et de bal de maïs (MH). Prouvant ainsi, l'efficacité de l'approche hybride AG-RNA pour la prédiction et l'optimisation de ce procédé.

Ces modèles hybrides permettent aux exploitants des procédés de méthanisation de contrôler, d'évaluer et d'anticiper les paramètres opérationnels sans compromettre la stabilité du processus, ce qui se traduit par des procédés de production de biogaz améliorés et plus efficaces. Cette avancée revêt une importance capitale pour la préservation de l'environnement à long terme et la prospérité économique des systèmes de digestion anaérobie.

### **Perspectives**

Nous proposons d'enrichir la base de données développée en incluant davantage de données, ainsi que d'autres paramètres non pris en compte dans cette étude, tels que la température, le pH, la charge organique, etc. et le perfectionnement du réseau de neurones, afin d'obtenir des prédictions plus précises et d'optimiser les paramètres d'entrée pour une production de biogaz et de méthane optimale. Une fois amélioré, ce modèle multi-paramètres global servira de base de données précieuse pour l'industrie de la méthanisation et pourra être utilisé dans la surveillance et le contrôle des systèmes de digestion.

---

**Références**

- [1] Samer, M. (Ed.). (2022). Biomass, Biorefineries and Bioeconomy. BoD–Books on Demand.
- [2] Moletta, R., 2015. La méthanisation 2ème édition. Lavoisier.
- [3] Batstone, D.J., Keller, J., Angelidaki, I., Kalyuzhnyi, S. V., Pavlostathis, S.G., Rozzi, A., Sanders, W.T., Siegrist, H., Vavilin, V.A., 2002. The IWA Anaerobic Digestion Model No 1 (ADM1). *Water Sci. Technol.* 45, 65–73. <https://doi.org/10.2166/wst.2002.0292>.
- [4] Madsen, M., Holm-Nielsen, J.B., Esbensen, K.H., 2011. Monitoring of anaerobic digestion processes: A review perspective. *Renew. Sustain. Energy Rev.* 15, 3141–3155. <https://doi.org/10.1016/J.RSER.2011.04.026>
- [5] Mata-Alvarez, J., Dosta, J., Romero-Güiza, M.S., Fonoll, X., Peces, M., Astals, S., 2014a. A critical review on anaerobic co-digestion achievements between 2010 and 2013. *Renew. Sustain. Energy Rev.* 36, 412–427. <https://doi.org/10.1016/j.rser.2014.04.039>.
- [6] Bernet, N., Buffière, P., 2008. Caractérisation de la mise en oeuvre de la méthanisation. Moletta, R., *La méthanisation* 87–113.
- [7] Mao, C., Feng, Y., Wang, X., Ren, G., 2015b. Review on research achievements of biogas from anaerobic digestion. *Renew. Sustain. Energy Rev.* 45, 540–555. <https://doi.org/10.1016/J.RSER.2015.02.032>.
- [8] Al Seadi, T., 2008. Biogas handbook.
- [9] Kothari, R., Pandey, A.K., Kumar, S., Tyagi, V. V., Tyagi, S.K., 2014. Different aspects of dry anaerobic digestion for bio-energy : An overview. *Renew. Sustain. Energy Rev.* 39, 174–195. <https://doi.org/10.1016/J.RSER.2014.07.011>.
- [10] Weiland, P., 2010. Biogas production : current state and perspectives. *Appl. Microbiol. Biotechnol.* 85, 849–860.
- [11] Ginsberg, M. (2012). *Essentials of artificial intelligence*. Newnes.
- [12] Zilouchian, A., 2001. *Fundamentals of Neural Networks. Intell. Control Syst. Using Soft Comput. Methodol.* <https://doi.org/10.1201/9781420058147.ch>.

