

## التنبؤ بالاحتياج الكيميائي للأوكسجين في المياه الخارجة من محطة معالجة مياه مجاري مدينة حمص باستخدام الشبكات العصبونية

د.م محمد بشار المفتي\* د.م مازن إبراهيم\*\* م. هبه فيصل الجدوع\*\*\*

(الإيداع: 9 آذار 2021 ، القبول: 3 حزيران 2021)

### الملخص :

تم في هذه الورقة البحثية استخدام الشبكات العصبونية (ANN) للتنبؤ بقيمة الاحتياج الكيميائي للأوكسجين في المياه الخارجة من محطة معالجة مياه مجاري مدينة حمص، وقد استخدمت في البحث بيانات جمعت على مدى عشرة أعوام من خلال السجلات اليومية لمحطة معالجة مياه مجاري مدينة حمص، تم بناء النموذج بالاعتماد على كل (Q,BOD,COD,SS,SSout) مدخلات للتنبؤ بقيمة الـ COD، كما تم تقييم أداء النموذج من خلال اعتماد مقلوب الخطأ لمجموعة التحقيق (Inverse validation error) ، كمتيار حاسم (Fitness) لانقضاء بنية الشبكة الأفضل بالإضافة إلى معايير المفاضلة الأخرى، تم تحديد البنية الأمثل للشبكة العصبونية بعد عدد من المحاولات والأخطاء، أظهرت النتائج كفاءة جيدة للنموذج المقترح بالتنبؤ بقيمة COD في المياه الخارجة من محطة المعالجة، حيث تم في نهاية هذا البحث التوصل إلى بنية الشبكة العصبونية للتنبؤ بقيمة مؤشر COD وهي (1-20-5) وذلك باستخدام دالة الظل القطعي في الطبقة الخفية والدالة اللوجستية في طبقة الخرج، اعتمدت خوارزمية Quick propagation للتدريب بلغت قيمة تابع الأداء 0.05 وبلغ متوسط الخطأ الأعظمي للمجموعات الثلاث 18.5 وقيمة معامل الارتباط 0.71.

الكلمات المفتاحية: الشبكات العصبونية، الاحتياج الكيميائي للأوكسجين ، محطة معالجة مياه المجاري.

\*أستاذ مساعد في قسم الهندسة البيئية في كلية الهندسة المدنية بجامعة دمشق.

\*\*أستاذ مساعد في قسم الإدارة الهندسية جامعة دمشق.

\*\*\* طالبة دكتوراة جامعة دمشق كلية الهندسة المدنية قسم الهندسة البيئية

## Prediction of Effluent COD for Homs Wastewater Treatment Plant Using Neural Networks

Prof. Dr.Mohamd Basher Almofti\* Prof. Dr. Mazen Ebrahim\*\* Eng. Heba Al Jaddou  
(Received: 9 March 2021, Accepted: 3 June 2021)

### ABSTRACT:

In this paper the artificial neural networks (ANN) is used for the prediction of chemical oxygen demand.

The data used in this research was collected over ten years through the daily records of the Homs wastewater treatment plant.

The model was built based on the approval of each of the values of (Q.BOD,COD ,SS ,SS out) as inputs to predict the value of the COD, and the performance of the model was evaluated by adopting an inverse validation error for selecting the best network structure in addition to other differential criteria.

The optimal structure of the neural network was determined after a number of attempts and errors, and the results showed a high efficiency of the proposed model algorithms in predicting the value of effluent COD.

As a result of this research, a neural network structure was selected to predict the value of the COD indicator which is (5-20-1) using the Hyperbolic Tangent function in the hidden layer and the logistic function in the output layer, the Quick propagation was used as a training algorithm for training, The value of the performance function was 0.05, and the average error value of the three groups was 18.5, the value of the correlation coefficient was 0.71.

Keywords:, neuronal network, chemical oxygen demand, wastewater treatment plant

---

\* Assitant Prof- Enviromment engineering department civil Engineering –Faculty Damscuse University.

