

استخدام شبكة المدرك اعتمادا على الانحدار الذاتي لتصنيف بيانات التبخر

Using Perceptron Network based on Autoregressive to Classify Evaporation Data

م. م. نعم سالم فاضل

Naam Salem Fadhil

naamsalem@uomosul.edu.iq

جامعة الموصل، كلية علوم الحاسوب والرياضيات، قسم الاحصاء والمعلوماتية، العراق، الموصل

الكلمات المفتاحية: التبخر، شبكة المدرك، الانحدار الذاتي، التصنيف.

المستخلص

تعد دراسة الظروف المناخية وتقلبات الغلاف الجوي وتأثيراتها مهمة جداً لتشخيص السمات البيئية والمناخية وتأثيرها على مختلف المجالات المتعلقة بحياة الإنسان والكائنات الحية الأخرى. في هذه الدراسة، سيتم دراسة متغير سلسلة كميات التبخر Evaporation الزمنية وتصنيفه باستخدام العديد من المؤثرات الجوية كالسلسلة الزمنية لدرجات حرارة الهواء Air Temperature في الحالتين العظمى والصغرى وكذلك السلاسل الزمنية للرطوبة النسبية Related Humidity في الحالتين العظمى والصغرى وتعد تأثيرات مباشرة مستعرضة على السلسلة الزمنية للتبخر اعتمادا على مبدأ الانحدار بين متغيرات الادخال والمتغير المعتمد. ان السلاسل الزمنية تتميز باعتمادها على مبدأ الانحدار الذاتي Autoregressive (AR) والذي يولد قوة دافعة كتأثيرات طولية زمنية تساعد على اجراء تصنيفات لفترات زمنية مستقبلية خارج عينات الدراسة ولكنها تتعارض مع طبيعة البيانات المناخية غير الخطية مما قد يتسبب في حالة اللايقين Uncertainty. تعد الشبكات العصبية من الاساليب التي تتعامل جيدا مع حالة عدم خطية البيانات وتعد شبكة المدرك العصبية Perceptron Neural Network (PNN) احدى اقدم الشبكات العصبية التي تعتمد اساسا في تصنيف البيانات عموما والسلاسل الزمنية خصوصا بهيكلية بعيدة عن التعقيد واختصارا للجهد والوقت. تم استخدام أكثر من نوع من دوال التعلم Learning Function بعد اختيار دالة التحويل المناسبة لطبيعة بيانات الدراسة. ان انواع الدوال المستخدمة في شبكة المدرك بالإضافة الى هيكليتها تعتمد أساساً على مبدأ الانحدار واستخدامه في التنبؤ والتصنيف Forecasting and Classification. ان استخدام بيانات السلاسل الزمنية المناخية تتطلب تحقيق التجانس في البيانات للحصول على افضل النتائج التصنيفية ولذلك تمت مراصفة البيانات زمنياً اعتمادا على طبيعة الغلاف الجوي ودرجات الحرارة خلال سنوات الدراسة لضمان تجانس اكبر في البيانات وبالتالي دقة اكبر في النتائج. أخذت بيانات الدراسة من محطة الأرصاد الجوية الزراعية العراقية في محطة الموصل واستخدمت كحالة حقيقية في هذه الدراسة. أظهرت نتائج المقارنات بين مواسم البيانات وكذلك دوال التعلم المختلفة دقة عالي في احيان ومقبولة في احيان اخرى مما يجعل من الممكن استخدام شبكة المدرك امرا موصى به للحصول على نتائج تصنيفية دقيقة توصل الى الغاية المتوخاة من استخدامها.

Abstract

The study of climatic conditions, atmospheric fluctuations and their effects is very important for diagnosing environmental and climatic features and their impact on various areas related to human life and other living organisms. In this study, the variable of the time series of evaporation quantities will be studied and classified

