

## تطوير نظام تشخيص للكشف عن أمراض الدم باستخدام الشبكات العصبونية الاصطناعية

د. م. فادي متوج<sup>(1)</sup> ود. م. فاتن عجيب<sup>(2)</sup>

### الملخص

أدى التقدم في الذكاء الاصطناعي إلى ظهور أنظمة ذكية وتطوير أدوات يمكن أن تساعد الأطباء في التشخيص واتخاذ القرارات. توضح هذه الورقة البحثية كيف يمكن للذكاء الاصطناعي، وعلى سبيل المثال الشبكات العصبونية الاصطناعية، تحسين مجال التشخيص هذا. تتضمن التقنية المقترحة تدريب بيرسيبترون متعدد الطبقات (نوع من أنواع الشبكات العصبونية الاصطناعية) مع خوارزمية تدريب الانتشار العكسي لتشخيص والتنبؤ بخمسة اضطرابات في الدم، من خلال نتائج فحص تعداد الدم الكامل CBC. أظهرت النتائج دقة نظام التشخيص المقترح وموثوقيته، حيث بلغت الحساسية والنوعية والدقة %75.78، %98.94، %97.86 على الترتيب.

**الكلمات المفتاحية:** التشخيص الطبي - الذكاء الاصطناعي - الشبكات العصبونية الاصطناعية - أمراض الدم.

(1) دكتور مدرس في قسم هندسة الميكاترونك في كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

(2) دكتورة مدرسة في قسم الهندسة الطبية في كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

## Detection of Blood-Related Diseases Using Artificial Neural Networks

Dr. Fadi Motawej<sup>(1)</sup> Dr. Faten Ajeeb <sup>(2)</sup>

### Abstract

Advances in artificial intelligence have led to the emergence of intelligent systems and the development of tools that can help doctors diagnose and make decisions. This paper explains how artificial intelligence, for example artificial neural networks, can improve this field of diagnosis. The proposed technique involves the training of multilayer perceptron (a type of artificial neural network) with a reverse propagation training algorithm to diagnose and predict five blood disorders, through the results of a complete blood count test (CBC). The results showed the accuracy and the reliability of the proposed diagnosis system with sensitivity, specificity and accuracy reached 75.78%, 98.94% and 97.86% respectively.

**Keywords:** Medical diagnosis - Artificial intelligence - Artificial neural networks – Blood diseases.

---

<sup>(1)</sup> Doctor in the Department of Mechatronic Engineering at the Faculty of Mechanical and Electrical Engineering- Tishreen University.

<sup>(2)</sup> Engineer in the Department of biomedical Engineering at the Faculty of Mechanical and Electrical Engineering- Damascus University.

## 1- مقدمة:

التعامل مع البيانات المتنوعة، فقد أثبتت الشبكات العصبونية أنها مفيدة في تحليل عينات الدم والبول عند مرضى السكري [1] ، [2]، تشخيص السل [3] ، [4]، تصنيف اللوكيميا [5]، وتحليل صور الأشعة أو حتى الأنسجة الحية [6] ، [7]. وكذلك استخدمت الشبكة العصبونية للتنبؤ بسرطان البروستاتا [8-10]، وفي تصنيف أمراض القلب مثل مرض الشريان التاجي [11]، وفي التشخيص المبكر لمرض الزهايمر [12]، تشخيص أمراض الدماغ [13]، تصنيف سرطان عنق الرحم [14]، وتشخيص سرطان المبيض [15].

## 2- الشبكات العصبونية الاصطناعية:

الشبكات العصبونية الاصطناعية هي تمثيل هندسي يهدف لمحاكاة عمل الشبكات العصبونية في الدماغ البشري. تتألف الشبكات العصبونية الصناعية من عناصر معالجة بسيطة متصلة فيما بينها تدعى عصبونات (neurons). ينجز كل عصبون مهمة حسابية بسيطة، لكن السلوك الكلي للشبكة يتحدد من خلال الوصلات بين مختلف هذه العناصر [16]. أهم ما يميز الشبكات العصبونية الاصطناعية هي قدرتها على التعلم والتعميم. لهذا السبب، يتم تطبيقها على نطاق واسع، لأنه من الممكن أن تقوم بنمذجة النظم غير الخطية، حيث تكون العلاقة بين المتغيرات غير معروفة أو معقدة للغاية.

