

نمذجة محطة معالجة مياه الصرف الصحي في محافظة حماة باستخدام الشبكات العصبية الاصطناعية في MATLAB

الدكتورة ناهد فرهود والطالبات: ديمة الشمالي، إخلاص الحصري، دانية عيد

جامعة حلب، كلية الهندسة التقنية، تقانات الهندسة البيئية

الجمهورية العربية السورية، حلب

ملخص

تستعرض هذه الدراسة نمذجة محطة مياه الصرف الصحي بحماة باستخدام الشبكة العصبية الاصطناعية (ANN) ذات البيانات المختلفة في برنامج ماتلاب، حيث تم الحصول على البيانات من قراءات أجهزة الاستشعار في منشأة معالجة مياه الصرف الصحي في محافظة حماة لسنة أعوام (2014-2019)، رغم النقص في بيانات الأعوام السابقة نتيجة الحرب، إلا أنه تم تطوير أربعة نماذج باستخدام الشبكات العصبية الاصطناعية متعددة الطبقات، وهذه النماذج هي:

- A. الطلب الكيميائي على الأكسجين COD حيث كان معامل الارتباط R: 0.96
- B. الطلب البيوكيميائي على الأكسجين BOD حيث كان معامل الارتباط R: 0.92
- C. المواد الصلبة العالقة الكلية TSS حيث كان معامل الارتباط R: 0.93
- D. معدل التدفق الخارج Qout حيث كان معامل الارتباط R: 0.98

حيث يساهم هذا البحث في تحقيق الهدف السادس من أهداف التنمية المستدامة الصادرة عن الأمم المتحدة (SDGs) الذي ينص على (ضمان توافر المياه وخدمات الصرف الصحي للجميع وإدارتها بشكل مستدام)، وكما يُمكن صناع القرار من استخدام نموذج الوعي لتعزيز مراقبة وتقييم جودة المياه، وتفهم الجمهور لرعاية وأهمية معالجة المياه.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، النمذجة، مياه الصرف الصحي

المقدمة

1. مياه الصرف الصحي:

تعتبر مياه الصرف الصحي الناتجة عن الاستخدامات المختلفة (المنزلية والصناعية والزراعية) المُحمّلة بالملوثات والميكروبات ضارة، وبالتالي يجب تنقيتها قبل إعادتها إلى البيئة وذلك من خلال معالجتها بشكل فعال.

ويتم ذلك من خلال محطة معالجة مياه الصرف الصحي التي تعد أمراً بالغاً في الأهمية لحماية الصحة العامة والحد من التلوث.

تُصَرَّف مياه الصرف الصحي إلى المحطة، حيث تُطبَّق سلسلة من العمليات الفيزيائية والكيميائية والبيولوجية المعقدة لإزالة الملوثات لذلك من المهم جداً زيادة كفاءة إزالة الملوثات واستقرار التشغيل في أنظمة معالجة مياه الصرف الصحي، ويمكن تحقيق سيطرة أفضل على محطة معالجة مياه الصرف الصحي من خلال تطوير أداة رياضية قوية للتنبؤ بأداء المحطة بناءً على الملاحظات السابقة لمعاملات معينة (Harez, R., Latifi, M. A., & Rosh, N. (2015))

ومع تطور الذكاء الاصطناعي الذي يتمتع بمزايا واضحة على طرق التحكم في العملية التقليدية، والتي يمكنها نمذجة عمليات معالجة مياه الصرف الصحي غير الخطية المعقدة من خلال نمذجة عمليات التفكير البشري.

يعتبر الذكاء الاصطناعي أداة عملية في أنظمة العالم الحقيقي وخاصة في الأنظمة المعقدة التي تتضمن كميات هائلة من البيانات. كأداة للتعامل مع الأنظمة المعقدة أو المشكلات الصعبة.

تخضع تقنية الذكاء الاصطناعي، وعادةً التعلم الآلي، لاستكشاف متزايد وتم تطبيقها لتحسين قدرة محطات معالجة مياه الصرف الصحي. حتى الآن، قدم تطبيق الذكاء الاصطناعي على محطات معالجة مياه الصرف الصحي نتائج أفضل من حيث تحليل البيانات مقارنةً بالتقييم الإحصائي التقليدي علاوة على ذلك، يمكن للذكاء الاصطناعي اكتشاف العلاقات المعقدة من خلال تحليل مجموعات البيانات الضخمة التي أصبحت جزءاً لا يتجزأ من عالم البيانات الحديث.


