

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

الباحث: نزار محمد - كلية الهندسة المدنية - جامعة دمشق

الملخص

إن ما قدمته النماذج لمصممي ومشغلي محطات المعالجة بالحماة المنشطة من معطيات ساهمت في تحسين أداء المحطات وحل مشاكل التشغيل والقدرة على التنبؤ بمواصفات المياه المعالجة وما نتج عن ذلك من تخفيض في التكاليف وضبط النوعية؛ يشكل حافزاً للمزيد من البحث في الطرق المعتمدة من قبل المختصين لبناء النماذج. فهناك الطرق التي تقوم على المعادلات والحساب وهي الأقدم في الاستخدام ويمثلها النموذج المعيار (ASM1) الذي يعتبر أساس نمذجة المحطات التي تعمل بالحماة المنشطة، وهناك طريقة الشبكة العصبونية الصناعية (ANN) واستخدمت في السنوات الأخيرة وهي الأحدث. فقد تركزت هذه الدراسة على إجراء مقارنة بين الطريقتين ومحاولة استخلاص ميزات وعيوب كل طريقة من خلال استعراض أمثلة لنماذج محطات قائمة تعمل بالحماة المنشطة، حيث تم عرض دراسة كل نموذج ونتائج محاكاته وطريقة تطويره ومدى الدقة ممثلة بعامل الارتباط R بين قيم محاكاة النموذج والقيم المقاسة من المحطات ، وبعد ذلك أفرد بحث خاص بالتحليل والتقييم والمقارنة. فأهمية المعطيات التي تقدمها النماذج لمشغلي المحطات والبحث عن النموذج الموثوق والدقيق وتوخي عامل الارتباط بقيمة قريبة الى الواحد سيقودنا حتما الى التفكير وإعطاء وقت لاختيار الطريقة التي تحقق لنا المطلوب وهذا بالتحديد ما تركز عليه العمل. فقد أظهرت النتائج تفوق الشبكة العصبونية بدقة التقارب بين قيم المحاكاة والقيم المقاسة (بيانات المحطة) حيث وصلت قيمة عامل الارتباط الكلي R الى 0.998 لكافة البيانات ، وعامل ارتباط التدريب الى 1.00 لمجموعة بيانات التدريب ، بينما كانت قيم R لنماذج طورت

على أساس ASM1 هي 0.91 و 0.827. فطريقة النموذج ASM1 يؤخذ عليها اعتمادها على علاقات تجريبية وافتراضات فهي تحقق تصميم محطة و معالجة ولكن يصعب أن تحقق نموذج بدقة عالية جداً بسبب حساسية العملية البيولوجية في أحواض التفاعل وتأثرها بظروف محيطية وعوامل بعلاقات لا خطية قد تؤدي الى انحراف أو ارتياب. بينما تقوم نظرية الشبكة العصبونية (ANN) على بيانات مأخوذة من المحطة المدروسة فقط ولا تعطى أية معلومات أو معادلات أو علاقات حساب، وتقوم أيضاً على ذكاء الشبكة وقدرتها الكبيرة على استنباط واستقراء المعلومات والتنبؤ بالنتائج ، فالتدريب الجيد للشبكة بحرفية وخبرة سيقود الى نتائج قد تصل الى 100% لعامل الارتباط R وبخطوات مختصرة، على عكس طريقة (ASM1) التي تعتبر بخطوات معقدة ومتعددة وطويلة وتحتاج الى خبرات كبيرة في المعايرة لضبط بارامترات محددة في حال التباعد بالنتائج بين القيم المقاسة والقيم التي تم محاكاتها (التنبؤ بها) .

الكلمات المفتاحية: نموذج الحمأة المنشطة المعياري؛ الشبكة العصبونية الصناعية؛ معايرة النموذج؛ محاكاة النموذج؛ معالجة مياه الصرف الصحي.

NEURAL ARTIFICIAL MODELLING OF ACTIVATED SLUDGE WWTP USING NETWORKS (ANN) METHOD AND CALCULATION - BASED METHODS IN A RESEARCH ON ACCREDITED MODELS WITH EVALUATION AND COMPARISON

Abstract_The models provided to designers and operators of activated sludge treatment plants have contributed to improving the performance of the plants, solving operational issues, and predicting treated wastewater characteristics, resulting in cost reduction and quality control. This drives

us to further research the methods endorsed by experts for modeling. There are traditional methods based on equation and calculations, represented by the ASM1 standard model, which is the basis for modeling activated sludge plants. Additionally, there is the artificial neural network (ANN) method, which has been used in recent years and is more modern. This study focuses on comparing these two methods, extracting their advantages and disadvantages through examples of existing activated sludge plant models. The study contained: simulation results, construction method, and accuracy represented by the correlation coefficient (R) between measured and predicted values, And then to analysis, evaluation, comparison, and results. The importance of the data provided by the models to plant operators and the search for a reliable and accurate model, aiming for (R) close to 100%, inevitably leads us to consider and allocate time to choose the method that achieves goals. This is precisely what the work focused on. The results of this paper showed the superiority of the neural network (ANN) according to R values which were used as evaluation function for the predicted models up to 0.998 for all data and 1.00 for training set of data, while 0.91 and 0.827 for ASM1-based models. ASM1 model relies on empirical relationships and assumptions, making it suitable for plant design and processing but challenging to achieve a model with very high precision due to uncertainties and deviations caused by the sensitivity of the biological process in reactors to environmental conditions and non-linear relationships. In contrast, neural network theory relies on data from the studied plant, without providing any information, equations, or calculation relationships. It also relies on the networks intelligence and its significant ability to infer information and predict results. Proper network training with skill and experience can lead to results with a correlation coefficient (R) up to 100% with short steps unlike ASM1 method which involves multiple lengthy steps and requires extensive expertise in calibration to adjust specific parameters in case of discrepancies between measured and predicted values.

Keywords ASM1; Artificial neural network (ANN);
Model calibration; Model Simulation; Wastewater
treatment.

1 - مقدمة: Introduction

بسبب التغيرات في تدفق الأحمال العضوية والهيدروليكية الداخلة إلى محطات المعالجة بالحماة المنشطة، وما تسببه من صدمات ومشاكل لعملية المعالجة في أحواض التهوية، وتدني في المردود أو القيمة المستهدفة من العملية، كان دائماً البحث عن آلية التحكم بعملية التشغيل، واعتمد مهندسي المعالجة على الخبرة والتجريب والمحاولة كحل متاح وسط غياب آلية علمية فعالة وهذا واقع الحال إلى اليوم في كثير من محطات المعالجة. إلى أن تم بناء النموذج ASM1 في عام 1986 من قبل فريق عمل الرابطة الدولية للمياه (IWA) وما تبعه من نماذج مطورة تأسيساً عليه ASM2، ASM2D، ASM3 إضافة إلى نماذج أخرى أضيفت إلى سيرة الاختصاص مثل ASAL، TUDP ومعظم هذه النماذج قادرة على محاكاة إزالة المادة العضوية، والنترجة، و نزح النتروجين، وبعضها قادر على إزالة الفوسفور بيولوجياً أو فيزيائياً أو كيميائياً، واستخدمت هذه النماذج على نطاق واسع في الأبحاث وتحسين أداء المحطات والتدريب والتحكم بالتشغيل وعمليات المعالجة للمحطات التي تعمل بالحماة المنشطة [17]، والنموذج ASM1 يسمى بالنموذج المعيار وطريقة النمذجة تأسيساً على ASM1 تمثل الطرق القائمة على المعادلات والحساب، وتستخدم نماذج عائلة (ASM) بشكل أساسي لمعالجة المياه المنزلية ويمكنها أن تتكيف بسهولة مع حالات محددة لوجود مخلفات صناعية، ويعتبر النموذج (ASM1) النموذج المرجع في عدة مشاريع علمية وتطبيقية [9]. ولكن تعقيد هذه النماذج جعلها غير مرغوبة بالنسبة للمصممين والمشغلين فعلى سبيل المثال يتطلب ASM1 تحديد حوالي 13 بارامتر، لا يتم قياس معظمها بشكل روتيني بواسطة محطات المعالجة [21]، ناهيك عن أن تقنيات النمذجة التقليدية المستخدمة في العمليات البيولوجية مبنية على معادلات التوازن و معادلات معدل النمو البكتيري واستهلاك الغذاء وتشكل النواتج، وأن التفاعلات الميكروبيولوجية مقترنة مع شروط وتداخلات بيئية غير خطية ولها طبيعة معقدة [13]، ما جعل النمذجة بهذه الطرق لا تخلو من النواقص [5]، وأن التنبؤ بالبارامترات التشغيلية باستخدام تقنيات التجريب التقليدية أصبحت تعتبر خطوة مستنزفة للوقت وعقبة في طريق التحكم الفعال بمثل هذه العمليات [10].

أما النمذجة بطريقة الشبكة العصبونية الصناعية ANN فهي تقوم بشكل طبيعي على البيانات التاريخية (Historical data) التي تمثل عملية المعالجة، كما تبين من كثير من مراجع الاختصاص عن تطبيقات الشبكة العصبونية في النمذجة بأن النماذج التي طورتهأ قدمت أداة قوية وفعالة في التنبؤ بأداء محطات المعالجة، وربما من أهم تطبيقات النماذج التي طورها الشبكة هي

فهم العلاقات المعقدة واللاخطية بين متغيرات المعالجة [16]. تضمنت الدراسة استعراض نماذج لمحطات معالجة مياه مجاري منزلية قائمة تعمل بطريقة الحمأة المنشطة منها ما تم تطويره باستخدام النموذج الأساس ASM1 بطريقة المعادلات والحساب مثل نموذج محطة معالجة مدينة Verona في إيطاليا (نموذج تم تطويره وفق شروط حالة الثبات في المعالجة (Steady state، ونموذج ديناميكي لمحطة مدينة Salamanca في اسبانيا، ونماذج تم تطويرها باستخدام الشبكة العصبونية الصناعية ANN لمحطات معالجة مياه مجاري منزلية شملت 7 محطات تعمل بالحمأة المنشطة (محطة معالجة دمشق في عدرا ، محطة خربة المعزة في طرطوس ، محطة العجمي في الاسكندرية في مصر ، محطتا كونيا وسيحان في تركيا ، ومحطتا الرستمية والمعمرة في العراق) ، حيث تضمنت هذه الدراسة استعراض (16) نموذج طورت من بيانات هذه المحطات ، منها (9) نماذج تجاوز فيه عامل الارتباط R القيمة (0.93) ومنها نموذج بقيمة (R= 0.998) ، ونموذج آخر بقيمة R = 0.99 ، ومن خارج هذه الدراسة فقد أعطت نماذج تم تطويرها بطريقة الشبكة العصبونية قيم عامل ارتباط للتنبؤ بقيمة COD لمحطة معالجة مخلفات صناعات غذائية في منطقة Aksaray في تركيا حتى (R=0.9997) [14]؛ نتائج يصعب أن نتوقعها من نماذج (ASM1) المعقدة والطويلة الخطوات والتي تقوم على الافتراضات والتبسيطات والتقريب والمعايرة وتعدد بارامترات النشاط الحيوي وتصحيحاتها. كما تضمنت بعض الدراسات تطوير نماذج باستخدام الشبكة العصبونية ذات التغذية الأمامية FFNN ، وشبكة الغابة العشوائية RF ، والشبكة العميقة DNN بأنواعها مثل الشبكة العصبونية الالتفافية CNN والشبكة المتكررة RNN والشبكة التراكمية SAE ، لتجنب عيوب أو نقاط ضعف النماذج التقليدية الميكانيكية، وقدمت الدراسة نتائج استخدام نماذج الشبكات الضحلة SNN والعميقة DNN للتنبؤ بمواصفات المياه الخارجة [12]. ويجدر التنويه بأن بيانات المحطة المستخدمة للنمذجة بطريقة الشبكة العصبونية هي مجموعة القياسات التي تتم بشكل يومي في مخابر المحطة ومن قبل العناصر الفنية العاملة لديها ولعينات تؤخذ من الأحواض داخل المحطة نفسها خلال فترات التشغيل. تركزت الدراسة على كلا الطريقتين وإجراء المزيد من المقارنات والتحليل من خلال الأمثلة الموجودة ، فطريقة النموذج الأساس (ASM1) لا تزال معتمدة وتقوم على المبادئ الهندسية الأساسية وتوازن المادة الصلبة في حوض التفاعل ومعادلات الحساب والنمو الحيوي، ولكن تحوي تعقيدات وتقوم على افتراضات و تعدد الخطوات والمراحل والمعايرة والتقريبات وحل المعادلات المعقدة وكل ذلك يؤثر في دقة الأداء ، مما يزيد في الحقيقة من احتمال أن تصبح طريقة الشبكة العصبونية لبساطتها ونتائج الدقة في التنبؤ التي وصلت إليها بديلاً حقيقياً.

2- الهدف من البحث: Target of the study

إيجاد معطيات أمام الباحثين ومصممي النماذج لمحطات معالجة مياه الصرف الصحي التي تعمل بالحمأة المنشطة تساعد في اختيار المنهجية والطريقة الأمثل في تطوير النماذج التي تقدم أعلى مستوى ممكن من الدقة في التنبؤ بمواصفات المياه المعالجة، واستثمارها في التحكم

بتشغيل المحطة، وضبط نوعية المياه الخارجة، وفهم طبيعة العلاقة بين متغيرات المعالجة وما يرافق ذلك من تخفيض في التكاليف، وإزالة أفضل للملوثات، والحفاظ على مصادر المياه.

3- مواد وطرق البحث: Materials and methods

تضمنت مادة البحث الرئيسية (18) نموذج مدروس لمحطات معالجة منزلية تعمل بطريقة الحماة المنشطة، تم تطوير اثنان منها بطريقة ASM1 وهي محطة معالجة مدينة Verona في إيطاليا (كنموذج ساكن Steady state)، ومحطة معالجة مدينة Salamanca في إسبانيا (كنموذج ديناميكي)، بينما تم تطوير النماذج الأخرى وهي (16) نموذج من (7) محطات معالجة باستخدام طريقة الشبكة العصبونية الصناعية ANN. كما تضمنت خطة البحث النقاط التالية:

- ترجمة دراسة نموذج محطة Verona من المرجع رقم (17)، ونموذج محطة Salamanca من المرجع رقم (4) من الإنكليزية الى العربية حيث تم التركيز وبشيء من التفصيل على دراسات هاتين المحطتين بسبب:

1- ضرورة التركيز على كافة خطوات العمل ومراحل تطوير النموذج لتكون المقارنة ذات موثوقية بين الطريقتين، سيما وأن طريقة (ASM1) طويلة ومتعددة الخطوات. (تم عرض الجداول والمخططات كما هي دون ترجمة).

2- تباين أساسي في بعض خطوات العمل بين طريقة تطوير النموذج الساكن والنموذج الديناميكي.

- ترجمة دراسات النماذج المطورة بطريقة الشبكة العصبونية (ANN) من الإنكليزية الى العربية من المراجع ذات الصلة (قائمة مراجع البحث) وتم عرض دراسة محطة العجمي بشيء من التفصيل وباقي المحطات باختصار كون جميع النماذج تم تطويرها باستخدام الشبكة FFBP، بينما في نموذج محطة خربة المعزة تم تطبيق الشبكات العصبونية العميقة DNN بأنواعها وشبكة الغابة العشوائية RF على بيانات النماذج الأكثر دقة الناتجة عن شبكة FFBP والضحلة SNN (بطبقتين مخفيتين أو طبقة واحدة). (لم يتم ترجمة الجداول والمخططات).
- دراسة نموذج محطة دمشق من المرجع 21 (باللغة العربية) وهو رسالة ماجستير عن تطوير نموذج للمحطة.

- تم في البند 4 إجراء التحليل والمقارنة مع تقييم النتائج بين النماذج بشكل دقيق ومفصل لكل خطوات العمل.

- في البند 5 الاستنتاجات والتوصيات، ثم المراجع في البند 6.

1-3- نموذج محطة معالجة مدينة (Verona) في إيطاليا:

وصف المحطة: Description of Verona WWTP

تم تصميم المحطة لتعالج (92000) م³/يوم كمعدل جريان وسطي في الطقس الجاف، مؤلفة من منشآت معالجة ابتدائية (مصافي خشنة وناعمة) إضافة إلى أربع أحواض ترسيب رمال مهواة مستطيلة الشكل، وثلاث أحواض ترسيب أولي دائرية الشكل، وخمس أحواض حماة منشطة (الحجم

الكلي $V=23777 \text{ m}^3$) حجم الجزء المهورى من حوض التفاعل ($VR=70\%$)، ستة أحواض ترسيب نهائي بحجم إجمالي $V(Sc)=26064 \text{ m}^3$. تم تصميم المحطة لإزالة BODs والنيتروجين من خلال عملية Denitrification في حوض (Anoxic) يسبق حوض التفاعل الذي يتم فيه عملية التهوية لإزالة المادة العضوية الكربونية مع النتجة حيث يعاد تدوير المياه التي تم نترجتها إلى حوض (Anoxic) لتتم عملية إزالة النيتروجين بيولوجياً. فيما يتعلق بإزالة الفوسفور، لم يؤخذ بالاعتبار أثناء التصميم إزالة الفوسفور بيولوجياً من خلال عملية "الاستهلاك الزائد" excess uptake، لذلك تم بمحطة Verona إزالة الفوسفور فقط من خلال عملية الأيض البكتيري. من أجل دراسة المحاكاة، استخدم فقط البيانات التشغيلية الروتينية للمحطة الواردة في الجدول (1)، ولم يتم إجراء أية قياسات إضافية. البيانات الخام التي جمعت من المحطة تم فحصها لاستخلاص عدة مجموعات من البيانات التي تمثل بشكل تقريبي فترات (30) يوم تشغيل في حالة الثبات (steady state). هذه البيانات كانت معالجة إحصائياً ومأخوذ المتوسط الحسابي لها، مفترضاً بأن هذا الوسطي يمثل حالة الثبات كما أن وسطى البيانات من فترتين مختلفتين استخدمت في دراسة المحاكاة لمعايرة النموذج (الجدول 1) ومن أجل التحقق Verification للنموذج المعايير [17].

بيئة المحاكاة : في هذه العملية نفذت المحاكاة باستخدام الحاسب على برنامج (WEST®) الإصدار 3.5.7 حيث تم اختياره كبيئة نمذجة ومحاكاة لأي نوع من العمليات يمكن أن يوصف من خلال نظام مبني على معادلات رياضية (جبرية) أو تفاضلية. [17] ويطبق بشكل رئيسي للنمذجة والمحاكاة لمحطات المعالجة (Vanhooren et al 2003)


Parameter	Unit	Value
Influent flow rate (Q)	$\text{m}^3 \text{d}^{-1}$	92 434
MLSS ¹ conc.	g L^{-1}	4.5
Return sludge ratio	% of Q	1.8
Nitrate recycle rate	% of Q	4.5
Waste sludge flow rate	$\text{m}^3 \text{d}^{-1}$	1 366
RAS ² conc.	g L^{-1}	5.8
DO ³ conc. in the aerobic tanks	mg L^{-1}	(1.3)
Concentration of:		
Settled wastewater		
COD _{tot} ⁴	mg L^{-1}	320
Total Kjeldahl Nitrogen (TKN)	mg L^{-1}	49.0
Ammonia nitrogen (N-NH ₄)	mg L^{-1}	-
Nitrate nitrogen (N-NO ₃)	mg L^{-1}	-
Total Suspended Solids (TSS)	mg L^{-1}	98
Final effluent		
		29
		6.1
		3.0
		4.1
		12.0

الجدول (1) البيانات التشغيلية ومواصفات المياه الداخلة لمحطة معالجة Verona

شكل النموذج (Model Configuration).

محاكاة محطة معالجة (Verona) العاملة بالحماة المنشطة قد أسست على نموذج (ASM1) المعياري والمدمج مع نموذج (Takács) لحوض الترسيب الثانوي (Takács et al 1991). لم يتم أي محاكاة لأحواض الترسيب الأولي وأحواض معالجة الحماة بسبب عدم توفر بيانات وثيقة الصلة بها، إضافة إلى أنه في حال تضمين أحواض الترسيب الأولي وخط معالجة الحماة في نموذج محطة المعالجة سيزيد فعلياً من تعقيد العملية علماً أن المعلومات المحدودة أيضاً قد تسبب عدم موثوقية بالنتائج. التفاعلات البيو كيميائية التي تحدث في حوضي التفاعل (Aeration & Anoxic) موصفة من قبل النموذج (ASM1) في حين ان السلوك الهيدروليكي يمثله نماذج (CSTR) حوض التفاعل المستمر المزج. (ASM1) مازال يستخدم بشكل واسع في مشاريع الصرف الصحي وأصبح النموذج المعياري لمحاكاة محطات المعالجة، وهذا ما نتج عنه قائمة طويلة من المراجع التي تضيف خبرات إلى تطبيقاته. في هذه الدراسة تم اختيار (ASM1) كونه الأقل تعقيداً نسبياً وأن هناك بيانات متوفرة ولو محدودة عن معاييرته، ناهيك عن توصيف واسع جداً للنموذج (ASM1) في مراجع النمذجة. هناك افتراض أن حوض التفاعل (CSTR) له تركيز ثابت ضمن حدوده (مثلاً: المياه الداخلة تمزج بشكل فوري وتام). [17] المخطط الهيدروديناميكي لحوض التفاعل البيولوجي تم تقييمه بوسائل اختبارات تجريبية (إضافة واستكشاف عنصر ذو نشاط إشعاعي) ويمثل الشكل (1) شكل النموذج لمحطة (Verona) بالحماة المنشطة وفق المحاكاة باستخدام البرنامج WEST[®] لمحطات المعالجة وفق (Vanhooren et al 2003). يوضح التوصيف التالي بعض التفاصيل عن شكل النموذج كما هو موضح في الشكل (1): حوض Anoxic تمت محاكاته بحوض واحد (CSTR) في المخطط، بينما حوض التهوية تمت محاكاته بحوضين (CSTR)s، وكلاهما تم توصيفه بـ 50% من حجم الحوض الاصلي (Zambarda 2000) الشكل 1. وسطي تركيز (DO) في حوض التهوية (1.3 mg/l) وتركيز DO في نموذج حوض التفاعل الهوائي الوحيد تم اقتراضه وفقاً لـ Zambarda 2008 (b) على مستويين 0.8 mg/l & 1.8 mg/l كما هو موضح في الشكل 1 على التوالي Aer1 ، Aer2 ؛ تركيز DO في أحواض التهوية مثبت على مستويات محددة بواسطة متحكم Proportional integral (PI) الذي يغير قيمة عامل معدل انتقال الأوكسجين الكتلي (KLa) ليصل إلى تراكيز الأوكسجين الثابتة. أما نموذج حوض الترسيب الثانوي (Takács) فقد تم اختياره ليصف عملية التكتيف والترسيب التي تحدث في الحوض. حوض الترسيب الثانوي المستخدم في هذه الحالة هو وحدة غير متفاعلة (لا تفاعلات بيولوجية تحدث) وتتألف من 10 طبقات أفقية، حيث الطبقة الخامسة اعتباراً من الأعلى هي طبقة التغذية. ولأنه قد تم التأكيد من قبل مشغلي المحطة فإن عملية Denitrification تحدث في حوض الترسيب الثانوي (المعلومات المتوفرة لا تستطيع تأكيد هذه الظاهرة) فقد تم وضع حوض Anoxic افتراضي في دارة الحماة sludge loop من النموذج في الشكل (1) ليصف العمليات البيوكيماوية التي تحدث في حوض الترسيب النهائي الحقيقي. العمليات الحيوية في حوض التفاعل الإضافي موصفة من قبل (ASM1) والسلوك الهيدروليكي بواسطة (CSTR). الحجم

المفترض لحوض الترسيب المتفاعل (Reactive clarifier) يساوي حجم بطانية الحماية في حوض الترسيب الحقيقي وهو (20% من $V(Sc)$. [17]



الشكل (1): مخطط النموذج لمحطة معالجة مدينة (Verona) وفق المحاكاة على (WEST[®])
(software).