\*\* Assitant Prof- Engineering Management . Civil Engineering– Faculty Damscuse University.

\*\*\*Php Student– Envirommental Engineering. department Civil Engineering– Faculty Damscuse University.

## 1- المقدمة:

تعد مياه الصرف الصحي المنزلية واحدة من أهم مصادر تلوث البيئة وذلك تبعاً لغناها بالكثير من الملوثات ،لذلك ولتقدير أداء المحطة ونوعية المياه الناتجة عنها كان لابد من إيجاد نموذج قوي وفعال للتحكم بهذه العملية المعقدة [1].

يعتبر مؤشر الـ COD أحد أكثر البارامترات المستخدمة للإشارة إلى المحتوى العضوي للمياه في كلاً من مياه الصرف الصحي والمياه السطحية ويعرف الـ COD على أنه الأوكسجين المستهلك كيميائياً لهضم المواد العضوية الموجودة في مياه الصرف الصحي تحت درجة حرارة قياسية، وعلى اعتبار أنه من الممكن استخدام مؤشر الـ COD كبديل لمؤشر الـ BOD فإنه من الممكن الاعتماد على مؤشر الـ COD في العديد من الأعمال الخاصة بتصميم أو تشغيل محطات المعالجة مثل: تحديد حجم وحدات المعالجة وكفاءة المعالجة لبعض وحدات المعالجة [4].

يعد الـ COD بارامتر ضروري جداً في تحليل جودة المياه من حيث أنه يعطي مؤشراً على تأثير المنصرفات السائلة على جسم المستقبل المائي .حيث أنه كلما ارتفعت نسبة مؤشر الـ COD في المستقبل المائي كلما ازدادت أكسدة المواد العضوية فيه، والذي سوف يؤدي في النهاية إلى إنقاص محتوى المصدر المائي من الأوكسجين المنحل (DO) ،هذا النقص في محتوى الأوكسجين المنحل في المصدر المائي ممكن أن يحول الشروط في البيئة المائية المحيطة إلى شروط لاهوائية مما يترك تأثيرات ضارة جداً على الوسط المائي [4].

نتيجة الاهتمام العالمي المتزايد بالبيئة والصحة العامة أصبح للصبب الناتج عن محطات المعالجة أهمية عالية لما له من آثار مهمة على البيئة المستقبلية، و السمة المميزة لمحطات المعالجة هي أنها ذات طبيعة ديناميكية تماماً وتتضمن العديد من العمليات المعقدة وغير الخطية والتي يصعب التنبؤ بها أو تفسيرها باستخدام نموذج إحصائي أو رياضي خطي، وعلى أية حال تلعب عملية النمذجة الملائمة دوراً أساسياً في وصف التفاعلات التي تحدث في المنظومة ككل [3].

أدت الزيادة السريعة في النمو السكاني أدت إلى التطور العمراني والزراعي والصناعي هذا التطور أدى إلى زيادة مستوى تلوث المياه، وهذا جعل من موضوع تأمين مياه ذات جودة عالية أمراً صعباً ومستهلكاً للمصادر [8]، وكل ما سبق يستدعي اللجوء إلى استخدام تقنيات جديدة عالمياً في عمليات التحكم والمراقبة لعمل محطات المعالجة وذلك لتطوير نوعية الصبب الناتج عن محطات المعالجة وتحقيق المواصفات المطلوبة حيث أن معظم النماذج الرقمية المعروفة لا تعطي نتائج موثوقة تبعاً لطبيعة النظام المعقدة [10].

