

# Département de Génie de l'Environnement

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE  
SCIENTIFIQUE.



UNIVERSITÉ SALAH BOUBNIDER, CONSTANTINE03  
FACULTÉ DE GÉNIE DES PROCÉDÉS  
DÉPARTEMENT DE GÉNIE DE L'ENVIRONNEMENT

Ordre N°:.....

Series:.....

Memory

PRESENTED FOR OBTAINING THE MASTER'S DIPLOMA  
IN PROCESS ENGINEERING  
OPTION: ENVIRONMENTAL PROCESS ENGINEERING

SENSITIVITY ANALYSIS AND CALIBRATION OF THE  
INTEGRATE ASM1-SMP MODEL IN A SUBMERGED  
MEMBRANE BIOREACTOR FOR WASTEWATER  
TREATMENT UNDER DIFFERENT COD/N RATIOS.

Presented by:

BENABDESSADOK DOUNIA  
MEZOUARI SARA  
KHELIFA DALIA YASSEMINE

Supervised by:

Dr. BENALIOUCHE Hana

Academic year

2022-2023

Session: June

## **Summary**

|                            |    |
|----------------------------|----|
| List of figures.....       |    |
| List of tables.....        |    |
| List of abbreviations..... |    |
| Abstract.....              |    |
| Résumé.....                |    |
| General introduction.....  | 01 |

## **Chapter I: Bibliographic synthesis**

### **Part 1: Membrane bioreactor (MBR)**

|   |    |
|---|----|
| I.1.1.Membrane bioreactor (MBR).....              | 07 |
| I.1.1.1 Membrane bioreactor process.....          | 07 |
| I.1.1.2.Advantages of membrane bioreactor.....    | 09 |
| I.1.1.3.Disadvantages of membrane bioreactor..... | 10 |
| I.1.2. Definition of clogging.....                | 11 |
| I.1.2.1. Soluble microbial products.....          | 12 |
| I.1.2.2. The role of SMP in clogging.....         | 13 |
| I.1.2.3. Modeling membrane bioreactor system..... | 14 |
| I.1.2.4. Activated sludge model No1.....          | 14 |
| I.1.3. The integrated ASM1 model.....             | 15 |

### **Part 2: Sensitivity analysis**

|  |    |
|--|----|
| I.2.1. Definition of sensitivity analysis in wastewater treatment.....   | 18 |
| I.2.2. Methods of sensitivity analysis in wastewater treatment.....      | 18 |
| I.2.3. Types of sensitivity analysis in wastewater treatment.....        | 19 |
| I.3.4. Applications of sensitivity analysis in wastewater treatment..... | 20 |

I.2.5. The advantages of sensitivity analysis in wastewater treatment.....21

I.2.6. The disadvantages of sensitivity analysis in wastewater treatment.....22

## **Part 3: Statistical analysis model**

I.3.1.Project to Latent Structures (PLS).....25

I.3.1.1.History.....25

I.3.1.2. Definition of PLS.....26

I.3.1.3. Projection to latent structures method.....27

I.3.1.4. Application of PLS in membrane bioreactor.....28

I.3.1.5. The advantages of PLS.....29

I.3.1.6. The disadvantages of PLS.....30

I.3.2.Artificial neural network (ANN).....31

I.3.2.1.History.....31

I.3.2.2. Definition of ANN.....32

I.3.2.3.principles of an Artificial Neural Network.....33

I.3.2.4. Structure and work of artificial neural network.....34

I.3.2.5. Effects of neuron number.....36

I.3.2.6. Effects of layer number.....37

I.3.2.7. The application of artificial neural network in membrane bioreactor.....38

I.3.2.8. Advantages of ANN.....39

I.3.2.9. Disadvantages of ANN.....40

I.3.3. Multiple linear regression (MLR).....41

I.3.3.1.History.....41

I.3.3.2. Definition of MLR.....42

|  |    |
|--|----|
| I.3.3.3. Process of MLR in MBR.....                                | 43 |
| I.3.3.4. Advantages of MLR.....                                    | 44 |
| I.3.3.5. Disadvantages of MLR.....                                 | 45 |
| I.3.4. principal component analysis (PCA).....                     | 46 |
| I.3.4.1.History.....   | 46 |
| I.3.4.2. Definition of "PCA".....                                  | 47 |
| I.3.4.3. Utilization of PCA in MBR.....                            | 47 |
| I.3.4.4. Advantages of PCA.....                                    | 48 |
| I.3.4.5. Disadvantages of PCA.....                                 | 49 |
| I.3.5. structural modeling equations(SME).....                     | 50 |
| I.3.5.1.History.....   | 50 |
| I.3.5.2. Definition of SME.....                                    | 51 |
| I.3.5.3. Applications of Structural modeling equations in MBR..... | 52 |
| I.3.5.4. Advantages of structural modeling equations.....          | 53 |
| I.3.5.5. Disadvantages of structural modeling equations.....       | 54 |
| I.3.6. Conclusion.....   | 55 |

