

استخدام التعلم الآلي: الشبكات العصبونية وآلية

متجه الدعم في تقدير وضع مريض سرطان الرئة

*دفاطمة شلاف

الكلمات المفتاحية: الشبكات العصبونية، التنبؤ، النمذجة، التعلم الآلي، آلية متجه الدعم، بيانات التدريب،

المخلص

يهدف البحث إلى بناء نماذج تعلم الآلي باستخدام الشبكات العصبونية وآلية متجه الدعم SVM ومقارنة النتائج بين كلا النوعين من حيث الدقة في تقدير وتنبؤ حالة الشخص (١- مصاب ٢- مهياً ٣- سليم) للإصابة بسرطان الرئة، وكانت العوامل المستقلة هي قيم (حمض البول - البوتاسيوم - الصوديوم - الأرجنين)، حيث جمعت البيانات من مشفى البيروني في دمشق ومشفى جامعة البعث التعليمي، تم جمع البيانات عن ٨٦ شخص موزعين كما يلي: 50 مصاب من مشفى البيروني في دمشق، و ١٦ مهياً (كلهم مدخنين) من مشفى جامعة البعث و ٢٠ سليم من مشفى جامعة البعث.

في البداية تم بناء نموذج آلية متجه الدعم SVM وقسمت البيانات الى قسمين قسم التدريب 29 قيمة وقسم الاختبار ٥٧ قيمة اختيرت بشكل عشوائي من بين القيم وحسبت دقة بيانات الاختبار فكانت 100% ودقة بيانات التدريب ٨٦% ثم طبق النموذج على كل البيانات فكانت دقته 95.34% وهذا يؤكد لنا فعالية آلية متجه الدعم في الكشف عن حالة المريض بشكل مبكر. تم بناء نماذج شبكات عصبونية وتبين لنا من خلال المحاكاة أن افضل نموذج هو: NN(2,2) حيث تم تقسيم البيانات الى قسم تدريب 80% وقسم اختبار ٢٠% فكانت دقة الشبكة بالنسبة لبيانات التدريب 100% و لبيانات الاختبار ٩٤% وكانت الدقة بشكل عام 98% وبالمقارنة مع نموذج آلية متجه الدعم SVM نجد أن هناك تفوق للشبكات العصبونية في تصنيف حالة المريض وننصح في استخدامها في تشخيص هذا النوع من الأمراض

بيانات الاختبار.

*مدرس- قسم الإحصاء الرياضي- كلية العلوم -جامعة حمص.

Using Machine Learning: Neural Networks and Support Vector Machine in Estimating the Condition of Lung Cancer Patients

Fatima Shallaf*

Abstract

The aim of this research is to build machine learning models using neural networks and Support Vector Machine (SVM), and compare the results of both types in terms of accuracy in estimating and predicting a person's condition (1-affected, 2-predisposed, 3-healthy) for lung cancer. The independent variables were values of (uric acid, potassium, sodium, arginine). Data were collected from Al-Biruni Hospital in Damascus and Al-Baath University Teaching Hospital. Data was gathered from 86 individuals distributed as follows: 50 affected patients from Al-Biruni Hospital in Damascus, 16 predisposed individuals (all smokers) from Al-Baath University Hospital, and 20 healthy individuals from Al-Baath University Hospital.

Initially, an SVM model was built, and the data was divided into two parts: 29 values for training and 57 values for testing, chosen randomly. The accuracy of the test data was 100%, and the accuracy of the training data was 86%. The model was then applied to all the data, achieving an overall accuracy of 95.34%, confirming the effectiveness of the SVM in early detection of the patient's condition.

Neural network models were also built, and through simulation, it was found that the best model was: NN(2,2), where the data was split into 80% for training and 20% for testing. The network's accuracy for the training data was 100%, and for the test data, it was 94%, with an overall accuracy of 98%. In comparison with the SVM model, it was found that neural networks outperform in classifying the patient's condition, and thus, their use in diagnosing this type of disease is recommended

Keywords: Neural Networks, Prediction, Modeling, Machine Learning, Support Vector Machine (SVM), Training Data, Test Data.

*Teacher, Dept. of Mathematical Statistics, Faculty of Science, Homs University.

مقدمة (Introduction):

تُعد تقنيات التعلم الآلي اليوم جزءاً لا يتجزأ من الذكاء الاصطناعي (AI) ، وهو مجال يتطور بسرعة كبيرة ويشهد تقدماً هائلاً. لقد بدأت رحلة الذكاء الاصطناعي رسمياً في عام ١٩٤٣ عندما قدّم كلٌّ من **Walter Pitts** و **McCulloch** أول نموذج لشبكة عصبية، وهي محاولة لمحاكاة وظائف الدماغ البشري باستخدام أنظمة حسابية. ثم جاء **Alan Turing** في عام ١٩٥٠، حيث أسهم بشكل كبير في تطور هذا المجال عبر طرحه السؤال الشهير: "هل تستطيع الآلات التفكير؟"، وهو السؤال الذي فتح الباب لمزيد من الأبحاث حول إمكانية تطوير أنظمة ذكية تُحاكي القدرات البشرية. وفي عام ١٩٥٦، تم استخدام مصطلح "الذكاء الاصطناعي" لأول مرة خلال ندوة علمية عقدت في **معهد ماساتشوستس للتكنولوجيا (MIT)** ، وهي الندوة التي كانت بمثابة نقطة الانطلاق لهذا المجال الذي يشهد تقدماً متسارعاً حتى يومنا هذا.