و تجدر الإشارة إلى أنه وفي ذات الوقت فإن الكلفة العالية والوقت المستهلك في نمذجة بارامترات جودة المياه عن طريق النماذج التجريبية يجعل من الضرورة البحث عن تطبيقات حاسوبية للتعامل مع مفهوم عدم اليقين والنقص في النماذج التجريبية [8] . وبالتالي استخدمت الشبكات العصبونية في نمذجة الجريانات الهيدرولوجية وعمليات معالجة مياه الصرف الصحي ،حيث تم في السنوات الأخيرة اعتماد الشبكات العصبونية (ANN) كنهج للتنبؤ والتحكم والتصنيف والمراقبة والمحاكاة للتفاعلات غير الخطية. إن قدرة الشبكات على الأخذ بعين الاعتبار العديد من المدخلات والمخرجات إضافة لقدرتها على التعلم الذاتي والتكيف جعل إمكانية اعتمادها لنمذجة أي نظام ممكنة [9].

نجح العديد من الباحثين في توظيف نماذج الـ ANN للتنبؤ أو التصنيف أو أمثلة بارامترات جودة المياه (WQI)، كما قدر ( Dogan et al 2015) الـ BOD لمدخل محطة معالجة باستخدام الشبكات العصبونية (ANN) [1].

وقد استخدمهما ( Areerachakul et al., 2011; Djeddou and Achour, 2015 ) لتقدير دليل الحمأة في محطة معالجة تعمل بالحمأة المنشطة [2] .

تم في هذه الدراسة تحديد كفاءة وأداء الشبكات العصبونية بالتنبؤ بمؤشر الـ COD للمياه الخارجة من محطة معالجة مياه مجاري مدينة حمص.


## 2-هدف البحث:

إيجاد نموذج يعتمد على تطبيقات الذكاء الصناعي للتنبؤ بمؤشر الـ COD للمياه الخارجة من محطة معالجة مياه مجاري مدينة حمص.

## 3-المواد وطرائق البحث:

### الشبكات العصبونية الصناعية (Artificial Neural Networks) ANNs:

هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، ومكونة من وحدات معالجة بسيطة هذه الوحدات عبارة عن عصبونات (Neurons) أو عُقد (Nodes)، والتي لها خاصية عصبية، حيث أنها تقوم بتخزين المعرفة العلمية والمعلومات التجريبية لجعلها متاحة للاستخدام وذلك عن طريق ضبط الأوزان [6]. يوضح الشكل (1) آلية عمل عصبون اصطناعي ومكوناته الأساسية، حيث تقوم (ANN) بمعالجة البيانات على التوازي (Parallel) مما يوفر سرعة عالية في الأداء تمكنها من حل المشاكل المعقدة التي تضم فرضيات كثيرة ومعلومات متغيرة بشكل سريع وفعال.



الشكل رقم (1): كيفية عمل العصبون الاصطناعي

هناك العديد من الشبكات العصبونية الصناعية المستخدمة في معالجة أنماط البيانات، وكل نوع من هذه الأنواع له خصوصية في البنية وآلية معالجة المعلومات من خلال عدد ونوع العقد في كل طبقة بالإضافة إلى نوع دوال التنشيط وآلية تعديل الأوزان، وقد تم اختيار الشبكة العصبونية أمامية التغذية ذات الانتشار العكسي للخطأ (Backpropagation Feedforward) التي اكتسبت الكثير من الاهتمام في مجال التنبؤ بالطقس [11].

### 3-1 المكونات الأساسية للشبكة العصبونية الصناعية:

تتألف الشبكات العصبونية من المكونات الأساسية الآتية أو بعضاً منها على الأقل [14]، وهذه المكونات هي: طبقة الدخل -طبقة الخرج-الطبقات الخفية-الوصلات البينية (الأوزان).

#### 1. طبقة الدخل (Input Layer):

تتكون طبقة الدخل من مجموعة من الوحدات أو عناصر المعالجة (Nodes) التي تعمل على توزيع القيم المدخلة إليها من الوسط الخارجي إلى الطبقة الخفية التي تليها عبر الارتباطات والتي بناءً عليها ستكون النتائج.

## 2. طبقة الخرج (Output Layer):


هي الطبقة الأخيرة التي تقع عند المخرج، حيث تقوم عناصر المعالجة فيها باستلام الإشارات من الطبقة الخفية السابقة لتعالجها حسابياً بشكل مشابه تماماً للطبقات الخفية، حيث يتم الحصول على النتائج النهائية، وهي تساهم مع الدخل في تكوين ذاكرة الشبكة.