تجزئى الدخل Influent Fractionation :

النموذج (ASM1) كان استخدم ليحاكي إزالة المادة العضوية BOD_5 والنتروجين بطريقة الحماة المنشطة، وتطبيق (ASM1) يتطلب توصيف مكونات الدخل على أساس الاكسجين الكيميائي الكلي المحتاج (COD_{tot})، التي تقسم بعدئذ ضمن تنوع من الأجزاء وفق متغيرات النموذج (Henze et al 1987). لغايات النمذجة فقد تم استخدام بيانات التشغيل الروتينية لمحطة Verona (بيانات الجدول 1). من أجل تشكيل مدخلات النموذج ، تم تحويل البارامترات التقليدية للمحطة التي تم توصيفها من خلال التراكيز الخارجة من حوض الترسيب الأولي كمدخلات للنموذج (ASM1) وتم استخدام طرق معيارية وطرق معدلة (طريقة A و طريقة B) حسب (Makinia et al 2002) ، حيث أن الطريقة B أكثر كلاسيكية وتأخذ الظروف الخاصة النوعية لعملية المعالجة لمحطة Verona بعين الاعتبار ، ويبين الجدول (2) مدخلات النموذج الناتجة بعد تجزئى الدخل على أساس COD_{tot} في كلتا الحالتين بارامترات الدخل لإجراءات التجزئى المطبقة هي TSS & COD_{tot} لمياه الخارجة من حوض الترسيب الأولي الحقيقي . هذه البارامترات سوف تستخدم لاحقاً لحساب تراكيز المكونات الكربونية المطلوبة للنموذج (ASM1) إما باستخدام معلومات افتراضية موثوقة أو بارامترات محسوبة بطريقة علم قياس اتحاد العناصر Stoichiometric. قيم البارامترات المحسوبة بطريقة علم قياس اتحاد العناصر تتغير من أجل كل طريقة / A أو B / ولذلك فإن مدخلات النموذج المحسوبة تختلف في المصطلح وفق الآتي: COD (SCOD) المنحل، COD (XCOD) الحبيبي، COD (BCOD) القابل للتحلل البيولوجي، والجدول 2 التالي يبين تراكيز المكونات الكربونية، أما تراكيز المركبات النيتروجينية لـ (ASM1) فقد تم حسابها باستخدام الصيغ المفترضة لـ (Vanhooren & Nguyen 1996) [17].

Table 2 Selected results for the model influents composition


	COD_{tot} [mg L ⁻¹]	TSS [mg L ⁻¹]	BCOD / COD_{tot}	SCOD / COD_{tot}	XCOD / COD_{tot}	TSS /XCOD
Influent A	320 ¹	98 ¹	0.85	0.42	0.58	0.53
Influent B	320 ¹	98 ¹	0.85	0.59	0.41	0.75

¹ measured value

الجدول (2) / مدخلات النموذج الناتجة بعد تجزئى الدخل على أساس COD_{tot} .

الناتج والتقييم Results and discussion / معايرة النموذج Model Calibration

تنبؤات النموذج لنوعية المياه الخارجة وتركيز MLSS في أحواض التهوية وفي الحمأة المنشطة المعادة تم استخدامها كمقياس لدقة النموذج ليحاكي أداء المحطة، والبارامترات البيولوجية الأولية المستخدمة في المحاكاة تطابق قيمها النموذجية في الدرجة 20 مئوية و PH المحايدة / المقترحة من قبل (Henze et al 1987). ويبين المخطط في الشكل (2) القيم المقاسة (Measured) وقيم المحاكاة (Simulated) وقيم



المكونات التي تم معايرتها (Calibrated) .

الشكل (2) مقارنة بين القيم المقاسة وقيم المحاكاة للنموذج لتراكيز المياه المعالجة.

نتائج المحاكاة الأولية في الشكل (2) المشار إليها بـ (Simulated) تم الحصول عليها بالحساب المبني على مجموعة البارامترات الافتراضية والمعيارية الحركية للنموذج ASM1. نتائج A ونتائج B في الشكل (2) هي نتائج محاكاة استخدام مدخلات A ومدخلات B على الترتيب من بيانات الجدول (2). الاختلاف في القيم بشكل كبير بين القيم المقاسة وتنبؤات المحاكاة خصوصا بموضوع إزالة النتروجين قد تم ملاحظتها في كلا النتائج بالطريقتين A و B (الشكل 2). لذلك من أجل الحصول على مطابقة أو تقارب معقول بين قيم المحاكاة والقيم الحقيقية التي تم قياسها، تمت معايرة بارامترات النموذج. معايرة النموذج أنجزت بشكل وأسلوب تعديل تدريجي (Stepwise Adjustment) مبنية على خبرة ومعرفة النمذج (خبير النمذجة). هذا الشخص خبير الطريقة (human expert method) يستمر حتى

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

الوصول إلى التطابق المقبول وفق خبرته بين القيم المقاسة وقيم نتائج المحاكاة (المشار إليها بـ calibrated في الشكل 2) [17]

توصيات بروتوكول المعايرة (Langergraber et al 2004, Manrolleghem et al 2003) طبقت

، لأجل مواصفات مياه خارجة حقيقية بدقة كافية. البارامترات الحركية لـ (ASM1) التي عدلت: K_S

Table 3 Comparison of the default and adjusted kinetic parameters				
Model parameter	Symbol	Unit	Values	
			Default	Adjusted
Half-saturation coefficient (hsc) for heterotrophs	K_S	gCOD m^{-3}	20.00	5.00
Nitrate hsc for denitrifying heterotrophs	K_{NO}	$\text{gNO}_3\text{-N m}^{-3}$	0.50	0.10
Autotrophic ammonia hsc	K_{NH}	$\text{gNH}_3\text{-N m}^{-3}$	1.00	0.80
Autotrophic oxygen hsc	$K_{O,A}$	$\text{gO}_2 \text{m}^{-3}$	0.40	0.30
Ammonification rate	k_A	$\text{m}^3 (\text{gCOD d})^{-1}$	0.08	0.04

K_{NO} , $K_{O,A}$, K_A , K_{NH}

الجدول (3) مقارنة بين (البارامترات الحركية الافتراضية والبارامترات الحركية المعدلة

(المعايرة)


- عامل نصف الإشباع K_S للكائنات عضوية التغذية انخفض من 20 إلى 5 (gCODm^{-3}) مسبباً انخفاض بقيمة تراكيز النترات الخارجة و COD_{tot} . القيم المنخفضة لـ K_S تقتضي زيادة بانجذاب الكتلة الحيوية نحوالمغذيات بسبب:
- 1_ تراكيز مرتفعة للمركبات (سريعة التحلل) لأن 25% من دخل المحطة هي صرف منشآت صناعية تعالج فيها مواد غذائية (Zambarda 2008b). 2_ تأثير الأداء الجيد لأحواض الرمال الموهوة و أحواض الترسيب الأولي.
- عامل نصف الإشباع من النترات للكائنات عضوية التغذية المسؤولة عن ارجاع الآزوت denitrification (K_{NO}) انخفض من 0.5 إلى $0.1 \text{ g N- NO}_3 \text{ m}^{-3}$ مفترضاً تحسن تحول النترات إلى ندف بيولوجية تبعاً لحجمها وتركيبها.
- عامل نصف الإشباع للكائنات ذاتية التغذية من الأوكسجين ($K_{O,A}$) انخفض من 0.4 إلى 0.3 gO_2/m^3 حيث تعديل هذا البارامتر أدى الى انخفاض تركيز مهم للأمونيا الخارجة. قيمة ($K_{O,A}$) المعايرة من أجل البكتريا ذاتية التغذية تشير إلى تحسن في تحول الأوكسجين إلى ندف بيولوجية ربما بسبب الحجم النوعي وتركيبية الندف وكذلك الكفاءة العالية لنظام لتهوية بسبب تجهيز ناشرات هواء جديدة مستطيلة (Zambarda 2008b).
- عامل نصف الإشباع للكائنات ذاتية التغذية من الأمونيا (K_{NH}) انخفض من 1.0 إلى 0.8 gN- $\text{NH}_4 \text{ m}^{-3}$ ليظهر انخفاض واضح في تركيز الأمونيا في المياه الخارجة، ويتزامن مع زيادة في تركيز النترات. الزيادة في قيمة (K_{NH}) ربما ترتبط أيضاً بحجوم وتركيب الندف البيولوجية، والتي

تزيد من انجذاب الكتلة الحيوية للمغذيات. من الجدير بالملاحظة أن أربع قيم من أصل (6) تم معايرتها لتأبى الإشباع للنموذج المعايير كانت أقل من القيم التي تم الحصول عليها للنموذج (ASM1) باستخدام مجموعة البارامترات المعيارية والافتراضية الحركية للنموذج (ASM1) والتي تشير إلى تحسن انجذاب الكتلة الحيوية نحو المغذيات / ربما يتعلق ذلك بوسطي حجم صغير نسبياً للندف البيولوجية التي تم قياسها خلال فترات أخذ العينات أو فترات استخلاص البيانات ولكن تم التأكد من قبل مشغلي المحطة بأن تلك هي الحالة النموذجية السائدة للمحطة وحسب Marquot et al (2006) فإن ثوابت الإشباع يمكن أن تؤخذ بعين الاعتبار كبارامترات مكافئة (تعويض، تعادل) لأجل حدوث مناطق ميتة في داخل حوض الحماة المنشطة والتي فيها تراكيز المكونات المنحلة أو الحبيبية تختلف عن المنطقة الممزوجة بشكل جيد. القيم الأقل لثوابت الإشباع ربما تشير أنه لا وجود لمناطق ميتة ذات أهمية تحدث في أحواض التفاعل للمحطة تبعاً للانتظام الهيدروليكي لأحواض التفاعل.

• معدل النشدة K_A انخفض من 0.08 الى 0.04 (g COD d) / m^3 حيث تعديل (معايرة) هذا البارامتر قاد إلى تخفيض الأمونيوم ونسبة النتروجين العضوي المرتبط في المياه الخارجة. وقيم أقل من K_A ستؤدي الى وجود مواد عضوية منحلة أكثر تحوي نتروجين متبقية في مياه المجاري المعالجة لأن معدل النشدة أبطأ. ولأن معدل النشدة $Ammonification$ أبطأ يكون الجزء المئوي للنتروجين العضوي للمياه الخارجة التي تم فحصها تتألف من أكثر من 50% من TKN وهذا يؤشر حتماً أن معدل النشدة هو أقل من النموذجي. المخطط في الشكل (2) يشير الى أن معايرة النموذج (ASM1) أدى الى تحسين الدقة في تنبؤات إزالة النتروجين. يوجد فقط اختلافات صغيرة جداً بين تنبؤات النموذج المعايير باعتبار (وفقاً) لمدخلات النموذج التي استخدمت. الجدير بالملاحظة بأن المحاكاة بمدخلات الطريقة A نتج عنها تراكيز أمونيا N_{NH4} خارجة أقرب إلى القيمة المقاسة بالمقارنة مع مدخلات الطريقة B. وعلى النقيض من ذلك، استخدام الطريقة B سمح بالتنبؤ بتراكيز النترات بالمياه الخارجة بدقة أعلى . [17]

التحقق من النموذج: Model Verification:

لكي نتحقق من قوة التنبؤ للبارامترات المعايير، أجريت المحاكاة باستخدام مجموعة جديدة من بيانات الدخل من أجل فترات أخرى مختلفة عن البيانات السابقة. المبدأ الأساسي للتحقق من



الشكل (3) (نتائج التحقق للنموذج الذي تم معايرته).

النموذج المعايير هو حفظ كل بارامترات النموذج المعدل (المعايير) ثابتة، حينئذ النتائج الجديدة تكون قابلة للمقارنة، مهما يكن، إضافة إلى ذلك لإنجاز نتائج مقنعة أكثر للتحقق فإن حجم حوض الترسيب التفاعلي ومكونات الدخل يجب معايرتها. التكيف مع مكونات دخل المغذيات يتطلب تعديل دخل المغذيات SI وخرج المغذيات SS لنتمكن من إنجاز نتائج مقبولة بما يخص التنبؤ بتركيز (COD_{tot}) الخارجة. الجزء العشري الحبيبي لـ (COD_{tot}) الداخل تم معايرته (تعديله) ليزيد تراكيز MLSS و RAS، مهما يكن من المهم القول بأن النتائج المتحصلة بعد مثل هذا التعديل يجب أن تعالج بحذر وانتباه وموثوقيتها موضع تساؤل. نتائج تحقق النموذج موضح في الشكل (3) أدناه (من أجل مدخلات النموذج المحسوبة باستخدام الطريقة A). نتائج التحقق (verification) تعطي (تظهر) أن النموذج المعايير قادر على توصيف الاتجاه العام لأداء المحطة

باستخدام المدخلات وبيانات التشغيل من فترات زمنية مختلفة، ومهما يكن فإن التوافق بين القيم المقاسة وقيم المحاكاة لبعض البارامترات هو معتدل أو متوسط. بعد تعديل (Adjustment) بارامترات النموذج المذكورة أعلاه (الجدول 3)، فإن نوعية نتائج المحاكاة تحسنت بشكل ملحوظ. وربما هذه تتعلق بتعديلات في شكل المعالجة (مثلاً: تغيير في الحجم الذي يتم تهويته والذي يكون مثبت من قبل مشغل المحطة)، أو تغيرات في تركيب مياه الدخل (تبعاً لتغيرات الأحمال العضوية وتواترها وتركيب مياه الصرف الصناعية)، وحقبة أن وسطي البيانات استخدمت في المحاكاة. [17]

نتائج الدراسة Conclusion: بناءً على النتائج التي تم الحصول عليها لمحاكاة ونمذجة محطة Verona يمكن استخلاص التالي: 1- البيانات النموذجية التشغيلية والأساسية بالرغم من محدوديتها يمكن أن تطبق بشكل ناجح لنمذجة ومحاكاة أداء محطة Verona المنزلية والصناعية. 2- تشير الدراسة بأنه يمكن تطوير (صنع) نموذج ناجح لأنظمة الحماة المنشطة المنزلية باستخدام (ASM1) كأساس.

3- النموذج الذي تم تطويره والتحقق منه خلال هذه الدراسة قادر على التنبؤ بسلوك محطة Verona بدقة مقبولة، والنمذجة ببيانات تشغيلية محدودة ملائمة لتشير إلى اتجاه أو نوعية التراكيز الخارجة. ومهما يكن فإنه لإنجاز تطابق أفضل هناك حاجة لأبحاث إضافية لنحدد المعالم الخاصة لسلوك المحطة النوعي، مثال: توزيع الأوكسجين ضمن أحواض التهوية، المواصفات التفصيلية لمياه المجاري، أو تركيب الحماة المعادة RAS. مجموعة بارامترات النموذج المعايير التي حصلنا عليها في المحاكاة الساكنة (Steady state) يجب أن تتعرض للتحقق مع نتائج دراسات إضافية مثل: التجارب المخبرية ضمن المحطة، المراقبة الموسعة للمحطة من أجل المحاكاة الديناميكية. dynamic simulation [17]

النموذج المطور في هذه الدراسة يمكن استخدامه لعدة غايات: [17]

1- لمشغلي محطة Verona كأداة مفيدة وعملية للتنبؤ بنتائج تغيرات بارامترات التشغيل مثل نسب التدوير، معدل صرف الحماة الفائضة، وتركيز الأوكسجين المنحل. 2- تحسين أداء المحطة مثل حفظ الطاقة (المرتبطة بالتهوية وإعادة التدوير)، تخفيض صرف الحماة الفائضة، تعزيز قدرة إزالة

الملوثات. 3- لمزيد من التطوير في النموذج الذي يمكن استخدامه في المحاكاة الديناميكية واستخدامه كعنصر تحكم في النظام في الزمن الحقيقي لأداء المحطة.

2-3- نموذج محطة معالجة مدينة Salamanca في إسبانيا:

مثال عملي: تطبيق النموذج الديناميكي ASM1 على محطة معالجة قائمة لمدينة Salamanca في إسبانيا كحالة عملية. وتتضمن الدراسة: 1- توصيف النموذج ASM1 بعمق 2- توضيح وشرح بروتوكول المحاكاة المبني على التقريب بين النموذج الديناميكي والبيانات الحقيقية للمحطة. 3- إجراء محاكاة قيم تراكيز COD الخارجة من المعالجة لمحطة Salamanca آخذين بالاعتبار الديناميكية في حوض التهوية مثل (تأثيرات درجة الحرارة على معدل نمو البكتريا μ ، وتراكيز الكتلة الحيوية MLSS، وقيمة COD_{in} وتغيراتها). 4- تحليل تأثير المتغيرات الديناميكية على البارامتر COD_{eff} من وجهة نظر المعالجة البيولوجية وتوضيح سلوك الكتلة الحيوية والاستجابة لإزالة المادة العضوية. [4]

وصف المحطة: Description of Salamanca WWTP

المحطة ذات قياس (Medium-high-sized) من وسطي الحجم الكبيرة، مصممة لتعداد سكاني (260,000) نسمة بوسطي جريان يومي (60,466) م³/يوم، وبحجم حوض تفاعل كامل (37,240) م³. مقسم إلى أربعة أحواض جزئية بحجم (9,130) م³ لكل حوض، وزمن الحجز الهيدروليكي (14.8h) وتركيز الاكسجين الذي تم المحافظة عليه $DO = 1.5 \pm 0.3$ mg/l. تعمل بالحماة المنشطة بنظام التهوية المديدة Extended Aeration يتم فيها أكسدة المادة العضوية الكربونية إضافة للنترجة Nitrification. 60% من حجم حوض التفاعل هوائي لإزالة BOD_5 + نترجة، و 40% لتفاعل إزالة النتروجين Denitrification (حجرتين على التسلسل Anoxic في مقدمة كل حوض جزئي). [4]

جمع البيانات: Data collection تم أخذ البيانات من الكادر الفني لمحطة Salamanca خلال الفترة (أيار 2020 - نيسان 2021) بفترة 343 يوماً، حيث القياسات في مخبر المحطة وكانت: 1- قيم COD_{in} - 2- قيم COD_{eff} . 3- قيم MLSS في أحواض التهوية. 4- درجات الحرارة في حوض التهوية T^o . القياسات كانت تتم على يومين أو ثلاثة في الأسبوع للمكونات وأخذت كوسطي يومي. الجدول (S3) في الملحق يتضمن عينة من البيانات. [4]

1- **النموذج الديناميكي ASM1:** نعبر عن العلاقة الرياضية لتوازن الكتلة في حوض التهوية والذي يمثل تركيز المغذيات أو الكتلة الحيوية وفق المعادلتين:

(1)

$$dc/dt = 1/\theta (C_{in} - C) + r(c) \quad (2)$$

حيث θ : مدة الحجز الهيدروليكي (فترة المكث)، $r(c)$ معدل استهلاك الغذاء، C تركيز المغذي في المياه الخارجة من حوض التهوية، C_{in} تركيز المغذي في المياه الداخلة الى حوض التهوية، Q معدل الجريان الداخل الى المحطة، V حجم حوض التهوية. أما معدل استهلاك الغذاء r_i في النموذج ASM1 فيعرف بمعدل التحول للمكون (i) بواسطة العملية البيولوجية (j) وفق المعادلة (3) التالية: V_{ij} حيث $r_i = \sum P_j$. P_j هي معدل العملية البيولوجية Process rate التي تؤثر على المكونات لـ ASM1

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

وهي موصوفة في مصفوفة بترسون (الجدول S1 في الملحق)، بينما V_{ij} هي عامل قياس اتحاد العناصر Stoichiometric Coefficient حيث تعرف المعادلة (3) نظام المعادلة التفاضلية التي بها كل معادلة تفاضلية لها شكل المعادلة (2) لكل مكون (i) من النموذج، متأثراً بمعدلات المعالجة المختلفة المصممة بـ (j).

أهم ما يميز النموذج ASM1 هو تقسيم المكونات الى أجزاء عشرية، وفصل معدلات العمليات الى وحدات معالجة Processes. المادة العضوية تقسم الى: 1- منحلة وسريعة الهضم البيولوجي S_s . 2- حبيبية وبطيئة الهضم البيولوجي X_s ، حيث S تعني منحلة و X تعني حبيبية، بينما s (Subscript) تشير الى نوع الغذاء Substrate.