using several atmospheric influences, such as the time series of air temperatures in the maximum and minimum cases, as well as the time series of relative humidity in the maximum and minimum cases, which are considered direct, cross-sectional influences on the time series of evaporation depending on The principle of regression between the input variables and the dependent variable. The time series is characterized by its reliance on the principle of autoregressive (AR), which generates a driving force in the form of longitudinal effects that help in making classifications for future time periods outside the study samples, but it conflicts with the nature of non-linear climate data, which may cause a state of uncertainty. Neural networks are one of the methods that deal well with non-linearity in data, and the Perceptron Neural Network (PNN) is one of the oldest neural networks that is mainly used to classify data in general and time series in particular, with a structure that is far from complexity and reduces effort and time. More than one type of learning function was used after choosing the appropriate transformation function for the nature of the study data. The types of functions used in the perceptron network, in addition to its structure, depend mainly on the principle of regression and its use in forecasting and classification. The use of climate time series data requires achieving homogeneity in the data to obtain the best classification results. Therefore, the data were aligned in time depending on the nature of the atmosphere and temperatures during the years of study to ensure greater homogeneity in the data and thus greater accuracy in the results. The study data were taken from the Iraqi agricultural meteorological station in Mosul station and were used as a real case in this study. The results of comparisons between seasons of data as well as different learning functions showed high accuracy at times and acceptable at other times, which makes it possible to use the perceptron network as a recommended matter to obtain accurate classification results that achieve the intended purpose of its use.

1. المقدمة

تم في هذه الدراسة تناول دراسة تصنيف أحد أهم متغيرات الطقس، حيث تكمن أهمية هذه التنبؤات في معرفة مدى تأثيرها على الإنسان والحيوان والنبات والكاننات الحية الأخرى، والتخطيط للمستقبل خالية من مشاكل الآثار السلبية لمتغيرات الطقس المختلفة وغنية بآثارها الإيجابية. سيتم استخدام بيانات التبخر وتصنيفها بناءً على مبدأ الانحدار الذاتي من خلال تشخيص العلاقة الرياضية بينها وبين العديد من التأثيرات المناخية من خلال نموذج من طريقة Perceptron Neural Network (PNN) لتصنيف متغير التبخر من حيث التبخر المرتفع أو المنخفض.

ستستخدم أهم أساليب التعلم الآلي والذكاء الاصطناعي متمثلة بشبكة المدرك العصبية PNN لتصنيف بيانات السلاسل الزمنية للتبخر بناءً على متغيرات السلاسل الزمنية المناخية الأخرى مثل درجات حرارة الهواء في الحالات العظمى والدنيا، بالإضافة إلى السلاسل الزمنية للرطوبة النسبية في الحالات العظمى والدنيا. معظم بيانات الطقس وملوثات الهواء هي من النوع غير الخطي لذلك فإن استخدام بعض الأساليب والنماذج الخطية قد يؤدي إلى نتائج قليلة الدقة، لأن بيانات الطقس بشكل عام هي أحد أنواع السلاسل الزمنية القائمة على مبدأ الانحدار الذاتي الذي يحتوي على العديد من التغيرات الموسمية

وكذلك الدورية التي قد تؤثر سلباً على جعل هذا النوع من البيانات غير متجانسة، وكذلك يؤثر على نتائج التنبؤ والتصنيف ودقتها (Chaichan, Kazem, Al-Waeli, & Sopian, 2020; Sekertekin, Arslan, & Bilgili, 2020). صنفت البيانات الى نوعين من التصنيفات وفقاً لطبيعة الأجواء في محافظة نينوى. المجموعة الأولى من البيانات صنفت الى الأشهر الحارة نسبياً وهي (أيار وحزيران وتموز وآب وأيلول) في حين تضم المجموعة الثانية من البيانات الأشهر الباردة نسبياً وهي (تشرين الثاني وكانون الأول وكانون الثاني وشباط وآذار). في هذه الدراسة سيقتراح استخدام أسلوب PNN بوصفه أسلوباً حديثاً لتحسين نتائج التصنيف لمتغير التبخر اعتماداً على العديد من المؤثرات المناخية ذات الانحدار الذاتي. إن عمل أسلوب PNN يجمع مبدأ عمل الانحدار والتصنيف في أسلوب واحد بهدف الحصول على دقة تصنيفية عالية ومتميزة.