## 3. الطبقات الخفية (Hidden Layers):

وهي مجموعة الطبقات البينية التي تقع بين طبقتي الدخل والخرج، وتكون مكونة من طبقة واحدة أو أكثر وذلك حسب حجم المشكلة وطبيعتها، وتعد العنصر الأساسي في حفظ واستعادة ذاكرة الشبكة، والأبحاث المتعلقة بالشبكات العصبونية تشير إلى عدم وجود أسلوب قياسي في تحديد عدد الطبقات الخفية أو عدد العصبونات في كل منها، وعادةً يتم بالتجريب حتى الوصول إلى الأداء الأفضل [12].

## 4. الوصلات البينية (الأوزان) (Weights):

هي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها أو الوحدات داخل كل طبقة مع الوحدات الأخرى عبر الأوزان التي تكون مصاحبة أو مرافقة مع كل وصلة بينية، ومهمة هذه الوصلات نقل البيانات أو الإشارات الموزونة بين وحدات المعالجة أو الطبقات، الشكل (2) يوضح المكونات الأساسية لشبكة عصبونية صناعية.



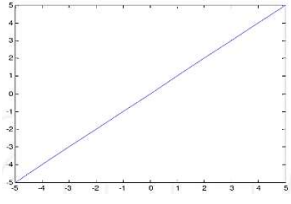
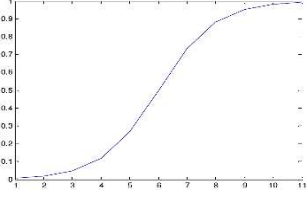
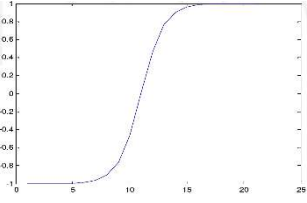
الشكل رقم (2): نموذج معماري لشبكة عصبونية صناعية.

يعتبر تعيين القيم الابتدائية للأوزان (Initializing weights) عملية بالغة الأهمية، فالتخمين الأولي الأقرب إلى القيم المثلى للأوزان يساعد على تعميم أسرع للشبكة؛ مع هذا لا توجد طريقة معينة للقيام بتخمين أولي جيد للأوزان، لذا فإنها تعتمد على تعيين قيم ابتدائية عشوائية بشكل آلي [5].

## 2-3-2-2 توابع التحويل (Transfer Function):

إن تابع التحويل يطبق على خرج العصبون، ويجب أن يمتلك الخواص التالية: أن يكون تابعاً مستمراً؛ أن يكون قابلاً للاشتقاق ومشتقه سهل الحساب؛ أن يكون انسيابياً غير متناقصاً [13]. ويوضح الجدول (1) أهم توابع التحويل (Transfer Function) أو توابع التنشيط (Activation Function) المتوفرة في برنامج (Matlab).

الجدول رقم (1): دوال التحويل ضمن بيئة برنامج (Matlab)

اسم التابع	الرسم البياني	الصيغة الرياضية
التابع الخطي Linear (Purelin): يعطي خرجاً يحمل نفس قيمة الدخل المقدم إليه.		$F(net) = net$
تابع السيغمويد المنطقي Sigmoid (logsig): يعطي خرجاً ثنائياً [0, 1].		$F(net) = \frac{1}{1 + e^{(-net)}}$
تابع السيغمويد ثنائي القطبية أو تابع الظل القطعي Hyperbolic Tangent Sigmoid (tansig): يعطي خرجاً ثنائي القطبية [-1,+1].		$F(net) = \frac{2}{1 + e^{-2*net}} - 1$