التعلم الآلي (Machine Learning) هو أحد الفروع الرئيسية للذكاء الاصطناعي، ويُعرف بأنه القدرة على تمكين الآلات من "التعلم" من البيانات بدون الحاجة إلى برمجتها بشكل صريح لتنفيذ مهام محددة. بعبارة أخرى، يتم تدريب الآلات على فهم الأنماط واكتشاف العلاقات في البيانات لتحقيق نتائج دقيقة. ينقسم التعلم الآلي إلى نوعين رئيسيين:

١. **التعلم تحت الإشراف (Supervised Learning)** ، حيث يتم تزويد الآلة ببيانات مدخلة مصحوبة بالنتائج المطلوبة (المخرجات)، مما يمكنها من تعلم كيفية التنبؤ بالنتائج بناءً على المدخلات الجديدة.
٢. **التعلم غير الخاضع للإشراف (Unsupervised Learning)** ، حيث يتم إعطاء الآلة بيانات غير مصحوبة بالمخرجات، ويُطلب منها اكتشاف الأنماط أو العلاقات المخفية داخل البيانات.

في هذا البحث، سيتم الاعتماد على أهم طرق التعلم الآلي، وهما: **الشبكات العصبية (Neural Networks)** و **آلية دعم المتجهات (Support Vector Machine – SVM)**

استخدام التعلم الآلي: الشبكات العصبونية وآلية متجه الدعم في تقدير وضع مريض سرطان الرئة

سنستعرض في هذا البحث شرحاً تفصيلياً لكل من هاتين الطريقتين، موضحين كيفية عملهما ودورهما في تقدير وتنبؤ حالة مرضى سرطان الرئة بناءً على البيانات الطبية المتاحة.

مشكلة البحث:

إن الكثير من الأمراض لا يتم اكتشافها إلا في وقت متأخر وخاصة أمراض السرطان ومنها سرطان الرئة، وهذا يتسبب في فقدان الكثير من البشر لحياتهم رغم أنه كان بالإمكان انقاذهم من الموت.

أهمية البحث:

يعتبر اكتشاف مرض سرطان الرئة في مرحلة مبكرة من خلال تصنيف المريض كمهياً للمرض مهماً جداً من أجل البدء بالعلاج قبل تطور المرض، ومن هنا تأتي أهمية البحث في استخدام الذكاء الاصطناعي والتعلم الآلي في محاولة الكشف عن المهيئين للمرض قبل فترة زمنية من استفحال المرض.

الهدف من البحث:

- ١- إيجاد فلتر ذكي لتصنيف المرضى لثلاث مجموعات (مصاب، سليم، مهياً) وذلك بطريقتي الشبكات العصبونية، وآلية متجه الدعم.
- ٢- المقارنة بين طريقتي الشبكات العصبونية وآلية متجه الدعم، من حيث الدقة في التصنيف.
- ٣- إضافة طرق إحصائية ذكية لتشخيص سرطان الرئة في سوريا مما يكشف المرض مبكراً وبالتالي معالجته قبل تأزم وضع المريض.

١- خوارزمية آلية متجه الدعم (Support Vector Machine): [3][2][4]

إن خوارزمية آلية متجه الدعم (Support Vector Machine) والتي قد تختصر

الى (أخصهراً) (SVM) من الطرائق الإحصائية التي تنتمي الى الذكاء الاصطناعي،

حيث قُدمت لأول مرة من قبل العالم Vladimir Vapnik عام ١٩٩٢، وهي عبارة عن خوارزمية تعلم عن طريق مشرف أو موجّه ، تُستعمل للتصنيف مُستندة إلى نظرية التعلم

(Statistical Learning Theory).

تستخدم هذه التقنية مجموعة (جزء من البيانات) للتدريب تسمى بمتجهات الدعم (Support Vector) لتمثيل حد القرار (Decision Boundary) من خلال البحث عن أكبر هامش تبتعد عنه البيانات من الطرفين، وهو مستو فائق ذو هامش أعظمية (Maximum Margin Hyperplane). [5]


ولتكن $X = (X_1, X_2, \dots, X_p)^T$ مجموعة من المتغيرات لبيانات تصنيف ثنائية ويراد تصنيفها في مجموعتين G_1, G_2 ، وبأخذ مجموعة تدريب $x_1, x_2, \dots, x_n$ ولها نفس المتغيرات p ، الهدف هو العثور على مستو يصنف بيانات التدريب إلى مجموعتين G_1, G_2 ، فإذا لوحظ أن النقطة x_i تنتمي إلى المجموعة G_1 نضع $y_i = 1$ وإذا كانت تنتمي للمجموعة G_2 وضعنا $y_i = -1$ ، يمكننا تمثيل n من بيانات التدريب على النحو التالي:

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n); y_i = \begin{cases} 1 & \text{if } x_i \in G_1 \\ -1 & \text{if } x_i \in G_2 \end{cases} \quad (1)$$

وسنعرض فيما يلي آلية متجه الدعم في حالة البيانات قابلة للفصل خطياً وغير القابلة للفصل خطياً.