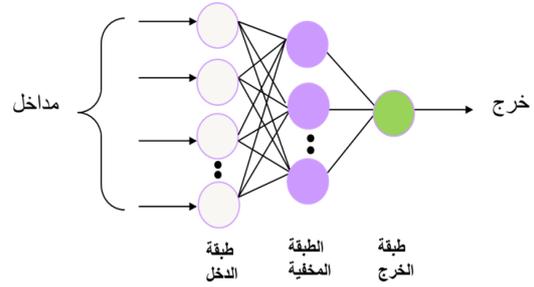
تعد الشبكة العصبونية من نوع بيرسيبترون متعدد الطبقات (MLP) الأكثر شيوعاً في مجال التشخيص الطبي. تتكون الشبكة العصبونية من نوع بيرسيبترون متعدد الطبقات (MLP) عادةً من ثلاث طبقات موضحة بالشكل (1) وهي :

1. طبقة الدخل Input layer
2. الطبقة المخفية Hidden layer
3. طبقة الخرج Output layer

التشخيص الطبي هو عملية تحديد المرض وتفسير الأعراض والعلامات الحيوية للمريض. بالنسبة للطبيب، ولكي يتمكن من تحديد التشخيص التفريقي ووضع خطط علاج سريعة فإن المعرفة الطبية والمهارات والخبرة تؤدي جميعها دوراً مهماً. في أي إجراء تشخيصي، تُستكمل المعلومات المتاحة بجمع بيانات إضافية يمكن الحصول عليها من التاريخ الطبي للمريض، ومن الفحص السريري ومن الاختبارات التشخيصية المختلفة، بما في ذلك الاختبارات المخبرية السريرية. تستخدم الاختبارات المخبرية لتأكيد، استبعاد، تصنيف، أو مراقبة الأمراض ووضع العلاج. ومع ذلك، لا يتم تقدير القيمة الحقيقية لنتائج الاختبارات المخبرية في كثير من الأحيان لأن المختبرات تميل إلى إصدار نتائج الاختبار كقيم رقمية، ويركز الأطباء بشكل أساسي على تلك القيم التي تقع خارج نطاق مرجعي معين.

يعتمد التشخيص السريري لأمراض الدم في المقام الأول على اختبارات الدم المخبرية - وحتى المختص في أمراض الدم الأكثر مهارة يمكن أن يغفل عن الأنماط والانحرافات والعلاقات بين الأرقام المتزايدة لبارامترات الدم المختلفة التي تقيسها المختبرات الحديثة. في المقابل، يمكن لخوارزميات الذكاء الصناعي التعامل بسهولة مع مئات السمات (المعلومات)، وهي قادرة على اكتشاف التأثيرات بين هذه السمات العديدة، مما يجعل هذا المجال من الطب مثيراً للاهتمام بشكل خاص لتطبيقات الذكاء الصناعي مثل الشبكات العصبونية الاصطناعية. يهدف بحثنا إلى تطوير نظام تشخيص باستخدام شبكة عصبونية اصطناعية (ANN) لتشخيص خمسة من أمراض الدم. تستخدم الشبكات العصبونية الاصطناعية (ANNs) على نطاق واسع في التشخيص الطبي. بفضل قدرتها على

- تدريب الشبكة العصبونية على المعطيات التي تم تجميعها.
- اختبار مدى كفاءة الشبكة المدربة على عينات جديدة لم تمرر للشبكة خلال عملية التدريب.
- في حال اجتازت الشبكة الاختبار بنجاح تصبح جاهزة للاستخدام العملي في التشخيص.



الشكل (1) بنية الشبكة العصبونية الاصطناعية MLP

[16].