أكثر العمليات أهمية التي تؤثر على إزالة المادة العضوية هي النمو الهوائي للكتلة الحيوية عضوية التغذية، والنمو وفق تفاعل (Anoxic) بوجود الاكسجين المرتبط في النترات NO_3 ، والتفكك Decay، والانحلالية Hydrolysis للمادة العضوية الحبيبية. يجدر بالذكر ان النموذج الديناميكي ASM1 يتضمن 13 مكون وهي (اشكال مختلفة من المغذيات والكتلة الحيوية) و 8 عمليات تفاعل أساسية (معدلات نمو واستهلاك غذاء) موضحة في الجدول S1 في الملحق - (مصفوفة بترسون) - ما ينتج عنها مبدئياً (13) معادلة توازن كتلة و 20 من البارامترات الحركية (Kinetic) معرفة بالجدول S4 في الملحق. عند تطبيق ASM1 لمحاكاة التأرجح في قيم تراكيز COD_{eff} للمحطة، نحتاج 3 معادلات للمكونات: (S_s)، و (X_s)، والبكتيريا عضوية التغذية (X_{BH}). نظام هذه المعادلات للمكونات الثلاثة (رقم 2، رقم 4، رقم 5) في (مصفوفة بترسون) بما يتفق مع معدلات العملية التي تؤثر عليها كما في المعادلات الثلاثة التالية

$$\frac{dS_s}{dt} = -\frac{\mu_H}{Y_H} \left(\frac{S_s}{K_s + S_s} \right) \left(\left(\frac{S_o}{K_{OH} + S_o} \right) + \eta_g \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) X_{BH} + k_h \left(\frac{X_{BH}}{K_r X_{BH} + X_s} \right) \left(\left(\frac{S_o}{K_{OH} + S_o} \right) + \eta_h \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) X_s + \frac{1}{\theta} (S_{s,in} - S_s) \quad (4)$$

$$\frac{dX_s}{dt} = (1 - f_p) b_H X_{BH} + (1 - f_p) b_A X_{BA} - k_h \left(\frac{X_{BH}}{K_r X_{BH} + X_s} \right) \left(\left(\frac{S_o}{K_{OH} + S_o} \right) + \eta_h \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) X_s + \frac{1}{\theta} (X_{s,in} - X_s) \quad (5)$$

$$\frac{dX_{BH}}{dt} = \mu_H \left(\frac{S_s}{K_s + S_s} \right) \left(\left(\frac{S_o}{K_{OH} + S_o} \right) + \eta_g \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) X_{BH} - b_H X_{BH} + \frac{1}{\theta} (X_{BH,in} - X_{BH}) \quad (6)$$

[4]: (6-5-4)

2- عدم الاقتران للمكونات: Uncoupling تعقيد حل هذه المعادلات التفاضلية واضح لأن المتغيرات مقترنة بين المعادلات المختلفة. لحل المعادلات التفاضلية بشكل منفصل، المتغيرات المقترنة الموجودة في معادلات توازن الكتلة يمكن إدخالها الى النموذج كبارامترات منفصلة تم تحليلها. وفي هذه الحالة تصبح معادلات التوازن مستقلة ويمكن حلها بشكل منفصل (مثال: حل المعادلة 4 من أجل S_s يتبأ بقيم COD_{eff} ، يسمى هذا الإجراء (عدم الاقتران). [4]

3- التقريب في معدل العمليات: Approximations in process rates نحتاج الى تقريبات في المعادلات (4-5-6) لتخفيض التعقيدات وتحديد البارامترات بشكل جيد. وهذه التقريبات تكون متوافقة مع طبيعة مياه المجاري، وشروط التشغيل:

- المياه التي تدخل حوض التهوية بعد الترسيب الأولي فيها تركيز قليل نسبياً للمواد الصلبة. لهذا فان الانحلالية Hydrolysis لن تكون عملية مسيطرة في تخفيض COD ويمكن افتراض عدم اعتبارها في المعادلات (4 و 5).
- النمو وفق تفاعل Anoxic للكائنات العضوية التغذية بالاعتماد على الاكسجين المرتبط لمركب NO3 لا يؤثر على تفاعل إزالة المادة العضوية الكربونية Ss ولا في تركيز MLSS في حوض الحمأة المنشطة. المعادلات (4 و 6).
- من المعروف أن تركيز DO لا يقتصر على 1.5 مغ/ل، وفي المعالجة يحافظ على قيم أعلى ، وتركيز DO لنمو البكتيريا عضوية التغذية هو غير محدد وبالتالي لا يتم اعتباره، ومع التقريبات تصبح المعادلات التفاضلية الثلاثة:

$$\frac{dS_s}{dt} = -\frac{\mu_H}{Y_H} \left(\frac{S_s}{K_s + S_s} \right) X_{BH} + \frac{1}{\theta} (S_{s,in} - S_s) \quad (7)$$

Particulate substrate:

$$\frac{dX_s}{dt} = (1 - f_p) b_H X_{BH} + (1 - f_p) b_A X_{BA} + \frac{1}{\theta} (X_{s,in} - X_s) \quad (8)$$

Heterotrophic biomass:

$$\frac{dX_{BH}}{dt} = \mu_H \left(\frac{S_s}{K_s + S_s} \right) X_{BH} - b_H X_{BH} + \frac{1}{\theta} (X_{BH,in} - X_{BH}) \quad (9)$$

عند هذه النقطة يجب ان نحدد بين البارامترات ماهي الثوابت في النموذج (Kinetic parameters)، وأيها متغيرات ديناميكية ستتغير مع الوقت وتدخل بشكل روتيني كقيم متعددة ترتبط بالزمن في المعادلات التفاضلية ليتم حلها.


المعادلة التفاضلية 7 يتم بها الحصول على محاكاة قيم COD الخارجة، المتغيرات الديناميكية التي تؤثر على قيم COD الخارجة هي تركيز MLSS ويمثلها X_{BH} ، ومعدل النمو النوعي μ_H ، وكلاهما يتأثر بدرجة الحرارة وفق المعادلة التالية: $\mu_H = \mu_{Hmax} (1.072)^{T-20}$ ، وكذلك قيمة $S_{s,in}$ (قيمة COD المنحلة الداخلة) هي أيضاً متغير ديناميكي بسبب التقلبات اليومية لمحطة المعالجة. المعادلة 7 تم حلها بواسطة برنامج MATLAB R2021b، ضبط قيم البارامترات الحركية K_s, Y_H باستخدام المجال (0.4-0.75) من اجل Y_H ، واستخدام الوسطي لـ COD_{eff} من بيانات المحطة من أجل K_s ، ويقسم بروتوكول المحاكاة الى ثلاث خطوات لتقريب خط المحاكاة من خط البيانات (المقاسة):

الخطوة الأولى: (المقاربة على Y_H) حيث تؤخذ Y_H في المجال (0.5-0.7) من اجل $\mu_{Hmax} = 0.1d^{-1}$ كقيمة مثبتة وهذه القيمة لمعدل النمو الأعظمي النوعي هي منخفضة من أجل رؤية أفضل لديناميكية المحاكاة. الخطوة الثانية: (المقاربة على μ_{Hmax}) ويتم اختيار قيمة مع المحافظة على قيمة مثبتة لـ Y_H التي نتجت في الخطوة الأولى. في الخطوة الثالثة (التقريب الدقيق على μ_{Hmax}) حيث قيمتها يتم مقاربتها بدقة كبيرة، ثم مقارنة الأخطاء بين قيم المحاكاة والقيم المقاسة. [4]

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

4-نتائج ومناقشة: Results and discussions


1-discussions - المتغيرات الديناميكية: محاكاة COD_{eff} في المعالجة البيولوجية يعتمد على حل المعادلة 7 التي فيها $S_{S,in}$, μ_H , X_{BH} هي المتغيرات الديناميكية الثلاثة المتضمنة في برنامج MATLAB لقيم منفصلة مرتبطة بالزمن والتي نحصل عليها من جدول بيانات المحطة [4].




الشكل (4) المقاربة الدقيقة على μ_{Hmax} من أجل $Y_H = 0.6$. الحالات (a,b,c)

2- (الخطوة الأولى) المقاربة على Y_H : Tuning on Y_H : من أجل بدء المعايرة لضبط Y_H يتضمن بروتوكول المحاكاة أخذ قيمة ثابتة لـ $(\mu_{Hmax} = 0.1d^{-1})$ وهي قيمة منخفضة بالمقارنة مع قيم مجالات مياه الصرف المنزلية، كما يتم أخذ قيمة لـ $(K_s = 27.7 \text{ mg/l})$ وهي تمثل وسطي قيم COD_{eff} المقاسة، كما تؤخذ فترة المكث $HRT = 14.8 \text{ h}$ من بيانات المحطة. رياضياً زيادة قيمة Y_H في المعادلة 7 تجعل مشتق S_s أقل سلبية وبالتالي ترتفع قيمة COD الخارجة من المعالجة. القيمة المقترحة لـ Y_H من خبرات الاختصاص هي بشكل طبيعي $Y_H = 0.6$ وستكون هي القيمة الثابتة في الخطوة التالية من المعايرة أو ضبط المحاكاة بغرض التقريب. كانت نتائج التقريب (المحاكاة المتتالية) في الخطوة الأولى على الشكل التالي: قيم Y_H من أجل $(\mu_{Hmax} = 0.1d^{-1})$: a) $Y_H = 0.6$, b) $Y_H = 0.5$, c) $Y_H = 0.7$ [4]

3- (الخطوة الثانية) المقاربة على μ_{Hmax} : Tuning on μ_{Hmax} : معدلات النمو النوعي للكتلة الحيوية يتأثر بشدة بدرجات الحرارة وفق المعادلة التالية: $\mu_H = \mu_{Hmax} (1.072)^{T-20}$ ، والتغير في قيمة μ_{Hmax} سيولد رد فعل عكسي على S_s . فالزيادة في قيمة μ_{Hmax} ستؤدي الى تخفيض تركيز COD الخارجة من المعالجة لأن الغذاء سيتم هضمه الى حد كبير، ونميز ثلاث حالات هنا: a- نتائج المحاكاة أقل



من القيم المقاسة وخط المحاكاة يقع أدنى من خط القيم المقاسة حيث كانت القيمة $\mu_{Hmax} = 0.6 d^{-1}$
b- خط المحاكاة فوق خط القيم المقاسة حيث كانت $\mu_{Hmax} = 0.3 d^{-1}$ -c خط المحاكاة متوافق
مع خط القيم المقاسة من أجل قيمة $\mu_{Hmax} = 0.5 d^{-1}$ حيث كانت نتائج المعايرة على μ_{Hmax} من
أجل $Y_H = 0.6$ وفق الآتي: a) $\mu_{Hmax} = 0.3 d^{-1}$, b) $\mu_{Hmax} = 0.6 d^{-1}$, c) $\mu_{Hmax} = 0.5 d^{-1}$
و بمقارنة الحالات الثلاث نجد أن الزيادات في قيمة μ_{Hmax} تخفض الديناميكية
في محاكاة النموذج الديناميكي كما في الحالتين (a,c)، والتقلبات في قيمة COD_{eff} كانت أعلى عندما
قيم μ_{Hmax} كانت أقل (الحالة b) الشكل F1 في الملحق [4].



4-الخطوة الثالثة (المقاربة الدقيقة على μ_{Hmax} / Fine tuning): عندما تقترب قيم المحاكاة من
القيم المقاسة كما في الشكل (F1- c) في الملحق (الخطوة الثانية)، فإن القياس الكمي لعملية
التوافق (Fine tuning) في النموذج الديناميكي (المبين في الشكل 4) يجب أن تتم. في الجدول S5
في الملحق، تم حساب الخطأ الوسطي بين قيم المحاكاة والقيم المقاسة من قيم COD_{eff} وقيم المحاكاة.
في هذه الحالة المعايرة الدقيقة في الشكل 4 تم حلها من أجل قيم μ_{Hmax} قريبة إلى $0.4 d^{-1}$ (0.38)
و (0.42) مع $Y_H = 0.6$ كقيمة مثبتة. الخطأ يحسب وفق العلاقة التالية: $Error = \frac{(Simulated - Analyzed value)}{Analyzed value} * 100$
محاكاة أعلى من القيم المقاسة Overestimation من أجل $\mu_{Hmax} = 0.38 d^{-1}$ (الخطأ = 8.1%
/ الحالة b في الشكل 4)، وقيم أقل من المقاسة Underestimation من أجل $\mu_{Hmax} = 0.42 d^{-1}$
(الخطأ = 7.7% / الحالة c في الشكل 4)، بينما كان الخطأ الأصغر بين قيم المحاكاة والقيم المقاسة
لـ COD الخارج من المعالجة فقد تم الحصول عليه من أجل قيمة $\mu_{Hmax} = 0.40 d^{-1}$ ، وكان
(الخطأ = 0.5% / الحالة a في الشكل 4)، حيث كانت هي القيمة التي تم اعتمادها لمعدل النمو
الأعظمي للكتلة البكتيرية، وهذه القيمة لـ μ_{Hmax} قريبة جداً للمجال $(1.0-0.45) d^{-1}$ ويبين الشكل
(4) نتائج المقاربة الدقيقة على μ_{Hmax} وحالات المحاكاة (a,b,c). [4]

في جدول الأخطاء S5 في الملحق التي تم حسابها في الخطوة الثالثة كان هناك قيم عالية لأخطاء نسبية
فردية وهذا شيء طبيعي في المحاكاة الديناميكية للمعالجة البيولوجية التي غالبا ما تشهد في نتائج ما يصطلح
بـ THE LIVE SYSTEM أو الأنظمة القائمة. السبب الرئيسي للتقدير الزائد أو الناقص عن القيم المقاسة
للنماذج الديناميكية يتعلق بشكل خاص بنشاط

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

الكتلة الحيوية (الأجزاء النشطة والأجزاء الخاملة)، حيث تأثير ضعف أو خمول الكتلة البكتيرية بسبب تقلبات درجة الحرارة، معدل الجريان، وتراكيز الغذاء، فالنموذج الرياضي الديناميكي لا يعيد إنتاج هذا السلوك للتجمع البكتيري، ولا يوجد نموذج نظري قادر على ذلك، لكن فائدته خصوصاً بموضوع التنبؤ والاستجابة للصدمات والسلوك المتذبذب للبارامترات الخارجة هو أكيد وواضح [4]

الخلاصة: Conclusion النموذج ASM1 هو أساس النمذجة الرياضية لتخفيض المادة العضوية في أنظمة المعالجة البيولوجية الهوائية لمياه المجاري، وعلى الرغم من أن النموذج الأصلي منشور من أكثر من 30 سنة فإن تكوين ومرونة ذلك النموذج تجعله عالمياً في توضيح وشرح عمليات المعالجة البيولوجية. حيث فهم آلية عمله وكيفية صياغته له أهمية كبيرة في النمذجة الرياضية للأنظمة الحقيقية، ومن أجل الافتراضات الجديدة في الأنظمة الخاصة. ثمة أحد أهم الخطوات في استخدام ASM1 هو اختيار العمليات المطلوبة بعد أن نختار المكونات. التعديل (Adjusting) أو المعايرة والتبسيط للنموذج الديناميكي هو أساسي للتطبيق الصحيح لهذا النموذج المفيد. عند تطبيق النموذج الديناميكي ASM1 من أجل التنبؤ بمحطات المعالجة، التقريب على Y_H ، μ_{Hmax} يجب أن يتم. في حالة محطة Salamanca، ($K_S=27.7$ mg/l) مثبت كقيمة وسطية لـ COD_{eff} ، و HRT بالتوافق مع حجم الحوض والغزارة $HRT=14.8h$. افتراض مجال قصير لقيم Y_H (0.4-0.75) في بروتوكول المحاكاة قد تم في هذه الدراسة، التي بها تقريب خط المحاكاة إلى خط القيم المقاسة انجز في 3 خطوات، التقريب على Y_H ، أعطى $Y_H=0.6$ ، والتقريب على μ_{Hmax} ، بعد التقريب للخط الرئيسي Baseline والديناميكية، وفي خطوة Fine tuning، الأخطاء النسبية بين بيانات المحاكاة والبيانات المقاسة قد أعطت لـ ($\mu_{Hmax} = 0.40d^{-1}$) القيمة الصحيحة. الأخطاء الفردية عالية في النمذجة الديناميكية لمحطات المعالجة البيولوجية، نظام المعالجة (القائم) live system الذي يعاد إنتاجه من قبل النموذج الرياضي سوف يقود بكل تأكيد لهذه النتيجة، ولكن العائد في التنبؤ بالسلوك المتأرجح لقيم البارامترات الخارجة خاصة أثناء حدوث الاضطرابات البيئية هو أساسي. [4]


3-3- نموذج محطة معالجة العجمي في منطقة الإسكندرية / مصر:

وصف المحطة: Description of EL_AGAMY WWTP محطة العجمي تعمل بطريقة (SBR) تقع في محافظة الإسكندرية - مصر وهي تخدم منطقة العجمي وتعالج $50,000m^3/day$ وتتجز معالجة ثانوية بهدف إزالة BOD الكربوني، لتحقيق مواصفات معيارية مصرية لمياه المجاري المنزلية. هذه الدراسة تتركز على تطبيق طريقة الشبكة العصبونية الصناعية ذات التغذية الامامية المرتدة FFBB(ANN) للتنبؤ بأداء محطة العجمي في منطقة الإسكندرية بما يخص بارامترات أساسية: TSS , BOD , COD تم جمع بياناتها من خلال بحث لمدة عام كامل. فائدة أو أهمية الدراسة أن (ANN) تستطيع التنبؤ بأداء المحطة من خلال عامل الارتباط (R) بين القيم المقاسة وبين قيم مخرجات الشبكة والتي قد تصل إلى أكثر من (0.9)، وعلاوة على ذلك فإن (ANN) تقدم أداة فعالة للتحليل والتشخيص لفهم ومحاكاة السلوك غير الخطي للمحطة، وأداة تقييم أداء فعالة لمشغلي المحطة وصناع القرار. تم الاعتماد على البيانات التاريخية historical data التي تمثل قياسات عملية المعالجة في المحطة، كما يوجد متغيرات مفتاحية يمكن استخدامها لتقييم أداء المحطة وهي COD , TSS , BOD . حيث أن نظم المعلومات المتوفرة في تطبيقات (ANNs) لنمذجة محطات

المعالجة تستخدم هذه المتغيرات ووجد بأن النماذج المبنية على (ANNs) تقدم أداة فعالة وقوية للتنبؤ بأداء المحطة ، و تنصب هذه الدراسة على مشكلة محددة وهي أنه كيف نسيطر على العلاقات المعقدة التي توجد بين متغيرات المعالجة، وكيف نشخص السلوك الديناميكي لمحطة العجمي من خلال تطبيق نموذج (ANN) . [16]

نظرية الشبكة العصبونية الصناعية (ANN):

الشبكة العصبونية الصناعية (ANN) هي نظام معالجة معلومات تحاكي بعملها الأنظمة العصبية الحيوية كالدمغ عند الانسان، والغاية منها هي حساب قيم مخرجات من قيم مدخلة من خلال حسابات داخلية [8] ، المكون الأساسي للشبكة العصبونية هو العصبون Neuron ويسمى عقدة Node، ويبين الشكل (5) عقدة وحيدة من شبكة عصبونية حيث المدخلات $a_1, a_2, a_3, \dots, a_n$ والمخرجات O_j . يمكن ان يكون عدة إشارات دخل الى عقدة واحدة. العقدة تعالج هذه المدخلات لتعطي إشارة خرج واحدة، والقيم $W_{1j}, W_{2j}, W_{3j}, \dots, W_{nj}$ هي عوامل أوزان مرتبطة بالمدخلات الى العقدة. الأوزان هي عوامل التكيف داخل الشبكة التي تقرر شدة إشارة الدخل. كل مدخل $(a_1, a_2, \dots, a_n)$ مضروب



(الشكل 5) / الخلية العصبية الصناعية (العصبون).


بعامل الوزن الموافق له $(W_{1j}, W_{2j}, \dots, W_{nj})$ والعقدة تستخدم مجموع هذه المدخلات الموزونة $(W_{1j} * a_1, W_{2j} * a_2, \dots, W_{nj} * a_n)$ لتقرر إشارة الخرج مستخدمة تابع التفعيل (تابع النقل) Activation function. [16]

المدخل الآخر الى العقدة، b_j ، هي عتبة التفعيل الداخلية للعقدة العصبية (العصبون) وتسمى بقيمة الانحراف وهي قيمة يتم اختيارها عشوائياً وتحدد الدخل الصافي للعقدة من خلال العلاقة التالية:
$$U_j = \sum (w_{ij} * a_i) + b_j$$
 ويحدد خرج العقدة باستخدام عملية رياضية على القيمة الصافية للعقدة؛

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

هذه العملية تسمى تابع التفعيل. تابع التفعيل يستطيع ان يحول الدخل الصافي للعقدة بطريقة خطية او لا خطية. وهناك ثلاثة نماذج من التوابع الأكثر استخداماً هي: $f(x) = x$ (التابع الخطي)، والتابع الأسّي: $f(x) = 1/(1+e^{-x})$ وأنواع أخرى مثل: $f(x) = e^x - e^{-x} / e^x + e^{-x}$ [16].

و تدرب الشبكة العصبونية لتؤدي وظيفة محددة من خلال ضبط قيم الوصلات (الاوزان) بين العناصر بناء على المقارنة بين المخرجات والقيم المستهدفة (المقاسة) حتى تصبح مخرجات الشبكة قريبة من القيم المقاسة للدرجة التي بها تكون الشبكة أصبحت قادرة على التنبؤ بالمخرجات الصحيحة لمجموعة معطاة من المدخلات الشكل (6) [161]




(الشكل 6) / مخطط تدريب الخلية العصبية الصناعية (العصبون).

