مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (١٠) العدد (٧) ٢٠٢٦

Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (7) 2026

تصميم نظام ذكي لاكتشاف وتصنيف التسرب في محطات ضخ مياه الشرب باستخدام الشبكات العصبونية.

الحالة المدروسة (مشروع الجكرة في ريف طرطوس).

أ . د . م . مخائيل سليم مخول*

د. م. ضحى خالد جديد **

م . صبا محمد فرحة***

(تاريخ الإيداع ٢٠٢٦/١/٢٥ . قُبِل للنشر في ٢٠٢٦/٤/١٦)

□ ملخّص □

يهدف هذا البحث إلى تصميم منصة المراقبة (odoo (On Demand Open Object)ERP) من أجل المراقبة الفورية لمحطة ضخ المياه في ريف طرطوس (مشروع الجكرة)، إذ يقوم بمحاكاة للحساسات المستخدمة الضغط والتدفق والحرارة والرطوبة، تم استخدام نموذج الشبكة العصبونية(LSTM) لتحليل بيانات محاكاة الحساسات من أجل كشف التسرب وتحديد موقعه.

تحاكي منصة المراقبة عمل الحساسات المستخدمة ، وتقييم خطر التسرب بناء على نتائج القياس ، وتتيح المنصة محاكاة حالات التسرب (صغير ، متوسط ،كارثي) بالإضافة إلى تحديد موقع التسرب على طول خط النقل الرئيسي.

أظهرت نتائج التطبيق أداءً جيداً، حيث تمكن نموذج الكشف عن التسربات من التعرف على حوادث التسربات المختلفة.

تم تقييم أداء الكشف عن التسريبات باستخدام مصفوفة الارتباك، وأظهر دقةً بلغت 100% في جميع سيناريوهات التسرب المختلفة.

الكلمات المفتاحية: تسرب الماء في محطات الضخ، الشبكات العصبونية (LSTM)، تقييم الأداء LSTM.

* أستاذ في قسم الأتمتة الصناعية، كلية الهندسة التقنية، جامعة طرطوس.

** مدرس في قسم الأتمتة الصناعية، كلية الهندسة التقنية، جامعة طرطوس.

*** طالبة دكتوراه في قسم الأتمتة الصناعية، كلية الهندسة التقنية، جامعة طرطوس

مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (١٠) العدد (٧) ٢٠٢٦

Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (7) 2026

Designing an intelligent system for detecting and classifying leaks in drinking water pumping stations using neural networks.
The case study (Al-Jakrah Pumping station in the Tartous countryside).

professor.Dr. Eng. Michael Saleem Makkoul*
Dr.Eng. Doha Khalid jdeed**
Eng. Seba Mohammed farha

(Received 25/1/2026 . Accepted 16/4/2026)

□ ABSTRACT □

This research aims to design an odoo (On Demand Open Object) ERP monitoring platform for real-time monitoring of the water pumping station in rural Tartous (Al-Jakrah). It simulates the sensors used for pressure, flow, temperature, and humidity. A neural network model (LSTM) was used to analyze the sensor simulation data in order to detect and locate leaks.

The monitoring platform simulates the operation of the sensors used and assesses leak risk based on measurement results. The platform allows for the simulation of various leak scenarios (minor, medium, and catastrophic) and pinpoints the leak's location along the main transmission line.

The application demonstrated good performance, with the leak detection model successfully identifying different leak incidents.

Keywords: Water leakage in pumping stations, LSTM neural networks, LSTM performance evaluation.

* Professor in the Department of Industrial Automation, Faculty of Technical Engineering, Tartous University.
** Doctor in the Department of Industrial Automation, Faculty of Technical Engineering, Tartous University.
*** PhD student in the Department of Industrial Automation, Faculty of Technical Engineering, Tartous University.

1-مقدمة:

تعد مشكلة تسرب المياه ومعالجتها وكشف حالات التسرب من أهم المشكلات التي تعترض مصممي شبكات ضخ المياه فقد تم تحليل مشكلة كشف تسرب المياه ومعالجتها باستخدام أنواع مختلفة من وسائط البارامترات (الضغط والتدفق) والتقنيات المعتمدة على البيانات، حيث حظيت تقنيات التعلم الآلي باهتمام كبير، ويمكن تصنيف الدراسات المتاحة بناءاً على بيانات الحساسات التي استخدمها الباحثون لتدريب تقنية التعلم الآلي [1]. وتشمل بيانات الإدخال بيانات الانبعاث الصوتي والاهتزاز والتدفق والضغط، وتستخدم هذه الحساسات بشكل متكرر نظراً لانخفاض تكلفتها وسهولة تركيبها [2].