تعد الشبكات العصبية واحدة من أسرع تقنيات الذكاء الاصطناعي تطور، حيث هي تقنيات حاسوبية تحاول محاكاة وظائف الدماغ البشري وعمليات اتخاذ القرار فيه. (Shargi, E., Norano, V., Ashrafi, A. A., & (Jokshikos, W. H. (2019)

وفي العقود القليلة الماضية، استُخدمت الشبكات العصبية الاصطناعية على نطاق واسع في مجموعة واسعة من التطبيقات الهندسية. ومؤخراً تم تطبيق الشبكات العصبية الاصطناعية بشكل متزايد في نمذجة جودة المياه. وقد أظهرت تطبيقات سابقة نجاح الشبكات العصبية الاصطناعية في مجالات هندسة المياه. (Suen et al., 2003; (Zaheer and Bai, 2003; Fogelman et al., 2008; Sovan et al., 1999

II. الشبكات العصبية الاصطناعية ANN:

تحاكي الشبكات العصبية الاصطناعية الوظائف العاملة في الدماغ البشري. وهي عبارة عن برامج منطقية تم تطويرها لإنتاج معلومات جديدة عن طريق التعميم. وهي أيضاً أنظمة اصطناعية تحاكي وظائف الدماغ البشري (Öztemel, 2012) يمكن للشبكات العصبية الاصطناعية إقامة اتصالات بين الحفظ والمعلومات، جنباً إلى جنب مع التعلم كآليات للتعلم الذاتي (Elmas, 1994) أدى نجاح نمذجة أنظمة مختلفة من خلال تدريب البيانات الموجودة باستخدام الشبكات العصبية الاصطناعية إلى زيادة قابلية استخدام الشبكات العصبية الاصطناعية (Haykin, 1994; Özcalık et al., 2003) وفقاً لخوارزمية الشبكات العصبية الاصطناعية، يتم ترتيب الخلايا العصبية في طبقات متعددة للترابط بين المدخلات والمخرجات. (Nasr, M. S., Mustafa, M. (2012) A. M. M., Seif, G. A. S., & Al-Firsi, J. (2012) في نموذج الشبكات العصبية الاصطناعية، توجد ثلاث طبقات كمدخلات وطبقات مخفية وطبقات مخرجات، ويمكن أن تحتوي الشبكة على أكثر من طبقة مخفية (Yaldız, 2006) يظهر نموذج الشبكات العصبية الاصطناعية النموذجي في الشكل 1

الشكل 1. نموذج الشبكات العصبية الاصطناعية



تسمح الشبكات العصبية ذات التغذية الأمامية بتدفق الإشارة في اتجاه واحد، ويتم تنظيم معظمها في طبقات (Weatherford et al., 2003). يتم إعطاء مخرجات الخلايا في طبقة واحدة كمدخلات للطبقة التالية عبر الأوزان. تنتقل طبقة الإدخال المعلومات التي تتلقاها من البيئة الخارجية إلى الطبقة المخفية دون إجراء أي تغييرات. (Al-Tujjar, H., & Ogunku, A. (2022)) يتم تحديد مخرجات الشبكة من خلال معالجة المعلومات في الطبقة المخفية وطبقة الإخراج (Öztemel, 2012)، في الشبكات العصبية الاصطناعية ذات التغذية الراجعة، يتم إعطاء مخرجات خلية واحدة على الأقل كمدخل لنفسها أو لخلايا أخرى، وعادةً ما تتم التغذية الراجعة من خلال عنصر تأخير. (Kebalci, 2014).

في السنوات الأخيرة، تم استخدام نماذج تعتمد على الشبكات العصبية الاصطناعية مع مدخل واحد أو أكثر ومخرج واحد أو اثنين للتنبؤ بأداء محطة معالجة مياه الصرف الصحي وضمان كفاءة المحطة. تتم عملية التعلم عن طريق تدريب العينات ومعالجة بيانات المدخلات والمخرجات. بعبارة أخرى، يتم التعلم عن طريق تكرار خوارزمية التدريب حتى يتم تحقيق التقارب باستخدام هذه البيانات (Kes-kin et al., 2007) (Oye, A. A., Jantan, A., Omolara, A. E., Dada, K. V., Mohammed, N. A., & Arshad, H. (2018)).