#### 4- تجميع المعطيات :

لقد قمنا باستشارة طبيب مختص من أجل إعداد هذه البيانات، فقد اطلعنا على الأمراض التي سنقوم بتشخيصها والعوامل المؤثرة في تلك الأمراض. لقد تم الاعتماد على البارامترات المستخدمة في فحص تعداد الدم الكامل CBC (Complete Blood Count) في إنشاء قاعدة البيانات المناسبة المستخدمة في تدريب الشبكة العصبونية المقترحة. إن فحص CBC هو اختبار دم يستخدم لتقييم صحة الإنسان بعامه، وكشف مجموعة واسعة من الاضطرابات بما في ذلك فقر الدم والعدوى وسرطان الدم، وهو تحليل شائع جداً يطلبه الطبيب لمختلف الأمراض تقريباً. يطلق على CBC أيضاً التعداد أو الصيغة.

تفاصيل السمات الموجودة في مجموعة البيانات

المستخدمة في البحث والأمراض الناتجة عن الزيادة

والنقصان عن الحالة الطبيعية موضحة في الجدول (1).

الجدول (1) سمات البيانات المستخدمة في البحث.

MCV	HCT	HGB	RBC	RDW	تحليل الدم التشخيص
under 70	under 35	under 11.5	(3.5-5.5)	normal or under 11	Talasimia
(70-75)	under 35	under 11.5	under 3.5	over 16	Iron deficiency anemia
over 100	under 35	under 11.5	under 3.5	over 16	B12 deficiency anemia
(75-100)	over 55	over 16.5	over 5.5	(11-16)%	Polycythemia
(75-100)	(3.5-5.5)	11.5-16.5	3.5-5.5	(11-16)%	Normal

تفاصيل الرموز الموجودة في الجدول:

MCV : حجم الكرية الحمراء الوسطي.

طبقة الدخل لا تقوم بأي عملية معالجة، فهي ببساطة مكان تغذية الشبكة بشعاع البيانات، تقوم طبقة الدخل بعد ذلك بتغذية الطبقة المخفية بالمعلومات، ومن ثم تقوم الطبقة المخفية بتغذية طبقة الخرج. إن المعالجة الفعلية للبيانات تتم في الطبقة المخفية وطبقة الخرج [16].

عندما يكون هناك عدد كاف من العصبونات في كل طبقة، تكون الشبكة قادرة على التدريب (training) للقيام بأشياء مفيدة بالاستعانة بخوارزميات التدريب (training algorithms).

خلال عملية التدريب تقوم الشبكة بتعديل مستمر للأوزان (weights) المرتبطة بكل عصبون، حيث يشكل تعديل الأوزان محور عملية التعلم للشبكة العصبونية. بعد كل تعديل للأوزان يقترب خرج الشبكة أكثر فأكثر من قيمة الخرج الحقيقية. تتعلم الشبكة عن طريق إعطائها مجموعة من الأمثلة، التي يجب أن تكون مختارة بعناية، لأن ذلك سيسهم في سرعة تعلم الشبكة. ومجموعة الأمثلة هذه تسمى مجموعة معطيات التدريب. تستمر عملية التدريب على كل المعطيات المتوفرة وتعديل الأوزان المرتبطة بكل عصبون حتى يصبح خرج الشبكة أقرب ما يمكن للواقع.

#### 3-خطوات إجراء البحث:

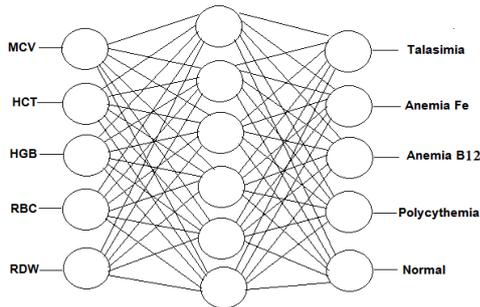
تتضمن خطوات البحث المراحل الآتية:

- تجميع المعطيات.
- بناء الشبكة العصبونية الاصطناعية المناسبة.