- استخدم باحثون بيانات التدفق والضغط لمقارنة أداء أربع طرق للتعلم الآلي للكشف عن التسربات في خزانات مياه الشرب، اعتمدت طرق المقارنة على الانحدار اللوجستي والغابة العشوائية و(K-means) والشبكات العصبونية الاصطناعية، حيث حقق الانحدار اللوجستي والغابة العشوائية أعلى أداء من خلال استخدام بيانات التدفق والضغط كمدخلات منفصلة [3].
- تم إجراء دراسة أخرى بين شبكة عصبونية اصطناعية(ANN) وشبكة عصبونية حسية (KNN) وآلة المتجه الداعم (SVM) والانحدار اللوجستي، ومع ذلك، لم تأخذ هذه الدراسة بعين الاعتبار بيانات التدفق والضغط في آن واحد كمدخلات لتدريب واختبار تقنيات التعلم الآلي [4] [5].
- حللت دراسة أخرى بيانات التدفق والضغط لتدريب شبكة (CNN)، ووفقاً لهذه الدراسة بلغت الدقة التي تم الحصول عليها باستخدام شبكة (CNN) 95% [6] [7].
- استخدم حساس الاهتزاز بشكل واسع للكشف عن تسربات المياه، واعتمدت الدراسة التي أجراها باحثون على بيانات الاهتزاز من خلال مقاييس التسارع الكهر ضغطية وقارنوا بين نهجين للكشف عن تسربات المياه يتضمن النهج الأول استخراج ميزات المجال الزمني والترددي من بيانات الاهتزاز لتدريب خوارزميات آلة المتجه الداعم (SVM) وخوارزمية الجار الأقرب (KNN)، وتضمن النهج الثاني استخراج صور التردد الزمني لبيانات الاهتزاز باستخدام تحويل فوريه قصير المدى، ومن خلال تطبيق تحويل فوريه قصير المدى على إشارات مقياس التسارع الكهروضغطي المرتبطة بتسربات المياه في ظل ظروف مختلفة بلغت الدقة 99% لدرجات دقة مختلفة للزمن والتردد [8] [9].

تظهر الدراسات استخدام منهجيات مختلفة قائمة على تقنيات التعلم الآلي للكشف عن تسرب المياه، فقد اعتمد الباحثون على نوع واحد فقط من طرق البيانات، مثل بيانات الاهتزاز، أو بيانات الضغط، أو التدفق لتدريب خوارزميات التعليم الآلي علاوة، على ذلك، لا تزال تقنيات الدمج لدراسة تأثير طرق البيانات المختلفة في أداء الكشف عن تسرب المياه القائمة على التعلم الآلي قيد الاستكشاف على نطاق واسع [10].

يعالج البحث الواقع الحالي لمحطة الضخ المدروسة (مشروع الجكرة) الموجود في ريف طرطوس (بلدة بملكة)، وتم في الآونة الأخيرة اكتشاف تسرب في خط الأنبوب الرئيسي الواصل بين الخزان التجميعي الموجود داخل المحطة والخزان الرئيسي (خارج المحطة)، والذي يبعد حوالي 2.5كم عن المحطة.

تعتمد الطريقة المتبعة في اكتشاف التسرب داخل الأنابيب على نظام الكشف الصوتي، إذ يتم قياس الصوت الناتج عن التسرب باستخدام جهاز صوتي (الميكروفونات الأرضية)، ولكن مشكلة هذه الطريقة بأن

التسربات الصغيرة لا يمكن اكتشافها بشكل فعال، وتعتمد دقة هذه الطريقة على خبرة العامل، بالإضافة إلى تداخل الضوضاء المحيطة مع ضوضاء التسرب ويؤدي ذلك إلى إنذارات كاذبة.

بعد الاطلاع على واقع محطة الضخ المدروسة كان لا بد من التفكير بجدية لإيجاد الحلول العلمية لهذه المسألة من خلال استخدام أنظمة الذكاء الاصطناعي للكشف عن تسرب المياه في الأنبوب الرئيسي الواصل بين الخزان التجميعي والخزان الرئيسي.

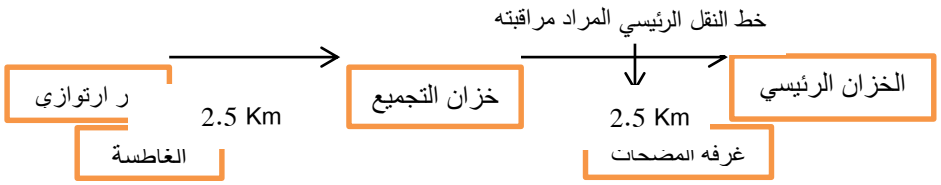
2- أهمية البحث وأهدافه:

تكمن أهمية البحث في مراقبة تسرب مياه الشرب وتحديد مكانه وكيفية معالجته ولتحقيق هدف البحث قمنا بتصميم واجهة المراقبة التي تجمع بين تقنيات التعلم الآلي ونظام تخطيط موارد المؤسسات (ERP).