## **Chapter II: Materials and Methods.**

|  |    |
|--|----|
| II.1 Experimental System .....                       | 57 |
| II.2 Hybrid model development .....                  | 58 |
| II.2.1 Development of the ASM-SMP.....               | 58 |
| II.2.1.1 Brief description of the model.....         | 58 |
| II.2.1.2 Mass balance in steady state condition..... | 61 |
| II..3 Model calibration using AQUASSIM SOFTWARE..... | 62 |

|   |    |
|---|----|
| II.4.The Proposed Modeling Methods.....         | 66 |
| II.5. Software Used in Simulation .....         | 67 |
| II.5.1. Spss Statistical Analysis Software..... | 67 |
| II.6. Conclusion.....                           | 68 |

### **Chapter III: Results and Discussions.**

|  |     |
|--|-----|
| III. 1 Introduction.....   | 70  |
| III.2 Development of a hybrid model strategy for monitoring fouling membrane bioreactors.  | 72  |
| III. 3. Sensitivity and optimization hybrid modeling.....                                  | 75  |
| III. 3.1 Sensitivity analysis using Projection to Latent Structure (PLS).....              | 75  |
| III. 3.1 .1. Impact of variable on SMP: using MATLAB and AQUASIM plateform data.....       | 75  |
| III. 3.1 .2. Impact of variable on $SMP_{UAP}$ : using MATLAB and AQUASIM plateform data.. | 81  |
| III. 3.1 .3. Impact of variable on $SMP_{BAP}$ : using MATLAB and AQUASIM plateform data.  | 87  |
| III. 3.1 .4. PLS model prediction.....   | 93  |
| III. 3.1 .4. 1. Actual and predicted model.....  | 96  |
| III. 3.1 .5. Impact of VIP: using MATLAB and AQUASIM plateform data.....                   | 106 |
| III. 3.1 .5.1 Impact of VIP: SMP.....  | 106 |
| III. 3.1 .5.2 Impact of VIP: SMP UAP.....  | 107 |
| III. 3.1 .5.2 Impact of VIP: SMP BAP.....  | 112 |
| III.3.2. Structural equation modelling (MES).....  | 116 |
| III.3.3. principal component analysis (PCA).....   | 124 |
| III.3.4.Artificial neural networks (ANN).....  | 134 |
| III.3.4.1. Training and testing model.....   | 134 |
| Conclusion.....  | 139 |
| Reference bibliographic.....   | 141 |

## Abstract

A study focused on developing a model for predicting soluble microbial products (SMP) in a Membrane Bioreactor (MBR) and addressing the issue of membrane fouling, which limits the efficiency of MBR systems. MBRs are widely used for wastewater treatment and produce high-quality effluent that meets regulatory standards.

Membrane fouling is a major challenge in MBR applications, leading to clogging of the pores in the membrane and reduced permeability. To overcome this issue, the study aims to establish a model that can predict SMP and membrane fouling by considering various parameters and limiting variables. The studied of sensitivity analysis by statistical analysis is performed to find out the most influential parameters in producing SMP (**SUAP, SBAP**) and by the way to calibrated the output integrate model (**ASM1-SMP**).

Four modeling techniques are employed: multivariate projection to latent structures (PLS), artificial neural network (ANN), Principal Component analysis (PCA) and Modeling Equation Structural (MES) models. PLS and ANN models were developed and analyzed to determine the factors influencing SMP production and membrane fouling. The models take into account the biological aspects of MBR and predict the SMP product. Both MES and PCA are valuable tools in exploratory data analysis and provide a basis for subsequent statistical modeling. MES allows gaining an overall understanding of the dataset, identifying trends, and detecting potential issues such as outliers or missing data. PCA, on the other hand, helps to identify the most important variables driving the patterns in the data, facilitates data visualization, and reduces the complexity of the dataset for further analysis

From overall performance, projection to latent structures (PLS) technique was the most performed methods of sensitivity, in term of regression, predicted, RMSE,  $R^2$ . , the application of integrate ASM1-SMP to MBRs requires supplying the model with updated input data that depends on laborious analysis (respirometric analysis and on line measurement). However, the present work shows that modeling and predicted ASM1-SMP model using hybrid modeling especially PLS model to correlate them with relevant parameters can significantly improve the outputs prediction (SMP SMPUAP SMPBAP), without requiring further laboratory analysis. For the three outputs modeled in this study (SMP, SMPUAP and SMP BAP), the best results were achieved when using inputs from Using ALL data (strategy 3). All experimental parameters data and all ASM1-SMP parameters data showed to be a comprehensive monitoring tool that can be used in hybrid models, to complement the mechanistic information described by an ASM1-SMP in order to obtain good prediction of key MBR performance indicators, fouling parameters in the case of this study.