III. الدراسات المرجعية:

أشارت العديد من الدراسات إلى أن الشبكات العصبية الاصطناعية قادرة على التنبؤ بأداء المحطة بقوة وكفاءة من خلال بعض المتغيرات التفسيرية الرئيسية مثل الطلب البيوكيميائي على الأكسجين (BOD) والطلب الكيميائي على الأكسجين (COD) والمواد الصلبة المعلقة الكلية (TSS) (Norani, F., Alkirran, J., & Abba, C. I. (2021) / Malfia, A., & Jaspal, D. (2021) / Kang, J. H., Song, J. H., (2020) / Yoo, S. S., Lee, B. J. L., & Ji, H. W. (2020) نموذج الشبكات العصبية الاصطناعية وتوقع بنجاح تركيز الرائحة في محطة معالجة مياه الصرف الصحي بناءً على الطلب البيولوجي للأكسجين. كما استخدم (Norani, F., Alkirran, J., & Abba, C. I. (2018) الطلب البيولوجي للأكسجين والطلب الكيميائي للأكسجين في التنبؤ بأداء محطة معالجة مياه الصرف الصحي في Nocisia من خلال ثلاثة نماذج غير خطية تعتمد على الذكاء

الاصطناعي. وقد أكدت مراجعة شاملة أجراها (Malfia, A., & Jaspal, D. (2021)) على فائدة تقنية الذكاء الاصطناعي في قطاعات معالجة مياه الصرف الصحي حيث يعد الطلب البيولوجي للأكسجين والطلب الكيميائي للأكسجين من بين المتغيرات التفسيرية الرئيسية السائدة المستخدمة لتقييم أداء محطة معالجة مياه الصرف الصحي. أدى تراكم الأدبيات الواسعة في ورقة المراجعة الخاصة بهم (Malfia, A., & Jaspal, D. (2021)) إلى استنتاج مفاده أن نماذج الشبكات العصبية الاصطناعية والخوارزمية الوراثية وخوارزميات المنطق الضبابي تستخدم إلى حد كبير في دراسة معالجة مياه الصرف الصحي. والجدير بالذكر أن جميع النماذج الثلاثة مصنفة ضمن الذكاء الاصطناعي.

بسبب الكفاءة والسرعة والاستقلال عن العمليات البشرية، تم استخدام العديد من النماذج الممكنة للذكاء الاصطناعي مثل الشبكات العصبية الاصطناعية والخوارزميات الجينية في معالجة المياه. [Van, M., Hu, J., (2018) Kaw, R., Ruan, W., & Wei, W.X.] على سبيل المثال، أظهرت أن دمج الشبكات العصبية الاصطناعية مع الخوارزميات الجينية في نمذجة إزالة الملوثات في عملية محطة معالجة مياه الصرف الصحي يؤدي إلى دقة أفضل بناءً على (Rsquared 2) وقيم الخطأ التربيعي المتوسط، عند مقارنتها بنمذجة سطح الاستجابة. وعلى نحو مماثل، ادعى عمل [Ahmed, M., Alam, K., Tariq, S., Anwar, S., Nasser, J., & Mansha, M. (2019)] دقة أفضل لنموذج الشبكة العصبية الاصطناعية من نموذج الانحدار الخطي المتعدد (MLR) في تقدير الجسيمات (PM2.5) التركيز. مراجعة شاملة من قبل [Shu, A., Chang, H., Shu, Y., Ri, (2021) R., Li, X., & Zhao, Y.] حول تطبيق أثبتت الشبكات العصبية الاصطناعية في المجالات البيئية من خلال 177 ورقة بحثية ذات صلة فوائد تنفيذ تقنية الشبكات العصبية الاصطناعية كنموذج تنبؤي خاصة في إدارة النفايات العامة

IV. أهمية البحث:

1. الدافع:

التنبؤ بمستويات الملوثات المستقبلية وتقديم حلول مخصصة تتناسب مع نوعية المياه المدخلة، إضافة لتحسين العمليات التشغيلية لمحطات المعالجة مما يؤدي لتقليل التكاليف وزيادة الاستدامة البيئية.

في هذه الدراسة، الهدف الرئيس هو تطوير نماذج تعتمد على الشبكات العصبية الاصطناعية للتنبؤ بمخرجات قيم كل من BOD (الطلب البيوكيميائي على الأكسجين)، COD (الطلب الكيميائي على الأكسجين)، TSS (المواد الصلبة العالقة الكلية) Qout (التدفق) في مجموعة متنوعة من أنظمة المعالجة الأولية والبيولوجية في معالجة مياه الصرف الصحي.

2. منهجية:

تم استخدام MATLAB لتوليد مجموعة بيانات. يتم استخدام مجموعات مختلفة من بيانات مياه الصرف الصحي مثل CODin و BODin و TSSin و Qin كمداخلات في ANN لمعرفة المخرجات لكل مدخل، وذلك من خلال إنشاء أربع نماذج مختلفة وجرى تقييم أداء النماذج من خلال معاملات الارتباط ومخططات الأداء (Performance) والانحدار (Regression). ومعامل الارتباط الخاص به، ثم تتم مقارنة هذه النتائج مع النتائج المتوفرة لدي لتقييم أداء النماذج.