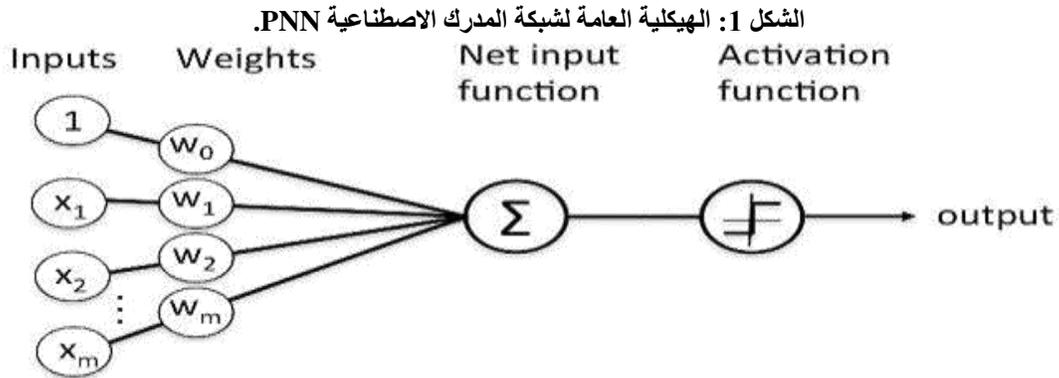
يعد التصنيف الثنائي في التعلم الآلي نوعاً من النماذج التي يتم تدريبها لتصنيف البيانات إلى واحدة من فئتين محتملتين، وعادة ما يتم تمثيلها على أنها تسميات ثنائية مثل 0 و 1، صواب و خطأ، أو ايجابي و سلبي أو تبخر عالٍ ومنخفض وما إلى ذلك. وتعد شبكة PNN حالها حال المصنفات الثنائية كلبنة أساسية في العديد من تطبيقات التعلم الآلي، الى جانب الانحدار اللوجستي Logistic regression وآلات المتجه الداعم (SVM)، وأشجار القرار، والغابات العشوائية، وغيرها الكثير. فيتم تدريب هذه النماذج عادة باستخدام البيانات المصنفة والفئة المستهدفة في مجموعة التدريب ثم تُستخدم لتصنيف بيانات خارج عينة الدراسة.

عادةً ما يتم تقييم أداء المصنفات وتصنيفاتها باستخدام مقاييس مثل الدقة التي تقيس مدى قدرة النموذج على تحديد الفئات الإيجابية والسلبية في البيانات بشكل صحيح (Kiangala & Wang, 2020). الشبكات العصبية الاصطناعية تعتبر دالة رياضية تعتمد على نموذج من الخلايا العصبية البيولوجية حيث تأخذ كل خلية عصبية المدخلات ثم تزنها بشكل منفصل وتلخصها وتمرر هذا المجموع من خلال وظيفة غير خطية لإنتاج المخرجات. تم تقديم Perceptron بواسطة Frank Rosenblatt في عام 1957. واقترح قاعدة التعلم Perceptron على أساس الخلايا العصبية الأصلية. وتعد PNN احد خوارزميات التعلم الخاضع للإشراف للمصنفات الثنائية. تمكن هذه الخوارزمية الخلايا العصبية من تعلم العناصر ومعالجتها في مجموعة التدريب واحداً تلو الأخرى (bbaskhah, Sedighi, & Marvi, 2023).

2. **المفاهيم النظرية:** في هذا الجانب سيتم تناول المفاهيم النظرية الأساسية للأساليب المستخدمة في هذا البحث والتي تتضمن أساسيات ومكونات شبكة المدرك العصبية PNN واهم ما سيتم استخدامه من أساليب ودوا ومقاييس.

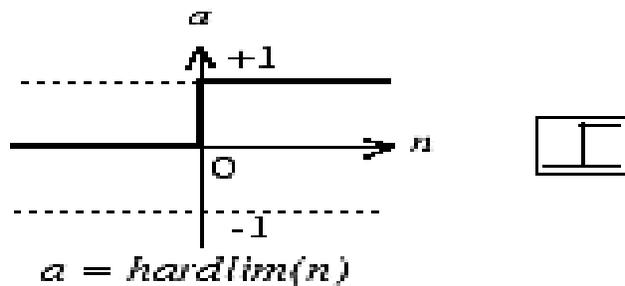
شبكة المدرك العصبية PNN: شبكة PNN كتقنية ذكائية تعتبر احدى خوارزميات التعلم الخاضعة للإشراف تستخدم بهدف التصنيف باستخدام مبدأ التعلم العميق واعتماداً على العديد من متغيرات الإدخال التي قد تكون مستمرة او فئوية متطابقة بذلك مع مبدأ الانحدار اللوجستي وإن مخرجاتها يجب ان تتطابق مع متغير الهدف وبمقارنتها تقاس دقة التصنيف.

الشكل 1 ادناه يوضح الهيكلية العامة لشبكة المدرك الاصطناعية PNN (Singh & Banerjee, 2019).