3-طرائق البحث ومواده:

3-1 توصيف محطة الضخ في ريف طرطوس (مشروع الجكرة):

يظهر الشكل (1) المخطط لمحطة الضخ المدروسة، والتي تتألف من محطتين للضخ وخزان رئيسي وتتألف المحطة الأولى من تجمع عدة ينابيع ويتم ضخ المياه منها إلى المحطة الثانية وتبعد عنها حوالي2.5Km ، أما المحطة الثانية فتتكون من خزان التجميع الذي يضخ إلى الخزان الرئيسي الذي يغذي عدة قرى (بملكة، العوينية، بسماقة، العلاقية، بهرمين)، وتحتوي محطة الضخ على ثلاثة مضخات، طرد مركزية، وتتغذى هذه المضخة من الشبكة العامة للكهرباء.



الشكل (1): المخطط لمحطة الضخ المدروسة (مشروع الجكرة).

3-2 تصميم منصة المراقبة الذكية:

تم تصميم منصة المراقبة الذكية لكشف التسرب وتحديد موقعه على طول خط النقل الرئيسي، حيث يتم من خلالها محاكاة عمل الحساسات (ضغط، تدفق، حرارة ورطوبة)، وإدخالها إلى نموذج الذكاء الاصطناعي (LSTM) لكشف التسرب وتحديد الموقع، تم بناء هذه المنصة باستخدام تقنيات الويب الحديثة (React/Vue) بحيث تكون تفاعلية وسهلة الاستخدام.

3-2-1 محاكاة بيانات الحساسات:

تم محاكاة عمل الحساسات (الحرارة والرطوبة والضغط والتدفق) في الكشف عن التسرب، تؤثر درجة الحرارة والرطوبة بشكل كبير على عملية تآكل الأنابيب كما تسبب التغيرات في درجة الحرارة والرطوبة إجهادات في الأنابيب مما يؤدي إلى ظهور تشققات تزيد من احتمالية التسرب ، إضافة لما سبق يؤثر تدفق المياه داخل الأنابيب بشكل كبير على عملية التسرب، فكلما زادت احتمالية التسرب

وخاصةً في الأنابيب الضعيفة، كما أن تغيرات ضغط المياه داخل الأنابيب يمكن أن تسبب تسربات، وذلك لإمكانية الضغط أن يوسع الشقوق الموجودة أو يتسبب في تلف الأنابيب.

تم توليد بيانات الضغط والتدفق في الظروف العادية وظروف التسرب باستخدام برنامج (water Network, Tool for Resilience,WNTR)، الذي يستخدم لمحاكاة وتحليل مرونة أنظمة توزيع المياه ويتطلب توليد هذه البيانات عدة خطوات:

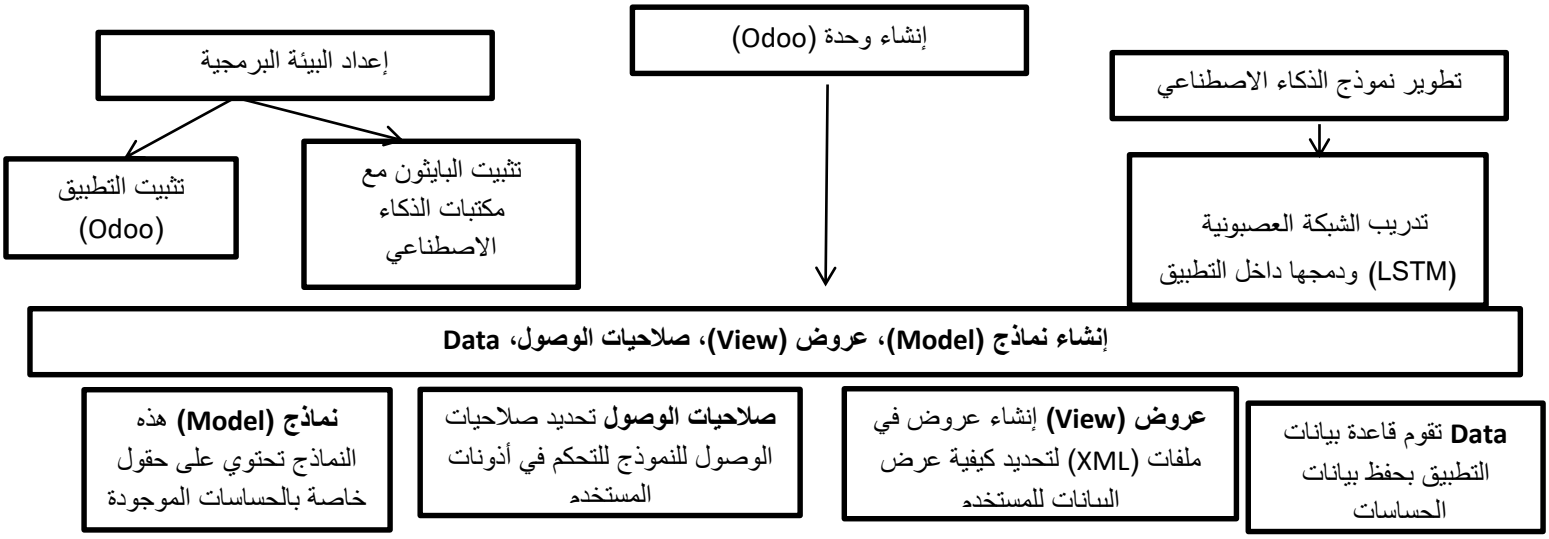
- إعداد بيئة (WNTR): عبارة عن حزمة برمجية مكتوبة بلغة البايثون، تستطيع نمذجة سلوك شبكات المياه وتوفير بيانات الضغط والتدفق متسلسلة زمنياً استناداً إلى مبادئ فيزيائية وهو ما يعد أكثر دقة من مجرد استخدام برنامج نصي بسيط.
- تحميل أو إنشاء نموذج شبكة المياه: ويتم ذلك من خلال تحديد شبكة المياه الخاصة (الأنابيب، العقد، الخزانات، المضخات) في ملف إدخال ((EPANET(inp) أو إنشائها برمجياً باستخدام بايثون.
- محاكاة الظروف الطبيعية (بدون تسرب): لمحاكاة الظروف الطبيعية يتم تشغيل محاكاة هيدروليكية قياسية باستخدام برنامج (WNTR Simulator)، ستوفر هذه المحاكاة قيم الضغط والتدفق الأساسية عبر الشبكة.