أولاً: آلية متجه الدعم في حالة بيانات قابلة للفصل خطياً Linear Separable

[3][6][4]: SVM



الشكل (١) بيانات قابلة للفصل خطياً

نرسم مستقيمين متوازيين H_+ , H_- من خلال نقاط الحافة لكل مجموعة، نرسم حد القرار H وهو منتصف المسافة بين المستقيمين المرسومين عند نقاط الحافة وموازيًا لهما، يمكن ملاحظة وجود أكثر من مستو لفصل البيانات إلا أننا نبحث عن المستو الذي تبتعد أو تقع عليه متجهات الدعم، بحيث يجب أن يكون أبعد ما يمكن عن نقاط المجموعتين.

تُصنف بيانات التدريب في مجموعتين G_1 , G_2 بالشكل التالي:

$$\begin{aligned} x_i \in G_1 &\Leftrightarrow w^T x_i + b \geq 1 \quad (2) \\ x_i \in G_2 &\Leftrightarrow w^T x_i + b \leq -1 \end{aligned}$$

حيث: w الأوزان، b الانحياز.

وتعطى المسافة بين بيانات التدريب وحد القرار بالشكل التالي:

$$d = \frac{|w^T x + b|}{\|w\|} ; \quad \|w\| = \sqrt{w_1^2 + w_2^2 + \dots + w_p^2} \quad (3)$$

بمعنى أن المستقيم الأول H_+ هو $w^T x_i + b = 1$

والمستقيم الثاني H_- هو $w^T x_i + b = -1$

وبالتالي يكون حد القرار H هو: $w^T x_i + b = 0$

من أجل إيجاد الهامش بين المستقيمين H_+ و H_- نقوم بحساب الفرق بين المستقيمين

(إيجاد المسافة) أي إيجاد المسافة بين نقطة من كل حافة $w^T x_1 + b = 1$

$$w^T x_2 + b = -1$$

وبحساب الفرق نحصل على:

$$wx_1 - wx_2 = 2 \Rightarrow w(x_1 - x_2) = 2$$

وبعدها نحصل على:

$$\frac{w}{\|w\|}(x_1 - x_2) = \frac{2}{\|w\|}$$

وذلك للوصول على الهامش الذي يكون عمودي على المستقيمات الثلاث وبالتالي تكون المسافة هي $\frac{2}{\|w\|}$ والتي يجب أن تكون أكبر ما يمكن وعلينا الوصول إلى القيمة العظمى لها أو إيجاد القيمي الصغرى لـ $\frac{\|w\|^2}{2}$ كما يلي:

• **تعلّم آلية متجه الدعم:** [4] [7] [8] [9]

تهدف عملية التعلم الوصول لأكبر هامش تباعد عنه البيانات من الطرفين، والتي تؤول إلى مسألة برمجة غير خطية مقيدة متمثلة بدالة الهدف:

$$f(w) = \min_w \frac{\|w\|^2}{2}$$

$$\text{Subject to } y_i(w^T x_i + b) \geq 1 \quad ; \quad i = 1, 2, \dots, N$$

تحل هذه المسألة باستخدام طريقة مضارب لاغرانج، وهي طريقة لإيجاد قيم النهايات الحدية المحلية لدالة لعدة متحولات خاضعة لواحد أو أكثر من القيود، بشكل دالة لاغرانج من أجل مسألة الأمثلية:

$$L(w, b, \lambda_1, \lambda_2, \dots, \lambda_n) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \lambda_i (y_i (w^T x_i + b) - 1) \quad (5)$$

حيث λ_i هي مضارب لاغرانج.

نشق دالة لاغرانج اشتقاق جزئي بالنسبة لـ w, b وذلك لإيجاد الحد الأدنى لها ومن ثم نعطي هذه المشتقات الجزئية القيمة صفر، كما يلي:

$$\frac{\partial L(w, b, \lambda_1, \lambda_2, \dots, \lambda_n)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^n \lambda_i y_i x_i$$

$$\frac{\partial L(w, b, \lambda_1, \lambda_2, \dots, \lambda_n)}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \lambda_i y_i = 0$$

نعوض في العلاقة (5) فنجد:

$$L_D(\lambda_1, \lambda_2, \dots, \lambda_n) = \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j \quad (6)$$

وبالتالي نكون قد حصلنا على مسألة مزدوجة بين w و λ_i ، تابع الهدف للمسألة المزدوجة يحتاج لإيجاد الحد الأعظمي:


$$\begin{aligned} \text{Max } L_D(\lambda_1, \lambda_2, \dots, \lambda_n) &= \max \left\{ \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j \right\} \\ \text{Subject to } \lambda_i &\geq 0 \quad ; i = 1, 2, \dots, n \\ \sum_{i=1}^n \lambda_i y_i &= 0 \end{aligned} \quad (7)$$

وهي مسألة برمجة تربيعية (Quadratic Programming (QP)) بحلها نحصل على:

$$\begin{aligned} \hat{b} &= -\frac{1}{2}(\hat{w}^T x_+ + \hat{w}^T x_-) \text{ والانهياز } \hat{w} = \sum_{i=1}^n \hat{\lambda}_i y_i x_i \\ \hat{w}^T x + \hat{b} &= \sum_{i=1}^n \hat{\lambda}_i y_i x_i^T x + \hat{b} = 0 \text{ وحده قرار مع هوامش أعظمية} \\ \text{وفقاً لذلك فإن قاعدة التصنيف للمجموعتين } G_1, G_2 &\text{ تكون كالتالي:} \\ \hat{w}^T x + \hat{b} &= \sum_{i=1}^n y_i \hat{\lambda}_i x_i^T + \hat{b} = \begin{cases} \geq 0 \Rightarrow G_1 \\ < 0 \Rightarrow G_2 \end{cases} \end{aligned} \quad (8)$$