جمع البيانات ومعالجتها: Data collection & Analysis

نموذج الشبكة العصبونية الصناعية (ANN) تم تطويره ليحاكي محطة معالجة العجمي، قياسات TSS, BOD, COD تم جمعها على مدار عام كامل وهذه الفترة كانت كافية، وتم تغطية التغيرات الفصلية المحتملة للمتغيرات المدروسة، ولما كان بناء نموذج (ANN) مؤسس على بيانات تاريخية Historical data لذلك فإن بيانات المدخلات والمخرجات التي تم تجميعها خلال البحث تم تحليلها احصائياً بواسطة تابع (ANOVA1) ضمن بيئة برنامج MATLAB. علاوة على ذلك، فإن تابع ANOVA1 يطبق قبل تصميم بناء شبكة ANN لنتمكن من استبعاد القيم الشاذة من البيانات الخام [16]. مجموعة البيانات المسبقة المعالجة تم تصنيفها ضمن أربع مجموعات في مصفوفة وتم تحليلها إحصائياً بتوليد مخطط صندوق (box) وحواف (whiskers) لكل متغير، وكل مجموعة هي عمود في مصفوفة حيث المجموعة الاولى تمثل بيانات الأشهر الثلاثة الأولى من السنة (كانون 2، شباط، آذار) والمجموعة الثانية (نيسان، أيار، حزيران) والمجموعة الثالثة (تموز، آب، أيلول) والرابعة (تشرين 1، تشرين 2، كانون 1)، ويوضح الشكل 7 قيم COD الخارجة بعد المعالجة الاحصائية. حيث يظهر على المخطط في المجموعة 2 والمجموعة 4 بعض القيم الشاذة مشاراً إليها بإشارة + وهي خارج حدود المجال الذي يدخل في بناء الشبكة [18]، فالمخطط يختصر كل متغير بأربع مكونات: - خط

مركزي بكل صندوق يسمى (Sample Median) وسطي العينة (يشير الى النزعة المركزية). - الصندوق box يشير الى مقدار التغير حول النزعة المركزية (أطراف الصندوق هي 25% (السفلي) و 75% (العلوي) من القيم وهي ممثلة على المخطط). أما الحواف (whiskers) فهي تمثل أطراف المجال لقيم المتغيرات. [18].



الشكل (7) / قيم COD الخارجة بعد المعالجة الاحصائية.

بناء الشبكة أو اختيار الحجم المناسب للشبكة : Network design

بعد إنجاز معالجة البيانات واستبعاد الشاذة منها ، تأتي عملية تطوير النموذج ضمن MATLAB [16] (ويعني هذا عملياً اختيار عدد الطبقات المخفية وعدد العصبونات في كل طبقة أو ما يعرف باختيار الحجم المناسب للشبكة) ، وتتم العملية بطريقة التجريب أو طريقة المحاولة والخطأ وتعتبر من أقدم الطرق وأسهلها في بناء الشبكات العصبونية حيث يتم البدء بشبكة بسيطة مكونة من طبقة مخفية واحدة بعدد قليل من الخلايا العصبونية ثم زيادة حجمها تدريجياً بإضافة طبقات وخلايا عصبونية جديدة حتى الوصول الى شبكة عصبونية مقبولة من ناحية التعقيد والأداء [21]. والشبكة العصبونية هي أداة من أدوات MATLAB تستخدم في النمذجة، بالإضافة لتقييم أداء الشبكة بالاعتماد على مدى تحقق معايير الأداء الجيد المتعلقة بتقييم قيمة متوسط مربع الخطأ MSE وقيمة معامل الارتباط R ، ويعتبر اختيار الحجم المناسب للشبكة من أصعب المشكلات على الإطلاق ، فبالإضافة إلى الاختيارات الكثيرة المتوفرة لدالة التنشيط لكل خلية، هناك إشكالية اختيار العدد المناسب للطبقات وعدد العقد في كل طبقة، وكل هذه الاختيارات يجب أن تتم قبل البداية في التدريب. ومازالت أكثر الطرق استعمالاً في اختيار حجم الشبكة هي طريقة المحاولة والخطأ. [21]


خواص الشبكة المستخدمة على الشكل التالي:

- 1- مدخلات الشبكة: BOD, COD, TSS - 2 مخرجات الشبكة: BOD, COD, TSS - 3. نوع الشبكة العصبونية المستخدمة: Feed forward - back propagation - 4 - تابع التدريب: Train

5LM- تابع الأداء: MSE الخطأ المتوسط التربيع. 6- عدد الطبقات المخفية (3): حيث تم بطريقة التجريب أو طريقة المحاولة والخطأ اختيار (3) طبقات مخفية ، وتم أيضاً بنفس الطريقة تحديد عدد العقد في هذه الطبقات فكانت 10 عصبونات للطبقة الأولى و 30 عصبون للثانية ، أما الثالثة فهي ذات تابع تفعيل خطي PURELIN . ويظهر الشكل (8) تصميم الشبكة بطبقاتها الخفية الثلاثة وطبقتي المدخلات والمخرجات [16] ويقوم MATLAB بتقسيم البيانات الى 3 مجموعات : مجموعة التدريب وهي بيانات يتم بها تدريب الشبكة بحيث تتغير أوزان المدخلات (60-70% من البيانات-60% للعجمي)، مجموعة التحقق: تستخدم للتأكد من أن الشبكة تم تدريبها بشكل جيد حيث يقاس الخطأ (الفرق بين القيمة المقاسة وقيمة المحاكاة) ويستخدم لذلك ميل المماس لمنحني الخطأ مقابل متحول الدخل والذي يجب ان يكون في حده الأدنى. (15-20% من البيانات-20% للعجمي)، مجموعة الاختبار: تستخدم لاختبار أداء الشبكة بعد التدريب ويتم تقييم الأداء بما يسمى متوسط الأخطاء المطلقة أو متوسط الأخطاء النسبية حيث يجب أن يكون متوسط الأخطاء لا يزيد عن قيمة معينة تحدد وفقاً للمجال المدروس، ويجب أن يكون متوسط الأخطاء لعينة الاختبار قريباً من متوسط أخطاء البيانات الكلية (15-20%)، (20% للعجمي) . [21]

نتائج ومناقشة (محطة العجمي) : الشبكة تستخدم خوارزمية default Levenberg– Marquardt للتدريب. حيث التطبيق وبشكل عشوائي يقسم أشعة المدخلات وأشعة القيم المستهدفة الى 3 مجموعات: 60- % للتدريب. 20- % للتحقق 20- % للاختبار ، للتأكد من تصميم الشبكة ووقف التدريب قبل حصول ما يسمى over- fitting طفحان الشبكة. ويظهر الشكل (8) النافذة المفتوحة للشبكة خلال التدريب ويظهر windows إنجاز التدريب ويسمح للمستخدم بوقف التدريب عند أية نقطة- بضغط (stop training)، فيما زر (Regression) في النافذة ينجز الخط البياني بين قيم المخرجات والقيم المقاسة. ويبين الشكل (F2) في الملحق نتائج مخرجات الشبكة لمحطة العجمي مع قيم R للتدريب: (R = 0.93004)، والتحقق (R = 0.86323) ، والاختبار (R = 0.86289). ولكل البيانات Total response= 090317 وهي قيمة عامل الارتباط الكلي R. وفي هذه الحالة تكون استجابة الشبكة مقبولة ويمكن عندها أن تجري المحاكاة من أجل قيم مدخلات جديدة.

النتائج Conclusions: (محطة العجمي) 1- النتائج من هذه الدراسة تشير الى عامل ارتباط عالٍ R- value بين القيم المقاسة والقيم التي تم التنبؤ بها لمخرجات المتغيرات تصل الى 0.9. 2- النموذج الذي تم تطويره بهذا العمل يملك الدقة والقدرة المقبولة على التعميم. 3- باستخدام الشبكة العصبونية نستطيع أن نحكي وبفعالية ونتنبأ بأداء محطة معالجة العجمي كما يمكن للشبكة أن تقدم أداة تحليل وتشخيص لفهم ومحاكاة السلوك غير الخطي للمحطة [16] .



الشكل (8) النافذة المفتوحة للشبكة خلال التدريب

3-4 - نموذج محطة معالجة كونيا في تركيا: [19]	
المواد والوسائل. Materials and methods	بناء نموذج محطة معالجة كونيا في تركيا باستخدام الشبكة العصبونية (ANN). Modeling of Konya WWTP in Turkey by applying (ANN).
وصف Description of المحطة: WWTP KONYA	تم تشغيلها في 2010م، تعالج 200,000 م ³ /يوم وتخدم مليون نسمة، وتعمل بطريقة الحماة المنشطة مع إزالة نيتروجين جزئية وفق Bardenpho process.
الهدف من المحطة:	إزالة BOD ₅ + إزالة جزئية للنيتروجين (أحواض تهوية مع نترجة) (Anoxic) +
المدخلات: INPUTS:	Q(M ³ /d), TSS, BOD ₅ , COD, PH, T.
المخرجات: OUTPUTS:	TSS
فترة أخذ البيانات ومعالجته The period of data collection Data analysis	أخذت البيانات خلال فترة أربعة أشهر تقريباً، الفترة كانت كافية لتغطية التغيرات الفصلية للبارامترات المدروسة. تم جمع قياسات TSS, BOD, COD من المحطة وهي البارامترات الرئيسية التي استخدمت في محاكاة النموذج كونها الأكثر تأثيراً في النتائج. ولتحقيق التقارب ضمن عدد مقبول من مجموعات البيانات، يجب أن تتم تسوية بيانات الدخل والخرج أو (معادلتها) (Normalize) وفق المعادلة التالية: $x = 0.8 * (x_i - x_{min}) / (x_{max} - x_{min}) + 0.1$ تسويتها. x_{min} x_{max} البيانات الأصلية للمتغير العظمى والصغرى. x_i البيانات الأصلية.
الشبكة العصبونية المستخدمة وملحقاتها: Type of () used & (ANN	Feed-Forward Back-propagation (FFBP) / تغذية أمامية بارتداد عكسي

Train LM. : تابع التدريب. تم تجريب ثلاثة توابع تفعيل للطبقة الخفية هي: (Tansig, Logsig, Purelin)، وتابع تفعيل لطبقة المخرجات هو: Purelin.	
نموذج الشبكة العصبونية تم تطويره في بيئة MATLAB بطريقة المحاولة والخطأ. عدد الطبقات المخفية: تم تجريب طبقة واحدة ثم طبقتان ثم 3 طبقات. تم تجريب عدد عصبونات في كل طبقة مخفية بين 7 عصبونات وحتى 11 عصبون. تبين بعد العديد من المحاولات والتجارب أن الشبكة ذات التصميم التالي قد أعطت أكبر قيمة لمعامل الارتباط $R=0.99$ وهي الشبكة (1-11-11-3)، 3 مدخلات فقط أجريت عليها المحاكاة TSS, COD, BOD. مخرج وحيد فقط TSS، 3 طبقات مخفية و 11 عصبون لكل طبقة.	<u>بناء الشبكة العصبونية:</u> The artificial neural network (ANN) design.
$R(\text{Training})$, $R(\text{For all data}) = 0.99$, $= 0.99$ $R(\text{Test}) = \text{الخطأ المتوسط التربيع}$ MSE= 0.0041654 0.96,	<u>قيم عامل الارتباط R والخطأ المتوسط التربيع: MSE</u>
نتيجة هذه الدراسة أعطت أعلى قيمة لمعامل الارتباط (R) بين القيم المقاسة والقيم الناتجة عن المحاكاة وصولاً الى قيمة (0.99) مع الشبكة ذات التصميم الذي تم اختياره ANN 3-3-1 (أي 3 مدخلات، 3 طبقات مخفية ب 11 عصبون لكل طبقة، طبقة مخرجات واحدة)، فالنموذج المطور في هذا العمل يمتلك الدقة المطلوبة ويمكن ان يكون أداة تحليل وتشخيص لفهم ومحاكاة المحطة ويمكن استخدامه كأداة تقييم للمشغلين وأصحاب القرار.	<u>النتائج والتوصيات:</u> Results and recommendations.

5-3- نموذج محطة معالجة دمشق في عدرا: [21]

بناء نموذج محطة معالجة دمشق في عدرا باستخدام الشبكة العصبونية (ANN). Modeling of Damascus WWTP in Adra by applying (ANN).	المواد والوسائل. Materials and methods
--	---

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

المحطة تعمل بطريقة الحماة المنشطة التقليدية ومصممة لتعالج 360,000 م³/يوم ويعاد حالياً تأهيلها بشكل تدريجي الى وضعها السابق وكانت تعالج 200,000 م³/يوم قبل توقفها بسبب ظروف طارئة في عام 2011م. المحطة تعالج المياه الداخلة من خلال معالجة ابتدائية وأولية وثانوية، إضافة الى خط معالجة حمأة بالهاضم اللاهوائي، والمياه الخارجة من المحطة يعاد استخدامها.	<u>وصف المحطة:</u> Description of Adra WWTP
إزالة BOD الكربوني وتحقيق مواصفات محلية معيارية للمياه الخارجة والاستفادة منها في ري المزروعات لمناطق الغوطة الشرقية المجاورة من محافظة ريف دمشق.	<u>الهدف من المحطة:</u> The Target of (WWTP)
COD, PH, TSS, MLSS(AS), MLSS(RAS).	<u>المدخلات:</u> INPUTS
BOD₅	<u>المخرجات:</u> OUTPUTS
أخذت البيانات على فترة سنة واحدة: 2010/12/30-2010/1/3 بإجمالي 261 يوماً تم فيها كطف العينات من المحطة، والبيانات تغطي التغيرات الفصلية. تم إجراء معالجة البيانات من خلال: 1- حذف العينات المتشابهة والمكررة. 2- حذف القيم الشاذة. وتم استخدام طريقة المعايرة الإحصائية Z-Score بهدف التقليل من تأثيرات القيم المتطرفة في البيانات وتقوم الطريقة على حساب المتوسط والانحراف المعياري لكل متغير عبر مجموعة من بيانات التدريب لمعايرة كل متجه لمتغير الإدخال حيث يتم إجراء التحويل من خلال المعادلة: $X = (x_i - \mu_i) / SD_i$ حيث μ_i المتوسط الحسابي للمتغير، SD_i الانحراف المعياري، x_i قيمة المتغير، بينما X تمثل قيمة المتغير بعد المعايرة الإحصائية. 3- تم تقسيم البيانات بعد المعالجة لـ 3 مجموعات التالي: 60% للتدريب، 20% للتحقق، 20% للاختبار.	<u>فترة أخذ البيانات ومعالجتها:</u> -The period of data collection. - Data analysis. - Data division.
Feed – Forward Back – Propagation (FFBP). الشبكة العصبونية المستخدمة وملحقاتها: Training function: Error Back Propagation. (الخطأ المرتد) Performance function: MSE تابع الأداء هو الخطأ المتوسط التربيع.	<u>الشبكة العصبونية المستخدمة وملحقاتها:</u>
اعتمد في تصميم الشبكة طريقة المحاولة والخطأ، وبعد عديد من المحاولات تجاوز (600) محاولة تجريبية تم الوصول الى أفضل تصميم بأعلى قيمة لعامل الارتباط	<u>بناء الشبكة العصبونية:</u>

(R) وأقل قيمة للخطأ المتوسط التربيع MSE وفق: (1-11-12-5) ANN الشكل (F3) في الملحق. 1- طبقة مدخلات ب (5) مصفوفات لقيم متغيرات الدخل (المنوه عنها سابقاً). 2- طبقتين مخفيتين الأولى ب (12) عصبون والثانية ب (11) عصبون. 3- طبقة مخرجات بمتغير وحيد هو قيمة BOD₅ الخارجة المراد التنبؤ بها.	The artificial neural network (ANN) design.
$R(\text{Training}) = 0.979$, $R(\text{Validation}) = 0.56$, $R(\text{Test}) = 0.738$ $MSE = 0.15$ $R(\text{for all data}) = 0.86$ يبيّن نتائج محاكاة محطة دمشق، مع مثال من مخرجات النموذج المعتمد.	نتائج محاكاة الشبكة وقيم عامل الارتباط R والخطأ متوسط التربيع MSE.
1- إمكانية استخدام النموذج المطور باستخدام ANN للتنبؤ بقيمة BOD₅ الخارجة. 2- يفيد النموذج باكتشاف العلاقات بين متغيرات المعالجة وتأثيرها على المردود. 3- يقدم النموذج إمكانية اختبار الفرضيات التشغيلية وفهم أعمق لسلوك القسم البيولوجي لأننا نستطيع أن نطبق تغييرات نظرية لا يمكن تطبيقها عملياً على المحطة. 4- ضرورة التوسع في القياسات اليومية للمحطة لأنها توفر عينة معلومات مناسبة لإجراء دراسات تفيدنا في مراقبة المحطة وتطويرها لاحقاً. 5- هدف النموذج المطور هو التنبؤ بمردود المعالجة بسبب تغير بارامترات الدخل ولكن غير معد لتحديد البارامترات التشغيلية اللازمة للوصول الى مردود معين.	النتائج والتوصيات: Results and recommendations.

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة


N	Date	Inlet parameters					Outlet Parameters	
		SS inlet	COD inlet	BOD inlet	PH inlet	Recycle MLSS	Activated MLSS	BOD outlet
11	1:27	180	371	141	7.7	11.4	4.5	8


```

>> sim(net1,[180;371;7.7;11.4;4.5])
ans =
8.3061

```

القيمة الناتجة عن النموذج



مثال من نتائج المحاكاة على نموذج

الشكل (9) نتائج محاكاة محطة دمشق / عدرا

محطة دمشق / عدرا

يبين المثال القيمة المقاسة: 8mg/l، قيمة محاكاة النموذج: 8.3061



3-6 - نموذج محطة معالجة سيحان في أضنا / تركيا: [6]

المواد والوسائل. Materials and methods	بناء نموذج محطة معالجة سيحان في تركيا باستخدام الشبكة العصبونية (ANN). Modeling of Seyhan WWTP in Turkey by applying (ANN).
وصف المحطة: Description of Seyhan WWTP	تعمل بطريقة الحماة المنشطة، تتألف من وحدات معالجة ابتدائية، أحواض ترسيب أولي، أحواض تهوية (حماة منشطة)، أحواض ترسيب نهائي (ثانوي)، خط معالجة حماة (هاضم لاهوائي). تصريف وسطي يومي: 155,000 m ³ /d، القيم الوسطية للمكونات التالية: BOD ₅ =229mg/l, COD=385mg/l, TSS=209mg/l
الهدف من المحطة:	إزالة BOD ₅
المدخلات: INPUTS	TSS, COD, BOD ₅ , Q _w (m ³ /d)

BOD ₅	المخرجات: OUTPUTS:
أخذت البيانات بشكل يومي على مدار 355 يوماً (سنة واحدة تقريباً). تم التحليل الإحصائي للبيانات المأخوذة من المحطة حيث تم حساب الوسطي والانحراف المعياري والتباين والقيمة الصغرى والعظمى والانحراف لكل متغير من الدخل والخرج؛ فبينما كانت قيم TSS أكثر البيانات تبايناً (تغائراً) كانت العلاقة بين COD و BOD₅ تتغير بشكل خطي، والعلاقة بين Q_w و BOD₅ متناسبة عكساً وعامل الارتباط بينهما سلبي وبقية (R² = -0.294). تم تقسيم البيانات الى قسمين: بيانات 240 يوم للتدريب training. وبيانات 115 يوم للاختبار test. استخدمت لصنع النموذج البيانات اليومية لكل من COD, TSS, Q_w BOD₅ للمحطة لعام 2021 (من مدخل المحطة) وبيانات BOD₅ من مخرج حوض الترسيب النهائي. البيانات المستخدمة لم تعط نتائج جيدة في التنبؤ من خلال النموذج المصنع؛ ولهذا السبب تم تسوية البيانات أو معادلتها (normalized) وتقسيمها الى مجموعتين من جديد (البيانات المعدلة) لتشكيل مجموعة تدريب ومجموعة اختبار بين قيمتي الصفر والواحد (0-1).	فترة أخذ البيانات ومعالجتها: فترة أخذ البيانات ومعالجته -The period Data of collection. - Data analysis.
Feed-Forward Back-propagation (FFBP).	الشبكة العصبونية المستخدمة
التصميم بطريقة المحاولة والخطأ، حيث الشبكة (4:4:1) أعطت أفضل النتائج تتضمن طبقة مدخلات ب 4 متغيرات هي (Q_w, TSS, COD, BOD₅) وطبقة مخفية واحدة ب 4 عصبونات، وطبقة مخرجات بمخرج وحيد هو BOD₅ وعصبون واحد الشكل (10).	بناء الشبكة العصبونية: - The (ANN) design.
- تبين الدراسة واستخدام نموذج الشبكة ANN (4:4:1) أن قيم (R²) عامل ارتباط قيم المتغير BOD₅ مع كل من البارامترات الأخرى كانت على الشكل التالي: عامل ارتباط BOD₅ مع COD = 0.906، عامل ارتباط BOD₅ مع TSS = 0.605 عامل ارتباط BOD₅ مع Q_w = -0.294، عامل ارتباط BOD₅ مع BOD₅ = 1.00	قيم عامل الارتباط R والخطأ المتوسط التربيع MSE.

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

وذلك من أجل كل قيم BOD_5 المأخوذة من مدخل محطة معالجة سيحان (أضنا) ولمدة 355 يوماً من عام 2021م. - وبإجراء تحليل الحساسية (Sensitivity Analysis) باستخدام نموذج FFBBP ANN الذي تم تطويره: إن اختيار بارامترات الدخل لاستخدامها في نموذج FFBBP ANN هو مهم من أجل أداء النموذج (Elmas,2007). تحليل الحساسية التي تعطي تقدير BOD_5 ومعظم المدخلات الفعالة بشكل متحد، وجد باستخدام نموذج (IBGYSA) الجدول 4. عند تقدير BOD_5، معظم بارامترات الدخل تقريباً حسبت لتكون مهمة بالمقارنة مع تحليل الثبات. كنتيجة لحساب درجات الفعالية في تقدير BOD_5، تم اعتبار أن أكثر البارامترات فعالية كانت COD، بينما أقلها فعالية هي Q_w. <u>الجدول (4): تقرير أكثر النماذج فعالية باستخدام تحليل الحساسية.</u> <table><tr><th></th><th>MAE</th><th>RMSE</th><th>R^2</th></tr><tr><td>COD+TSS+Q_w</td><td>10.32 %</td><td>722.21</td><td>0.891</td></tr></table> حيث MAE متوسط الأخطاء المطلقة. RMSE هو جذر الخطأ المتوسط التربيع. R^2 عامل الارتباط. / ويبين الشكل (11) نتائج محاكاة نموذج FFBBP ANN لمحطة سيحان.		MAE	RMSE	R^2	COD+TSS+ Q_w	10.32 %	722.21	0.891	
	MAE	RMSE	R^2						
COD+TSS+ Q_w	10.32 %	722.21	0.891						
1 -نموذج ANN كان ناجحاً في التنبؤ بقيم BOD_5 لمحطة معالجة Seyhan من خلال الحصول على نتائج موثوقة وواقعية. 2- يصلح أداة تقييم أداء جيدة بما يتصل بتخفيض تكاليف التشغيل. 3- أداة تحليل فعال من خلال محاكاة السلوك غير الخطي.	النتائج والتوصيات: Results and recommendations								



الشكل (10) تصميم نموذج شبكة ANN لمحطة سيحان.
 الشكل (11) العلاقة بين قيم BOD_5 المقاسة وقيم المحاكاة.