**Keywords:** Membrane bioreactor, wastewater treatment, fouling, multivariate projection to latent structures (PLS), artificial neural network (ANN), hybrid model, prediction, Principal Component analysis(PCA), Modelling Equation Structural(MES),Smp,Suap,Sbap,sensitivity analysis, statistical analysis.

## Résumé

Une étude a porté sur l’élaboration d’un modèle pour prédire les produits microbiens solubles (SMP) dans un bioréacteurs à Membrane (MBR) et sur la question de l’encrassement des membranes, qui limite l’efficacité des systèmes MBR. Les MRB sont largement utilisés pour le traitement des eaux usées et produisent des effluents de haute qualité qui répondent aux normes réglementaires.

L’encrassement des membranes est un défi majeur dans les applications MBR, ce qui entraîne un colmatage des pores de la membrane et une perméabilité réduite. Pour surmonter ce problème, l’étude vise à établir un modèle qui peut prédire le SMP et l’encrassement des membranes en tenant compte de divers paramètres et variables limitantes. L’étude de l’analyse de sensibilité par analyse statistique est réalisée pour découvrir les paramètres les plus influents dans la production de SMP (SUAP, SBAP) et par la manière de calibrer le modèle d’intégration de sortie (ASM1-SMP).

Quatre techniques de modélisation sont utilisées: la projection multivariée à des structures latentes (PLS), le réseau de neurones artificiels (ANN), l’analyse des composantes principales (PCA) et les modèles équations structurelles de modélisation (MES). Des modèles de PLS et d’ann ont été élaborés et analysés pour déterminer les facteurs qui influent sur la production de MPN et l’encrassement des membranes. Les modèles tiennent compte des aspects biologiques du MBR et prédisent le produit SMP. La sem et la cpa sont des outils précieux pour l’analyse exploratoire des données et fournissent une base pour la modélisation statistique subséquente. MES permet d’acquérir une compréhension globale de l’ensemble de données, d’identifier les tendances et de détecter les problèmes potentiels tels que les données aberrantes ou manquantes. PCA, d’autre part, aide à identifier les variables les plus importantes à l’origine des modèles dans les données, facilite la visualisation des données, et réduit la complexité de l’ensemble de données pour une analyse plus poussée

De la performance globale, la technique de projection aux structures latentes (PLS) a été la méthode de sensibilité la plus performante, en terme de régression, prédit, RMSE, R<sup>2</sup>, , l’application de l’intégration ASM1-SMP aux MBRs nécessite la fourniture du modèle avec des données d’entrée mises à jour qui dépendent d’une analyse laborieuse (analyse pneuométrique et mesure en ligne). Cependant, le présent travail montre que la modélisation et le modèle ASM1-SMP prédit en utilisant la modélisation hybride, en particulier le modèle PLS pour les corrélérer avec des paramètres pertinents peut améliorer considérablement la prédiction des extrants (SMP SMPUAP SMPBAP), sans nécessiter d’autres analyses en laboratoire. Pour les trois extrants modélisés dans cette étude (SMP, SMPUAP et SMP BAP), les meilleurs résultats ont été obtenus en utilisant les entrées de l’utilisation de toutes les données (stratégie 3). Toutes les données de paramètres expérimentaux et toutes les données de paramètres ASM1-SMP se sont révélées être un outil de surveillance complet qui peut être utilisé dans les modèles hybrides, pour compléter l’information mécaniste décrite par un ASM1-SMP afin d’obtenir une bonne prévision des indicateurs de rendement clés MBR, paramètres d’encrage dans le cas de cette étude.

**Mots-clés:** bioréacteur à Membrane, traitement des eaux usées, salissage, projection multivariée aux structures latentes (PLS), réseau de neurones artificiels (ANN), modèle hybride, prédiction, analyse des composantes principales (PCA), équation de modélisation structurelle (MES),Smp,Suap,Sbap, analyse de sensibilité, analyse statistique.