ثانياً: آلية متجه الدعم في حالة البيانات غير القابلة للفصل خطياً (Nonlinearly Separable SVM) [3][6]:

تستخدم آلية متجه الدعم في هذه الحالة الهامش اللين (Soft Margin) الذي يسمح لحد القرار بأن يحتل أخطاء صغيرة في بيانات التدريب كونها غير قابلة للفصل خطياً، وبالتالي يعمل الهامش اللين على حل هذه المشكلة من خلال المقايضة (Trade-Off) بين عرض الهامش وعدد أخطاء التدريب التي يرتكبها حد القرار من خلال تخفيض القيود الخطية بإدخال متحولات صورية غير سالبة ($\xi_i \geq 0$) .



الشكل (٢) بيانات غير قابلة للفصل خطياً

لتصبح القيود كمايلي:

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad ; i = 1, 2, \dots, n \quad (9)$$

$$\xi_i = \max \left\{ 0, d - \frac{y_i(w^T x_i + b)}{\|w\|} \right\} \quad \text{حيث:}$$

• تعلّم آلية متجه الدعم: [6][3][8]

لتجنب خوارزمية التعلّم تكبير هامش حد القرار الذي يؤدي للوقوع في أخطاء تصنيف الكثير من أمثلة التدريب، يتم تعديل حد القرار من خلال إعطاء قيم كبيرة لمتحولاته الصورية لتصبح مسألة البرمجة الخطية بالشكل:

$$f(x) = \min_{w, \xi} \left\{ \frac{\|w\|^2}{2} + \alpha \sum_{i=1}^n \xi_i \right\} \quad (10)$$

$$\text{Subject to} \quad y_i(w^T x_i + b) \geq 1 - \xi_i \quad ; \xi_i \geq 0, i = 1, 2, \dots, n$$

حيث: $\alpha > 0$ تتحكم في المقايضة بين عرض الهامش والقيود.

نشكل دالة لاغرانج لمسألة الأمثلية المقيدة السابقة:

$$L(w, b, \xi, \lambda, \beta) = \frac{1}{2} \|w\|^2 + \alpha \sum_{i=1}^n \xi_i - \sum_{i=1}^n \lambda_i (y_i(w^T x_i + b) - 1 + \xi_i) - \sum_{i=1}^n \beta_i \xi_i \quad (11)$$

حيث: λ_i, β_i هي مضارب لاغرانج.

باشتقاق دالة لاغرانج:

$$\frac{\partial L(w, b, \xi, \lambda, \beta)}{\partial w} = w - \sum_{i=1}^n \lambda_i y_i x_i = 0 \quad (12)$$

$$\frac{\partial L(w, b, \xi, \lambda, \beta)}{\partial b} = - \sum_{i=1}^n \lambda_i y_i = 0 \quad (13)$$

$$\frac{\partial L(w, b, \xi, \lambda, \beta)}{\partial \xi_i} = \alpha - \lambda_i - \beta_i = 0 ; i = 1, 2, \dots, n \quad (14)$$

نعوض في العلاقة (11) فنحصل على:

$$L_D(\lambda_1, \lambda_2, \dots, \lambda_n) = \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j \quad (15)$$

من خلال العلاقة (15) نكون قد حصلنا على مسألة مزدوجة تابع الهدف لها

بالشكل:

$$\text{Max } L_D(\lambda_1, \lambda_2, \dots, \lambda_n) = \text{Max} \left\{ \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j \right\}$$

$$\text{Subject to } \sum_{i=1}^n \lambda_i y_i = 0, 0 \leq \lambda_i \leq \alpha ; i = 1, 2, \dots, n \quad (16)$$

نلاحظ تطابق الدالتي لاغرانج في حالتي البيانات القابلة للفصل خطياً وغير

القابلة للفصل خطياً.

أما القيود على دالة لاغرانج في الحالتين مختلفة: ففي حالة البيانات القابلة

للفصل خطياً كانت $\lambda_i \geq 0$ أما في حالة البيانات غير القابلة للفصل خطياً فإن λ_i يجب

أن تحقق $0 \leq \lambda_i \leq \alpha$.

وبحل مسألة البرمجة التربيعية (16) نحصل على:

$$\hat{w} = \sum_{i=1}^n \hat{\lambda}_i y_i x_i \text{ والانحياز } \hat{b} = -\frac{1}{2}(\hat{w}^T x_+ + \hat{w}^T x_-)$$

$$\hat{w}^T x + \hat{b} = \sum_{i=1}^n \hat{\lambda}_i y_i x_i^T x + \hat{b} = 0 \text{ الأمثلين وحد قرار بهوامش أعظمية}$$

وفقاً لذلك فإن قاعدة التصنيف للمجموعتين G_1, G_2 تكون كالتالي:

$$\hat{w}^T x + \hat{b} = \sum_{i=1}^n y_i \hat{\lambda}_i x_i^T + \hat{b} = \begin{cases} \geq 0 \Rightarrow G_1 \\ < 0 \Rightarrow G_2 \end{cases} \quad (18)$$

٢- الشبكات العصبونية الاصطناعية Artificial Neural Networks [9]:

[10] [11] [12]

٢-١- مقدمة:


إن الشبكات العصبونية الاصطناعية هي محاكاة للطريقة التي يعمل بها الجهاز العصبي عند الانسان حيث وجد العلماء قابلية التعلم والتذكر والقدرة على التمييز واتخاذ القرارات، ومكونات الشبكة العصبونية الاصطناعية عبارة عن مجموعة من المعالجات التي تدعى بالعصبونات تمر الإشارات بين العصبونات عبر خطوط ربط ويفرق كل خط ربط بوزن معين (قيمة عددية) والذي يضرب مع الإشارات الداخلة إلى العصبون، ويطبق على كل عصبون تابع تفعيل ليحدد إشارة الخرج الناجمة عنه.