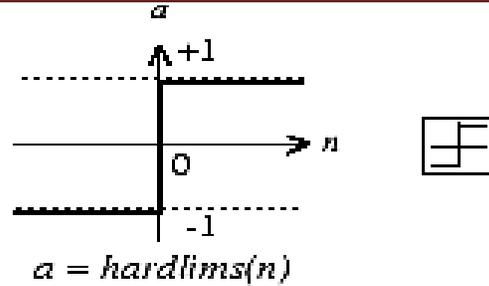


ومن
 الشكل 1 اعلاه فان المكونات الاساسية للهيكل العام لشبكة PNN يمكن تلخيصها كما هو ادناه.
 1. طبقة الإدخال Input Layer: تتكون من خلية واحدة أو أكثر من الخلايا العصبية المدخلة، والتي تمثلها متغيرات الإدخال.
 2. الأوزان Weights: ترتبط كل خلية من خلايا الإدخال العصبية بوزن هو قوة الاتصال بين خلايا الإدخال العصبية والعصبون الناتج.
 3. جزء التحيز Biased part: يضاف مصطلح التحيز إلى طبقة الإدخال لدعم شبكة المدرك بمرونة إضافية في نمذجة الأنماط المعقدة من بيانات الإدخال.
 4. دالة التنشيط Activation function: وتسمى أيضاً دالة التحويل Transfer function وتحدد طبيعة مشاهدات متغير الإخراج بناءً على المجموع الموزون لمتغيرات الإدخال اضافة لجزء التحيز. في هذه الدراسة سيتم استخدام بعض دوال التنشيط الشائعة وتشمل دالة الخطوة Step function او تسمى (دالة الحد الصعب Hard-limit transfer function) وكذلك دالة الإشارة Sign function او ما تسمى (دالة الحد الصعب المتماثلة Symmetric hard-limit transfer function) (Savalia & Emamian, 2018). الشكل 2 يوضح بعض أنواع دوال التحويل المستخدمة مع شبكة المدرك الاصطناعية PNN.

الشكل 2: بعض دوال التحويل المستخدمة مع شبكة المدرك الاصطناعية PNN.



Hard-Limit Transfer Function



Symmetric Hard-Limit Transfer Function

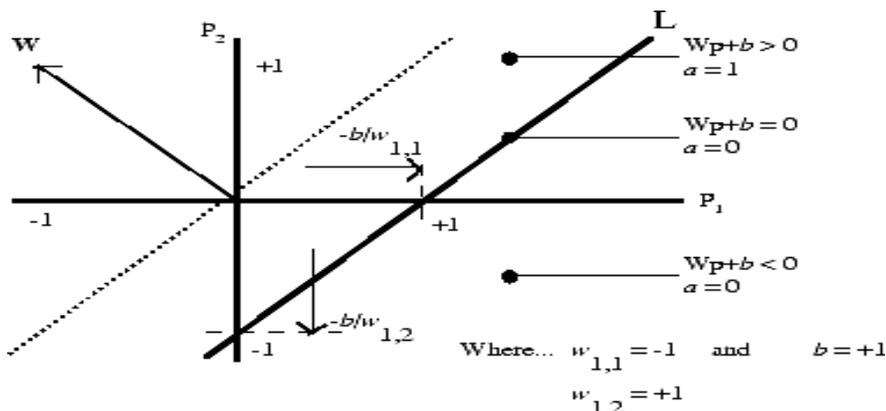
5. متغير الإخراج Output variable: وتمثل ناتج شبكة المدرك PNN ومشاهداته ذات قيمة ثنائية إما 0 أو 1 التي تمثل الفئة التي تنتمي إليها بيانات متغيرات الإدخال.

6. خوارزمية التدريب Training algorithm: خوارزمية تعلم خاضعة للإشراف حالها حال بقية خوارزميات تدريب الشبكات العصبية الأخرى. أثناء التدريب يتم تعديل الأوزان والتحييزات لتقليل الخطأ بين متغيرات الإخراج والهدف لفترة التدريب.

يتم ترجيح كل مدخل خارجي بوزن مناسب w_{1j} ، ويتم إرسال مجموع المدخلات الموزونة إلى وظيفة النقل ذات الحد الصلب، والتي تحتوي أيضاً على مدخل 1 يتم إرساله إليها من خلال التحييز. يتم عرض وظيفة النقل ذات الحد الثابت، والتي تُرجع 0 أو 1، أدناه.