فتمثل الأمراض المختلفة والحالة الطبيعية. تم اختيار عدد العصبونات في الطبقة المخفية من خلال اتباع طريقة المحاولة والخطأ (trial and error)، حيث قمنا بمراقبة الخطأ التربيعي المتوسط (mse) لعدد مختلف من العصبونات، ووجدنا أن الشبكة بـ 6 عصبونات مخفية أعطت أفضل أداء. يبين الشكل (3) بنية الشبكة العصبونية المستخدمة في بحثنا. وتجدر الإشارة إلى أننا استخدمنا برنامج MATLAB كأداة برمجية [17].

### 6- تدريب الشبكة العصبونية الاصطناعية:

الآن الشبكة على استعداد للتدريب. وتنقسم العينات تلقائياً إلى مجموعة للتدريب (training) ومجموعة للتدقيق (validation) وأخرى للاختبار (test) حيث توزعت العينات كما يأتي:



الشكل (3) بنية الشبكة العصبونية المستخدمة.

- عدد العينات الكلي 250 عينة تمثل العدد الإجمالي لاختبارات CBC.
  - مجموعة عينات التدريب 174 عينة، وهو ما نسبته 70% من عدد العينات الكلي.
  - مجموعة عينات التدقيق 38 عينة، وهو ما نسبته 15% من عدد العينات الكلي.
  - مجموعة عينات الاختبار 38 عينة، وهو ما نسبته 15% من عدد العينات الكلي.
- تظهر البارامترات المستخدمة في الشبكة العصبونية في نافذة التدريب (الشكل 4).

**HCT:** الهيماتوكريت (فحص حجم الكريات الحمر المكسدة)

**HGB:** الهيموغلوبين (خضاب الدم).

**RBC:** عدد الكريات الحمر.

**RDW:** قياس توزيع كريات الدم الحمراء.

**Thalasasemi:** الثلاسيميا (فقر الدم الوراثي أو فقر دم حوض البحر الأبيض المتوسط).

**Iron deficiency anemia:** فقر الدم بعوز الحديد.

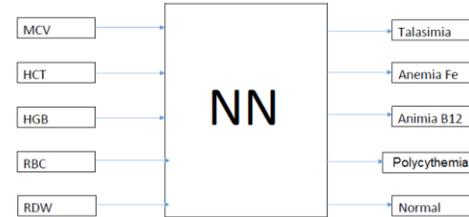
**B12 deficiency anemia:** فقر الدم بعوز فيتامين ب 12 أو حمض الفوليك.

12 أو حمض الفوليك.

**Polycythemia:** مرض احمرار الدم (أي زيادة عدد الكريات الحمر).

**Normal:** الشخص معافى وغير مصاب بأي من الأمراض السابقة.

و يوضح الشكل (2) مداخل ومخارج الشبكة العصبونية المقترحة لتشخيص أمراض الدم.

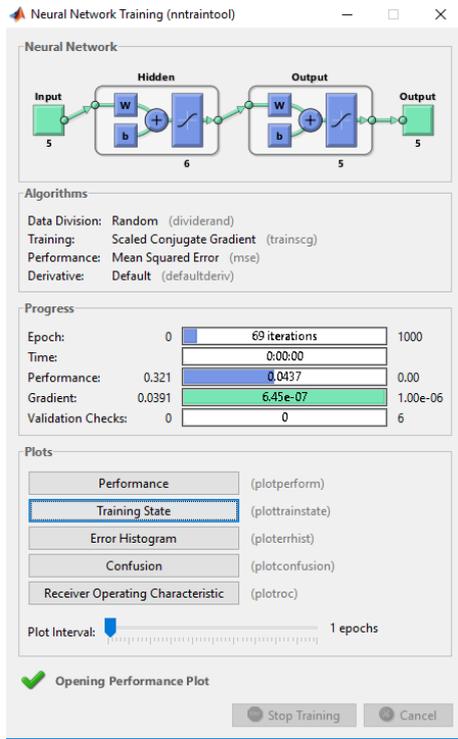


الشكل (2) مداخل الشبكة العصبونية المقترحة ومخارجها

وكما يوضح الشكل فإن كل دخل للشبكة العصبونية سيكون عبارة عن شعاع عمود فيه 5 أسطر تمثل القيم الناتجة من تحليل الدم لمريض معين، بينما يعطي خرج الشبكة التشخيص المناسب لكل حالة دخل.