- [13] Wang, G., Zhang, Y., Ye, X., & Mou, X. (2019). Artificial neural networks. In *Machine Learning for Tomographic Imaging*. IOP Publishing.
- [14] Anthony, M., Bartlett, P.L., 2009. *Neural network learning : Theoretical foundations*. cambridge university press.
- [15] Medsker, L., & Jain, L. C. (Eds.). (1999). *Recurrent neural networks : design and applications*. CRC press.
- [16] Akbari, M., Asadi, P., Givi, M.K.B., Khodabandehlouie, G., 2014. Artificial neural network and optimization, *Advances in Friction-Stir Welding and Processing*. <https://doi.org/10.1533/9780857094551.543>
- [17] Sazli, M. H. (2006). A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 50(01).
- [18] Kramer, O., & Kramer, O. (2017). Genetic algorithms (pp. 11-19). Springer International Publishing.
- [19] Qdais, H. A., Hani, K. B., & Shatnawi, N. (2010). Modeling and optimization of biogas production from a waste digester using artificial neural network and genetic algorithm. *Resources, Conservation and Recycling*, 54(6), 359-363.
- [20] Kana, E. G., Oloke, J. K., Lateef, A., & Adesiyun, M. O. (2012). Modeling and optimization of biogas production on saw dust and other co-substrates using artificial neural network and genetic algorithm. *Renewable energy*, 46, 276-281.
- [21] Mahanty, B., Zafar, M., & Park, H. S. (2013). Characterization of co-digestion of industrial sludges for biogas production by artificial neural network and statistical regression models. *Environmental technology*, 34(13-14), 2145-2153.
- [22] Dhussa, A. K., Sambhi, S. S., Kumar, S., Kumar, S., & Kumar, S. (2014). Nonlinear Autoregressive Exogenous modeling of a large anaerobic digester producing biogas from cattle waste. *Bioresource technology*, 170, 342-349.
- [23] Barik, D., & Murugan, S. (2015). An artificial neural network and genetic algorithm optimized model for biogas production from co-digestion of seed cake of karanja and cattle dung. *Waste and biomass valorization*, 6, 1015-1027.

- [24] Nair, V. V., Dhar, H., Kumar, S., Thalla, A. K., Mukherjee, S., & Wong, J. W. (2016). Artificial neural network based modeling to evaluate methane yield from biogas in a laboratory-scale anaerobic bioreactor. *Bioresource technology*, 217, 90-99.
- [25] Deepanraj, B., Sivasubramanian, V., & Jayaraj, S. (2017). Multi-response optimization of process parameters in biogas production from food waste using Taguchi–Grey relational analysis. *Energy Conversion and Management*, 141, 429-438.
- [26] Najafi, B., & Ardabili, S. F. (2018). Application of ANFIS, ANN, and logistic methods in estimating biogas production from spent mushroom compost (SMC). *Resources, Conservation and Recycling*, 133, 169-178.
- [27] Ugwu, SN, & Enweremadu, CC (2019). Effets des prétraitements et de la co-digestion sur la production de biogaz à partir des déchets de gombo. *Journal des énergies renouvelables et durables*, 11 (1), 013101
- [28] Almomani, F. (2020). Prediction of biogas production from chemically treated co-digested agricultural waste using artificial neural network. *Fuel*, 280, 118573.
- [29] Quashie, F. K., Fang, A., Wei, L., Kabutey, F. T., & Xing, D. (2021). Prediction of biogas production from food waste in a continuous stirred microbial electrolysis cell (CSMEC) with backpropagation artificial neural network. *Biomass Conversion and Biorefinery*, 1-12
- [30] Neto, J. G., Ozorio, L. V., de Abreu, T. C. C., Dos Santos, B. F., & Pradelle, F. (2021). Modeling of biogas production from food, fruits and vegetables wastes using artificial neural network (ANN). *Fuel*, 285, 119081.
- [31] Mougari, N. E., Largeau, J. F., Himrane, N., Hachemi, M., & Tazerout, M. (2021). Application of artificial neural network and kinetic modeling for the prediction of biogas and methane production in anaerobic digestion of several organic wastes. *International Journal of Green Energy*, 18(15), 1584-1596.
- [32] Chen, W. Y., Chan, Y. J., Lim, J. W., Liew, C. S., Mohamad, M., Ho, C. D., ... & Tan, W. N. (2022). Artificial neural network (ANN) modelling for biogas production in pre-commercialized integrated anaerobic-aerobic bioreactors (IAAB). *Water*, 14(9), 1410.

- [33] Cruz, I. A., Nascimento, V. R. S., Felisardo, R. J. A., dos Santos, A. M. G., de Jesus, A. A., de Vasconcelos, B. R., ... & Ferreira, L. F. R. (2023). Evaluation of artificial neural network models for predictive monitoring of biogas production from cassava wastewater: A training algorithms approach. *Biomass and Bioenergy*, 175, 106869.
- [34] Owamah, H. I., Ikpeseni, S. C., Alfa, M. I., Oyebisi, S. O., Gopikumar, S., Samuel, O. D., & Ilabor, S. C. (2022). Influence of inoculum/substrate ratio on biogas yield and kinetics from the anaerobic co-digestion of food waste and maize husk. *TIDEE : TERI Information Digest on Energy and Environment*, 21(1), 39-40.