حيث تم استخدام مجموعة عينات تتكون من 62 عينة، حيث كانت عينات التدريب (54) عينة وعينات الاختبار (8) عينات.

كما تم تقسيم مجموعة بيانات التدريب إلى 70% تدريب و15% اختبار و15% تحقق، وهو تقسيم شائع يهدف إلى ضمان تدريب النموذج على غالبية البيانات وتقييم أدائه على بيانات جديدة وغير مرئية.

يوضح الجدول التالي معاملات الشبكة العصبية المستخدمة:

المعامل	القيمة
عدد الطبقات	2(طبقة إدخال، طبقة مخفية، طبقة إخراج)
عدد الخلايا العصبية في الطبقة المخفية	10 خلايا عصبية
نوع الدالة التنشيطية	Hyperbolic tangent
خوارزمية التدريب	Adam

بعد اختبار العديد من الطبقات وعدد من الخلايا العصبية، تم اختيار بنية الشبكة العصبية البسيطة التي تتكون من طبقة مخفية واحدة وعشر خلايا عصبية، لأنها أعطت نتائج أدق ومعامل ارتباط أعلى، كما أنها أفضل من أجل البساطة وتجنب التعقيد، كما يقلل بشكل كبير من عدد الأوزان التي يجب تعلمها والذي يؤدي إلى تسريع عملية التدريب، وتكون النماذج الأبسط أكثر قابلية للفهم والتفسير.

V. هدف البحث:

الهدف هو نمذجة محطة مياه الصرف الصحي باستخدام ANN والحصول على التنبؤ بكل من BODout, Qout TSSout, CODout,

VI. دراسات العملية:

A. محطة معالجة مياه الصرف الصحي في مدينة حماة:


تقع محطة معالجة مياه الصرف الصحي بجانب قرية أرزة الشرقية شمال محافظة حماة، على بعد نحو 7 كم من مركز المدينة، وعلى ضفاف نهر العاصي. تمتد المحطة على مساحة إجمالية قدرها 80,000 متر مربع، وقد دخلت الخدمة بتاريخ 2005/3/6 وكمية مياه الصرف الصحي التي تصلها حوالي 50000 متر مكعب في اليوم من مياه الصرف الصحي لمدينة حماة، وينتهي عمرها التصميمي عندما تصبح قيم الأحمال والتدفقات الداخلة إليها أعلى من الأحمال التي صممت على استقبالها.

مكونات المحطة:

- A. منشأة المدخل (المصافي الخشنة) ومحطة الضخ الرئيسية.
- B. خط الضخ الرئيسين.
- C. منشأة المدخل (المصافي الناعمة والمرسبات الرملية).
- D. أحواض الترسيب الأولية.
- E. أحواض التهوية.
- F. أحواض الترسيب الثانوية.
- G. محطة ضخ الحمأة الراجعة.
- H. أحواض تكتيف الحمأة.
- I. محطة ضخ الحمأة المكثفة ومياه الغسيل.
- J. منظومة التعقيم بالكلور.
- K. المنشأة الخدمية.

الشكل 2. موقع المحطة وتسلسل أحواض المعالجة فيها

B. جمع البيانات:



تم جمع بيانات شهرية لكل من BODin, CODin, TSSin, Qin لمدة ست سنوات (2014-2019) كانت هذه الفترة مرضية لأنها تغطي جميع الاختلافات الموسمية المحتملة في المتغيرات المدروسة. حيث تم إعطاء هذه المعلومات في الجدول. وكما تم تطوير أربع نماذج للشبكة العصبية الاصطناعية ANN لنمذجة محطة معالجة مياه الصرف الصحي بالبيانات التي تم جمعها.

المواصفات التي تم الاعتماد عليها والتي أعطت أدق النتائج هي الشبكة ذات طبقة خفية واحدة وعدد خلايا عصبونات 10، حيث كانت النتائج المتوقعة والحقيقة متقاربة.

حيث قمنا بإدخال مجموعة من القيم الشهرية إلى الشبكة، وتم تقسيمها داخل الشبكة إلى 70% تدريب، 15% اختبار، 15% تحقق.