### 5- بناء الشبكة العصبونية الاصطناعية:

قمنا بإنشاء شبكة عصبونية ذات تغذية أمامية بطبقة مخفية واحدة تحوي 6 عصبونات مخفية. هذه الشبكة تتألف من 5 مداخل، كل مدخل يمثل سمة من السمات المحددة في الجدول (1)، بينما تحوي الشبكة 5 مخارج



الشكل (4) نافذة التدريب كما تظهر في برنامج الماتلاب.

		Actual Values	
		Positive	Negative
Predicted Values	Positive	TP الإيجابي الحقيقي	FP الإيجابي الكاذب
	Negative	FN السلبي الكاذب	TN السلبي الحقيقي

الشكل (5) مصفوفة الإرياك.

يبين الشكل (6) مصفوفة الإرياك الخاصة بنظامنا وهي من البعد (5x5)، حيث الأصناف 1، 2، 3، 4، 5 تمثل Iron deficiency anemia، Thalassemia، Polycythemia، deficiency anemia، Normal على الترتيب. تمثل المربعات الخضراء عدد العينات التي نجحت الشبكة بتشخيصها لكل صنف مع نسبتها المئوية، بينما تمثل المربعات الحمراء عدد التشخيصات الخاطئة

قمنا باستخدام تابع التدريب Levenberg-Marquardt لتدريب الشبكة العصبونية حيث أظهر نتائج جيدة من حيث دقة التصنيف وزمن التدريب مقارنة مع توابع التدريب الأخرى التي قمنا بتجربتها. كذلك قمنا باستخدام طريقة التوقيف المبكر (Early Stopping) لتجنب حصول مشكلة التدريب المفرط (Overfitting)، وتعتمد هذه الطريقة في عملها على بيانات التدقيق حيث تقوم بإيقاف عملية التدريب في اللحظة التي يبدأ فيها منحنى تابع الخطأ المقاس على هذه البيانات بالتزايد، حيث يكون أداء الشبكة أفضل ما يمكن في هذه الحالة.

### 7- اختبار الشبكة العصبونية الاصطناعية:

بعد تدريب الشبكة العصبونية في الخطوة السابقة، يمكننا الآن اختبار كفاءة هذه الشبكة باستخدام عينات الاختبار التي تم تخصيصها من مجموعة البيانات الرئيسية. لم يتم استخدام بيانات الاختبار في التدريب بأي شكل من الأشكال، ومن ثم فهي توفر مجموعة بيانات مهمة لاختبار الشبكة. وهذا سوف يعطينا تصوراً كيف سيكون أداء الشبكة عند اختبارها مع بيانات من العالم الحقيقي.

### 8- مناقشة النتائج:

لتقييم أداء النظام المقترح سنقوم بحساب بعض المقاييس الشائعة اعتماداً على مصفوفة الإرياك (Confusion Matrix). وتظهر مصفوفة الإرياك النسب المئوية للتصنيفات (التشخيصات) الصحيحة وغير الصحيحة، وينبع اسم هذه المصفوفة من حقيقة أنها تجعل من السهل رؤية ما إذا كان النظام المصمم مرتبكاً بين التصنيفين (أي يخطئ بين أحد التصنيفين على أنه الآخر). يظهر الشكل (5) مصفوفة إرياك بالبعد (2x2). تمثل الأرقام على طول المحور الرئيس للمصفوفة القرارات الصائبة المتخذة.

يبين الجدول 2 قيم الحساسية والنوعية والدقة لكل صنف من الأصناف التي يقوم نظامنا بتمييزها. الجدول (2) قيم الحساسية والنوعية والدقة لكل صنف من الأصناف.