وبالتالي ستكون الشبكة العصبونية الاصطناعية مؤلفة من الأقسام التالية [13]:

١- طبقة الدخل input layer : هي طبقة الخلايا التي تستقبل إشارات الدخل من الوسط الخارجي


٢- طبقة الخرج output layer : هي طبقة الخلايا التي تعطي إشارات الخرج إلى الوسط الخارجي.

٣- الطبقة المخفية hidden layer : هي طبقة (طبقات) الخلايا التي تقع بين طبقتي الدخل والخرج وتقوم بعملية المعالجة، علما أنها تكون غير موجودة في الشبكة العصبونية البسيطة التي تكون مؤلفة من طبقة فقط (المدخلات وطبقة الخرج) كما في الشكل التالي



الشكل (3) شبكة عصبونية بسيطة وحيدة الطبقة.

أما في الشبكات العصبونية متعددة الطبقات يكون هناك طبقة مخفية واحدة أو أكثر من طبقة مخفية كما في الشكل التالي:



الشكل (4) شبكة عصبونية متعددة الطبقات.

وتدفق البيانات ضمن الشبكة العصبونية من طبقة الدخل الى الطبقات المخفية ثم طبقة الخرج وأن الشبكة العصبونية لا يمكن أن تتلقى من الخارج الا عن طريق هذه الطبقة (طبقة الدخل).

والجدير بالذكر أن الشبكة العصبونية يمكن أن تستوعب بيانات من عدد متغيرات أقل من عدد عصبونات الدخل بحيث نضع قيمة الصفر لعصبونات الدخل الإضافية وفي الحالة المعاكسة لا يمكن للشبكة العصبونية تلقي بيانات من عدد متغيرات أكبر من عدد عصبونات طبقة الدخل.

ويتم تحديد عدد المداخل وعدد عصبونات طبقة الخرج من المعطيات التي يتم تحليلها لذلك إذا كان ضمن المعطيات خمسة متغيرات لاستخدامها كمدخلات، ستبنى الشبكة العصبونية بخمسة مداخل، وبالمثل إذا كان هناك ثلاث متغيرات يجب دراستها كخرج للشبكة العصبونية تبنى الشبكة العصبونية بثلاث عصبونات في طبقة الخرج.

أما عدد عصبونات الطبقة المخفية لا يمكن تحديدها بسهولة حيث تُبنى بالتجريب، فلو كان عدد عصبونات الطبقة المخفية قليلاً فإن الشبكة العصبونية لن تتعلم، وإن كان عدد عصبونات الطبقة المخفية كبيراً عندها ببساطة تميل الشبكة للحفظ، لذلك يتم تحديد عدد عصبونات الطبقة المخفية بين القلة التي تجعل الشبكة تتعلم وبين الكثرة التي تجعل الشبكة لا تحفظ معطيات الدخل.

(نبدأ ببناء الشبكة بعدد كبير نسبياً من عصبونات الطبقة المخفية وندرّب الشبكة، هنا نعلم أن الشبكة تميل للحفظ وندرب الشبكة وثم نبدأ بتقليل عدد العصبونات بالتدريج إلى أن نحصل على أفضل النتائج مع الحفاظ على تدريب الشبكة العصبونية).


٢-٢ - أنواع الشبكات العصبونية حسب نوع التدريب: [9][10][11]

حيث تعتبر عملية التدريب الأساس بالنسبة للشبكات العصبونية، لأنها عبارة عن عملية تستطيع الشبكة العصبونية من خلالها أن تتكيف مع مدخلات محددة من أجل الحصول على استجابات مطلوبة ويمكن تصنيف أساليب التدريب المختلفة للشبكات العصبونية إلى:

التدريب تحت الإشراف (المراقب) : Supervised Training

في التعليم المراقب (تحت الإشراف) تعطى مجموعة من بيانات التدريب المكونة من أزواج من (دخل - خرج) أي أن التدريب تحت الإشراف يحتاج إلى معلم أو مشرف يتمثل بشعاع الهدف ويتم التنبؤ بالخرج لدخل جديد وبعد إدخال معطيات التدريب تعالج الشبكة المدخلات وتقارن النتائج مع النتائج المرغوبة (الخرج المرغوب) وتحسب الخطأ (الفرق بين الخرج الحالي الذي تم الحصول عليه

من المدخلات وفق خوارزمية التدريب والخرج المرغوب) وتعاد (تتشر - تبث) الأخطاء من خلال الشبكة مما يؤدي لتحديث الأوزان التي تتحكم بالشبكة، تحدث هذه العملية عدة مرات طالما أن الأوزان تتعدل.