### 3-2 وصف المحطة:

يتم تصفية مياه المجاري الواصلة إلى المحطة بشكل مبدئي وإزالة المواد المعلقة الثقيلة ضمن منشآت المعالجة الأولية التي تتضمن أيضاً قياس التدفق ومعدات التسجيل. يتم ترسيب مياه المجاري بعد المعالجة الأولية في أحواض ترسيب شعاعية يتم بعد ذلك تتجه المياه الخارجة من حوض الترسيب الأولي نحو أحواض المعالجة البيولوجية بالتهوية السطحية والتي يعقبها فصل للحمأة المنشطة في أحواض الترسيب الثانوي. ويعاد قسم من الحمأة المنشطة إلى أحواض التهوية والفائض من الحمأة إما أن تضح إلى أحواض الترسيب الأولي من أجل الترسيب المشترك مع الرواسب الأولية أو توجه مباشرة نحو منشآت معالجة الحمأة. يحقن الصبيب القادم من أحواض الترسيب الثانوي مباشرة بالكلور بشكل سابق لدخوله حوض التماس مع الكلور، والصبيب المعالج بالكلور يصرف مباشرة إلى نهر العاصي من أجل تمديده وبدء المعالجة الطبيعية المعقمة له. تخضع جميع الغزارات القادمة إلى محطة المعالجة للمعالجة الأولية والتحضيرية أما التدفقات التي تمرر باتجاه المعالجة الثانوية فتحدد بكمية أكبر بعض الشيء من تدفق الذروة اليومي في الطقس الجاف، والبقية تصرف مباشرة إلى نهر العاصي، ويبين الشكل رقم (3) صورة جوية لمحطة معالجة مياه مجاري مدينة حمص.



الشكل رقم (3): يوضح صورة جوية لمحطة معالجة مياه مجاري مدينة حمص

3-3 مصدر البيانات :

تم جمع عينات مياه المجاري من محطة معالجة مياه مجاري مدينة حمص وتضمنت الدراسة بارامترات المياه الداخلة للمحطة وهي (BOD.COD,SS,Q, SSeff) .

4- نتائج البحث:

تم في هذا البحث استخدام برنامج (Alyuda NeuroIntelligence) وهو تطبيق برمجي لتصميم الشبكات العصبونية , كما تم استخدام برنامج الـ (SPSS25) للتحليل الإحصائي .

معالجة البيانات (Preprocessing Datasets)

تقوم هذه المرحلة على المعالجة المسبقة (Pre-Processing) للبيانات قبل تغذية الشبكة العصبونية الصناعية، ويتم ذلك من خلال عملية التحجيم (Scaling) أو التقييس (Normalization) للقيم الرقمية بما يتناسب مع الخلايا العصبونية (Artificial Neurons) التي لديها نطاق محدد من قيم التشغيل، كما هو موضح في الجدول (2).

الجدول رقم (2): مجال التحجيم الخاص بدوال التفعيل

Output layer activation function	Scaling range
Linear	[-1..1]
Logistic	[0..1]
Hyperbolic Tangent	[-1..1]

• يتم إجراء التقييس في النموذج تلقائياً وفق المعادلتين (1)،(2)

$$S_f = \frac{(SR_{max} - SR_{min})}{(X_{max} - X_{min})} \dots \dots (1)$$

$$X_p = SR_{min} + (X - X_{min}) * S_f \dots \dots (2)$$

حيث:

$X$ : القيمة الحقيقية &  $X_{min}$ : القيمة الصغرى الحقيقية &  $X_{max}$ : القيمة العظمى الحقيقية &  $SR_{min}$ : الحد الأدنى الفعلي لمجال التحجيم &  $SR_{max}$ : الحد الأعظمي الفعلي لمجال التحجيم &  $S_f$ : معامل التحجيم &  $X_P$ : القيمة بعد المعالجة.

وفق معظم الدراسات والنتائج البحثية الموجودة في الأبحاث، تم استخدام المجال الثنائي القطب  $[-1,1]$  الخاص بدالة الظل القطعي (Hyperbolic Tangent) من أجل أعمدة الإدخال، والمجال  $[0..1]$  الخاص بالدالة اللوجستية (Logistic) لعمود الخرج والجدول (3) يبين الخواص الإحصائية للمتغيرات ومعامل التقييس لكل منها.