النوعية	الحساسية	الدقة	الصنف
100%	100%	100%	1
100%	100%	100%	2
100%	88.9%	97.3%	3
100%	90%	97.3%	4
94.7%	0%	94.7%	5
المعدل 98.94%	المعدل 75.78%	المعدل 97.86%	

ومن أجل الاستفادة القصوى من نتائج بحثنا من قبل الأطباء والكادر الطبي الممارس في المستشفيات والعيادات والمختبرات قمنا بتصميم واجهة رسومية تفاعلية GUI باستخدام برنامج الماتلاب تسهل على الطبيب الممارس استخدام نظام التشخيص الأوتوماتيكي، حيث يقوم الطبيب بإدخال بيانات فحص الدم للمريض في الحقول المخصصة لها، ثم يقوم بالنقر على زر start لتظهر نتيجة التشخيص بكل سهولة ويسر كما يوضح الشكل (7).

الشكل (7) واجهة رسومية تفاعلية GUI لنظام التشخيص

### 9-الخلاصة:

تمثل ال ANNs أداة فعالة لمساعدة الأطباء على إجراء التشخيص في الحقل الطبي. وقد أثبتت ANNs نجاعتها في تشخيص أمراض الدم حيث إن استخدامها يجعل التشخيص أكثر دقة وموثوقية، ومن ثمّ يزيد من رضى المرضى. ومع ذلك، لا بد من عدّها فقط كأداة لدعم القرار النهائي للطبيب فهو المسؤول في نهاية المطاف عن

ونسبتها . يمثل المربع الأزرق النسبة المئوية الكلية للتشخيص الصحيح.

Confusion Matrix						
Output Class	Target Class					
	1	2	3	4	5	
1	10 26.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	9 23.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	8 21.1%	0 0.0%	1 2.6%	88.9% 11.1%
4	0 0.0%	0 0.0%	0 0.0%	9 23.7%	1 2.6%	90.0% 10.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	0.0% 100%	94.7% 5.3%

الشكل (6) مصفوفة الإرباك الخاصة بنظامنا.

وفيما يأتي النسب المئوية الإجمالية للتشخيص

الصحيح وغير الصحيح:

Percentage Correct Classification : 94.7%

Percentage Incorrect Classification: 5.3%

وكما هو واضح فمن أصل 38 عينة نجحت الشبكة بتشخيص 36 عينة وفشلت في حالتين وهي نسبة مرتفعة تعبر عن دقة نظام التشخيص المقترح في بحثنا وموثوقيته. وفيما يأتي بعض المعايير الشائعة التي يمكن حسابها من مصفوفة الإرباك:

• الحساسية Sensitivity

$$Sensitivity = \frac{TP}{TP + FN} \times 100$$

• النوعية Specificity

$$Specificity = \frac{TN}{TN + FP} \times 100$$

• الدقة Accuracy

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \times 100$$

Models Predicting Prostate Cancer on Initial Extended Biopsy. *Eur Urol*, 2008; 54(3): 611. Epub 2008 Jan 15.