الشكل (5) طريقة التدريب بمعلم

التدريب غير المشرف عليه (غير المراقب) :Unsupervised Training:

[9][10][14][15][16]

التدريب بدون اشراف (بدون مراقبة)

لا تحتاج الشبكات التي تستخدم هذا الأسلوب من التدريب إلى معلم أي إلى شعاع الهدف (المخرجات المرغوبة) فهي قادرة على التعلم والتصنيف للمدخلات المقدمة لها بشكل ذاتي أي تقدم المدخلات للشبكة بدون المخرجات المرغوبة، فهي نوع من أنواع شبكات التنظيم الذاتي، حيث تبني الشبكة العصبونية الاصطناعية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبع في أسلوب التعليم بواسطة معلم، ويوجد عدة أنواع للشبكات ذات خوارزميات التعلم بدون مشرف نذكر منها:

١- شبكة الخريطة ذاتية التنظيم self_Organizing Mapping: أو شبكة

Kohonen وهي نوع من شبكات التعلم التنافسي غير المشرف عليه وسميت بهذه التسمية بسبب التنافس بين العقد لتصبح نشطة وتدعى العقدة الرابحة حيث تقوم بإجراء تعديل على شعاع الوزن، وتنقل جزء من التعلم للعقد المجاورة لها. [14][15]

٢- الغاز العصبوني Neural Gas: تستخدم أيضاً في التدريب التنافسي وتطبق في مجالات التنبؤ، وتعتبر أكثر فعالية من شبكة الخريطة ذاتية التنظيم في مهام تنقيب المعطيات، حيث تقوم باكتشاف الطبوغرافية بنفسها وتعمل على إيجاد أفضل تمثيل لهيكلي المعطيات وإعطاء أفضل نتائج للتنقيب. [14][15]

٣- الغاز العصبوني المتنامي Growing Neural Gas: يشبه العقدة التي تقوم على تجميع المعطيات (البيانات) في فضاء R^2 في عدد محدد مسبقاً من العناقيد حيث أن كل النقاط الموجودة في العناقيد حيث أن كل النقاط الموجودة ضمن العنقود متقاربة بالخواص فيما بينها أكثر من النقاط الموجودة في العناقيد الأخرى أما في الغاز العصبوني المتنامي يتم توزيع المدخلات ضمن R^n ويشكل بشكل متزايد شبكة من العقد حيث تمثل كل عقدة من الشبكة بنقطة من R^n ، وفي حال تغير المدخلات فإن الغاز العصبوني قادر على تحريك العقد لتغطي التوزيع الجديد للدخل، أي لا يتم تحديد عدد العقد ولكنه يتم زيادتها بشكل متنامي أثناء التنفيذ ويم إيقاف إدراج العقد الجديدة عند قيام المستخدم بتعريف تابع الأداء أو في حال الوصول الى الحد الأقصى لحجم الشبكة، وهكذا يكون لكل عقدة ثلاث عناصر هي الأوزان المعرفة على R^n ، والخطأ المتراكم، ومجموعة الحواف التي تعرف جيران العقدة. [14]

٢-٣- أنواع الشبكات حسب البنية: [13]

١- الشبكات العصبونية بتغذية أمامية feedforward networks

٢- الشبكات العصبونية العكسية Recurrent Neural Networks

الشبكات العصبونية بتغذية أمامية feed forward networks [13]

تنتشر هنا المدخلات من وحدات الدخل الى الطبقات المخفية طبقة الخرج عن طريق وصلات مقترنة بأوزان كما يلي:

المدخلات inputs: تستقبل الاشارات الواردة من المحيط الخارجي وتمثل بالشعاع $(x_1, x_2, \dots, x_n)$ حيث يتم نقلها إلى جسم الخلية بنسب مختلفة.

الأوزان weights: قيم عددية قابلة للزيادة والنقصان وفق معادلات رياضية محددة ويرمز لها بـ $(w_1, w_2, \dots, w_n)$ ، حيث يتم اعطائها قيم ابتدائية في الخطوة الأولى للتدريب ثم يتم تعديل هذه القيم حتى الوصول الى أصغر قيمة ممكنة للخطأ الذي يتمثل بالفرق بين الخرج الفعلي للشبكة العصبونية والخرج المرغوب.

تابع التجميع summation function: يقوم بجمع المدخلات الموزونة weighted function وفق العلاقة:


$$yin = \sum_{i=1}^{i=n} w_i x_i = w_1 x_1 + w_2 x_2 + \dots + w_n x_n \quad (19)$$

تابع التنشيط (activation function): يقوم بتحويل حاصل جمع المدخلات الموزونة إلى إشارة رياضية محددة حسب طبيعة المشكلة لينتج الخرج النهائي للخلية العصبية كما يلي:

$$yin = \sum_{i=1}^n w_i x_i$$

فيكون خرج الشبكة العصبونية بتطبيق تابع التنشيط على **yin** كما في العلاقة التالية:

$$output = f(yin) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (20)$$



الشكل (6) الشكل التفصيلي للشبكة العصبونية بتابع التجميع والتفعيل.