3-7 - نموذج محطة معالجة المعمرة في الحلة / العراق: [1]	
المواد والوسائل . Materials and methods	بناء نموذج محطة معالجة المعمرة في العراق باستخدام الشبكة العصبونية (ANN). Modeling of AL-Muamirah WWTP in Iraq by applying (ANN).
وصف المحطة: Description AL-Muamirah WWTP	10 كم جنوب مدينة الحلة. تعمل بتصريف وسطي يومي 25,000 م ³ /يوم، تقوم المحطة على معالجة بيولوجية لمياه منزلية ومياه صرف صناعية معالجة مسبقاً.
الهدف من المحطة:	إزالة BOD_5 .
المدخلات INPUTS :	BOD_5 , COD, NH_3 , TN, PO_4 , NO_3 , NO_2 , PH, TSS, T° .
المخرجات OUTPUTS :	BOD_5 , COD, TSS, (COD&BOD), (COD&TSS), (COD&BOD&TSS)
فترة أخذ البيانات ومعالجتها: -The Data period of collection	على مدار سنتين حيث مجموعات البيانات توصف القيم الوسطية الناتجة من القياسات، تمت عملية المعالجة الإحصائية وفق التالي: 1- تم معايرة (Standardized) المدخلات والمخرجات ضمن مجال (0-1) ، من خلال تحديد القيم العليا والدنيا لكل متغير عبر كل مجموعات البيانات: $X_{norm} = (x_i - x_{min}) / (x_{max} - x_{min})$. 2- بالإضافة الى ذلك فإن البيانات تم تعديلها أيضاً حوالي قيمتها الوسطى حسب الانحراف المعياري على الشكل التالي: $X_i = (x_i - \mu) / Sd$ (حيث μ الوسطي ، Sd الانحراف

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

المعيارى للبيانات الخام) ، ويجدر التنويه هنا انه قد أصبح لدينا 3 أنواع من البيانات: - بيانات تمت تسويتها ضمن المجال (0-1). - بيانات تمت تسويتها حوالي قيمتها الوسطى حسب الانحراف المعياري. - البيانات الأصلية قبل التحليل. حيث تبين أن أفضل النتائج كانت لنماذج مجموعة البيانات (1-0) حسب الأداء لـ R والخطأ المتوسط التربيع MSE.	Data . analysis
Levenberg-Marquardt ، خوارزمية feed-forward-back propagation للتدريب، وخوارزمية الارتداد العكسي BP . عامل الارتباط R والخطأ المتوسط التربيع استخدمت كتابع أداء، تابع التفعيل Tansig للطبقات المخفية والتابع الخطي Purelin لطبقة المخرجات .	الشبكة العصبونية المستخدمة وملحقاتها: Type of (ANN) applied.
استخدم ضمن هذا التحليل عدة خيارات للطبقات المخفية وأرقام مختلفة لعدد العصبونات ضمن كل طبقة بهدف الحصول على أفضل نموذج ممكن. كل خطوات النمذجة طبقت ضمن برنامج MATLAB. اعتمدت طريقة المحاولة والخطأ ومقارنات الأداء في عملية بناء الشبكة العصبونية. أفضل النتائج كانت للشبكة بطبقتين مخفيتين و 6 عصبونات لكل طبقة، ويبين الجدول 13 نتائج المحاكاة لأكثر النماذج دقة في التنبؤ التي تم تطويرها من بيانات محطة المعمره وتصميم الشبكة لكل نموذج . تم بناء 6 نماذج وتقييمها: 3 نماذج من نوع MISO (متعدد المدخلات بمخرج واحد) إما COD أو BOD أو TSS. و 3 نماذج من نوع MIMO (متعدد المدخلات متعدد المخرجات): إما COD&BOD ، أو COD&TSS ، أو BOD&COD&TSS . (تم عرض نتائج النموذج 2 بشكل مفصل) .	بناء الشبكة العصبونية: The (ANN) design
1- <u>نماذج التنبؤ بقيم COD</u> : نموذج واحد نوع MISO بـ 9 متغيرات دخل، و 3 نماذج نوع MIMO تم تطويرها لتقدير قيمة COD في المياه المعالجة. بين النماذج المطورة للتنبؤ بقيم COD فان النموذج من نوع MIMO مع مخرج (COD&BOD) أثبت قدرة عالية الأداء على التعميم والتنبؤ بقيمة $R=0.9133$ في وقت كان نموذج MISO ونماذج MIMO الأخرى بقيم أقل لـ R. 2- <u>نماذج التنبؤ بقيم BOD₅</u> : نموذج نوع MISO واثنان نوع MIMO تم تطويرهما لإيجاد أفضل بناء شبكة للتنبؤ بقيمة BOD ₅ في المياه الخارجة. نموذج MISO وجد أنه الأفضل للتنبؤ بقيم BOD ₅ من نموذج MIMO بقيمة $R=0.99867$. الجدول (S6) في الملحق يبين الخواص الإحصائية لنماذج BOD ₅ ، والشكل (F4) في الملحق للنتائج. 3- <u>نماذج التنبؤ بقيم TSS</u> : نموذج نوع MISO بـ 9 بارامترات دخل ونموذجان نوع MIMO تم تطويرهما للتنبؤ بقيم TSS الخارجة. نموذج	قيم عامل الارتباط R والخطأ المتوسط التربيع: MSE

MIMO بمخرجات (BOD&COD&TSS) كان بأفضل أداء للتنبؤ بقيمة $R=0.9017$	
1- تأسيساً على نتائج المحاكاة فإن نماذج ANN قابلة للتطبيق والتنبؤ بقيم COD, BOD, TSS. 2- برهنت النتائج أن BOD_5 لها أكبر تأثير على قيم R في نماذج التنبؤ بقيم COD، وأكثر من قيم TSS وباقي البارامترات؛ بينما تركيز BOD_5 الخارج من المعالجة كان يعتمد بشكل مباشر على COD الداخل. 3- نموذج MIMO يفوق بأدائه نموذج MISO بما يخص أداء التنبؤ. 4 - اختيار تصميم الشبكة المناسب، واختيار بارامترات الدخل، هو ضروري للوصول الى دقة تنبؤ أو تقدير ممتاز. 5- نفس السلوك والتأثير لوحظ في نماذج TSS بوجود BOD_5 أو عدم وجودها ضمن المدخلات حيث عندما النماذج بدون BOD_5 في المدخلات أنجزت قيم أعلى ل R. 6 - مدخلات النماذج التي لا تحوي BOD_5 أعطت أفضل قياس أداء. التأثير كان عكسي بالنسبة لنماذج التنبؤ بقيمة BOD_5، إذ عندما النموذج الذي يحوي COD ضمن بارامترات الدخل تم إنجاز أفضل أداء وقيمة ل R وصلت حتى 0.99867 بالمقارنة مع النماذج حيث COD غير موجود. ولا تأثير مهم ل TSS.	النتائج والتوصيات: Results and recommendations.
8- 3 - نموذج محطة معالجة خربة المعزة في طرطوس / سورية: [12]	
بناء نموذج محطة معالجة خربة المعزة في سورية باستخدام الشبكة العصبونية (ANN). modeling of Khirbet al-Muazah WWTP in Syria by applying (ANN)	المواد والوسائل. Materials and methods
تقع بين مدينتي طرطوس وصافيتا ، تعمل بالحماة المنشطة وتقنية التهوية المديدة (Extended Aeration)، تخدم تجمع قري (10.000) نسمة، بجريان وسطي يومي (1000)م³/يوم. النسبة ($COD/BOD_5 = 2$) ويشير إلى نسبة جيدة من المادة العضوية سهلة التحلل بيولوجياً، معظم BOD_5 مصدره منزلي مع نسبة قليلة صناعي.	وصف المحطة: Description of Khirbet al-Muazah WWTP
إزالة BOD_5 + نترجة.	الهدف من المحطة:
COD, BOD_5, PO_4^{-3}, NO_3^{-}, T, PH, EC, TDS.	المدخلات: INPUTS

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

المخرجات: OUTPUTS	نفس المدخلات استخدمت كمخرجات وكقيم مستهدفة للنموذج.
فترة أخذ البيانات ومعالجتها: -The period Data .of collection Data analysis. -	أخذت العينات من دخل وخرج المحطة خلال فترة 3 سنوات (2020-2018) استخدمت قاعدة البيانات لتطوير النموذج، حيث أخذت 198 عينة مياه مجاري من الدخل ومثلها من خرج المحطة. البيانات تغطي التغيرات الفصلية. تم قياس 8 بارامترات دخل و 8 بارامترات خرج للمكونات المذكورة سابقا. تمت المعالجة الإحصائية للبيانات ضمن بيئة برنامج MATLAB وبواسطة التابع ANOVA1. قبل استخدام قيم المدخلات والقيم المستهدفة في بناء الشبكة ANN تمت تسويتها Normalized لتصبح بين قيمتي الصفر والواحد.
الشبكة العصبونية المستخدمة وملحقاتها: Type of (ANN) .applied	بما يخالف الدراسات السابقة التي استخدمت عامل الارتباط الخطي بين بارامترات الدخل والخرج لاختيار المدخلات المسيطرة للنماذج غير الخطية، هذه الدراسة تختبر أشكال مختلفة من دمج بارامترات الدخل باستخدام شبكة ANN. سيناريوات شبكة ANN الضحلة (SNN) الرئيسية استهدفت إنجاز أداء مثالي باستخدام صندوق أدوات MATLAB وخوارزمية LM للتدريب، حيث السيناريو الأول S1 يتألف من طبقة مدخلات وطبقة مخفية واحدة وطبقة مخرجات وتابع تفعيل هو Tansig للطبقة المخفية وتابع تفعيل Linear لطبقة المخرجات. السيناريو الثاني S2 طبقة مدخلات و 2 طبقة مخفية وطبقة مخرجات وتابع تفعيل Sigmoid للطبقة المخفية الأولى و Tansig للطبقة المخفية الثانية وتابع تفعيل Linear لطبقة المخرجات. الخطأ متوسط التربيع MSE وعامل الارتباط R استخدمتا لتقييم أداء الشبكة في كلا السيناريوين. تضمنت الدراسة تطوير 7 نماذج باستخدام شبكة ANN. حيث استخدمت شبكة التغذية الامامية FFNN وشبكة الغابة العشوائية RF وشبكات طرائق التعلم المعمق (deep learning methods) مثل الشبكة العصبونية الالتقافية CNN والشبكة المتكررة RNN والشبكة التراكمية SAE والهدف من هذه النماذج هو التنبؤ بأداء المحطة والتعرف على مواصفات المياه من خلال توضيح العلاقة بين بارامترات الدخل والخرج لمحطة قائمة.
بناء الشبكة العصبونية: The (ANN) design	تضمنت الدراسة تطوير (7) نماذج محاكاة ، وكانت أكثر النتائج دقة للشبكات بطبقتين مخفيتين وببين الجدول 13 نتائج المحاكاة للنماذج التي تم تطويرها من بيانات محطة خربة المعزة و في الجدول 5 عرض

كل نتائج محاكاة النموذج (1) المفرد COD_{eff} وتصميم الشبكة العصبونية (عدد الطبقات المخفية وعدد العصبونات بكل طبقة) : 1-نموذج مفرد: COD_{eff} Single mode: تم تطوير عدة شبكات عصبونية وفق سيناريوين رئيسيين. سيناريو 1: طبقة مخفية واحدة. سيناريو 2: طبقتان مخفيتان. كل من السيناريوين تتضمن طبقة مدخلات تتألف من خمس سيناريوات جزئية (الجدول 5). 2- النموذج المفرد BOD_{5eff} بشكل مشابه تماما لتطوير نموذج (COD_{eff}) تم بناء نموذج مفرد للبارامتر BOD_{eff} خمس سيناريوات جزئية بعدد المدخلات التالية: (4,5,6,7,8) من مدخلات بارامترات المحطة. ووفق سيناريو 1 طبقة مخفية واحدة وسيناريو 2 طبقتان مخفيتان وطبقة مخرجات واحدة هي BOD_{eff}. كما تم تطوير النماذج التالية بشكل مشابه تماماً لنماذج COD_{eff}، BOD_{eff} - 3 - النموذج المفرد: $PO_4^{-3} eff$ ، 4- النموذج المفرد: $NO_3^{-} eff$ ، 5- النموذج المدمج: (COD_{eff} and BOD_{5eff}) Ensemble 6 ، - النموذج المدمج: ($PO_4^{-3} eff$ and $NO_3^{-} eff$) - 7- النموذج المدمج: ($NO_3^{-} eff$ & $PO_4^{-3} eff$ & BOD_{5eff}) Ensemble(COD_{eff})	
- يتضمن الجدول 13 نتائج النماذج التي تم تطويرها من بيانات محطة معالجة خربة المعزه وهي (7) نماذج تحوي قيم عامل الارتباط والخطأ المتوسط التربيع وبناء الشبكة لكل نموذج. - وقد طبقت الشبكة العصبونية العميقة (DNN) على بيانات أفضل نموذج COD_{eff} للسيناريو الثاني ($M_4 - S_2$). تتألف الشبكة من ثلاث طبقات مخفية وفق تسلسل العصبونات التالية (50:30:10) وأعطت نتائج أفضل بقليل حيث قيمة $MSE = 54.71, R = 0.929$. - وطبقت شبكة الغابة العشوائية (RF) على بيانات أفضل نموذج COD_{eff} للسيناريو الثاني ($M_4 - S_2$) فأعطت: $MSE = 24.3, R = 0.933$ ، - أما نتائج تطبيق الشبكة الالتفافية CNN على بيانات $M_4 - S_2$ فكانت: $MSE, R = 0.42$ ، $152.81 =$ ونتائج تطبيق الشبكة التكرارية RNN على بيانات $M_4 - S_2$ فكانت : $MSE = 62.16, R = 0.51$ ، - كما طبقت الشبكة التراكمية (SAE) وتم تجربتها بثلاث طبقات مخفية وأربعة وخمسة وتم	قيم عامل الارتباط R والخطأ المتوسط التربيع: MSE

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

تجريب أرقام عدد عصبونات لكل طبقة حيث بقيت طبقة المدخلات بـ 7 بارامترات للنموذج الأفضل S2 – M4 وكانت النتائج: $R = 0.34$، $MSE = 0.174$ ، والهدف من مقارنة النماذج بطبقتين مخفيتين مع نماذج طبقة مخفية واحدة هو تحقيق تكامل بين النماذج، بمعنى تخفيض عيوب كل نموذج طبقة، وتعزيز النموذج الأكثر موثوقية بدقة عالية بطبقتين.	
1- استخدام نماذج SNN بطبقتين مخفيتين، ونماذج شبكة RF أعطى نتائج ارتباط ممتازة في كل المراحل (التدريب، التحقق، الاختبار، العام) ، وأفضل بالمقارنة مع نماذج طبقة مخفية واحدة من SNN. 2- أكثر من ذلك، أداء النماذج طبقة واحدة أو طبقتين مخفيتين قد تحسن عند زيادة عدد المدخلات من متغيرات أو بارامترات المحطة. 3- الشبكة العصبونية العميقة (CNN, RNN, SAE) DNN يمكن أن تستخدم لنمذجة محطات المعالجة ولكن تعطي دقة أقل وأداء أقل في حال مجموعات قواعد البيانات الصغيرة، وحسب المعلومات المتوفرة من إدارات مياه الصرف الصحي عن مجموعات البيانات الصغيرة، أن الشبكات العصبونية الضحلة SNN (طبقة مخفية أو طبقتان مخفيتان) ينصح بها بشكل كبير في نمذجة محطات معالجة المياه. 4- استخدام هذه النماذج يساهم بشكل معتبر في تخفيض القياسات المخبرية الدورية، بما يخفض تكاليف التشغيل لهذه المحطات، كما يمكن إضافة بارامترات تشغيلية من أحواض التفاعل إلى النماذج ومقارنتها حيث ينصح بأن تتضمن ذلك في أعمال مستقبلية.	<u>النتائج والتوصيات:</u> -Results and recommendations

الجدول 5



Model No.	Model Input Variables	Model Output Variable(S)	Training (Correlation Coefficient)	Validation (Correlation Coefficient)	Testing (Correlation Coefficient)	All Data (Correlation Coefficient)	No. Neurons in Hidden Layers	MSE
M1-S1 M1-S2	T_{inf} , pH_{inf} , EC_{inf} , TDS_{inf}	COD_{eff}	0.557 0.6637	0.37 0.317	0.49 0.6104	0.504 0.605	67 60-40	137.42 121.26
M2-S1 M2-S2	T_{inf} , pH_{inf} , EC_{inf} , TDS_{inf} , $NO_3^-_{inf}$	COD_{eff}	0.65 0.6859	0.703 0.6838	0.806 0.6023	0.676 0.671	65 55-30	39.57 67.34
M3-S1 M3-S2	T_{inf} , pH_{inf} , EC_{inf} , TDS_{inf} , $NO_3^-_{inf}$, $PO_4^{3-}_{inf}$	COD_{eff}	0.605 0.696	0.71 0.804	0.393 0.769	0.59 0.719	65 60-40	169.21 46.61
M4-S1 M4-S2	T_{inf} , pH_{inf} , EC_{inf} , TDS_{inf} , $NO_3^-_{inf}$, $PO_4^{3-}_{inf}$, BOD_{5inf}	COD_{eff}	0.79 0.891	0.752 0.912	0.872 0.833	0.798 0.888	55 50-30	48.937 8.5135
M5-S1 M5-S2	T_{inf} , pH_{inf} , EC_{inf} , TDS_{inf} , $NO_3^-_{inf}$, $PO_4^{3-}_{inf}$, BOD_{5inf} , COD_{inf}	COD_{eff}	0.79 0.826	0.67 0.78	0.658 0.895	0.754 0.841	60 50-30	44.963 40.09

9-3 - نموذج محطة معالجة الرستمية في بغداد / العراق [7]

المواد والوسائل. Materials and methods	بناء نموذج محطة معالجة الرستمية في بغداد باستخدام الشبكة العصبونية (ANN). Modeling of AL-Rustumiya WWTP in Iraq by applying (ANN).
وصف المحطة: Description AL-Rustumiya WWTP	تخدم 1,500,000 نسمة مصممة لمعالجة مياه منزلية، تصريف وسطي للمحطة Q= 300,000m ³ /d محطة حمأة منشطة تقليدية لإزالة بيولوجية للمواد العضوية الكربونية.
الهدف من المحطة:	إزالة BOD ₅ .
المدخلات : INPUTS	PH, CL ⁻ , TDS, TSS
المخرجات : OUTPUTS	COD, BOD ₅
فترة أخذ البيانات ومعالجتها:	أخذ البيانات على فترة 10 سنوات (2011-2021) على أساس شهري من مدخل المحطة ومخرج حوض الترسيب الثانوي.
الشبكة العصبونية المستخدمة وملحقاتها: Type of (ANN) applied.	Feed-Forward Back Propagation (FFBP) / خوارزمية التدريب: $f(x)=e^x-e^{-x}/e^x$, $f(x)=1/1+e^{-x}$ ، توابع التفعيل Levenberg-Marquardt ، e^{-x} تابع الأداء: الخطأ المتوسط التربيع: MSE، عامل الارتباط: R
بناء الشبكة العصبونية: The (ANN) design.	تضمنت الدراسة بناء نموذجين اثنين: النموذج الأول : استخدمت المدخلات الأربعة المذكورة سابقا كمدخلات و BOD ₅ كمخرج وحيد للنموذج الأول. النموذج الثاني : استخدمت نفس المدخلات الأربعة كمدخلات ومخرج وحيد فقط هو COD للنموذج الثاني. تم بناء النماذج (تصميم شبكة ANN) بطريقة المحاولة والخطأ وتبين بعد عديد من المحاولات ان الشبكة التالية (4:13:1) ANN قد أعطت أفضل النتائج لمحاكاة قيم (BOD ₅) الخارجة من المعالجة (النموذج الأول): طبقة مدخلات (4 مدخلات) PH, CL ⁻ , TDS, TSS. طبقة مخفية واحدة (13 عقدة او عصبون) . طبقة مخرجات (خرج وحيد هو قيمة BOD ₅ الخارجة). أما النموذج الثاني لمحاكاة قيم COD الخارجة من المعالجة وبعد محاولات وتجريب تبين أن أفضل النتائج كانت من الشبكة ذات التصميم التالي: (4,13,1) / 4 مدخلات هي نفسها للنموذج 1، طبقة مخفية واحدة ب 13 عصبون طبقة خرج بقيمة وحيدة هي COD الخارجة.

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

وكانت النتائج كما في الشكل (12) للنموذج الأول: R (for all data) = 0.96 R (Training) = 0.98, R (Test) = 0.88, R (Validation) = 0.94 R (for all data) = 0.96 R (Training) = 0.96, R (Validation) = 0.94, R (Test) = 0.88	قيم عامل الارتباط R والخطأ المتوسط التربيع: MSE
نتائج النمذجة باستخدام ANN للتنبؤ بقيم COD & BOD_5 الخارجة من المعالجة قدمت ميزات متعددة تفوق طرق الحساب التقليدية حيث النماذج قادرة وبدقة ان تحسب كفاءة الإزالة لـ COD & BOD_5 لمحطة الرستمية باستخدام البيانات الخام. النماذج المطورة يمكن اعتبارها بسيطة وسريعة وأكثر الأدوات دقة في الحساب وأثبتت ان الشبكة المدربة بطريقة الارتداد العكسي وخوارزمية LM كانت كافية للتنبؤ بأداء المحطة من اجل COD & BOD_5 الخارجة وتم الحصول على أفضل النتائج بـ 13 عصبون للطبقة المخفية.	النتائج والتوصيات: Results and recommendations.



الشكل (13) نتائج محاكاة قيم COD

الشكل (12) نتائج محاكاة قيم BOD_5 الخارجة (النموذج 1).

الخارجة (النموذج 2).