- [9] Kawakami S, Numao N, Okubo Y, et al. Development, Validation, and Head-to-Head Comparison of Logistic Regression-Based Nomograms and Artificial Neural Network Models Predicting Prostate Cancer on Initial Extended Biopsy. *Eur Urol*, 2008; 54(3): 601-11. Epub 2008 Jan 15.
- [10] F. K. H. Chun, M. Graefen, A. Briganti, et al. "Initial Biopsy Outcome Prediction Head-to-Head Comparison of a Logistic Regression-Based Nomogram versus Artificial Neural Network," *Eur Urol*, 2007; 51: 1236- 43.
- [11] I. Kurt, M. Ture, A. T. Kurum, "Comparing Performances of Logistic Regression, Classification and Regression Tree, and Neural Networks for Predicting Coronary Artery Disease," *Expert Systems with Applications*, vol. 34, pp. 366- 374, 2008.
- [12] M. Di Luca<sup>1</sup>, E. Grossi, B. Borroni, et al. "Artificial Neural Networks Allow the Use of Simultaneous Measurements of Alzheimer Disease Markers for Early Detection of the Disease," *J Transl Med*, vol. 3, pp. 1: 30. 2005.
- [13] H. Uğuz, A. Öztürk, R. Saraçoğlu, et al. "A Biomedical System Based on Fuzzy Discrete Hidden Markov model for the diagnosis of the brain diseases," *Expert Systems with Applications: An International Journal*, vol. 35, pp. 1104-1114, 2008.
- [14] X. Qiua, N. Taob, Y. Tana, and et al, "Constructing of the Risk Classification Model of Cervical Cancer by Artificial Neural Network," *Expert Systems with Applications: An International Journal archive*, vol. 32, pp. 1094-1099, 2007
- [15] M. Mataria, G. M. Janech, J. Almeida, et al, "Prediction of Progression of Diabetic Nephropathy in a Small Set of Patients by Artificial Neural Networks and Proteomic Analysis," *American Journal of Kidney Diseases*, vol. 51, B67-B67, 2008.
- [16] Filippo Amato, Alberto López, Eladia María Peña-Méndez, Petr Vaňhara, Aleš Hampl & Josef Havel. (2013). "Artificial neural networks in medical diagnosis". *Appl Biomed*. 11: 47–58,
- [17] <https://www.mathworks.com>

التقييم النهائي. إن هذا المشروع قابل للتطوير بشكل كبير، بحيث يمكن إضافة أمراض أخرى لنظام التشخيص الحالي، وبذلك يصبح أكثر فائدة في المستقبل.

### المصطلحات

المصطلحات باللغة العربية	المصطلحات باللغة الإنكليزية
الشبكات العصبونية الاصطناعية	Artificial Neural Network
مصفوفة الإرباك	Confusion Matrix
البيرسيترون متعدد الطبقات	Multilayer perceptron (MLP)
التدريب المفرط	Overfitting

### المراجع References

- [1] Catalogna M, Cohen E, Fishman S, Halpern Z, Nevo U & Ben-Jacob E. (2012). "Artificial neural networks based controller for glucose monitoring during clamp test". *PloS One*. 7: e44587.
- [2] Fernandez de Canete J, Gonzalez-Perez S & Ramos-Diaz JC. (2012). "Artificial neural networks for closed loop control of in silico and ad hoc type 1 diabetes". *Comput Meth Progr Biomed*. 106: 55–66.
- [3] Elveren E & Yumuşak N. (2011). "Tuberculosis disease diagnosis using artificial neural network trained with genetic algorithm". *J Med Syst*. 35: 329–332.
- [4] Er O, Temurtas F & Tanrikulu. (2008). "A Tuberculosis Disease Diagnosis Using Artificial Neural Networks". *J Med Syst*. 34: 299–302.
- [5] Dey P, Lamba A, Kumari S & Marwaha N. "Application of an artificial neural network in the prognosis of chronic myeloid leukemia". (2012). *Anal Quant Cytol Histol*. 33: 335–339.
- [6] Barbosa D, Roupar D, Ramos J, Tavares A & Lima C. (2012). "Automatic small bowel tumor diagnosis by using multi-scale wavelet-based analysis in wireless capsule endoscopy images". *Biomed Eng Online*. 11: 3.
- [7] Saghiri M, Asgar K, Boukani K, Lotfi M, Aghili H, Delvarani A, Karamifar K, Saghiri A, Mehrvarzfar P & Garcia-Godoy F. (2012). "A new approach for locating the minor apical foramen using an artificial neural network". *Int Endod J*. 45: 257–265.
- [8] W. M. Kattan, Editorial Comment on: Development, Validation, and Head-to-Head Comparison of Logistic Regression-Based Nomograms and Artificial Neural Network

Received	2019/10/30	إيداع البحث
Accepted for Publ.	2019/12/19	قبول البحث للنشر