كما تم تحديد دقة الشبكة بالتنبؤ من خلال مخططين هما:

- Performance (أداء الشبكة).
- Regression (الانحدار)

الشكل 3. الشبكة العصبية الاصطناعية

الجدول 1. بيانات محطة معالجة مياه الصرف الصحي في حماه

year	month	Qin	cBOD5in	CODin	TSSin	Qout	cBOD5out	CODout	TSSout
2014	1	51539	414	628	375	53858	10	50	12
	2	44704	517	474	461	47123	10	50	12
	3	51613	473	671	443	54032	8	51	14
	4	45827	493	802	444	47180	10	55	14
	5	53887	466	722	441	55181	12	53	16
	6	52163	472	747	447	52400	11	58	18
	7	50100	367	670	373	48842	13	56	18
	8	46713	382	711	406	45927	16	62	22
	9	52360	355	699	432	50900	16	75	16
	10	59623	301	582	358	58677	6	53	12
	11	43240	340	569	341	41841	8	53	13
	12	56000	370	626	379	53458	10	52	
2015	1	57419	377		346	55694	9		11
	2	40264	398	574	389	37918	9	49	12
	3	32735	394	615	371	29832	9	57	15
	4	38883	448		362	35850	10		17
	5	38158	459	752	402	34548	12	59	16
	6	42563	435	712	421	39073	12	55	13
	7	44013	423	735	420	41710	14	59	14
	8	41865	385	653	393	38187	11	53	11
	9	46783	384	631	384	43400	11	52	11
	10	39103	376	696	447	36377	12	59	19
	11	37470	395	640	412	34527	13	66	22
	12	50371	343	549	327	46339	13	52	11
2016	1	42961	315	487	300	39435	14	52	12
	2	50017	321	556	282	46172	12	55	10
	3	47535	325	573	306	44032	10	52	10
	4	35813	384	572	345	31267	9	53	8
	5	41432	389	622	353	38097	11	54	12
	6	47903	400	626	429	43533	16	56	15
	7	42877	386	654	414	39903	14	56	11
	8	42629	368	635	373	40806	17	56	13
	9	55240	364	698	417	52490	11	64	17
	10	51819	362	663	452	48413	14	60	16
	11	30700	381	617	470	29217	12	61	12
	12	39697	327	538	321	38945	13	53	9
2017	1	46674	349	528	313	43926	12	51	10
	2	45625	434	655	381	44036	13	55	11
	3	49323	424	695	369	46571	15	56	11
	4								
	5	53103	478	682	434	51013	15	59	12
	6	58193	409	610	366	56300	11	59	12
	7	49037	427	596	356	47397	12	57	11
	8	47729	425	674	386	46313	11		11
	9	56482	386	630	373	54617	10	58	12
	10	58523	408	606	403	56726	9	55	11
	11	58921	405	588	410	56950	10	56	12
	12	59231	393	612	389	57381	10	54	11
2018	1	57000	430	600	369	55345	10	58	10
	2	54095	374	519	294	52143	10	56	11


	3	56619	434	595	362	54677	11	57	11
	4	58840	452	634	387	56370	11	57	12
	5	63849	426	642	365	60545	10	57	11
	6	61740	425	681	383	58313	12	58	11
	7	51413	445	694	414	48439	13	58	10
	8	52126	465	652	465	49371	13	57	12
	9	53270	407	601	427	50150	12	54	11
	10	57934	379	629	393	54387	11	59	13
	11	56315	340	589	422	53100	10	57	12
	12	53769	414	623	413	50506	10	55	11
2019	1	54108	363	594	311	51090	11	55	13
	2	45309	387	599	316	42768	13	56	15
	3								
	4	49888	447	548	354	46767	28	67	23
	5	47089	424	591	346	44226	13	63	15
	6	49628	402	573	340	46133	11	56	11
	7								
	8								
	9	51595	404	666	384	48857	19	67	19
	10	47121	435	678	409	44010	16	64	15
	11	41297	416	669	363	39083	15	63	14
	12	43090	387	558	366	40484	13	61	13

C. استخدام MATLAB في تشكيل الشبكات العصبية الاصطناعية ANN:


تم تطوير أربع شبكات عصبية لأربع مخرجات الموجودة لدي، حيث جميع الشبكات تتضمن العدد ذاته من الخلايا العصبونية في الطبقة الخفية، حيث تم اختيار الشبكات (بطبقة خفية واحدة وعشر خلايا عصبونية) باستخدام وظيفة مضمنة في مجموعة أدوات الشبكة العصبية في برنامج MATLAB، إذ كانت هي الأكثر دقة في إعطاء النتائج.