4-النتائج ومناقشتها: Results and discussions

ضمن عملية المقارنة بين طريقة الشبكة العصبونية (ANN) في تطوير نماذج محطات المعالجة ، وطريقة النموذج الأساس (ASM1) المبني على المعادلات والحساب والمبادئ الهندسية الاساسية ، سيتم تناول المحاور التالية:

أولاً-الدقة في التنبؤ بمخرجات عملية المعالجة البيولوجية من خلال مؤشرات (عامل الارتباط R ، والخطأ MSE):

- عرض مختصر لنتائج نموذج محطة معالجة مدينة Verona بإيطاليا:
- يبين الشكل (2) مخطط المقارنة بين القيم المقاسة لمحطة Verona وقيم نتائج محاكاة النموذج التي تم التنبؤ بها لبارامترات COD, N-NH4, TSS, MLSS, N-NO3, RAS، وفق طريقتان للمحاكاة (A,B) كما تقدم. (الجدول 2) :
- حيث يظهر المخطط بشكل واضح خمسة قيم لكل بارامتر وهي مرتبة على الشكل التالي من اليسار الى اليمين:
- 1- القيمة المقاسة (بيانات المحطة)، 2- قيمة المحاكاة (طريقة A)، 3- قيمة المحاكاة (طريقة A / تم معايرتها) 4- قيمة المحاكاة (طريقة B)، 5- قيمة المحاكاة (طريقة B / تم معايرتها). - يذكر أنه تمت معايرة النموذج (ASM1) لبعض القيم وهي آزوت النشادر N-NH4 وآزوت النترات N-NO3 بسبب عدم تقارب القيم المقاسة مع قيم محاكاة النموذج (فرق كبير نسبياً). وتم بطريقة القياس الدقيق تحويل المخطط في الشكل (2) الى الجدول (6) التالي مبيناً فيه قيم كل بارامتر قبل وبعد المعايرة:

البارامتر	القيمة المقاسة بيانات المحطة	قيمة المحاكاة طريقة A	قيمة المحاكاة طريقة A(معايرة)	قيمة المحاكاة طريقة B	قيمة المحاكاة طريقة B(معايرة)
COD _{tot}	29.0	29.65	29.4	29.45	29.35
N-NH4	3.0	6.57	3.0	6.72	3.22
N-NO3	4.1	6.13	5.18	4.88	4.50
TSS	12.0	11.8	11.70	11.70	11.55
MLSS	4.50	3.95	3.80	3.35	3.80
RAS	5.8	5.10	5.00	4.35	5.00

الجدول 6

وتم حساب عامل الارتباط (R) بين القيم المقاسة وقيم المحاكاة قبل المعايرة للنموذج وبعد المعايرة: (الطريقتان A و B) وفق التالي : $R = \text{قيم المحاكاة} / \text{القيم المقاسة}$ ، ويتم حساب قيمة R عامل الارتباط

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

وبطريقتين: - وفق قيم المحاكاة قبل معايرة النموذج ASM1 - وفق قيم المحاكاة بعد معايرة النموذج ASM1. ويبين (الجدول 7) التالي قيم R لنموذج Verona وفق التالي:

الجدول 7

البارامتر	COD _{tot}	N-NH ₄	N-NO ₃	TSS	MLSS	RAS
قيمة R قبل المعايرة / ط A	1.02	2.19	1.49	0.98	0.87	0.87
قيمة R بعد المعايرة / ط A	1.01	1.00	1.26	0.98	0.85	0.86
قيمة R قبل المعايرة / ط B	1.02	2.24	1.19	0.98	0.74	0.75
قيمة R بعد المعايرة / ط B	1.01	1.07	1.09	0.96	0.84	0.86

ويسبب تقارب النتائج نسبياً بين قيم الطريقة A والطريقة B تم أخذ الوسطي لقياسات R (وسطي (A+B/2) وبحساب R للبارامترات السابقة قبل معايرة النموذج نجد: R(COD_{tot})=1.02, R(TSS)=0.98,

$$R(0.8, R(N-NH_4)=2.20$$

R(N-NO₃)=1.35, R(RAS)=0.82, وتصبح بعد معايرة النموذج وفق التالي: R(TSS)=0.97,

R(N-NO₃)=1.18, R(COD_{tot})=1.01, R(N-NH₄)=1.03, R(MLSS)=0.85, وبالنظر للنتائج قبل المعايرة وبعدها يتبين ان قيمة عامل الارتباط R هي نفسها تقريباً (متطابقة)، و(RAS)=0.86،

قبل المعايرة وبعدها للبارامترات: RAS, MLSS, TSS, COD_{tot}.

وأنها قد اختلفت بشكل كبير جداً لآزوت النشادر N-NH₄ حيث كان R قبل المعايرة (2.20) (بعيد جداً عن القيمة المقاسة) ليصبح بعد المعايرة (1.03) (مطابق تقريباً للقيمة المقاسة بانحراف 3%)، وأن قيمة المحاكاة لآزوت النترات N-NO₃ قد اقتربت أكثر من القيمة المقاسة- حيث كانت قبل المعايرة (1.35) ليصبح بعد المعايرة (1.18) (ما تزال نسبياً كبيرة). ويبين الجدول التالي قيم عامل الارتباط للبارامترات قبل وبعد المعايرة وقيمة الانحراف لكل بارامتر (بعد المعايرة).

(الجدول 8)

البارامتر	COD _{tot}	TSS	N-NH ₄	N-NO ₃	MLSS	RAS
R قبل المعايرة	1.02	0.98	2.20	1.35	0.8	0.82
R بعد المعايرة	1.01	0.97	1.03	1.18	0.85	0.86
d قيمة الانحراف %	1	3	3	18	15	14

وسيتم اعتماد قيم R بعد المعايرة لكون قيم المحاكاة أصبحت قريبة من القيم المقاسة ودقة النموذج أفضل لكل البارامترات، أما قيمة R الوسطية للبارامترات المقاسة الواردة في الجدول 7 وبعد حساب عامل الارتباط لكافة البارامترات التي أجريت عليها المحاكاة تصبح كالتالي: القيمة الوسطية للانحراف = مجموع الانحرافات / عدد البارامترات (n): حيث (n= 6) عدد البارامترات التي أجريت عليها المحاكاة. قيمة الانحراف (d) لكل

بارامتر = 1- (عامل الارتباط بعد المعايرة في الجدول 8) %، وتتخذ قيمة الانحراف بالقيمة المطلقة ولا تؤخذ إشارة الناتج لكون الانحراف هو البعد عن القيمة المقاسة سواء زيادة أو نقصان.

$$d = \text{SUM } d_i / n = 1+3+3+18+15+14/6 \rightarrow d = 54/6 = 9\%$$

(d).

القيمة الوسطية لعامل الارتباط R: $R = 1 - d = 1 - 0.09 = 0.91$ ، فتكون قيمة عامل الارتباط $R = 0.91$

لنموذج Verona

• عرض مختصر لنتائج نموذج محطة معالجة مدينة Salamanca /إسبانيا:

يبين المخطط بالشكل (4-a) نتائج محاكاة نموذج ASM1 الديناميكي لقيم COD الخارجة من المعالجة، ويمثل الحالة الأكثر دقة والموافقة لأصغر قيمة خطأ محسوبة بين نتائج المحاكاة والقيم المقاسة (-0.05%) من خلال خطوة التقريب الدقيق Fine tuning والتي أعطت أدق القيم لـ μ_{Hmax} و Y_H وفق التالي: $\mu_{Hmax} = 0.40 \text{ d}^{-1}$ ، $Y_H = 0.6$. ويتضمن الجدول S5 في الملحق كافة قيم نتائج المحاكاة، وقيم COD المقاسة الخارجة من المعالجة، وقد أخذت الأسطر الأربعة الأولى والأسطر الأربعة الأخيرة من الجدول لبيان الحسابات والنتائج، وتم تنزيل الرابط المتضمن كافة معلومات الجدول وبيانات المحطة وحسابات الأخطاء. تم حساب قيمة عامل الارتباط بين قيم محاكاة ASM1 والقيم المقاسة من المحطة من خلال أخذ 3 عينات من كتلة القياسات البالغة (93) قياس وفق الإجراء التالي: عينة A (من المجال الزمني 0-100/يوم) وتتخذ القراءات من القيمة رقم 6 حتى القيمة رقم 21 ضمناً - مجال مستمر - تتضمن 15 قيمة متتالية (تم استبعاد القيمة رقم X20 من القيم المقاسة واعتبرت

متطرفة أو شاذة وهي 45.6 mg/l ويبين الجدول رقم (9) التالي كافة الحسابات لقيم عوامل الارتباط

n	6	7	8	9	10	11	12	13	14	15	16	17	18	19	21
قيم مقاسة X_i	21.6	21.0	27.2	34.1	29.3	31.1	25.9	25.6	23.7	23.9	26.2	23.7	18.6	24.3	22.4
قيم محاكاة Y_i	24.5	24.2	27.6	31.0	34.3	37.6	21.6	21.0	17.7	21.5	19.2	24.3	12.4	27.3	16.4
عامل الارتباط	1.13	1.15	1.01	0.91	1.17	1.21	0.83	0.81	0.75	0.90	0.73	1.06	0.67	1.13	0.73
% الانحراف d_i	13	15	1	9	17	21	17	19	25	10	27	6	33	13	27

والانحرافات: الجدول (9)

$$d = \text{SUM } d_i / n = 253/15 = 16.87\%$$

القيمة الوسطية للانحراف (d) : $R_1 = 1 - d = 1 - 16.87\% = 83.13\%$: (a) للقيمة الوسطية لعامل الارتباط R

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

- عينة B (من المجال الزمني / 200 - 100/ يوم) وتتؤخذ القراءات من القيمة رقم 30 حتى القيمة رقم 47 ضمناً - مجال مستمر - تتضمن 17 قيمة متتالية (تم استبعاد القيمة رقم 42 من قيم المحاكاة واعتبرت متطرفة أو شاذة) ويبين الجدول رقم (10) التالي كافة الحسابات لقيم عوامل الارتباط والانحرافات والقيم الوسطية للانحراف :

الجدول(10)

n	30	31	32	33	34	35	36	37	38	39	40	41	43	44	45	46	47
مقاسة X_i	27	29	35	17	22	37	30	26	26	25	27	28	15	18	20	27	33
	.5	.9	.0	.8	.7	.0	.2	.7	.9	.0	.2	.3	.4	.1	.2	6	.2
محاكاة Y_i	27	23	33	17	16	25	36	16	21	18	36	31	9	20	21	35	28
	.7	.1	.5	.1	.2	.5	.9	.5	.6	.9	.2	.3	5	.2	.8	4	.7
R	1.	0.	0.	0.	0.	0.	1.	0.	0.	0.	1.	1.	0.	1.	1.	1.2	0.
ارتباط	01	77	96	96	71	69	22	62	80	76	33	11	62	12	08	8	86
(d _i) %	1	23	4	4	29	31	22	38	20	24	33	11	38	12	8	28	14

القيمة الوسطية للانحراف: $d = \text{SUM } d_i / n = 340/17 = 20\%$ القيمة الوسطية لـ R: $R_2 = 1 - R = 80\%$ عينة C (من المجال الزمني / 343 - 250/ يوم) وتتؤخذ القراءات من القيمة رقم 80 حتى القيمة رقم 91 ضمناً - مجال مستمر - تتضمن 12 قيمة متتالية ويبين الجدول رقم (11) التالي كافة الحسابات.

الجدول(11)

n	80	81	82	83	84	85	86	87	88	89	90	91
مقاسة X_i	24.1	26.8	28.8	24.3	26.9	47.6	28.6	30.8	27.1	22.7	24.5	27.4
محاكاة Y_i	24.7	28.2	35.7	28.1	28.2	36.7	32.2	22.1	20.1	19.9	23.7	20.9
R / ارتباط	1.03	1.05	1.24	1.15	1.05	0.77	1.13	0.72	0.74	0.88	0.97	0.76
(d _i) %	3	5	24	15	5	23	13	28	26	12	3	24

القيمة الوسطية للانحراف: $d = \text{SUM } d_i / n = 181/12 = 15.08\%$ القيمة الوسطية لـ R للعينة (c): $R_3 = 1 - R = 84.92\%$

تم حساب الوسطي لعامل الارتباط للعينات الثلاث (a,b,c)، ويكون بذلك عامل الارتباط R لنموذج Salamanca:

$$R = R_1 + R_2 + R_3 / 3 = 83.13\% + 80\% + 84.92\% / 3 = 82.68\%$$

المحطة (93) قياس لـ COD_{eff} فقد تضمنت العينات A,B,C (44) قياس واستبعاد قياسين ليكون 50% من البيانات المقاسة أخذت فعلياً في حساب R

لنموذج ، حيث قيم عامل الارتباط للعينات كانت متقاربة وضمن مجال (80-85%)، وتشير النتائج الى موثوقية ودقة.

ا. وتكون بذلك نتائج محطات المعالجة التي تم نمذجتها وفق النموذج الاساس (ASM1) كما في الجدول(12) التالي:

المحطة	عامل الارتباط R بين قيم محاكاة النموذج Simulated والقيم المقاسة (Real data)
--------	---

Verona / إيطاليا	0.91
Salamanca / إسبانيا	0.827

ويلاحظ من المقارنة وجود فرق كبير نسبياً بقيم عامل الارتباط بين نموذج Verona ونموذج Salamanca والسبب أن الأول تم تطويره على أساس النموذج (ASM1) الساكن أو ما يصطلح به (Steady state)، بينما الثاني تم تطويره على أساس النموذج (ASM1) الديناميكي أو (Non-steady state) حيث تشغيل محطة المعالجة بالحماة المنشطة بهذه الطريقة يتأثر بشروط ومدة التفاعلات المعقدة وديناميك السوائل و انتقال الكتلة (Mass transfer) ويعني معدل انتقال الأكسجين والانتقال الهيدروليكي، كما يتأثر بإزالة المغذيات والنترجة وديناميكية الكتلة الحيوية. [11]

II. أما نتائج نماذج محطات المعالجة بطريقة الشبكة العصبونية (ANN) فكانت قيم عامل الارتباط R وفق

الجدول (13) التالي:

المحطة WWTP	عدد النماذج المطورة لكل محطة	رقم النموذج كما ورد في الدراسة	عامل الارتباط R					
			التدريب Training	التحقق Validation	الاختبار Test	Total/ الكلية response	الخطأ متوسط التربيع MSE	عدد الطبقات المخفية للشبكة / العقد بكل طبقة.
العجمي/مصر	1	-	0.93004	0.86323	0.86289	0.90317	-	3/ 10, 30, 0
عدرا/دمشق	1	-	0.97903	0.56238	0.73884	0.86134	0.15	2/ 12, 11
كونيا/تركيا	1	-	0.99	-	0.96	-	0.00416	3/ 11,11,11
الرستمية/ بغداد	2	1	0.98	0.94	0.88	0.96	3.09	1/ 13
		2	0.96	0.94	0.96	0.96	4.28	1/ 13
سيحان/ تركيا	1	-	-	-	-	0.891	-	1/ 4
المعمرة/ العراق	3	1	0.9325	0.88	0.772	0.9133	1×10^{-6}	2/ 6,6
		2	1.00	0.9999	0.997	0.998	6.2×10^{-11}	2/ 6,6
		3	0.9165	0.85	0.895	0.9017	2×10^{-4}	2/ 6,6
خربة المعزه/ سورية	7	1	0.891	0.912	0.833	0.888	8.513	2/ 50,30
		2	0.901	0.942	0.895	0.906	2.14	2/ 30,50
		3	0.976	0.622	0.97	0.963	10.26	2/ 40,60
		4	0.928	0.953	0.937	0.932	65.94	2/ 30,50
		5	0.873	0.891	0.894	0.878	34.34	2/ 30,50
		6	0.958	0.966	0.738	0.942	56.94	2/ 30,50
		7	0.925	0.952	0.972	0.936	51.05	2/ 30,50

مقارنة النتائج مع المناقشة: Comparison and discussions

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

من خلال قراءة نتائج نماذج محطات المعالجة المطورة بطريقة الشبكة العصبونية (ANN) في الجدول (14) ، وحيث لدينا (7) محطات معالجة ، وتم تطوير (16) نموذج باستخدام بيانات هذه المحطات ، يجدر أن نلخص النتائج من خلال تقسيم قيم R الى مجالات وعدد النماذج ضمن كل مجال وفق الجدول (14) التالي:

قيمة عامل الارتباط R (%)	0.998	96-99	93-96	90-93	86-90	SUM
عدد النماذج ضمن كل مجال	1	5	3	3	4	16

وبالنظر في نتائج عامل الارتباط R لنماذج محطات الشبكة العصبونية، حيث النموذج رقم (2) لمحطة المعمرية حقق أعلى قيمة لعامل الارتباط R : (R= 100% للتدريب، R= 0.998 لكافة البيانات) -تقريباً 100% بانحراف 0.002.

ولدينا 5 نماذج بقيم (0.99-0.96) لـ R ، و 3 نماذج بقيم (0.96-0.93) لـ R ، بينما كانت أدنى 4 قيم لـ R هي: 0.891، 0.888، 0.887 وآخرها القيمة الأدنى على الإطلاق هي 0.86 لمحطة معالجة دمشق في عذرا .

ونشير هنا الى قيمة R للتدريب في محطة دمشق R=0.97 وهي قيمة محاكاة عالية جداً بعد تمرير 60% من المدخلات من بيانات المحطة ، بينما كانت R للتحقق Validation لمحطة دمشق (R=0.56) وهي منخفضة، وكانت قيمة R للاختبار Test (R=0.73) وهي قيمة منخفضة أيضاً وهذه الحالة تعرف بحالة التدريب الزائد أو حالة المبالغة في تدريب الشبكة؛ حيث الخطأ صغير جداً في محاكاة التدريب وخطأ كبير في نتائج محاكاة قيم التحقق والاختبار وكان يجب إعادة ضبط بارامترات الشبكة من أجل الحصول على ما يسمى "التوقف المبكر" للتدريب عند الحصول على أقل خطأ ممكن ويؤشر ذلك الى أن نتائج محاكاة نموذج محطة دمشق أقل دقة وموثوقية، وهذه الحالة لم تكن موجودة في أي من النماذج الأخرى الـ (15) التي تضمنتها هذه الدراسة . فمثلاً كانت قيم نتائج محاكاة محطة العجمي على الشكل التالي: R=0.93 للتدريب، R=0.86 للتحقق، R=0.86 للاختبار و R=0.903 لكل البيانات، فالقيم المتقاربة هي دليل على التدريب الصحيح للشبكة والبارامترات المضبوطة وبالتالي نتوقع محاكاة ودقة عالية لنموذج محطة العجمي .

❖ وبمقارنة نتائج نماذج Verona و Salamanca مع قيم R لنماذج الشبكة العصبونية يتبين:

وجود فرق كبير في الدقة والقدرة على التنبؤ بمواصفات المياه المعالجة بين النماذج المطورة باستخدام الشبكة العصبونية (ANN) التي وصلت قيمة R لبعضها حتى 100% ، بينما كانت قيم R للنماذج المطورة باستخدام النموذج الاساس (ASM1) بحدود 0.827 لمحطة Salamanca وهي

أقل بكثير من أدنى قيمة ناتجة لنماذج الشبكة العصبونية دقة والتي شملت الدراسة الحالية ، وقيمة 0.91 لمحطة Verona وهي قيمة جيدة نسبياً ولكن أيضاً أقل من معظم نتائج النماذج المطورة باستخدام الشبكة العصبونية ، ويستخلص من المقارنة أن نماذج الشبكة العصبونية (ANN) هي الأكثر دقة في التنبؤ بأداء المحطة والاستجابة للصدمات والسلوك المتأرجح للبارامترات الخارجة من المعالجة. خلال المقارنة بما يخص دقة الأداء يتبين قيم عالية لـ R لمعظم نماذج الشبكة العصبونية ANN وقيم أقل دقة وعامل ارتباط أقل لنماذج (ASM1) ونبين أهم الأسباب لتدني قيم R لنماذج (ASM1) :

- 1- تعتمد طريقة النموذج المعياري (ASM1) مجموعة من الافتراضات:
 - يتبين من نموذج VERONA افتراض تفاعل إرجاع أزوت في حوض الترسيب النهائي مشابه لما يحدث في حوض التفاعل (Anoxic). وتم في مخطط النموذج (الشكل 1) لحظ حوض ترسيب تفاعلي Reactive clarifier وأن النموذج ASM1 يوصف التفاعلات الحيوية ضمنه، حيث لا معلومات تؤكد صحة هذه الظاهرة [17].
 - تركيز المكونات في حوض التفاعل متجانس داخل كل حدود الحوض، بمعنى ان المياه الداخلة الى الحوض تمتزج بشكل كامل فور دخولها وهذا الافتراض هو للنماذج الهيدروليكية (CSTR) كون ASM1 مدمج مع نموذج هيدروليكي لحوض الترسيب الثانوي لبناء نموذج محطة Verona وهذا الافتراض يحمل نسبة من عدم الدقة.
 - تطبيق (ASM1) يتطلب توصيف المدخلات على أساس COD_{tot} وفق إجراءات معيارية (الطريقة A) وهي طريقة افتراضية، وتستخدم (الطريقة B) وهي معدلة عن A حيث يدخل في الحساب خصوصية المحطة التي يتم صنع النموذج لها، وكلا الطريقتان تطبق لإعداد مدخلات النموذج. (الجدول (2)). ومن خلال عملية المحاكاة للطريقتين (A,B) كان هناك فروق واضحة وكبيرة أحياناً في النتائج. بعد انجاز المدخلات كنسب من COD_{tot} ، تجري المحاكاة بإدخال بيانات الدخل للحصول على المخرجات ومقارنتها مع القيم المقاسة ، و تتم عملية الحساب ضمن البرنامج الحاسوبي الذي يقوم بإجراء المحاكاة حيث يتم الحساب وفق قيم افتراضية ومعيارية لمجموعة بارامترات النموذج المعياري (ASM1) وهنا تأتي الحاجة الى إجراء المعايرة (Calibration) للنموذج في حال كان هناك فروق كبيرة بين القيم المقاسة وقيم المحاكاة. ويكون ذلك من أجل بارامترات محددة وليس كل البارامترات المدروسة وقد تم في محطة Verona إجراء معايرة لثابت الاشباع K_s لأنواع من البكتريا لتعديل البارامترات والحصول على قيم محاكاة أقرب الى المقاسة.
 - عملية جمع البيانات في صنع النموذج بطريقة ASM1 تقوم على فرضية حالة الثبات في المعالجة البيولوجية حيث تجمع البيانات الخام من المحطة ويتم فحصها لاستخلاص مجموعات منها تمثل

بشكل تقريبي فترات تشغيل 30 يوم من حالة الثبات وبحسب الوسطي وتعالج احصائياً والوسطي يمثل حالة الثبات. (حالة محطة Verona). [17]

■ التفاعلات البيو كيميائية التي تحدث في أحواض التفاعل موصفة ضمن النموذج (ASM1)، كما أن السلوك الهيدروليكي للأحواض يمثل بنماذج هيدروليكية (CSTR) [17]. وفي كلا الحالتين يوجد افتراضات ضمن هذه النماذج.