بالنسبة لدالة التحويل Hard-limit فإنه تبعاً لها تنتج عصبونات شبكة PNN القيمة 1 إذا كانت نتيجة الدالة الجمعية Additive function أكبر من أو تساوي 0 والا وفي حالات أخرى فتنتج 0. تعطي لدالة التحويل Hard-limit لشبكة المدرك PNN القدرة على تصنيف متغيرات الإدخال من خلال تقسيم فضاء الإدخال إلى منطقتين كما هو الحال في آلة المتجه الداعم وتحديد المستوي الأمثل Optimal Hyperplane. الشبكة PNN ستصنف الإخراج إلى 0 إذا أنتجت دالة الإخال الجمعية اقل من 0، وستصنف الإخراج إلى 1 إذا أنتجت دالة الإخال الجمعية قيمة أكبر من أو تساوي 1. الشكل 3 ادناه يبين منطقتي التصنيف لفضاء الإدخال لمدخلين لعصبون Hard-limit مع الأوزان $w_{1,1} = -1$ وكذلك $w_{1,2} = 1$ مع تحديد مقدار التحييز $b = 1$ في شبكة المدرك الاصطناعية PNN (Sharma, Kim, & Gupta, 2022).

الشكل 3: منطقتي التصنيف وحدي القرار في شبكة المدرك الاصطناعية PNN.



يتم تشكيل منطقتي التصنيف بواسطة خط حدود القرار Decision boundary line المشار له في الشكل 3 بالرمز L عندما $W_p + b = 0$. أما الخط عمودي على مصفوفة الأوزان W فتتشكل إزاحته وفقاً لمقدار التحيز b . متجهات الإدخال أعلى يسار الخط L تنتج عندما ناتج الإدخال أكبر من 0 والذي يتسبب بأن يكون ناتج إخراج العصبون Hard-limit يساوي 1. أما متجهات الإدخال أسفل يمين الخط L فستتسبب بأن يكون ناتج إخراج العصبون Hard-limit يساوي 0. يمكن التحكم بموقع وميل الخط الفاصل من خلال تغيير قيم الأوزان والتحيز للتحكم بالمساحة التصنيفية.

ومن الممكن الدخول أكثر في تفاصيل هيكلية شبكة المدرك ومكوناتها مع تفاصيل لأبعاد كل المصفوفات والمتجهات المكونة للشبكة. تتكون شبكة PNN من طبقة واحدة من S من الخلايا العصبية المتصلة بمتغيرات ادخال بعدد R من خلال مجموعة من الأوزان العشوائية $w_{i,j}$ لمتغيرات الإدخال يمكن كتابتها كمصفوفة وعلى النحو التالي (Desai & Shah, 2021).

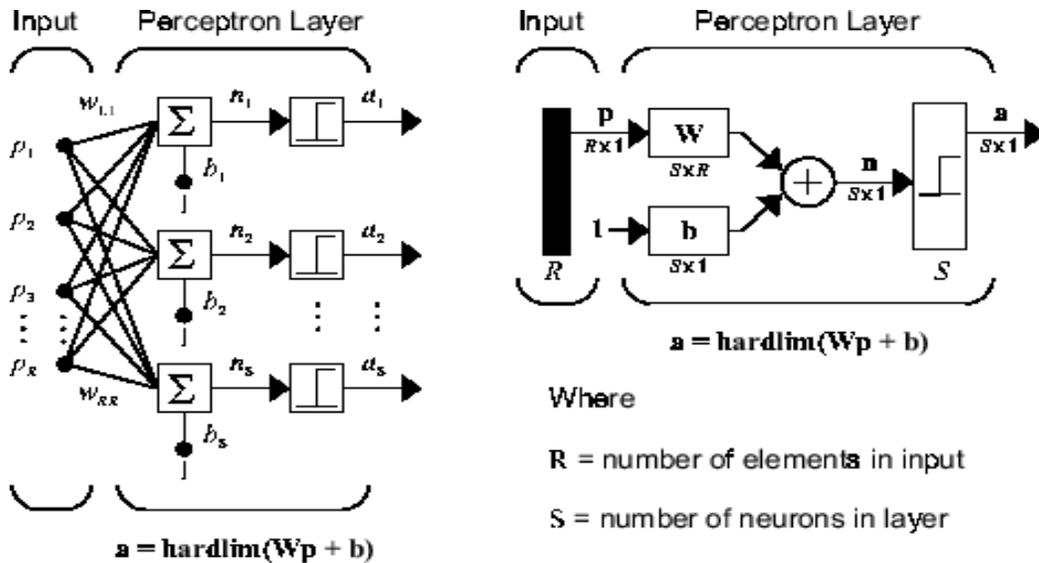
$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix}_{S \times R}$$

في حين يصاغ متجه متغيرات الادخال على فرض ان يرمز لمتغيرات الادخال Z فتكون صيغته كما يلي.

$$Z = [Z_{i1} \quad Z_{i2} \quad \dots \quad Z_{iR}]'$$

الشكل 4 ادناه يضم شكلين تفصيليين مع توضيح تفصيلي لأحجام المتجهات والمصفوفات المكونة لشبكة المدرك الاصطناعية PNN.