## الملخص

التتبُّؤ بالمنتَجات الميكروبية القابلة للذوبان (SMP) في مفاعل ببولوجي غشائي (MBR) ومعالجة قضية فساد الغشاء، مما يحد من كفاءة نظم ذلك. وتستخدم MBRs على نطاق واسع لمعالجة مياه الصرف الصحي وإنتاج النفايات السائلة عالية الجودة التي تلبي المعايير التنظيمية.

ويشكل الفاقدورات العثمانية تحدياً رئيسياً في تطبيقات MBR مما يؤدي إلى انسداد المسام في الغشاء وانخفاض النفايات. للتغلب على هذه القضية، تهدف الدراسة إلى إنشاء نموذج يمكن التتبُّؤ SMP وفاقدورات الغشاء من خلال النظر في مختلف البارامترات والحد من المتغيرات. يتم إجراء دراسة تحليل الحساسية من خلال التحليل الإحصائي لمعرفة المعلومات الأكثر تأثيراً في إنتاج SBAP ، SMP (SUAP)، وبالطريقة لمعايرة نموذج تكامل المخرجات (ASM1-SMP).

يتم استخدام أربع تقنيات نمذجة: الإسقاط متعدد المتغيرات للهيكل الكامنة (PLS) ، الشبكة العصبية الاصطناعية (ANN) تحليل المكون الرئيسي (PCA) ونمذاج البنية المعادلة (MES). وقد تم تطوير وتحليل نماذج PLS و ANN لتحديد العوامل التي تؤثر على إنتاج SMP وفاقدورات الغشاء. تأخذ النماذج في الاعتبار الجوانب البيولوجية من MBR ، وتتوقع منتج كل من MES و PCA أدوات قيمة في تحليل البيانات الاستكشافية وتتوفر أساساً للنمذجة الإحصائية اللاحقة. ويسمح هذا النظام باكتساب فهم عام لمجموعة البيانات، وتحديد الاتجاهات، والكشف عن المشاكل المحتملة مثل الناشرات أو البيانات المفقودة. من ناحية أخرى، يساعد التخويل الخماسي الكلور على تحديد أهم المتغيرات التي تحرّك الأنماط في البيانات، ويسهل تصوير البيانات، ويقلل من تعقيد مجموعة البيانات لمزيد من التحليل.

من الأداء العام، كانت تقنية الإسقاط إلى الهيكل الكامنة (PLS) الطرق الأكثر أداءً للحساسية، في مجال الانحدار، التتبُّؤ، RMSE، R<sup>2</sup>.)، يتطلب تطبيق نموذج إدماج ASM1-SMP في تقارير فترة الإبلاغ الصغرى تزويد النموذج ببيانات مدخلات مستكملة تعتمد على التحليل الشاق (تحليل قياس الاستنشاق وقياس الخطوط). غير أنَّ العمل الحالي يبيّن أنَّ نمذجة نموذج ASM1-SMP وتوقيعه باستخدام نمذجة هجين، وخصوصاً نموذج PLS لربطها مع البارامترات ذات الصلة، يمكن أن تُحسَّن بدرجة كبيرة من التتبُّؤ بالمخرجات (SMP SMPUAP SMPBAP)، دون الحاجة إلى مزيد من التحليل المختبري. من أجل المخرجات الثلاثة التي تم نماذجها في هذه الدراسة (البرنامج المسمى SMPUAP والبرنامج المسمى BAP)، تحقّقت أفضل النتائج عند استخدام المدخلات من استخدام جميع المعطيات (الاستراتيجية 3)، وأظهرت جميع معطيات البارامترات التجريبية وجميع معطيات بaramترات البرنامج المسمى ASM1-SMP أنها أداة رصد شاملة يمكن استخدامها في النماذج الهجين، وذلك من أجل استكمال المعلومات الميكانيكية التي وصفها البرنامج المسمى ASM1-SMP من أجل الحصول على تنبؤ جيد بمؤشرات الأداء الرئيسية الخاصة بتقارير أداء الإدارة المسمّاة، وبaramترات التعفن في حالة هذه الدراسة

**الكلمات الرئيسية:** مفاعل حيوي غشائي، معالجة مياه الصرف الصحي، الفاقدورات، إسقاط متعدد المتغيرات للهيكل الكامنة (PLS)، الشبكة العصبية الاصطناعية (ANN)، النموذج الهجين، التتبُّؤ، تحليل المكونات الرئيسية (PCA)، نمذجة هيكل المعادلة (MES، Smp، Suap، Sbap)، تحليل الحساسية، التحليل الإحصائي.