الجدول رقم (3): الخواص الإحصائية للبيانات المعالجة

	N	Minimum	Maximum	Mean	Std. Deviation	correlation with cod_out
m <sub>3</sub> /d)(Q	3903	822.00	777178.00	75065.0361	29519.08393	-0.1
BOD(mg/l)	2315	16.00	2696.00	560.6618	335.78836	0.42
COD(mg/l)	3100	41.00	7600.00	939.4932	589.15510	0.93
SS(mg/l)	2926	15.00	4350.00	724.9125	523.95843	0.12
SS_out(mg/l)	2972	3.00	210.00	30.5851	20.66592	0.674
Valid N (listwise)	2012					

#### 1-4 تصميم الشبكة (Designing Network):

اعتماد التصميم النهائي لنموذج (ANN) يتكون من جزأين هما:

- خصائص الشبكة (Properties Network) والمتعلقة بتحديد عدد الطبقات الخفية، ودوال التفعيل في كل من الطبقة الخفية وطبقة الخرج، في هذه الدراسة تم استخدام شبكة عصبية وحيدة الطبقة مع استخدام دالة الظل القطعي في الطبقة الخفية، والدالة اللوجستية في طبقة الخرج، واعتماد تابع مجموع مربعات الخطأ (MSE) لتقييم أداء النموذج وفق المجموعات الثلاثة.
- البحث عن بنية الشبكة (Architecture Network) والمتعلق بشكل أساسي بتحديد عدد العصبونات في الطبقة الخفية والمتوافق مع درجة التعقيد في المشكلة (Problem Complexity) المدروسة، وهناك نمطين للبحث وهما:
- ♣ البحث التجريبي (Heuristic Search): يبدأ من خلال ترشيح مجموعة من التصاميم ضمن مجال محدد لعدد العصبونات في الطبقة الخفية، وهو ملائم للشبكات وحيدة الطبقة.




♣ البحث الشامل (Exhaustive Search): يقوم على اختبار جميع الخيارات الممكنة ضمن مجال محدد لعدد العصبونات وخطوة انتقال محددة فيما بينها في الطبقة الخفية، وهو ملائم للشبكات التي يصل عدد الطبقات الخفية فيها حتى خمس طبقات والتي يصح احتمالات التخمين والتجريب فيها مضيعة للوقت، وسريعاً ما يتبادر للذهن حجم الوقت الذي يحتاجه البرنامج لإنجاز العملية.

مرجعياً يمكن استخدام البحث التجريبي لعدم وجود معلومات عن درجة تعقيد المشكلة المدروسة ولتسهيل عملية البحث، من خلال ترشيح مجموعة من التصاميم ضمن مجال محدد لعدد العصبونات في الطبقة الخفية بين (20) و(100) عصبوناً، واعتماد معيار مقلوب الخطأ لمجموع التحقيق (Inverse Validation Error) كمعيار حاسم (Fitness) لانتقاء بنية الشبكة بالإضافة إلى معايير المفاضلة الأخرى؛ مع تكرار الحسابات (Iteration=300) عند تشغيل النموذج (Retrain=1) لمرة واحدة، ويبين الجدول (4) النتائج التي تم الحصول عليها لبنية أفضل 12 شبكة مقترحة، حيث تبين أن أفضل بنية هي ANN(2-50-1)، أي وجود عصبونين في طبقة الدخل و50 عصبون في الطبقة الخفية، وعصبون واحد في طبقة الخرج.