وذلك باتباع الطريقة التالية:

قمنا بإدخال البيانات في نافذة Workspace وذلك بعد القيام بإزالة الأشهر ذات القيم الناقصة بسبب عدم الاستطاعة بأخذ قراءات بعض البيانات لها، حيث قمنا بتشكيل ثلاث ملفات، **الملف الأول** يتضمن قيم (BOD, COD, TSS, Qin) الداخلة في محطة معالجة، **الملف الثاني** يتضمن قيم مخرجات المدخل الذي أعمل على إنشاء الشبكة له، **الملف الثالث** يتضمن بعض البيانات من أجل اختبار الشبكة.




الشكل 5. نافذة البرنامج MATLAB وكتابة الأمر nntool




فتح النافذة الخاصة بتشكيل الشبكة وكتابة الأمر nntool في نافذة الأوامر.

. ظهر نافذة الشبكة ونقوم بتعريف الملفات التي قمنا بتشكيلها سابقاً وذلك بتصديرها بالضغط على زر .import

الشكل 6. واجهة تعريف بيانات الشبكة العصبية الاصطناعية



الشكل 7. تصدير البيانات إلى الشبكة



تحديد مواصفات الشبكة تم اختيار المواصفات الخاصة بالشبكة كما يلي:

نوع الشبكة: Feed-forward backprop

بيانات الإدخال: input

بيانات الإخراج: output

وظيفة التعلم: learn GDM

وظيفة الأداء: MSE

عدد الطبقات الكلية للشبكة: 2

عدد الطبقات الخفية: 1

عدد الخلايا العصبونية في الطبقة المخفية:10

الدالة التنشيطية: Hyperbolic tangent (Tanh)

الشكل8. مواصفات الشبكة العصبية الاصطناعية

★ Create Network or Data

Network Data

Name: network1

Network Properties

Network Type: Feed-forward backprop

Input data: input

Target data: output

Training function: TRAINLM

Adaption learning function: LEARNGDM

Performance function: MSE

Number of layers: 2

Properties for: Layer 1

Number of neurons: 10


Transfer Function: TANSIG

View Restore Defaults


Help Create Close

يُجرى تدريب الشبكة باستخدام أداة Train Network بعد تحديد معلمات التدريب مسبقاً، ويُستمر في التدريب حتى يتحقق أدنى فرق ممكن بين القيم المتوقعة والقيم الفعلية، وذلك بالاعتماد على مخطط الأداء (Performance).

الشكل9. نافذة تدريب الشبكة



محاكاة الشبكة وذلك باختيار البيانات test التي سيتم اختبارها، ثم الضغط على زر Simulate. الشكل 10. نافذة محاكاة الشبكة



استخراج نتائج التنبؤ ببيانات test بالضغط على زر Export ومقارنة النتائج المتوقعة والملاحظة للبيانات test.


VII. النتائج:


1. نمذجة الشبكات العصبية الاصطناعية في برنامج MATLAB:

بسبب الحرب تعذر الحصول على بيانات متكاملة لمحطة المعالجة، لعدة ظروف منها انقطاع التيار الكهربائي أو عدم عمل المحطة لفترة من الزمن أو بسبب أعطال متفاوتة، لذلك قمنا بحذف الأشهر التي بياناتها غير مكتملة ولم نقوم بتعويضها وذلك لعدم وجود طريقة موثوقة لتعويض القيم، بسبب عدم وجود أنماط واضحة لفقدان البيانات، فإن طرق الاستكمال قد تدخل ضوضاء غير مرغوب فيها.

2. نمذجة الطلب الكيميائي على الأكسجين COD:

الشكل 11. الانحدار عند الشبكة الخاصة لcod







الشكل 12. أداء الشبكة الخاصة بـ COD

3. نمذجة الطلب البيوكيميائي على الأكسجين BOD:

الشكل 13. الانحدار عند الشبكة الخاصة بـ bod







الشكل 14. أداء الشبكة الخاصة بـ BOD

4. نمذجة المواد الصلبة العالقة الكلية TSS:


الشكل 15. الانحدار عند الشبكة الخاصة لـ TSS






الشكل 16. أداء الشبكة الخاصة بـ TSS

5. نموذج معدل التدفق الخارج Qout:



الشكل 17. الانحدار عند الشبكة الخاصة لـ Qout



الشكل 18. أداء الشبكة الخاصة بـ Qout

VIII. المناقشة:

المخرج	معامل الارتباط الشامل R	أداء مرحلة التدريب (training)	أداء مرحلة الاختبار (test)	أداء مرحلة التحقق (Validation)	معادلة التنبؤ الرياضية	أداء الشبكة
نمذجة الطلب الكيميائي على الأكسجين COD	0.968	0.953	0.983	0.995	$Y=0.94*T+3.7$	انخفاض الخطأ مع تكرار التدريب مما يدل على تعلم النموذج
الطلب البيوكيميائي على الأكسجين BOD	0.92	0.95	0.983	0.99	$Y=1*T-0.39$	انخفاض سريع في الخطأ في المراحل الأولى واستقرار عند قيمة خطأ منخفضة
المواد الصلبة العالقة الكلية TSS	0.93	0.92	0.96	0.99	$Y=0.73*T+3.2$	أداء جيد ولكن أقل من COD و bod ويحتاج لمزيد من التكرارات للاستقرار

معدل التدفق الخارج Qout	0.98	0.98	0.99	0.98	Y=0.94*T+1900	أفضل أداء بين جميع النماذج وخطأ منخفض جداً
----------------------------	------	------	------	------	---------------	--

A. نمذجة الطلب الكيميائي على الأكسجين COD:

يتميز نموذج الشبكة العصبية المصمم لcod بدقة تنبؤ عالية، حيث سجل معامل ارتباط بلغ 0.96 مما يعكس كفاءته في تفسير التغيرات في قيم COD، وقد أظهر النموذج أداء ممتاز في 85% من الحالات، حيث كانت الفروق بين القيم المتوقعة والفعلية ضمن هامش 5%

دلالات معادلة التنبؤ:

Y: القيم المتوقعة لcod

0.94: النموذج يتنبأ ب94% من القيم الفعلية

3.7: انحراف بسيط يضاف لضبط الدقة

T: القيمة الفعلية لcod

أثبت النموذج قدرة عالية على التنبؤ بالقيم التي تتراوح بين 36-53 mg/l، حيث يعكس هذا التطابق كفاءة النموذج في محاكاة عمليات المعالجة الروتينية.

يعزى الفرق إلى عوامل استثنائية مثل: تصريف مفاجئ لمياه الصرف الصناعية عالية التركيز، أو أعطال مؤقتة في وحدات المعالجة البيولوجية

تشير النتائج إلى أن هذا النموذج يمكن أن يصبح نظاماً مساعداً مهماً في اتخاذ القرارات التشغيلية.

B. نمذجة الطلب البيوكيميائي على الأكسجين BOD:

تمكن النموذج من تحقيق دقة تنبؤية عالية بلغ معامل ارتباطها 0.92 مع متوسط خطأ نسبي 6.19% للقيم في المدى الطبيعي 5-20mg/l

دلالات معادلة التنبؤ:

Y: القيم المتوقعة ل bod

1: النموذج يتنبأ ب100% من القيم الفعلية

39: انحراف بسيط يضاف لضبط الدقة

T: القيمة الفعلية ل bod

ومع ذلك لوحظت بعض التحديات في التنبؤ بالقيم العالية <20mg/l حيث ارتفع الخطأ النسبي إلى 32%، يعزى هذا إلى:

ندرة البيانات التدريبية في هذا المدى

تأثير التفاعلات البيوكيميائية المعقدة

حساسية بارامترات BOD للتغيرات الموسمية

C. نمذجة المواد الصلبة العالقة الكلية TSS:

دلالات معادلة التنبؤ:

Y: القيم المتوقعة لـ TSS

0.73: النموذج يتنبأ بـ 73% من القيم الفعلية

3.2: انحراف بسيط يضاف لضبط الدقة

T: القيمة الفعلية لـ TSS

(دقيق في المتوسط، يحتاج تعديلاً للقيم العالية والمنخفضة)

المقارنة العلمية:

متوسط الخطأ: 6.19%

أفضل أداء بين (10-12) بأقل من 2.5% خطأ

يحتاج تحسيناً للقيم >9

يظهر النموذج إمكانية تطبيقية واعدة، لكنه يحتاج إلى:

اختبار على بيانات من محطات أخرى

تكامل مع أنظمة المراقبة الآنية

تحديث دوري بأحدث البيانات

D. نمذجة معدل التدفق الخارج Qout:

دلالات معادلة التنبؤ:

Y: القيم المتوقعة لـ Qout

0.94: النموذج يتنبأ بـ 94% من القيم الفعلية

1900: يضاف هذا الثابت لتعويض الفروق النظامية بين التوقعات والقياسات الفعلية.