أنواع تابع التفعيل:

١. تابع التفعيل الخطي
٢. تابع الخطوة الثنائي (ذو عتبة θ)
٣. تابع الإشارة (ذو عتبة θ)
٤. تابع سيغمويد (Sigmoid)
٥. تابع سيغمويد الثنائي (Sigmoid)

٣- التطبيق العملي:

تم قياس المشعرات الأربعة وهي الأرجنين وحمض البول واليوتاسيوم والصوديوم وجمعت البيانات عن ٨٦ شخص موزعين كمايلي: 50 مصاب، ١٦ مهياً (كلهم مدخنين)، ٢٠ سليم.

أولاً: تطبيق آلية متجه الدعم:

حيث تم بناء نموذج التعلم الآلي SVM وقسمت البيانات الى قسمين قسم التدريب 29 قيمة كما يلي:

الجدول (1) بيانات التدريب لآلية متجه الدعم

رقم المريض	Y	Uricacid	Na	K	Arginine
3	1	11	145.3	3.69	12.6
6	1	4.4	136.7	5.22	29.7
14	1	6.4	133.3	3.57	21
16	1	1.8	134.3	3.58	11.9
19	1	3.8	139.9	4.29	14.8
20	1	5.4	138.7	4.45	24.5
25	1	2.8	144.5	4.32	9.1
26	1	4.4	138.6	3.94	13.6
28	1	4.8	136.7	4.44	23.7
30	1	5	142.1	5.05	22.9
43	1	2.9	144	4.64	12.4
45	1	5.1	138.2	4.5	18
49	1	3.7	142	4.93	16.3
51	2	4.1	138	4.2	20.4
52	2	3.8	136.2	4.4	55.1
55	2	5.1	152	4.3	47.9
57	2	3.3	150.1	5.3	29.7
58	2	5.2	139	4.1	31.4
59	2	4.1	148.2	5.1	28.2
60	2	3.3	136	4.8	33.1
61	2	5.8	145.4	4.1	21
62	2	4.1	132.7	3.9	44.7
63	2	6	139	4.6	27.5
65	2	2.9	142.5	4.8	37.1
66	2	3.8	137.6	4.6	21.9
67	3	5.4	137.1	4.81	68.3
77	3	3.1	136.6	5	82.9
82	3	4.8	139.1	3.64	76.8
86	3	3.7	142.2	3.84	84

أما بيانات الاختبار فكانت 57 قيمة بالشكل التالي:

الجدول (2) بيانات الاختبار لآلية متجه الدعم

رقم المريض	y	Uricacid	Na	K	Arginine
1	1	3.6	127.5	4.85	1.2
2	1	3.2	137.9	4.18	9.3
4	1	4	142.5	4.18	5.7
5	1	5.4	136.5	4.46	11.5
7	1	6.3	137.6	4.08	1
8	1	4.4	139.2	4.15	1.3
9	1	4.6	139.6	4.09	9.7
10	1	5.3	132.8	4.9	4.3
11	1	3.7	132.8	4.93	5.9
12	1	5.6	140.7	4.78	16.8
13	1	2.1	136.9	3.96	9.1
15	1	4	134.5	3.74	9.7
17	1	3.8	140.2	5.38	4.2
18	1	4.7	135.3	4.72	17.4
21	1	6.1	139.3	6.37	27.4
22	1	6.2	138.6	6.65	9.7
23	1	4	137.5	5.36	2.7
24	1	4.9	134.4	7.7	8
27	1	3.3	138	4.25	2
29	1	3	139.4	4.4	3.9
31	1	3	139.6	5.03	14.2
32	1	3.7	133.2	5.3	3.7
33	1	4.1	134.6	4.34	17.4
34	1	4.3	132.4	5.13	14.1
35	1	3.1	133.1	4.9	9.1
36	1	4.2	132.8	4.22	12
37	1	5	131	5.1	14.6
38	1	3.4	134.7	4.36	8.6
39	1	2.7	140.1	4.82	7
40	1	5.3	139.2	5.1	10.5
41	1	5	135.6	5	11.3
42	1	3.6	132.2	5.22	16
44	1	6	132.6	5.12	9.3

استخدام التعلم الآلي: الشبكات العصبونية وآلية متجه الدعم في تقدير وضع مريض سرطان الرئة

46	1	6.1	142.1	4.92	13.3
47	1	2.6	139.1	5.02	10.1
48	1	4.8	134.2	5.44	20
50	1	2.8	140.1	5.13	9.1
53	2	3.4	142.7	4.3	50
54	2	4.6	151	4.7	27.6
56	2	4.6	148.6	4.8	32
64	2	5.2	156	5.2	28
68	3	6.9	139.5	3.9	75
69	3	3.4	140.1	5.02	102.1
70	3	3.9	143	3.99	88
71	3	5.1	142.2	4.16	113
72	3	4.2	144.1	4.08	90.6
73	3	6.5	141	4.9	103
74	3	5	138.1	3.78	84.2
75	3	3.9	140.2	3.6	110
76	3	4.6	139	4.25	130.5
78	3	5.3	144.7	4.82	98
79	3	4	139.5	3.84	114.7
80	3	2.8	142.6	4.16	132
81	3	4.1	143	4.55	94.7
83	3	5.1	143.7	5.08	108.2
84	3	6.2	140	4.76	120.5
85	3	4.2	138.2	4.46	116

بلغت دقة التنبؤ في بيانات الاختبار الى ١٠٠ % وهو شرط أساسي ليكون النموذج قابل

للتطبيق بينما كانت دقة بيانات التدريب ٨٦,٢١ % وبعد تطبيق النموذج على كل

البيانات كانت الدقة ٩٥,٣٥ %

وكانت نتائج بيانات التدريب كما في الجداول التالي:

نسبة الخطأ	3	2	1	y
0	0	0	13	١
4/29	0	8	4	٢
0	4	0	0	٣
0.137931	نسبة الخطأ الكلي			

وكانت نتائج بيانات الاختبار:

نسبة الخطأ	3	2	1	y
0	0	0	٣٧	١
0	0	٤	٠	٢
0	١٦	0	0	٣
0	نسبة الخطأ الكلي			


والنتائج النهائية لكل البيانات:

نسبة الخطأ	3	2	1	y
0	0	0	٥٠	١
4/86	0	١٢	4	٢
0	٢٠	0	0	٣
0.046512	نسبة الخطأ الكلي			

وهذا يؤكد فعالية آلية متجه الدعم في الكشف عن حالة المريض بشكل مبكر.

ثانياً: تطبيق الشبكات العصبونية:

تم بناء نماذج شبكات عصبونية وتبين لنا من خلال المحاكاة أن افضل نموذج هو: NN(2,2) حيث تم تقسيم البيانات الى قسم تدريب 80% وقسم اختبار 20% وبنفس أسلوب الدراسة في آلية متجه الدعم كانت دقة الشبكة بالنسبة لبيانات التدريب 100% وليبيانات الاختبار 94% وكانت الدقة بشكل عام 98% ويمكن تمثيل الشبكة بالشكل التالي:



الشكل (7) هيكل الشبكة العصبونية المدربة على البيانات

وبالمقارنة مع نموذج آلية متجه الدعم SVM نجد أن هناك تفوق للشبكات العصبونية في تصنيف حالة المريض وننصح في استخدامها في تشخيص هذا النوع من الأمراض.

النتائج:

١- حصلنا على دقة تنبؤ تصنيف سرطان الرئة باستخدام آلية متجه الدعم بلغت

96%

٢- حصلنا على دقة في تصنيف سرطان الرئة باستخدام الشبكات العصبونية باغت

(بلغت) ٩٨%

٣- تفوقت الشبكات العصبونية على طريقة متجه الدعم في تصنيف حالات مرض
سرطان الرئة

التوصيات:

١- استخدام طرق التعلم الآلي مثل الشبكات ومتجه الدعم في الكشف عن أمراض
أخرى

٢- استخدام طرق العقدة والانحدار اللوجستي واللوجستي الضبابي في الكشف عن
الامراض.

المراجع:

[1]Mohammed Mohssen, Bashier Eihab Bashier,(2017),_ **Machine Learning: Algorithms and Applications**_ by Taylor & Francis Group, LLC

[2] Suicheng Gu, YingTan , XinguiHe (2010),_ **Discriminant analysis via support vectors.**, Elsevier.

[٣] SADANORI K., -**Introduction to Multivariate Analysis**. Chuo University, Tokyo, Japan, 299.

[4] حباق هبة، 2018 _ مقارنة بين تحليل التمايز الخطي لفisher /Fisher-LDA/

وآلية متجه الدعم /SVM/ للتصنيف الثنائي بين بيانات زيت الذرة وزيت دوار

الشمس _ جامعة حلب، سوريا، ١٢٥

[5] أبوزلام أحمد، ٢٠١٣-دراسة بعض طرائق الشبكات العصبية وآلة متجه الدعم والطرائق الإحصائية في مسائل التصنيف لدعم القرار الطبي. جامعة حلب، سوريا، ٩٨.

[6] GARETH J., DANIELA W., TREVOR H., ROBERT T., -An Introduction to Statistical Learning with Applications in R. New York Heidelberg Dordrecht London, 426.

[7] خانطوماني آية، ٢٠١٧-مقارنة التصنيف المتعدد باستخدام طريقة المركبات الأساسية (PCA) وطريقة تحليل التمايز الخطي لفيشر (Fisher-LDA). جامعة حلب، سوريا، ١٤٩.

[8] YIZENG L., QING-SONG X., HONG-DONG L., DONG-SHENG C., 2011- Support Vector Machines and Their Application in Chemistry and Biotechnology. United State of America, 194.

[9]- Michael Negnevitsky, 2005- Artificial Intelligence A Guide to Intelligent Systems- 2^{ed} Edition. Addison-Wesley p435 .

[10] Zurada M. Jacek (1995) , "Introduction to Artificial Neural Systems" , PWS.

[11]-Ben Coppin,2004-Artificial Intelligence Illuminated- Jones And Bartlett Publishers

[12] شلاف فاطمة، 2019 _ معالجة المعطيات المفقودة والشاذة من خلال تطوير خوارزمية شبكة ذكاء صناعي متقدمة _ جامعة حلب، سوريا، رسالة دكتوراه.

[13] Sivanandam S N, Sumathi S, Deepa S N.,2006-introduction to Neural Networks Using Matlab 6.0-Tata Mcgraw_Hill Publishing Company Limited New Delhi.p549.

[14]M.Guthikonda S.,2005,Kohonen Self-Organizing Maps, Wittenberg University.

[15]Mehotra K & Mohan K & Ranka S.,1997, ELEMENTS OF ARTIFICIAL NEURAL NETWORKS. MIT Press .

[16]J. Holmström ., 2002-Growing Neural Gas Experiments with GNG, GNG with Utility and Supervised GNG. Uppsala University Department of Information Technology Computer Systems