الجدول رقم (4): نتائج البحث التجريبي عن بنية الشبكة العصبونية الأفضل

Architecture	# of Weights	Fitness	Train Error	Validation Error	Test Error	AIC	Correlation
[5-19-1]	134	0.052581	18.31057	19.018337	18.10083	-5564.026096	0.711705
[5-12-1]	85	0.052509	18.404882	19.044222	18.039284	-5655.064709	0.708396
[5-26-1]	183	0.052048	18.689253	19.213202	18.283197	-5438.288898	0.701853
[5-23-1]	162	0.052402	18.314651	19.083292	18.175867	-5507.72407	0.710661
[5-16-1]	113	0.052455	17.708342	19.064001	17.431501	-5651.340805	0.738976
[5-21-1]	148	0.053016	17.614161	18.86212	17.478462	-5588.566554	0.740425
[5-22-1]	155	0.052421	19.105478	19.076338	18.304541	-5464.443117	0.686317
<b>1 [5-20-1]</b>	<b>141</b>	<b>0.053108</b>	<b>18.238043</b>	<b>18.829714</b>	<b>18.188267</b>	<b>-5555.403761</b>	<b>0.717256</b>

يوضح الشكل (4) انحدار الخطأ المطلق (Absolute Error) لأفضل نموذج عصبي صناعي ANN(5-20-1) مقترح لتمثيل قيم (COD)، حيث بلغت قيمة أخطاء الشبكة لمجموعة التدريب والتحقيق والاختبار القيم (18.2,18.8,18.18) على الترتيب، مع معامل ارتباط (0.717).



الشكل رقم (4): انحدار الخطأ المطلق لنموذج ANN (5-20-1)

## 2-4- تدريب الشبكة العصبونية (Training Networks):

تدرب الشبكة بتقديم بيانات التدريب التي تم تجهيزها في الخطوة الأولى وباختيار هيكلية الشبكة (1-54-2) ANN الأفضل التي تم تحديدها في الخطوة السابقة، يبدأ التدريب انطلاقاً من أوزان ابتدائية (Initializing weights) وتتغير مع تكرار الحسابات باتجاه تحسين أداء الشبكة وتحقيق أقل خطأ ممكن، ومع تحديد معدلات التعلم (The Learning Rates) والزخم (Momentum) واختيار معايير توقف التدريب لتجنب التدريب المفرط، سيتوقف التدريب عندما يصل متوسط مربع الخطأ (MSE) للقيمة (0.01) أو اكتمال التدريب عند 1000 تكرار، أيهما يحدث أولاً. وأيضاً سيتم حساب متوسط الخطأ المطلق (Average Absolute Error)، وخطأ الشبكة (Sum-of-Squares) وفقاً لخوارزمية التدريب المختارة (quick propagation). ويوضح الجدول رقم (5) متوسط مربعات الأخطاء لخوارزمية التدريب المختارة.

الجدول رقم (5): متوسط مربعات الأخطاء (MSE) لخوارزمية التدريب المختارة

Name	Architecture	Training algorithm	Hidden FX	Output FX	Iterations	Avg training error	Avg test error
Last Trained	[5-20-1]	Quick Propagation	Hyperbolic tangent	Logistic	501	19.18077	18.154783

يوفر برنامج (alyuda) واجهة استعمال بسيطة للمستخدم ممكن من خلالها إدخال المدخلات المدروسة وسوف يقوم البرنامج بالتنبؤ ب COD\_OUT كما هو موضح في الشكل رقم (5)

Q	BOD	COD	SS	SSCW
max: 144949	max: 1700	max: 3031	max: 2760	max: 88
min: 2750	min: 16	min: 57	min: 15	min: 3

Q	BOD	COD	SS	SSCW	CODCW

الشكل رقم (5): يوضح واجهة الاستعلام التي يوفرها البرنامج

## 5- استنتاجات:

- إمكانية استخدام الشبكات العصبونية الصناعية للتنبؤ بقيم مؤشر الـ COD في المياه الخارجة من محطة معالجة مياه مجاري مدينة حمص.

• الحصول على نموذج تنبؤي للتنبؤ بـ COD مكون من خمس عناصر في طبقة الدخل هي (Q,BOD,COD,SS,SSeff) وعنصر واحد في طبقة الخرج هو الـ COD ، و 20 عصبون في طبقة الدخل وقد تم استخدام خوارزمية Quick propagation للتدريب حيث أثبتت فعالية وكفاءة عالية في التدريب مقارنة مع الخوارزميات الأخرى المتوفرة في البرنامج.