الشكل 4: الاشكال التفصيلية لأحجام المتجهات والمصفوفات المكونة لشبكة المدرك الاصطناعية PNN.



عصبونات شبكة PNN يتم تدريبها على أمثلة السلوك المرغوب فيه من خلال بيانات فترة التدريب المتمثلة بمتغيرات الإدخال على شكل أزواج من متغيرات الإدخال مع ما يقابلها من متغير الهدف وكما يلي (Hosseinzadeh et al., 2021).

$$p_1t_1, p_2t_2, \dots, p_qt_q$$

اذ ان p هو متغير ادخال الشبكة PNN و t هو متغير الهدف (المعتمد) لفترة التدريب. الهدف هو تقليل خطأ التنبؤ e ، وهو الفرق بين اخراج (استجابة) العصبون ونرمز لها a و متجه متغير الهدف t . ان من أهم قواعد دوال التعلم هي دالة تعلم الوزن والتحيز لشبكة المدرك ويطلق عليها اصطلاحاً (Learnp) Perceptron weight and bias learning function والتي تصف التغييرات المرغوب بها للأوزان وقيم التحيزات لشبكة PNN حسب طبيعة متغيرات الإدخال. يجب أن يحتوي متجه متغير الهدف t فقط على إما القيمة 0 أو القيمة 1 وان استخدام دالة التحويل Hard-limit (hardlim) تحقق هذا الهدف لمتغير الاخراج الذي سيضم تلك القيم فقط لا غيرها. في كل مرة يتم فيها تنفيذ دالة التعلم Learnp، يكون لدى شبكة المدرك PNN فرصة أفضل لتوليد مخرجات بشكل ادق خلال عدد محدود من التكرارات في حالة وجود حل مناسب ومخرجات دقيقة. إذا لم يتم استخدام التحيز فإن دالة التعلم Learnp ستعمل على إيجاد حل من خلال تغييرات مستمرة لمتجه الأوزان لينتج عن هذا حدي قرار متعامدين مع متجه w والذي سيساعد في تصنيف متجهات الإدخال بشكل صحيح واكثر دقة. وتتلخص حالات الاخراج وتحديث الأوزان بناء عليها من خلال ثلاثة شروط وقواعد التي تحدث عند كل خلية عصبية واحدة من حيث الخطأ $e = t - a$ والتغيير الذي يجب إجراؤه على متجه الوزن Δw :

الحالة 1. إذا كانت $e = 0$ ، فسيتم تغيير Δw لتساوي 0 وذلك عندما

$$(a = t \text{ and } e = t - a = 0).$$

الحالة 2. إذا كانت $e = 1$ ، فسيتم تغيير Δw لتساوي p^T وذلك عندما

$$(a = 0 \text{ and } t = 1, \text{ and } e = t - a = 1).$$

الحالة 3. إذا كانت $e = -1$ ، فسيتم تغيير Δw لتساوي $-p^T$ وذلك عندما

$$(a = 1 \text{ and } t = 0, \text{ and } e = t - a = -1).$$

عندما

$$\Delta w = (t - a) p^T = ep^T$$

اذ ان α تمثل مقدار التعلم. كما يمكن تحديد قيم التحيز حسب المعادلة التالية.

$$\Delta b = (t - a)(1) = e$$

اما بالنسبة لطبقة العصبونات كاملةً فيتم حساب تغييرا الأوزان حسب المعادلة التالية.

$$\Delta W = (t - a)(p)^T = e(p)^T$$

وكذلك لتغييرات قيم التحيزات لكامل الطبقة تحسب كما يلي.

$$\Delta b = (t - a) = e$$

ومن خلال اتباع قاعدة التعلم سيتم تحديث الأوزان والتحيزات للطبقة في كل تكرار حسبما يلي.

$$W_{new} = W_{old} + ep^T \text{ وكذلك } b_{new} = b_{old} + e$$

عندما

$$e = t - a$$

يتم استخدام بعض المقاييس لقياس دقة الأداء التصنيفي ومنها مصفوفة الارباك (Confusion Matrix) (Luque, Carrasco, Martín, & de Las Heras, 2019) والموضحة هيكلتها كما في الجدول 1: هيكلية مصفوفة الإرباك Confusion Matrix الجدول 1 ادناه.