محاكاة ظروف التسرب: لمحاكاة التسرب يتم تعديل نموذج الشبكة من خلال إضافة مكون تسرب اصطناعي إلى عقدة أو أنبوب محدد، ويتم حساب تدفق التسرب داخلياً بواسطة المحاكي بناءً على مساحة التسرب والضغط عند نقطة التسرب وفقاً لمعادلة برنولي الموضحة في العلاقة التالية: $Q= C_d\ A\ \sqrt{\frac{2\Delta P}{\rho}}$ حيث: (A): مساحة الفتحة و (C_d): معامل التصريف و (ρ) : كثافة السائل.

استخراج بيانات الضغط والتدفق: يتم تشغيل المحاكاة واستخراج بيانات الضغط والتدفق المتسلسلة زمنياً وتم توليد بيانات درجات الحرارة والرطوبة في بايثون باستخدام وحدة (Random)، (Numpy) للتوزيعات الأكثر تطوراً.

3-2-2 التصميم البرمجي (odoo) لمنصة المراقبة الذكية:

يعد نظام odoo المبين في الشكل (2)نظام متكامل لتخطيط موارد المؤسسات (Enterprise Resource Planning)، حيث تم إنشاء وحدة برمجية للنظام تستخدم الذكاء الاصطناعي وذلك بهدف كشف تسرب المياه في خط النقل الرئيسي، ومن ثم استخدام لغة بايثون لنموذج الذكاء الاصطناعي ودمجه مع التطبيق من خلال وحدات برمجية مخصصة.



الشكل (2): الهيكل الأساسي لبرمجة (odoo).

3-2-3 بناء وتدريب نموذج الذكاء الاصطناعي (LSTM):

تم في هذا البحث استخدام شبكات LSTM (ذاكرة قصيرة المدى مطولة)، وهي اختصار لـ (Long Short–Term Memory) التي حلّت مشاكل اختفاء التدرج إلى حد ما بفضل سعة التخزين الكبيرة للبيانات السابقة، وLSTM، كحالة خلوية، تُنفذ بشكل متتالي بوابة النسيان وبوابة الإدخال وبوابة الإخراج مع إزالة أو إضافة بيانات سابقة .

فبوابة النسيان، كما هو موضح في المعادلة (1) تستقبل (x,h)، وترسلهما إلى (C) حالة الخلية، وتتجاهل البيانات غير الصحيحة. وبعد ذلك، تُحدد البيانات المخزنة في حالة الخلية ببوابة الإدخال المحسوبة، كما هو موضح في المعادلة (2)، وفي هذه المرحلة تضيف دالة (tanh) قيماً مرشحة جديدة وفقاً للمعادلة (3)، لتحديد البيانات المراد إضافتها إلى حالة الخلية. وأخيراً، تكتمل المعالجة المسبقة لتحديث وإخراج حالة الخلية في الوقت الحالي والأخير، كما هو موضح في المعادلة (4)، ومن ثم يتم نقل قيمة الإخراج من المعادلتين (5) و(6) إلى الطبقة التالية.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(Wi \cdot [hi-1, xi] + b_i) \quad (2)$$

$$'c_t = \tanh(WC \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

$$C_t = (f_t \times C_{t-1}) + (i_t \times 'C_i) \quad (4)$$

$$o_t = \sigma(W_0[h_{t-1}, x_t] + b_0) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

ويتضمن بناء نموذج (LSTM) في (Tensor Flow) استخدام واجهة برمجة تطبيقات (Keras) المدمجة في (Tensor flow)، وتتم العملية بالخطوات التالية:

١. **استيراد المكتبات الضرورية** (numpy, Keras).