#### 6- التوصيات:

امكانية الاعتماد على النمذجة الحاسوبية للتنبؤ بمؤشر الـ COD عند ضرورات المراقبة والتحكم في تشغيل محطات معالجة مياه المجاري ، أو عند الحاجة لرد فعل تصحيحي سريع عند قدوم أحمال تلوث غير متوقعة .  
ممكن للنموذج التنبؤي المبني اعتماداً على الشبكات العصبونية أن يعطي نتائج جيدة في حال الظروف التشغيلية غير المتوقعة مثل صدمات التحميل العضوي أو الهيدروليكي غير المتوقعة.  
إجراء المزيد من الدراسات حول استخدام تقنيات الذكاء الصناعي من أجل التنبؤ بمؤشرات المعالجة المختلفة التي تخص محطات معالجة مياه المجاري.

#### 7- المراجع:

- [1] Dogan E., Asude A., Yilmaz E.C, and Eren B., 2015. **Application of Artificial Neural Networks to Estimate Wastewater Treatment Plant Inlet Biochemical Oxygen Demand** Wiley InterScience, 27(4),439-446.
- [2] Djeddou.M , Achour B.,2015. The Use of a Neural Network Technique for the Prediction of Sludge Volume Index in Municipal Wastewater Treatment .Larhyss journal,24,351-370.
- [3] Hamed, M. M., Khalafallah, M. G., and Hassanien, E. A., 2004. **Prediction of wastewater treatment plant performance using artificial neural networks. Environmental Modelling & Software**, 19, 919-928
- [4] Jain, B. .,P. K. and J. K. 2014. Wastewater Engineering (Including Air Pollution). (B. . Purnia, Ed.) (Second). India: Laxmi Publications (P) LTD. Kuo-lin Hsu, Hoshin Vijai Gupta, and S.Sorooshian.,1995. **Artificial Neural Networks Modelling of the rainfall - runoff process. Journal of Hydrologic Engineering**, 31(10), 2517-2530.
- [5] [21]JAIN, S. K; SINGH, V. P 2003- **Applications of artificial neural networks to water resources**. Water and Environment International Conference (WE-2003), Bhopal, India.
- [6] MAKRIDAKIS, S; WHEELWRIGHT, S. C; HYNOMAN, R. J 1998- **Forecasting Methods and Application**. New York: John Wiley & Sons.
- [7] Nourani, V., Alami, M. T., and Aminfar, M. H., 2009. **A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation**. Engineering Applications of Artificial Intelligence, 22(3), 466-472.

- [8] Nourani, V., Hakimzadeh, H., and Amini, A. B., 2012., **Implementation of artificial neural network technique in the simulation of dam breach hydrograph**. Journal of Hydroinformatics, 14(2), 478
- [9] Nourani, V., Alami, M. T., and Vousoughi, F. D., 2015. **Wavelet–entropy data pre–processing approach for ANN–based groundwater level modeling**. Journal Of Hydrology,524, 255–269
- [10] Pai, T. Y., Yang, P. Y., Wang, S. C., Lo, M. H., Chiang, C. F., Kuo, J. L.,and Chang, Y. H., 2011. **Predicting effluent from wastewater treatment of industrial park base on fuzzy network and influent quality**, **Applied Mathematical Modelling**, 35, 367–3684..
- [11] VANRULLEN, R. **The power of the feed–forward sweep**. **Advances in Cognitive Psychology**, vol. 3, no. 1–2, 2007, 167–176.
- [12] WILMOT, C.G; MEI, B 2005– **Neural Network Modeling of Highway Construction Costs**. Journal of Construction Engineering and Management ASCE.
- [13] ZUPAN, J 1994– Introduction to Artificial Neural Network (ANN) Methods. Department of Chemistry, University Rovira Virgili, Tarragona, Spain.
- [14] ZURADA, J. M 1992. **Introduction to Artificial Neural Systems**. West Publishing Company, U.S.A.