الجدول 1: هيكلية مصفوفة الإرباك Confusion Matrix

| | | Actual | |
|-----------|-----|---------------------|---------------------|
| | | Yes | No |
| Predicted | Yes | True positive (TP) | False positive (FP) |
| | No | False negative (FN) | True negative (TN) |

ومن المقاييس المستخدمة في التصنيف هو مقياس الدقة Accuracy يتم فيه حساب نسبة الحالات المتوقعة المطابقة للحالات الفعلية الى العدد الكلي لجميع الحالات المتوقعة والفعلية المطابقة وغير المطابقة وكما يلي.

$$\text{Accuracy} = \frac{\text{Number of correctly classified}}{\text{Total Number}} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100$$

3. **النتائج والمناقشات:** في هذه الدراسة سيتم استخدام شبكة المدرك من خلال كتابة برنامج باستخدام برمجيات (MATLAB). ان البيانات المستخدمة في هذه الدراسة تضمنت استخدام خمسة انواع من المتغيرات المناخية. المتغير الاول هو متغير كميات التبخر والذي تم افتراضه كمتغير معتمد (متغير الهدف). اما متغيرات الإدخال فهي اربع متغيرات وهي متغيري درجات حرارة الهواء بالحالتين العظمى والدنيا ومتغيري الرطوبة النسبية بالحالتين العظمى والدنيا. لتحقيق التجانس المطلوب والذي يحقق نتائج بدقة تصنيفية عالية فقد تم مراصفة البيانات اعتمادا على طبيعة حرارة الغلاف الجوي. ومن خلال المراصفة الزمنية فقد تم الحصول على مجموعتين متجانستين من البيانات. المجموعة الاولى تخص الموسم الحار للأشهر (أيار وحزيران وتموز وآب وأيلول) في حين تضم المجموعة الثانية من البيانات الأشهر الباردة نسبياً وهي (تشرين الثاني وكانون الاول وكانون الثاني وشباط وأذار) وللأعوام 2018 و2019 و2020. في المرحلة الثانية تم تقسيم البيانات لكل موسم الى مجموعتين الاولى للتدريب وتضم اغلب البيانات لما يقارب 70% والمجموعة الثانية للاختبار وتضم ما يقارب 30%. الموسم الحار يضم 372 مشاهدة بواقع 262 مشاهدة للتدريب و 110 مشاهدة في فترة الاختبار. اما الموسم البارد فقد ضم 303 مشاهدة بواقع 212 مشاهدة لفترة التدريب و 91 مشاهدة في فترة الاختبار. متغير الهدف تم تحويله من نوعه المستمر في الأصل الى الشكل الفئوي باستخدام عتبة الوسيط والمتوسط لكل فترة ولكل موسم. تم كذلك في هذه الدراسة استخدام نوعين لنفس متغيرات الإدخال. نوعها الاول كان باستخدامها بعد تحويلها الى الصيغة الفئوية باستخدام عتبة الوسيط والمتوسط لكل منها في الفترات والمواسم المختلفة. وفي النوع الثاني تم استخدامها بصيغتها المستمرة كما هي دون تغيير. ان الاطار العام لتنفيذ خوارزمية شبكة المدرك تتلخص بعدة خطوات متسلسلة وكما يلي.

1. تحديد الفئتين الإيجابية والسلبية لمتغير الهدف.
2. تقسيم مشاهدات السلسلة الزمنية الى مجموعتين للتدريب والاختبار وبالتناظر لجميع متغيرات الإدخال وكذلك متغير الهدف.
3. جمع قيمة التحيز مع الدالة الجمعية لمتغيرات الإدخال الموزونة.