٢. **تحضير البيانات:** تم استخدام مجموعة بيانات **"Leak Simulations in Experimental Testbed"** موجودة على موقع (Mendeley Data) لتدريب نموذج (LSTM)، وهي مجموعة بيانات للكشف عن التسربات وتحديد مواقعها في أنظمة توزيع المياه، وتتضمن هذه المجموعة 280 إشارة مأخوذة من منصة اختبار لتوزيع المياه على نطاق مخبري مع أربعة أنواع من

التسربات وعدم وجود تسرب (طبيعي)، وبلغ طول منصة الاختبار 47m، وهي مصنوعة من أنابيب PVC وقطرها 152.4mm، وسجلت البيانات من خلال تجارب متحكم فيها، حيث تم تغيير ما يلي: بنية الشبكة، ونوع التسرب، وأنواع الحساسات ومواقعها ويتم تنزيل مجموعة البيانات بالخطوات التالية:

١. **الدخول إلى الموقع**

http://data.mendeley.com/datasets/tbrnp6vrnj/1

للبحث عن مجموعات البيانات المتعلقة ب **"Leak Simulations in Experimental Testbed"**

٢. **اختيار مجموعة البيانات:** يجب البحث عن مجموعات البيانات التي تحتوي على بيانات حساسات التسربات، والتي غالباً ما تتضمن بيانات من نوع الضغط والتدفق والحرارة والرطوبة.

٣. **تنزيل مجموعة البيانات:** يجب اتباع التعليمات الموجودة على الموقع لتنزيل ملفات البيانات والتي تكون غالباً بصيغ مثل CSV أو ملفات نصية.

٣. **إعداد البيانات:** يتم تقسيم البيانات إلى مجموعات تدريب واختبار، وتُطبَّق عملية تطبيع البيانات (إزالة المتوسط وتقسيم الانحراف المعيارى) لتحسين أداء النموذج ودقته، وتُحوَّل السلاسل الزمنية إلى نوافذ متتالية (sequence windows) لإدخالها في الخلايا المتكررة.

٤. **بناء نموذج (LSTM):**

- تهيئة نموذج متسلسل: وهو عبارة عن مجموعة طبقات خطية مكدسة.
- إضافة طبقات (LSTM): تتضمن المعلمات الرئيسية وعدد الوحدات (الخلايا العصبونية) في الطبقة وشكل الإدخال للطبقة الأولى.
- إضافة طبقات الإسقاط (اختياري): تساعد هذه الطبقات على منع الإفراط في التجهيز من خلال تعيين جزء عشوائي من وحدات الإدخال إلى الصفر عند كل تحديث أثناء التدريب.
- إضافة طبقات كثيفة: هذه طبقات متصلة بالكامل لإخراج التنبؤات.

٥. **تجميع النموذج:**

- تحديد دالة المُحسن (مثل "adam"، أو "rmsprop").
- تحديد دالة الخسارة (مثل "binary_crossentropy") والتي يجب مراقبتها أثناء التدريب.

٦. **تدريب النموذج:**

- ملاءمة النموذج: من خلال استخدام دالة model.fit() لتدريب النموذج على بيانات التدريب.
- المعلمات: من خلال تحديد عدد مرات تكرار التدريب (epochs)، وحجم الدفعة (batch_size)، واختيار بيانات التحقق من الصحة لمراقبة الأداء أثناء التدريب.
- الاسترجاعات (اختياري): مثل Early Stopping أو Model Check point) لتحسين التحكم في التدريب.

٧. **التقييم والتنبؤ:**

- من أجل تقييم أداء النموذج تم استخدام مصفوفة الارباك.

○من أجل التنبؤ، ويتم استخدام دالة (model predict) للتنبؤ بالبيانات الجديدة باستخدام النموذج المدرب.

٨. **حفظ النموذج المدرب:** لاستخدامه لاحقاً في برنامج (odoo).

3-2-4 تقييم أداء نموذج (LSTM):

تم تقييم أداء النموذج من خلال استخدام مصفوفة الارتباك الموضحة في الجدول (1)، حيث نتائج توقعات النموذج هي: النتائج الإيجابية الحقيقية (TP)، والنتائج السلبية الحقيقية (TN)، والنتائج الإيجابية الكاذبة (FP)، والنتائج السلبية الكاذبة (FN)، ويتم حساب (TPR)، وهي نسبة البيانات التي تم تحديدها على أنها تسربات في ظل حدوث التسرب وفق المعادلة (7)، وحساب (FPR) وهي نسبة البيانات التي تم تحديدها على أنها تسريبات من البيانات العادية وفق المعادلة (8)، ويشير (ACC) الموضح في المعادلة (9) إلى دقة الدرجة التي تعلم بها النموذج، وهذا يعني درجة مماثلة من بيانات التعلم وبيانات الاختبار، ومن خلال مصفوفة الارتباك يمكن حساب مقاييس الأداء (Precision، Recall، F_1–Score) وفق المعادلات (10) و(11) و (12).