T: القيمة الفعلية لـ Qout

يفسر 98% من تباين البيانات

متوسط الخطأ 4%

يمكن استخدامه مع:

مراقبة الأداء شهرياً

تحديث النموذج كل 6 أشهر

ونلاحظ بأن النماذج حققت أداء جيد مقارنة مع الدراسات الأخرى حيث عند النظر إلى الدراسات المرجعية السابقة مثل دراسة العالم M.S. Nasr في محطة العجمي بالإسكندرية (مصر) عندما استخدم الشبكات العصبية الاصطناعية وصلت قيمة معامل الارتباط لكل من (COD, BOD, TSS) إلى 0.9

ودراسة العالمان H.AL-Tujjer and A. Ogunku التي حققت نتائج عالية باستخدام نظام ANFIS، حيث وصلت معاملات الارتباط لـ (BOD, TN, TSS, TP) إلى 0.9137 و 0.9231 لـ TSS

الاستنتاجات والتوصيات:

بناءً على نتائج هذا المشروع، نستنتج بأن البنية المختارة للشبكة العصبونية من نوع Feed-forward backprop ذات الطبقة المخفية الواحدة بعشر خلايا عصبونية قد حققت أداءً فعالاً وممتازاً في قدرتها على التنبؤ بمتغيرات جودة المياه بدقة قدرها 0.9 مما يؤكد هذا التصميم البسيط وقدرته على استخلاص الأنماط المعقدة من مجموعة البيانات بنجاح.

وتوصى هذه الدراسة بما يلي:

1. ربط النماذج مع أنظمة التحكم بالمحطة لضبط العمليات تلقائياً بناءً على تنبؤات جودة المياه، مما يزيد من الكفاءة التشغيلية.
2. تدريب النماذج بشكل دوري (كل 6 أشهر) باستخدام بيانات جديدة لضمان استمرارية الدقة في التنبؤ.
3. تنظيم حملات تثقيفية لأفراد المجتمع توضح أهمية معالجة مياه الصرف الصحي ودور الذكاء الاصطناعي في تحسين جودة المياه.
4. تطوير خوارزميات متقدمة للتعليم الآلي قادرة على التعامل مع البيانات غير المكتملة والقيم المتطرفة.
5. تشجيع البحث والتطوير في مجال تقنيات المعالجة المتقدمة.

المراجع:

Harez, R., Latifi, M. A., & Rosh, N. (2015). [Prediction of the adsorption of reactive dyes on the sawdust of Eucalyptus Camaldulensis by artificial neural network]. *Journal of Chemical Engineering*, 281(5), 900–920

Shargi, E., Norano, V., Ashrafi, A. A., & Jokshikos, W. H. (2019). [A comprehensive review of prediction models for reverse osmosis desalination plants using artificial intelligence]. *Water Desalination and Treatment*, 164, 86–97.

Nasr, M. S., Mustafa, M. A. M. M., Seif, G. A. S., & Al-Firsi, J. (2012). [Application of artificial neural networks to predict the performance of Al-Ajami wastewater treatment plant, Egypt]. *Alexandria Engineering Journal*, 51(15).

Al-Tujjar, H., & Ogunku, A. (2022). [Improving pollution removal modeling prediction in wastewater treatment plants using adaptive neuro-fuzzy inference system]. *Journal of Environmental Research and Technology*, 5(1), 213–226.

Oye, A. A., Jantan, A., Omolara, A. E., Dada, K. V., Mohammed, N. A., & Arshad, H. (2018). [State-of-the-art in artificial neural network applications: A survey]. *Heliyon*, 4(1), 7–41.

Norani, F., Alkirran, J., & Abba, C. I. (2018). [Assessment of Water Quality Using Machine Learning Techniques]. *Water Science and Technology*, 7(10), 2064–2076.

Kang, J. H., Song, J. H., Yoo, S. S., Lee, B. J. L., & Ji, H. W. (2020). [Analysis of Air Pollution Trends Using Satellite Data]. *Atmosphere*, 11(9), 1–9.

Malfia, A., & Jaspal, D. (2021). [Article title]. *Environmental Technology Reviews*, 1(10), 177–187.

Van, M., Hu, J., Kaw, R., Ruan, W., & Wei, W.X. (2018). "Impact of chemical factors on marine environment." *Chemosphere*, *200*, 330-343.

Ahmed, M., Alam, K., Tariq, S., Anwar, S., Nasser, J., & Mansha, M. (2019). [Article title]. *Atmospheric Environment*, *2*, 330-343.

Shu, A., Chang, H., Shu, Y., Ri, R., Li, X., & Zhao, Y. (2021). [Article title]. Waste Management, *124*, 385-402.

تقرير من محطة معالجة مياه الصرف الصحي في مدينة حماه.