■ تم تطبيق النموذج الديناميكي (ASM1) على محطة Salamanca ويتألف من 13- مكون (أشكال مختلفة للمغذيات والبكتريا) و-8- (عمليات نمو حيوي واستهلاك غذاء) وبالتالي يتضمن أولاً 13 معادلة تفاضلية لتوازن الكتلة و20 بارامتر Kinetic أو Stoichiometric. [4] فالنموذج ASM1 غالباً معقد جداً لحل معادلات التنبؤ في الحجم الحقيقي للمحطة ، وتوصيف مياه الصرف للنمذجة الرياضية وفق ASM1 صعب جداً ومستغرقاً للوقت، وأن استخدام عدد كبير من البارامترات للنمذجة (وجود عدد كبير من البارامترات في معادلات التوازن) سيؤدي الى فقدان ما يسمى "الاستجابة الجيدة" أو الدقة في تقارب قيم المحاكاة مع القيم المقاسة في مخرجات النموذج. [3] ولتخفيض التعقيدات غير الضرورية في المعادلات التفاضلية لتوازن الكتلة ومن أجل الاستجابة الجيدة للنموذج وللحصول على تقارب بين قيم النموذج الديناميكي والبيانات المقاسة فقد تم اعتماد الافتراضات أو التقريبات التالية : -**الافتراض الأول:** أن المياه الداخلة الى المعالجة البيولوجية بعد الترسيب الأولي عادة تكون بتركيز مواد صلبة نسبياً منخفضة، لذلك فإن عملية الانحلال Hydrolysis ليست عملية مهيمنة في تفاعل هدم المادة العضوية، وبالتالي لن تؤخذ بالاعتبار وسيتم استبعاد تأثير عملية الانحلال من المعادلات التفاضلية لتوازن الكتلة الصلبة . -**الافتراض الثاني:** عدم إزالة أي كمية من المادة العضوية COD في حوض تفاعل Anoxic و استبعاد تأثير العملية من المعادلات التفاضلية لتوازن الكتلة الصلبة . -**الافتراض الثالث:** تركيز الأكسجين لا يقتصر على 1.5 مع/ل، وفي عمليات المعالجة البيولوجية، يتم الحفاظ عليه أعلى من هذه القيمة، وتركيز الأكسجين (علاقة Monod) في النمو الهوائي للكائنات الدقيقة عضوية التغذية غير محدد، وبالتالي لا يؤخذ بالاعتبار في المعادلات التفاضلية . وبالرجوع الى المعادلات (4,5,6) ص(11) لتوازن الكتلة الصلبة في محطة Salamanca وبعد تطبيق التقريبات بناء على الافتراضات الثلاثة المذكورة وإزالة التعقيدات فقد حصلنا على معادلات جديدة (7,8,9) ص(12) بشكل مختزل وسهلة الحل وتحقق الاستجابة الجيدة للنموذج. بالمقابل فإن افتراض تركيز المادة العضوية الصلبة الحبيبية X_S الخارجة من حوض الترسيب الأولي قليلة نسبياً يتأثر بعوامل مختلفة مثل: - كفاءة عملية الترسيب في أحواض الترسيب الأولي . - تقلبات الجريان وصددمات الأحمال العضوية . - وخبرة مشغلي المحطة . ورغم هذه العوامل أو بدونها فهناك دراسات أعطت قيم عالية لتركيز X_S للمياه الخارجة من الترسيب الأولي : فمثلاً كانت قيمة $X_S = 131 \text{ mg/l}$ بمحطة Verona الجدول (2) ، وفي دراسة عن توصيف نموذج الحماة المنشطة رقم 1 (ASM1) كانت قيمة $X_S = 150 \text{ mg/l}$ لبارامترات نموذجية [11]. وبكل الحالات فإن حذف تأثير عملية الانحلال Hydrolysis لحبيبات X_S من حساب COD_{eff} سيقود الى انحراف في النتائج لأن مدخلات

عملية المحاكاة بالأصل تحمل أخطاء. وفيما يخص الافتراض الثاني بعدم إزالة أية مادة عضوية COD خلال تفاعل Anoxic أيضاً يحمل نسبة من الخطأ وسيؤدي الى انحراف إضافي وتباعداً أكثر بين قيم المحاكاة والقيم المقاسة (حيث أنه يحدث بعض التخفيض في قيم COD خلال التفاعل اللاهوائي Anaerobic ، وخلال تفاعل Anoxic). [4,11,15] أما فيما يخص الافتراض الثالث ورغم أهميته فهو الأقل تأثيراً بالنتائج من الافتراض الأول والثاني إضافة الى سهولة التحكم بتركيز الأكسجين في الأحواض بالزيادة أو النقصان بالمقارنة مع تراكيز المغذيات أو التأثير على معدل العمليات البيولوجية. فالنموذج ASM1 وطبيعته المعقدة وكثرة الافتراضات وصعوبة توصيف مياه المجاري لتناسب مدخلاته على أساس تجزئ COD_{tot} كلها جملة معقدة يصعب أن تتوقع في نهايتها دقة في التنبؤ ترضي طموح المصممين والمشغلين.

❖ بينما بطريقة الشبكة العصبونية (ANN) لا يوجد افتراضات ولا يوجد معادلات توازن أو علاقات حساب أو أية معلومات تخص عملية المعالجة يتم إعطاؤها للشبكة والحساب وفقها باستثناء بيانات المحطة.

2- تأثير آلية حساب مخرجات النموذج (ASM1) على دقة النتائج: النموذج (ASM1) يقوم على معادلات وعلاقات حساب تجريبية لإعطاء المخرجات ، فالبرامج الحاسوبية التي استخدمت لمحاكاة القيم سواء برنامج WEST[®] لنموذج محطة Verona ، أو برنامج MATLAB R2021b لمحطة Salamanca تنفذ عمليات حساب بارامترات الخرج بناءً على المعادلات والعلاقات التي تم تخزينها في حساب (ASM1) ضمن البرمجيات المذكورة ، حيث يستخدم أكثر من 20 من بارامترات النشاط الحيوي (Kinetic parameters) أهمها عامل كفاءة النمو Y ، و معدل النمو الأعظمي للكتلة الحيوية μ_{max} ، وثابت نصف الإشباع K_s ، وعامل الاضمحلال الخلوي K_d ، وعوامل تصحيح التقاعلات.... الخ ومعظمها ليس لها قيمة محددة بل تعطى ضمن مجال واسع من القيم أحياناً وتحتاج الى تصحيحات وتقريبات من خلال المعايرة ، وتدخل في حساب مخرجات النموذج وأهمها COD_{eff} (المادة العضوية الخارجة من المعالجة) ، وهنا تكمن المشكلة ، والحل هنا من أجل نتائج أفضل يتطلب المزيد من البحث لتطوير عملية حساب بارامترات الحمأة المنشطة .

❖ بينما بطريقة الشبكة العصبونية لا يوجد عمليات حساب في الأصل ولا علاقات ولا معادلات تعطى للشبكة ؛ بل عملية تصميم بطريقة التجريب والمحاولة والخطأ ، يتبعها عملية تدريب للشبكة وكلتا العمليتان تقومان على خبرة النمذج، ويتم المحاكاة على الحاسب ويطبق MATLAB، وتتم عملية التدريب بمحاكاة 60-70% من البيانات المعالجة المقاسة بإدخال أزواج البيانات (شعاع الدخل، شعاع الخرج) وهناك تابع للتدريب ضمن MATLAB يدير العملية هو Train LM ومن خلال استقراء نتائج النماذج المطورة بطريقة الشبكة العصبونية (ANN) بالجدول (13) و (14) ل (7) محطات معالجة و (16) نموذج نستخلص : 1 - قيمة R للتدريب أكبر من R لكل من التحقق والاختبار والكل ل

10 نماذج من أصل 16 نموذج. 2 - قيمة R للتدريب أكبر من R لكل من التحقق والاختبار والكل ل 6 محطات من أصل 7 ، فقط نتائج محطة خربة المعزة في سوريا نتائجها كانت مخالفة لباقي المحطات بخمس نماذج لها من أصل 6 نماذج. 3- التدريب الصحيح للشبكة العصبونية كان السبب الأهم في الحصول على قيم كبيرة ل R في النماذج المدروسة، فعندما قيم R للتدريب كانت كبيرة و متقاربة مع R للتحقق والاختبار والكل كان التدريب صحيح ونتائج الشبكة بأعلى دقة ممكنة (نموذج 2 المعمرة)، وعندما قيمة R للتدريب كبيرة ومتباعدة عن قيم باقي عوامل الارتباط يكون التدريب مبالغ فيه ودقة الشبكة أقل (حالة التدريب الزائد/ كما حالة محطة معالجة دمشق) والحل لتفادي هذه الحالة هو التوقف المبكر لعملية التدريب عند الوصول لقيم صغيرة وقيم كبيرة ل R، وعندما قيم R للتدريب صغيرة فالتدريب مرفوض والحل يكون (تكبير نسبة بيانات التدريب أو توسيع قاعدة البيانات المأخوذة من المحطة). 4- الخبرة أساسية في بناء الشبكة بطريقة المحاولة والخطأ وفي عملية التدريب فاختيار الحجم المناسب للشبكة يؤسس لحالة تدريب ناجح، وعندما يتحقق تصميم مناسب وتدريب صحيح نتوقع نتائج كبيرة ل R وقيم صغيرة للخطأ MSE و تنبؤ أفضل للبارامترات الخارجية.

ثانياً - خطوات ومراحل عملية النمذجة: تتلخص مراحل تطوير النماذج تأسيساً على ASM1 بالخطوات التالية (حالة النموذج الساكن Steady state): - جمع البيانات من المحطة المدروسة. - معالجة البيانات وتتضمن: -تحقق البيانات الخام واستخلاص عدة مجموعات منها التي تمثل فترات 30 يوم تشغيل في حالة الثبات. - يحسب الوسطي لها وتدقق على أساس معادلات توازن الكتلة (يجب أن يكون الوسطي يمثل وسطى حالة الثبات). - يستخدم في إجراء المحاكاة ووسطى البيانات من فترتين مختلفتين ونفس الوسطي يستخدم لإجراء المعايرة (لاحقاً). - اعداد مخطط النموذج على الحاسب باستخدام برنامج احترافي. (الشكل 1). - يتطلب تطبيق ASM1 توصيف المدخلات على أساس COD_{tot} ويتم إعداد جدول نتائج التجزيء باسم "مكونات دخل النموذج" (الجدول 2) حيث لدينا جدولان معطيات/ جدول مدخلات للمكونات الكربونية/ و جدول مدخلات للمكونات الآزوتية. وفي كل جدول يتم اعداد المدخلات بطريقتين A، B حيث A هي الطريقة المعيارية المتضمنة في ASM1 و B أكثر كلاسيكية وتأخذ بالحسبان ظروف المعالجة الخاصة بالمحطة. - إجراء المحاكاة بإدخال قيم المدخلات الى (البرمجية المختصة) ورسم مخطط المقارنة. - تقييم النتائج وإجراء المقارنة بين القيم المقاسة وقيم المحاكاة وتحديد حالات الفروقات الكبيرة. - إجراء المعايرة في حالات الفروقات الكبيرة (وهي حالة مؤكدة لبعض البارامترات). - تقييم النتائج وتحليلها بعد إجراء المعايرة والمقارنة بين القيم المعدلة الجديدة والقيم المقاسة. - (قد يلزم معايرة ثانية في حال بقيت فروق كبيرة بين القيم المقاسة وقيم خرج النموذج). - في حال عدم إجراء معايرة ثانية والقبول بالقيم الناتجة يتم إجراء التحقق على النموذج ويعني التحقق

إجراء محاكاة على النموذج لكن باستخدام مجموعة جديدة من بيانات الدخل مختلفة عن البيانات المدخلة سابقا ومن فترات زمنية مختلفة أيضا. حيث أن المبدأ الأساسي للتحقق من النموذج المعايير أن نحافظ على كافة البارامترات المعدلة (المعايرة سابقاً) ثابتة من أجل أن تكون النتائج الجديدة قابلة للمقارنة. [17] - عرض النتائج والتطبيقات الممكنة للنموذج والفائدة المتحصلة من تطبيقه على المحطة المستهدفة أو محطة مشابهة بعد المعايرة . - كافة الخطوات السابقة نفذت لتطوير نموذج محطة Verona على أساس النموذج الاساس ASM1 وفي حالة الثبات Steady state وهي مبسطة بإجراءاتها بالمقارنة مع النموذج الديناميكي (ASM1) الذي طبق على محطة Salamanca كون معادلات توازن الكتلة في حوض التهوية تصبح أبسط بكثير في حالة الثبات عندما $dx/dt=0$ أو $ds/dt=0$ (التغير اللحظي في تركيز الكتلة الحيوية أو الغذاء معدوم- المعادلة 2 ص 11) ويصبح حساب البارامترات من خلال معادلات الحساب أكثر سهولة. بينما في النموذج الديناميكي تصبح المعادلات أكثر تعقيداً فالمتغيرات الديناميكية مثل : μ_{Hmax} , $MLSS$, COD_{in} تتغير بشكل مستمر خلال المعالجة ويتوجب حل المعادلات التفاضلية التي تحوي الكثير من بارامترات النشاط الحيوي وقيمها متغيرة وتتأثر بدرجات الحرارة واضطرابات الجريان والأحمال العضوية والكثير من العوامل البيئية الأخرى. وتبسيط المعادلات من خلال فرضيات تشغيلية سيؤدي الى الابتعاد أكثر عن القيم المقاسة وبالتالي عن دقة النتائج والتنبؤ المطلوب.

❖ بينما طريقة الشبكة العصبونية (ANN) أقل تعقيداً بكثير وتقوم على منهجية وخطوات بسيطة وفق الآتي:

- جمع البيانات من المحطة المستهدفة حيث تؤخذ بيانات المحطة لسنة واحدة أو أكثر أو أقل حسب خطة المنذج (محطة العجمي ومحطة معالجة دمشق ومحطة سيحان ثم أخذ البيانات لسنة واحدة فقط، وأربعة أشهر لمحطة كونيا، سنتان لمحطة المعمرة ، 3 سنوات محطة خربة المعزة، وعشر سنوات لمحطة الرستمية في بغداد). البيانات يجب أن تغطي التغيرات الفصلية ، تؤخذ من مخبر المحطة دون استبعاد أية قياسات ، أو أية فترات معالجة .
- معالجة البيانات: تتم المعالجة الإحصائية بواسطة تابع ضمن برنامج MATLAB ويتم استبعاد القياسات الشاذة.
- تقسيم البيانات: يقوم MATLAB بتقسيم البيانات المعالجة الى 3 مجموعات؛ تدريب، تحقق، اختبار.
- بناء الشبكة وتدريبها ، نتائج المحاكاة ومخططات عامل الارتباط (كافة المعلومات تم عرضها في الفقرة 3-3).

➤ عرض النتائج والتطبيقات الممكنة للنموذج والفائدة من تطبيقه على المحطة المستهدفة أو محطة مشابهة بعد المعايرة.

➤ ثالثاً- دراسات وخبرات سابقة في النمذجة: 1- في عام 1992 قام كل من J. Blaesi و B. Jensen بتطوير نموذج باستخدام الشبكة العصبونية لمجزئ مفحم النفط في مصفاة بترول حيث تساوت دقته مع دقة النماذج النظرية وأظهر قدرة على التعامل مع شروط التشغيل الطبيعية. وبمقارنة النماذج النظرية مع نماذج الشبكة العصبونية لكل من نقطة المعايرة النهائية لمفحم النفط للمصفاة، وزيت فرن التفحيم بنقطة معايرة 90% تبين ان قيمة الارتباط بينهما كانت 80% وبمتوسط انحراف معياري 4 درجات. وهذا يشير الى أن نماذج الشبكة العصبونية كانت على الأقل قادرة كما النماذج النظرية على حساب المواصفات أو الخواص بطريقة التنبؤ والحدس، حيث تم تسميتها بالبديل الحقيقي للنماذج النظرية الدقيقة، وأن مشكلة الشبكة العصبونية الصناعية (ANN) الوحيدة أنها تحتاج الى حجم بيانات ضخم لإنجاز نموذج جيد [2]. 2- تتميز الشبكة العصبونية بقدرتها على معالجة كم كبير من البيانات بأن معاً ، مما يوفر لها سرعة أداء عالية تمكنها من حل المشاكل المعقدة ؛ وبدون إعطائها خوارزمية الحل ، وهذه الميزة تفردت بها الشبكة ، كما تتميز بقدرتها على التعلم والتدريب ما يمكنها من التذكر والتكيف وتوفير الحلول للمسائل المتشابهة حتى في حال المدخلات المشوشة ، وقدرتها على استخلاص المعنى من البيانات المعقدة وخلق تنظيمها الخاص بمجرد تدريبها على البيانات للظاهرة المدروسة [21]. 3- تستطيع طرق الذكاء الصناعي AI أن ترفع من سوية المعرفة المستخلصة من البيانات الى الدرجة القصوى ، ومن خبرة المشغل ، وتطبق هذه المعرفة لتحسين التحكم بمحطات المعالجة ، وفي الحالة التي لا تقدم فيها النماذج التقليدية (النماذج القائمة على المعادلات والحساب أو نماذج الصندوق الأبيض) تنبؤات دقيقة ، أو في حال تبين أن افتراضات الطريقة غير فعالة أو غير صحيحة سيكون الدمج أو التفاعل مع مناهج الذكاء الصناعي AI من الخيارات المتاحة والذي يمكنه أن يقدم طيف واسع من الطرق وكثير منها تم تطبيقه ومنها أنظمة التحكم والاشراف لمحطات المعالجة [9] .

5- الاستنتاجات والتوصيات: Results and Recommendations

1- للشبكة العصبونية الصناعية (ANN) قدرة على التنبؤ بدقة وصلت الى 100% من قيمة البيانات المقاسة ، وتصنع نموذج لمحطة المعالجة من بيانات المحطة ذاتها، ومن قيم حقيقية مقاسة مخبرياً ، فهي لا تحتاج الى نموذج جاهز مثل (ASM1) والتأسيس عليه ومعايرته، وتفردت بميزة أنه لا يتم إعطاؤها أية خوارزميات أو معادلات أو علاقات تصميم تجريبية أو رياضية لإجراء حسابات وفقها ، فهي تكتشف قوانين الظاهرة ومعادلات وعلاقات الحساب بمجرد تدريبها على بيانات المشروع المطلوب نمذجته أو محطة المعالجة المدروسة.

2- لم تكن نماذج عائلة ASM مرغوبة بالنسبة للمصممين والمشغلين بسبب تعقيدها ، فمنذ عام 1992 أي بعد 6 سنوات على تطوير ASM1 طرحت أسئلة عن قدرة الشبكة العصبونية

ANN على منافسة الطرق القائمة على الحساب و تم تسميتها بالبديل الحقيقي للنماذج النظرية الدقيقة، وفي عام 2003 وبسبب احتمالات نتائج تنبؤات بدقة غير كافية للنماذج التقليدية ناجمة عن افتراضات غير فعالة أو غير صحيحة اقترح فريق من الباحثين الدمج بين طرق النمذجة القائمة على الحساب والمعادلات مع مناهج الذكاء الصناعي AI ، وكان هناك تطبيقات لهذا الدمج في التحكم بتشغيل محطات المعالجة، ومنذ عام 2006 بدأت نمذجة محطات المعالجة باستخدام الشبكات العصبونية الصناعية (ANN) وبدأ يتزايد استخدامها مع تطور الحاسبات والبرمجيات وتقانة المعلومات الى أن بلغت مراحل متقدمة من الدقة في التنبؤ مضافاً الى بساطة خطواتها وعدم اعتمادها على معلومات أو خوارزميات للحل .

3- النموذج (ASM1) على أهميته وأنه مازال مستخدماً في نمذجة محطات المعالجة بالحماة المنشطة وتأسس على المبادئ الهندسية الأساسية ومعادلات حساب وتصميم نظام المعالجة بالحماة المنشطة، إضافة الى مرونته وقابليته للتطور واستيعاب مكونات جديدة ونظم معالجة جديدة كالمعالجة البيولوجية بالطحالب الدقيقة Microalgae bioreactor ، والغشاء البيولوجي MBR ؛ فإن قدرته على إنتاج نموذج بدقة تنبؤ تنافس الشبكة العصبونية التي أظهرت نتائج ارتباط حتى 100% للتدريب و 0.998 لكل البيانات، أصبحت موضع تساؤل كبير وربما من الماضي. والأمثلة من الدراسة الحالية لنموذج ASM1 على محطة Verona كان عامل الارتباط $R=0.91$ وهو قيمة جيدة ولكن لنموذج ساكن صنع من بيانات حالة الثبات في المعالجة للمحطة وهي حالة افتراضية لحظية خلال عملية المعالجة ، ولأن الحالة الديناميكية في المعالجة البيولوجية بالحماة المنشطة هي الحالة الطبيعية التي تميز عمل المحطة، ولهذا السبب كان R لمحطة Salamanca هو أقل منه لـ Verona وبقية $R=0.827$ ، وتعتبر قيمة متدنية لدقة التنبؤ للنموذج الديناميكي ASM1 الذي طبق عليها، وتكون بذلك نتائج الدقة في التنبؤ لكلا المحطتين منخفضة ومتواضعة بالمقارنة مع نتائج نماذج الشبكة العصبونية (ANN).