كما تم استخدام منحنى خصائص التشغيل المستقبل (Receiver Operating Characteristic curve أو ROC) في تقييم أداء النموذج، حيث تم رسم معدل الإيجابيات الحقيقية (TPR) مقابل معدل الإيجابيات الخاطئة (FPR) لتحديد قدرة النموذج على التمييز بين الفئات، كما هو موضح في الشكل (10).

الجدول (1): مصفوفة الارتباك :

N=240 عدد بيانات الاختبار	Actual outcome=yes	Actual outcome=No
Predicted outcome=Yes	TP(190)	**FN (10)**
Predicted outcome=No	FP (5)	**TN (35)**

TPR= $TP/(TP+FN)$ *100 (7)

FPR= $FP/(FP+TN)$ *100 (8)

Accuracy = $(TP+TN)/(TP+FN+TN+FP)$ (9)

Precision = $TP/(TP+FP)$ (10)

Recall = $TP/(TP+FN)$ (11)

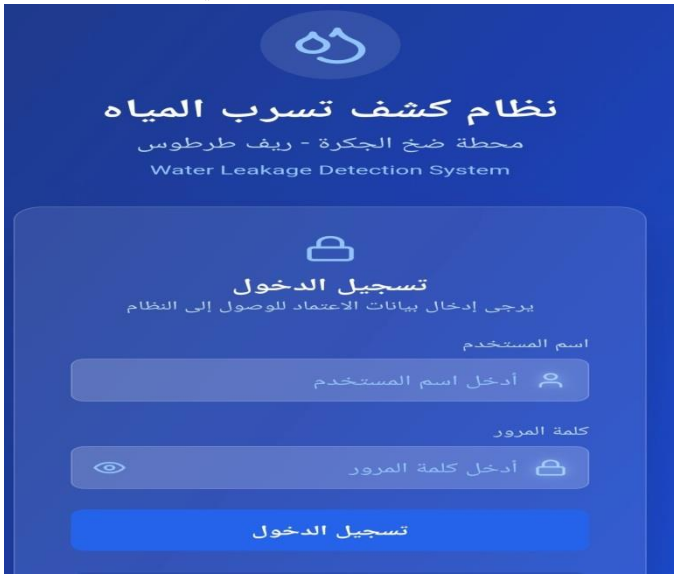
F_1–Score = 2* $(Precision * Recall)/(Precision + Recall)$ (12)

3-2-5 واجهة المستخدم:

يبين الشكل (4) منصة المراقبة المركزية التي تم تصميمها، حيث تم استضافة هذه المنصة على موقع bolt.new، لتكون متاحة للجميع وتتألف من جزء علوي يعرض حالة النظام ودرجة الخطر، اربعة بطاقات تعرض محاكاة عمل الحساسات، ثم جزء سفلي يعرض شريط تقييم خطر التسرب (يُظهر نسبة الخطر والثقة في التنبؤ)، إذ تم ضبط أمان واجهة المستخدم من خلال وضع كلمة المرور واسم المستخدم كما هو مبين في الشكل (5).



الشكل (4): منصة المراقبة المركزية.



الشكل (5): أمان واجهة المستخدم.

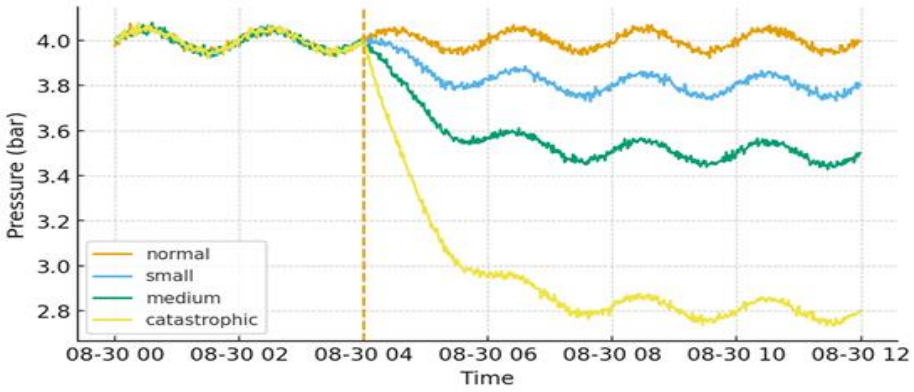
4- النتائج والمناقشة:

4-1 نتائج محاكاة منصة المراقبة الذكية:

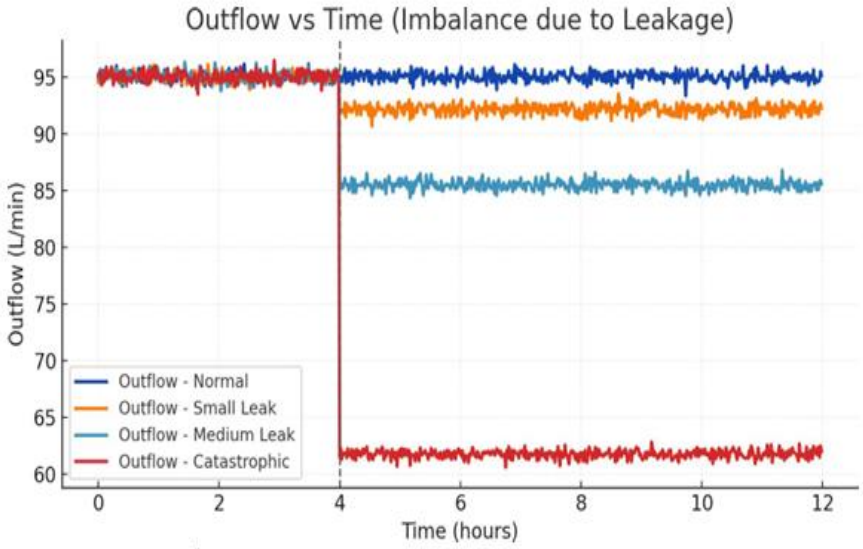
تم اختبار النظام المصمم من خلال محاكاة سيناريوهات التسرب مع الوضع العادي لنظام المياه في خط النقل الرئيسي وذلك عند قيم مختلفة للضغط والتدفق مدتها اثنتي عشرة ساعة.

4-1-1 حالة التشغيل العادي وسيناريوهات التسرب:

يبين الشكل (6) قيم الضغط في حالة التشغيل العادي وسيناريوهات التسرب (صغير، متوسط، كارثي) التي تشير إلى انخفاض الضغط عن الوضع الطبيعي، وكلما قل انخفاض الضغط قل معدل التدفق كما هو مبين في الشكل (7) حيث تغطي هذه الأشكال جميع السيناريوهات بعلامة رأسية عند t=4 ساعات، مما يشير إلى بداية التسرب.



الشكل (6): بيانات الضغط بمرور الوقت في ظل سيناريوهات التسرب المختلفة.



الشكل (7): بيانات التدفق بمرور الوقت في ظل سيناريوهات التسرب المختلفة.

▪ يبين الشكل (8) قدرة نموذج (LSTM)، على اكتشاف انخفاضاً في الضغط بمقدار 0.4 بار عن الوضع الطبيعي وذلك في حالة التسرب الصغير، بالإضافة إلى تحديد موقع التسرب من خلال تحليل الانخفاض الحاد في الضغط بين الحساسات لتحديد المقطع المتأثر (برمجياً تم تقسيم الأنبوب إلى مقاطع تتوزع عليها الحساسات).



الشكل (8): حالة التسرب الصغير.

- يعرض الشكل (9) **اكتشاف الانخفاض لحالة التسرب المتوسط، إذ انخفض الضغط عن الضغط الطبيعي بمقدار واحد بار.**



الشكل (9): حالة التسرب المتوسط.

- أما الشكل (10) ، فيعبر عن حالة التسرب الكارثي، إذ انخفض الضغط عن الضغط الطبيعي بمقدار 2.4 بار.



الشكل (10): حالة التسرب الكارثي.

4-1-2 نتائج تقييم أداء النموذج (LSTM):

من خلال التعويض في المعادلات السابقة (9)، (10)، (11)، (12)، (13)، (14) ، تبين أن:

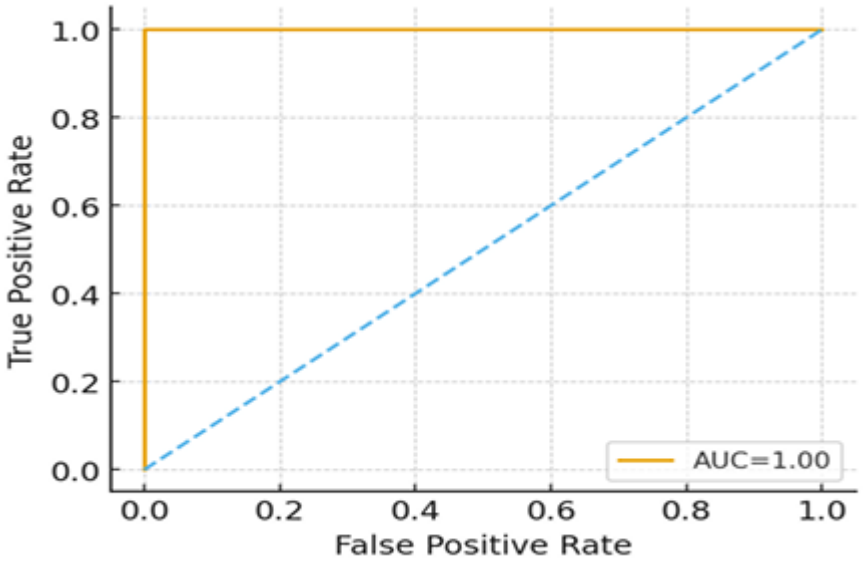
Accuracy=100%, Precision=100%, 100%

Recall =

F1-Score= 100%

من نتائج هذه المعادلات، تبين أن نموذج (LSTM)، هو نموذج مثالي لكونه خالياً من النتائج الإيجابية الخاطئة والنتائج السلبية الخاطئة.