4- وبما يخص تصميم الشبكة العصبونية (ANN) الأمثل لمحاكاة بيانات محطات المعالجة ، ولكون طريقة التجريب أو المحاولة والخطأ ما تزال معتمدة بشكل واسع ، وأن الشبكات ذات التغذية الأمامية والارتداد العكسي FFBP بطبقة مخفية واحدة أو طبقتين مخفيتين (الشبكات الضحلة SNN) قد استخدمت، كما استخدمت أيضاً الشبكات العميقة DNN (شبكات FFBP بأكثر من طبقتين مخفيتين مثل محطة العجمي ومحطة كونيا) ؛ تم استخلاص ما يلي :

- كانت أفضل النتائج بدقة التنبؤ للشبكات "بطبقتين مخفيتين" في كل مراحل المحاكاة (تدريب، تحقق، اختبار) حيث 11 نموذج من أصل 16 شملتها الدراسة كانت بطبقتين، و 3 نماذج بطبقة واحدة، ونموذجان بـ 3 طبقات، وكانت أكبر قيمة لعامل الارتباط R لكل البيانات $R=0.998$ لنموذج شبكة ذات طبقتين مخفيتين (محطة المعمرة نموذج 2)، وتوصي الدراسة الحالية بالتركيز على الشبكات بطبقتين مخفيتين كأولى المحاولات لاختيار التصميم الأفضل في حالة قواعد البيانات الصغيرة، حيث قواعد بيانات محطات المعالجة تعتبر صغيرة.

- تحسنت دقة النماذج بزيادة عدد المدخلات، وزيادة عدد العقد في الطبقات المخفية في الشبكات الضحلة SNN.
 - توصي إدارات الصرف الصحي بخبراتها باستخدام شبكات بطبقة مخفية واحدة أو طبقتان وتعتبرها الأكثر دقة.
 - الشبكات العصبونية العميقة DNN بأنواعها (أكثر من طبقتين مخفيتين) يمكن استخدامها للنماذج، ولكن أعطت نتائج أقل دقة من الشبكات الضحلة SNN عند تطبيقها على قواعد البيانات الصغيرة .
 - النماذج المدمجة Ensemble نوع MIMO (متعدد المدخلات متعدد المخرجات) أعطت نتائج أكثر دقة وموثوقية من النماذج المفردة MISO (متعدد المدخلات بمخرج واحد) .
- 5- سواء كانت النمذجة بطريقة ASM1 أو باستخدام الشبكة العصبونية الصناعية ANN ؛ ويهدف تطوير نموذج بقدرة أكبر على التنبؤ وتحقيق تحكم أفضل بتشغيل المحطات من خلال السيطرة على العلاقة بين بارامترات التشغيل وتراكيز الملوثات الخارجة ؛ توصي الدراسة الحالية باستخدام بارامترات تشغيلية للمحطات كمداخل مساعدة للنماذج مثل (Q_w معدل صرف الحماة الفائضة ، DO تركيز الاكسجين في حوض التهوية، MLSS تركيز الكتلة الحيوية في حوض التهوية وفي الحماة المعادة RAS ، ونسب التدوير للحماة المعادة ، ونسب التدوير للمياه المنتجة الى حوض Anoxic) كلها أو جزء منها، إضافة الى المدخلات من البارامترات الأساسية مثل (COD, TSS, TKN , NH_4^+) ، حيث تم تطوير نموذج محطة Verona بمدخلات تشغيلية وأساسية على أساس ASM1 ، وتضمنت مدخلات نموذج محطة دمشق بارامترات MLSS لحوض التهوية والحماة المعادة (تركيز mg/l) بطريقة الشبكة العصبونية ، كما تضمنت دراسة نموذج الشبكة ANN لمحطة معالجة خربة المعزة توصية بإضافة بعض البارامترات التشغيلية من حوض التهوية الى النماذج المطورة من بيانات المحطة ومقارنتها في أبحاث مستقبلية. ويمكن تحسين دقة التنبؤ بإدخال بارامترات تشغيلية لنماذج ASM1 بسبب ضعف أدائها ولكن قد يزيد العملية تعقيداً بسبب مدخلات النموذج المتعددة أصلاً، أما بالنسبة للشبكة العصبونية فقد لا تضيق هذه العملية كثيراً من الدقة ولكن نستطيع الربط بين البارامترات التشغيلية وأداء المحطة وتحقيق تحكم فعال بعملية التشغيل وتخفيض في التكاليف.
- 6- بالنظر لأهمية دقة النتائج وبأي طريقة اعتمدت عملية النمذجة، ولتحقيق أعلى معدل دقة تنبؤ للنماذج المطورة؛ ثمة تساؤلات لم يتاح للدراسة الحالية التعرض لها، وتحتاج للبحث مستقبلاً: a - عملية التوسع في البيانات وتأثيرها على النتائج (توسع أفقي بأخذ البيانات على فترة زمنية أطول مثلاً سنتين أو ثلاثة أو أكثر، أو شاقولي بأخذ البيانات بشكل يومي لكافة البارامترات التصميمية والتشغيلية ولكن لأيام محددة خلال كل فصل لتغطية ما يسمى بالتغيرات الفصلية Seasonal

variations، أو حتى تحجيم البيانات، فهناك نماذج أخذت بياناتها على فترة (4) أشهر فقط وتم اعتمادها وأنه تم تغطية التغيرات الفصلية لها- محطة Konya في تركيا- وبناتج ارتباط ل (R=0.99).

b- مدى تأثير نتائج النمذجة والتي تقوم أصلاً على البيانات المأخوذة من المحطات بدرجات الحرارة خصوصاً أو المناخ بشكل عام ، فالبيانات التي تغطي التغيرات الفصلية بشكل دقيق ستكون أكثر مصداقية، ولأن درجات الحرارة وظروف المناخ تتغير بين سنة وأخرى لأسباب كثيرة سيكون وسطي البيانات لعدة أعوام أكثر دقة، ويمكن في حال أخذ البيانات خلال فترة قصيرة لدواعي الضرورة أن نعلم قيمة الانحراف وأن تجري التصحيح المناسب للنتائج .

7- مما تقدم من خلال المقارنة واستعراض نقاط القوة والضعف في كلا الطريقتين نجد أن طريقة الشبكة العصبونية الصناعية ANN لها ميزات وقدرات تتفوق بكثير على طرق الحساب والمعادلات، حيث أن قدرة الشبكة العصبونية على التنبؤ والاستنتاج لا يمكن منافستها من قبل أي طريقة أخرى بتوفر شرطين أساسيين: **a-** الخبرة لدى الشخص النمذج. **b-** حجم بيانات مطلوب يغطي التغيرات الفصلية. حيث بوجود الخبرة تتم عملية بناء الشبكة وتصميمها بطريقة المحاولة والخطأ، ومن أجل نماذج محطات المعالجة سيكون بدء التجريب بطبقتين مخفيتين ربما يوفر الكثير من الوقت بحيث يتم البدء مباشرة بتجريب عدد العقد في كل طبقة ، وعملية التدريب ليست من التعقيد، إذ يقوم MATLAB بتقسيم البيانات و تحديد حجم البيانات المطلوبة للتدريب ، ويتم اختيار خوارزمية التدريب وهنا يأتي دور الخبرة بالتوقف عن التدريب وعدم المبالغة في حال وصلنا الى قيمة خطأ صغرى ، فالتدريب الصحيح والتصميم المناسب للشبكة يقودنا الى توقع نتائج عامل ارتباط قريبة من (100%)، ويضاف الى ميزات الشبكة العصبونية بساطة تنفيذ خطواتها، فالبيانات تؤخذ لفترة محددة ، وبكل ظروف التشغيل، ولا يستبعد أي قياس بشكل أولي ، أو أية فترة معالجة، ولا يوجد شروط لعدد المدخلات أو المخرجات .

نمذجة محطات المعالجة بالحماة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

APPENDIX

Table 1. Peterson matrix for the ASM1. Components are recorded in columns and processes can be identified in rows.

i-Component→ j-Process↓	1 S_I	2 S_S	3 X_I	4 X_S	5 X_{BH}	6 X_{BA}	7 X_P	8 S_O	9 S_{NO}	10 S_{NH}	11 S_{ND}	12 X_{ND}	13 S_{ALK}
1-Aerobic growth of heterotrophs		$-\frac{1}{V_H}$			1			$-\frac{1-Y_H}{V_H}$		$-i_{XB}$			$-\frac{i_{XA}}{V_A}$
2-Anoxic growth of heterotrophs		$-\frac{1}{V_H}$			1			$-\frac{1-Y_H}{2.86V_H}$		$-i_{XB}$			$\frac{1-Y_H}{14 \times 2.86V_H} - \frac{i_{XA}}{V_A}$
3-Aerobic growth of autotrophs						1		$-\frac{4.57-Y_A}{V_A}$	$\frac{1}{V_A}$	$-i_{XB} - \frac{1}{V_A}$			$-\frac{i_{XB}}{V_A} - \frac{1}{V_A}$
4-Decay of heterotrophs				$1-f_P$	-1		f_P					$-i_{XB} - f_P i_{XP}$	
5-Decay of autotrophs				$1-f_P$		-1	f_P					$-i_{XB} - f_P i_{XP}$	
6-Ammonification of soluble organic nitrogen										1	-1		$\frac{1}{V_A}$
7-Hydrolysis of entrapped organics		1		-1									
8-Hydrolysis of entrapped organic nitrogen											1	-1	

الملحق

الجدول (S1) مصفوفة بترسون يبين كافة مكونات النموذج ASM1 (السطر 1/13 مكون)، والعمود 1/8) عمليات بيولوجية

Table 2. Expression of the process rates for ASM1 in accordance with Henze et al. (2000). Numbers of the processes are identified by j subscript.

Process Rate	Mathematical Expression
1—Heterotrophs, aerobic growth	$\mu_H \left(\frac{S_o}{K_s + S_o} \right) \left(\frac{S_o}{K_{OH} + S_o} \right) X_{BH}$
2—Heterotrophs, anaerobic growth	$\mu_H \left(\frac{S_o}{K_s + S_o} \right) \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \eta_g X_{BH}$
3—Autotrophs, aerobic growth	$\mu_A \left(\frac{S_{NH}}{K_{NH} + S_{NH}} \right) \left(\frac{S_o}{K_{OA} + S_o} \right) X_{BA}$
4—Heterotrophs, decay	$b_H X_{BH}$
5—Autotrophs, decay	$b_A X_{BA}$
6—Organic nitrogen, ammonification	$k_a S_{ND} X_{BH}$
7—Hydrolysis of particulate organic matter	$k_h \left(\frac{X_p / X_{BH}}{K_X + X_p / X_{BH}} \right) \left(\left(\frac{S_o}{K_{OH} + S_o} \right) + \eta_h \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) X_{BH}$
8—Hydrolysis of particulate organic nitrogen	$k_h \left(\frac{X_p / X_{BH}}{K_X + X_p / X_{BH}} \right) \left(\left(\frac{S_o}{K_{OH} + S_o} \right) + \eta_h \left(\frac{K_{OH}}{K_{OH} + S_o} \right) \left(\frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right) X_{BH} \left(\frac{X_{ND}}{X_p} \right)$

Table 3. Experimental values for biological treatment measured in the WWTP between May 2020 and April 2021 (343 days). Data were supplied by the staff of the WWTP.

Day	COD _{in} (mg/L)	COD (mg/L)	Temp (°C)	Biomass (mg/L)
1	—	23.7	17.6	2723
5	367	32.9	18.3	2160
7	302	27.3	18.5	2210
12	229	25.3	18.3	1967
14	250	24.1	18.9	1850
19	290	21.6	19.2	1477
21	338	21.0	18.7	1730
26	331	27.2	18.4	1623
29	365	34.1	19.0	1720
33	326	29.3	19.5	1367
35	369	31.1	19.8	1433
40	342	25.9	20.5	1790

الجدول (S2) يبين العمليات البيولوجية الثمانية الرئيسية للنموذج ASM1 والعلاقة الرياضية لمعدل كل

عملية

Abbreviations

Nomenclature

b_A	decay coefficient for autotrophic biomass (d^{-1});
b_H	decay coefficient for heterotrophic biomass (d^{-1});
f_p	fraction of biomass leading to particulate products;
i_{XB}	nitrogen fraction in biomass;
i_{XP}	nitrogen fraction in products from biomass;
k	kinetic coefficient (d^{-1});
k_h	hydrolysis rate constant (d^{-1});
K_{OH}	oxygen half-saturation coefficient for heterotrophic biomass (mg/L);
K_s	half-saturation coefficient for readily biodegradable substrate (mg/L);
K_X	half-saturation coefficient for particulate biodegradable substrate (mg/L);
Q	influent flow rate (L/d);
r_i	substrate utilization rate (mg/(L d));
$r(\xi)$	conversion vector of the variable ξ (mg/(L d));
S_{ALK}	alkalinity (mol/L);
S_I	soluble inert organic matter (mg/L);
S_{ND}	soluble biodegradable organic nitrogen (mg/L);
S_{NH}	ammonia nitrogen (mg/L);
S_{NO}	nitrate and nitrite nitrogen (mg/L);
S_O	dissolved oxygen (mg/L);
S_S	readily biodegradable substrate (mg/L);
$S_{S,in}$	influent readily biodegradable substrate (mg/L);
t	time (d);
T	temperature (°C);
V	reactor volume (L);
X_{BA}	active autotrophic biomass (mg/L);
X_{BH}	active heterotrophic biomass (mg/L);
$X_{BH,in}$	influent active heterotrophic biomass (mg/L);
X_I	particulate inert organic matter (mg/L);
X_{ND}	particulate biodegradable organic nitrogen (mg/L);
X_P	particulate products arising from biomass decay (mg/L);
X_S	slowly biodegradable substrate (mg/L);
$X_{S,in}$	influent slowly biodegradable substrate (mg/L);
Y_A	growth yield of autotrophic biomass;
Y_H	growth yield of heterotrophic biomass.

Greek symbols

ξ	vector of reactor and effluent concentration (mg/L);
ξ_{in}	vector of influent concentration (mg/L);
μ_H	specific growth rate for heterotrophic biomass (d^{-1});
$\mu_{H,max}$	maximum specific growth rate for heterotrophic biomass (d^{-1});
$\rho(\xi)$	vector of reaction kinetics (mg/(L d));
ρ_j	process rate (mg/(L d));
Θ	hydraulic residence time, HRT (d);
ν_{ij}	stoichiometric coefficient;
η_g	correction factor of μ_H under anoxic conditions;
η_h	correction factor for hydrolysis under anoxic conditions.




نمذجة محطات المعالجة بالحمأة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة

الجدول (S3) يمثل عينة من بيانات مقاسة لمحطة Salamanca / إسبانيا

kinetic parameters and Stoichiometric

جدول (S4) يوضح كافة البارامترات الحركية

coefficients



الشكل (F1) الخطوة الثانية في المقارنة على μ_H من أجل $Y_H = 0.6$. الحالات (a,b,c) /


محطة Salamanca إسبانيا

Day	COD (mg/L)	Sim 0.40	Error (%) 0.40	Sim 0.38	Error (%) 0.38	Sim 0.42	Error (%) 0.42
1	23.7	30.0	26.6	30.0	26.6	30.0	26.6
5	32.9	22.7	-31.0	25.5	-22.5	21.5	-34.5
7	27.3	14.9	-45.4	16.0	-41.3	14.2	-48.0

336	27.4	20.9	-23.8	22.3	-18.4	19.4	-29.1
341	62.1	19.4	-68.7	20.8	-66.5	18.4	-70.4
343	19.9	38.8	94.8	42.1	111.8	35.8	79.9
Average error			-0.5		8.1		-7.7


الجدول S5 : جدول الأخطاء بين قيم المحاكاة (SIM) والقيم المقاسة COD_{eff} من أجل التقريب الدقيق Fine tuning ، وقيمة $Y_H = 0.6$ (مثبتة) ، وقيم $\mu_{Hmax} = 0.40, 0.38, 0.42 d^{-1}$. أخذ الأسطر الأربعة الأولى من الجدول S5 وفيها بيانات اليوم الأول والخامس والسابع ، والأسطر الأربعة الأخيرة وتشمل آخر يوم من فترة البيانات وهو اليوم رقم 343 ، والسطر الأخير هو سطر النتائج للأخطاء الوسطية . ويمكن الحصول على صفحات الجدول S5 كاملاً من خلال الرابط التالي:

<https://www.mdpi.com/article/10.3390/w14071046/s1>



الشكل (F2) نتائج مخرجات الشبكة لمحطة العجمي مع قيم عامل الارتباط .

نمذجة محطات المعالجة بالحمأة المنشطة بين طريقة الشبكة العصبونية (ANN) والطرق القائمة على المعادلات والحساب في بحث على نماذج معتمدة مع التقييم والمقارنة




الشكل (F3) مخطط الشبكة العصبونية التي تم تصميمها ومحاكاتها لمحطة عدرا/ دمشق

Configuration	Input	Output	Training		Testing		All R
			MSE	R	MSE	R	
MISO	COD, NH ₃ , TN, PO ₄ , NO ₃ , NO ₂ , pH, TSS and temperature	BOD ₅	6.2×10^{-11}	1	4.1×10^{-7}	0.99782	0.99867
MIMO	NH ₃ , TN, PO ₄ , NO ₃ , NO ₂ , pH, TSS and temperature	BOD ₅ and COD	1×10^{-6}	0.9325	9.25×10^{-3}	0.77219	0.9133
MIMO	NH ₃ , TN, PO ₄ , NO ₃ , NO ₂ , pH and temperature	BOD ₅ , COD and TSS	2×10^{-4}	0.91657	3.3×10^{-3}	0.89516	0.9017

الجدول (S6) الخواص الإحصائية لنماذج التنبؤ بقيم BOD₅ لمحطة المعمره/ العراق.

الشكل (F4) عوامل الارتباط بين نتائج محاكاة قيم BOD5 والقيم المقاسة للنماذج (a) MISO و (b,c) MIMO /لمحطة المعمرة/



6 - المراجع: REFERENCES:

- 1- AL SALEH, H.A 2021 Wastewater Pollutants Modeling Using Artificial Neural Networks, Journal of Ecological Engineering, 22(7), pp. 35-45.
- 2 - BLAESI, J JENSEN, B 1992 can neural networks compete with process calculations? Intech Applying Technology, 39 (12), pp. 34-37.

3 – BRUN, R KÜHNI, M SIEGRIST, H GUJER, W REICHERT, P Practical Identifiability of ASM2D Parameters–Systematic Selection and Tuning of Parameter Subsets, Water Research 2002, 36, pp. 4113–4127.

4 – COSTA, C 2022 A Comprehensive View of the ASM1 Dynamic Model: Study on a Practical Case, Water 2022, 14, 1046.

5 – COTE, M GRANDIJEAN, B.P LESSARD, P YHIBAUT, J 1995 Dynamic modeling of the activated sludge process: improving prediction using neural networks, Water Research, 29 pp. 995– 1004

6 – DAGTEKIN, M YELMEN, B 2022 Modeling Wastewater Treatment Plant Performance Using Artificial Neural Networks: Case of Adana(Seyhan), International Journal of Agriculture, Environment and Food Sciences 2022, 6(4) pp. 579–584.

7 – DALJA, H.A and Mohammad, A.I 2023 Artificial Neural Networks Modeling For AL–Rustumiya wastewater plant in Baghdad, 3C Empresa. Investigacion Y pensamiento Critico, 12(1), pp. 257–271.

8 – DELGRANGE, V.N CABASSUD, N CABASSUD, M DURANDBOURLIER, L LAINE, J.M 1998 Neural networks for prediction of ultrafiltration trans membrane pressure: application to drinking water production, Journal of Membrane Science, 150 pp. 111–123.

9 – GERNAEY, K VAN LOOSDRECHT, M LIND, M JORGENSEN, S 2003 Activated Sludge wastewater treatment Plant modeling and Simulation: State of the art, Environmental Modeling & Software, 19(2004), pp. 763–783.

10 – HAMED, M. KHALAFALLAH, M.G HASSANEIN, E.A 2004 Prediction of wastewater treatment plant performance using artificial neural network, Environmental Modeling &Software, 19 pp. 919– 928.

11 – HASSANPOUR, M Activated Sludge Model 1 (ASM1), International Journal of Engineering Sciences & Research Technology, 3(11), 2014.

12 – JAFAR, R AWAD, A JAFAR, K SHAHROUR, I Predicting Effluent Quality in Full– Scale wastewater Treatment Plants Using Shallow and Deep Artificial Neural Networks, Sustainability , 2022, 14, 15598.

13 – LEE, D.S PARK, J.M 1999 Neural network modeling for on – line estimation of nutrient dynamics in a sequentially – operated batch reactor, Journal of Biotechnology, 75 pp. 229–239.

14 – MESUTOGLU, Ö.Ç Prediction of COD in Industrial Wastewater Treatment Plant Using an Artificial Neural Network, Scientific Report, 2024, (14), 13750.

15 – METCALF & EDDY, Inc.: Wastewater Engineering: Treatment, Disposal, Reuse, 3rd ed., McGraw–Hill, Singapore, 1991

16 – NASR, M.S MOUSTAFA, M.A.E SEIF, H.A.E EL KOBROSY, G 2011 Application of artificial neural network (ANN) for the prediction of EL–AGAMY wastewater treatment plant performance– EGYPT, Alexandria Engineering Journal, (2012) 51, pp. 37–43.

17 – SOCHACKI, A KNODEL, J GEISSEN, S.–U ZAMBARDA, V BERTANZA, G PLONKA, L 2009 Modeling and simulation of a municipal WWTP with limited operational data, Academia.edu, pp.1–9.

18 – TUKEY, J.W Explanatory Data Analysis, Addison–Wesley, Reading, MA, 1977

19 – TÜMER, A.E EDEBALI, S 2015 An Artificial Neural Network Model for Wastewater Treatment Plant of Konya, International Journal of Intelligent Systems and Applications in Engineering, 2015, pp. 131–135

- 20- الأصفري، أحمد. (1991). تصميم محطات معالجة مياه المجاري. الشركة العربية لمعالجة المياه. الكويت
- 21- طامزوق، تمارا. 2021. بناء نموذج محاكاة للتنبؤ بتغير قيمة الـ BOD5 في القسم البيولوجي في محطات معالجة مياه المجاري التي تعمل بطريقة الحمأة المنشطة. رسالة ماجستير - كلية الهندسة المدنية - جامعة دمشق.