يبين الشكل (11)، المساحة تحت المنحنى (AUC=1)، وهذا يدل على قدرة نموذج (LSTM) العالية على التمييز بين الوضع الطبيعي ووضع التسرب.



الشكل (11): منحنى ROC وحساب AUC.

عند حدوث أحد التسربات المذكورة سابقاً يتم تفعيل واجهة التحكم في المضخات من خلال تفعيل بروتوكول الطوارئ والذي يتمثل بعدة خيارات مثل (إيقاف جميع المضخات، تشغيل المضخة الاحتياطية، وضع الانتظار للمضخة)، كما هو مبين في الشكل (12).



الشكل (12): واجهة التحكم في المضخات.

5- الاستنتاجات والتوصيات:

يتطلب نظام شبكة أنابيب المياه، وهو بنية تحتية أساسية لتوفير المياه، صيانةً مستمرةً وخطط طوارئ لضمان استمرارية واستقرار إمدادات المياه.

من الضروري التعرف الفوري على التسرب وتحديد موقعه، وتطبيق التدابير الوقائية المُخطط لها لتقليل الأضرار، مثل انقطاع المياه في الحالات غير الطبيعية والمفاجئة . وعليه، يُعد التعرف السريع على حوادث التسرب في شبكة أنابيب المياه ذا أهمية اقتصادية، إذ يمنع الأضرار الثانوية من خلال توفير وقت الاستجابة وزيادة وقت إعداد التدابير الوقائية. لذا، يُعدُ ذلك ضرورياً لضمان استقرار إمدادات المياه وتقليل الأضرار التي تُلحق بالمستهلكين.

في هذا البحث، تم اقتراح نموذج قائم على بيانات الضغط والتدفق والحرارة والرطوبة للكشف عن التسربات في خط أنبوب نقل المياه الرئيسي، وتم تقييم أدائه من خلال إجراء محاكاة تضمنت تطبيقهُ على سيناريوهات التسرب المختلفة (طبيعي، صغير، متوسط، كارثي).

أظهرت نتائج التطبيق أداءً جيداً، حيث تمكن نموذج الكشف عن التسربات من التعرف على حوادث التسربات المختلفة.

تم تقييم أداء الكشف عن التسريبات باستخدام مصفوفة الارتباك، وأظهر دقةً بلغت 100% في جميع سيناريوهات التسرب المختلفة، ومن المتوقع أن يكون هذا النموذج تقنية برمجية بالغة الأهمية لتحديد مختلف المشكلات بشكل استباقي.

نوصي بإجراء تحليلات مقارنة مع نماذج التعلم العميق الأخرى لمزيد من التحقق من نموذج التعرف على التسريبات المقترح في هذا البحث.

6- المراجع:

1. ZENG, W,; LAMBERT, M,; GONG, J, B.; STEPHENS, M.2023. *Prediction of Water Leakage in Pipeline Networks Using Graph Convolutional Network Method. Appl. Sci.*Switzerland , vol.*13*,N. 13, 120-130.

2. WENMING,W,;HAIBO,S,2023.*Advancement in Underground Drinking Water Pipe Leak Detection. Measurement.ijrpr* India, vol.4,N.7,1761-1769.

3. STEFEEL, D,; DEUERLEIN, J,2022. *Leak detection and localization in water distribution networks: review and perspective. Journal of Water Resources Planning and Management* Britain,vol.166,N.1,65-112.

4. NEDA, M,; ISAM, S,2021 , *Use of Machine Learning for Leak Detection and Localization in Water Distribution Systems . Dead Sea* Jordan, vol.4,N.4,1-14.

5. LIU,S,2021.*Water leakage detection and localization using hydraulic modeling and classification . Urban Water Journal* U.S.A,vol.14,N.9, 972–983.

6. DALALD, H,;VASANI,R,2022. *A Review on Comparison of Different Water Leak Detection Techniques Suitable for Indian Scenario*. *Curr World Environ* India,vol.17,N.2,306-318.

7. ISLAM,M,; ASLAN,S,2021, *Leak Detection and Location Pinpointing in Water Pipeline Systems Using a Wireless Sensor Network. IEEE International Symposium on Circuits and Systems (ISCAS)* Daegu, Korea,vol.17,N.14,1-7.

8. SHUKLA, H,; PIRATIA, K,2019. *An Automated Leakage Det ection Model For Water Distribution Pipeline Systems. Proceedings of the 37th International No-Dig Conference* Florence, Italy,vol.13,N.16, 1220-1230.

9. ROJEK, I; STUDZINS, J,2019, *Detection and Localizat ion of Water Leaks in Water Nets Supported by an ICT System with Artificial Intellig ence Methods as a Way Forward for Smart Cities*. *Sustainability*Switzerland,vol.11,N.2,730-740.

10. KAYA, Y,; PEHLIVAN,H,2015. *Feature selection using genetic algorithms for premature ventricular contraction classification*. *In Electrical and Electronics Engineering (ELECO)*Turkey, vol.12,N.4, 1229-1232.