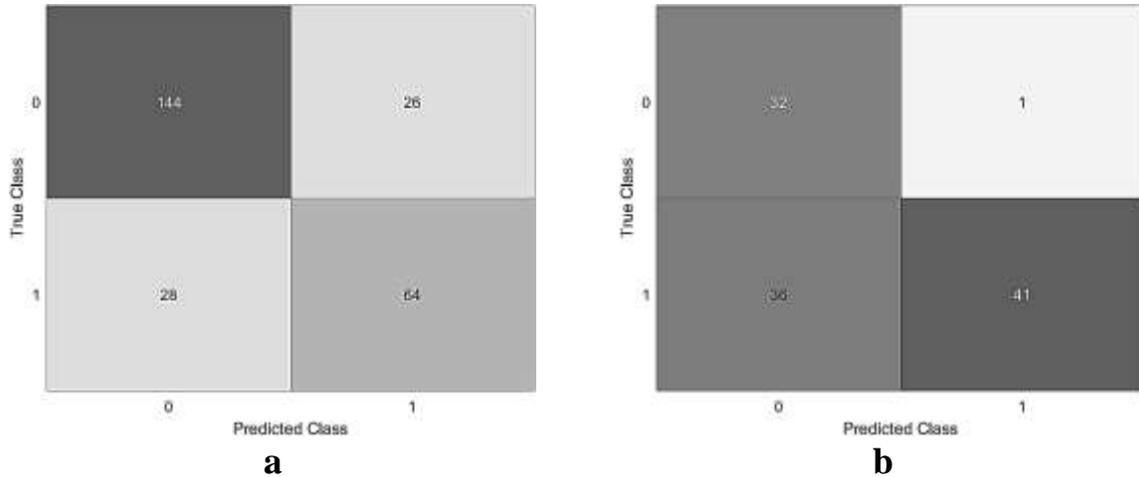
4. تحديد بنية الشبكة العصبية PNN (هيكل الشبكة) من خلال تحديد دوال التعلم ودوال التحويل وحسب طبيعة البيانات. اذ تم استخدام دالة التحويل Hard-limit فقط لانها هي فقط من تتناسب وطبيعة البيانات. كما وتم استخدام كلا دالتي التعلم Learnp و كذلك دالة التعلم Normalized perceptron (Learnpn) weight and bias learning function.

5. تحديد معدل التعلم لتحديد توقف العملية اعتماداً على معدل التعلم المطلوب.

6. قياس الدقة التصنيفية لنموذج شبكة المدرك PNN.

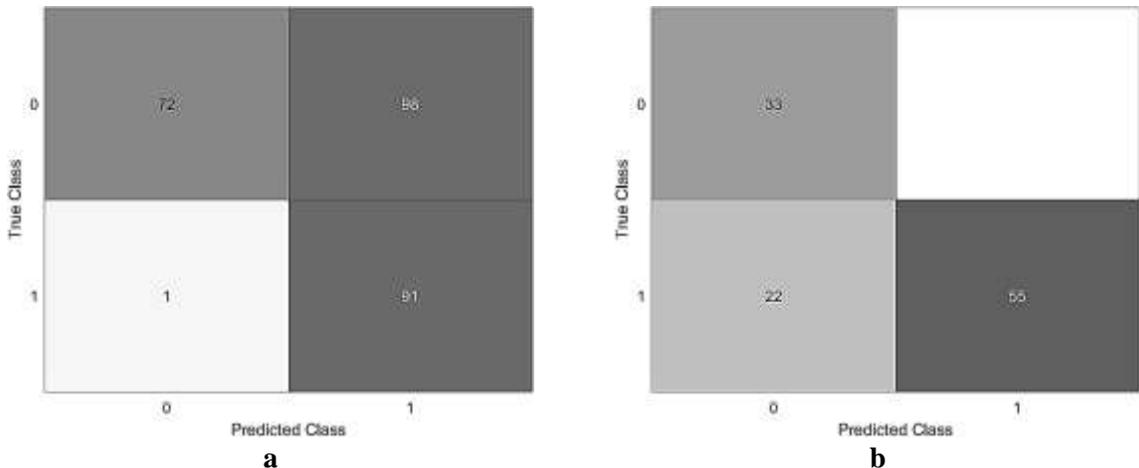
تم استخدام هيكلية مصفوفات الارباك للتعبير عن الدقة التصنيفية بتفاصيلها فكانت النتائج كما هو مبين في الاشكال ادناه.

الشكل 5: مخطط مصفوفة الارباك التصنيفية (CCMC) لبيانات الموسم الحار باستخدام متغيرات ادخال فنوية ثنائية ودالة التحويل (hardlim) ودالة التعلم (learnp): a لفترة التدريب، b: لفترة الاختبار



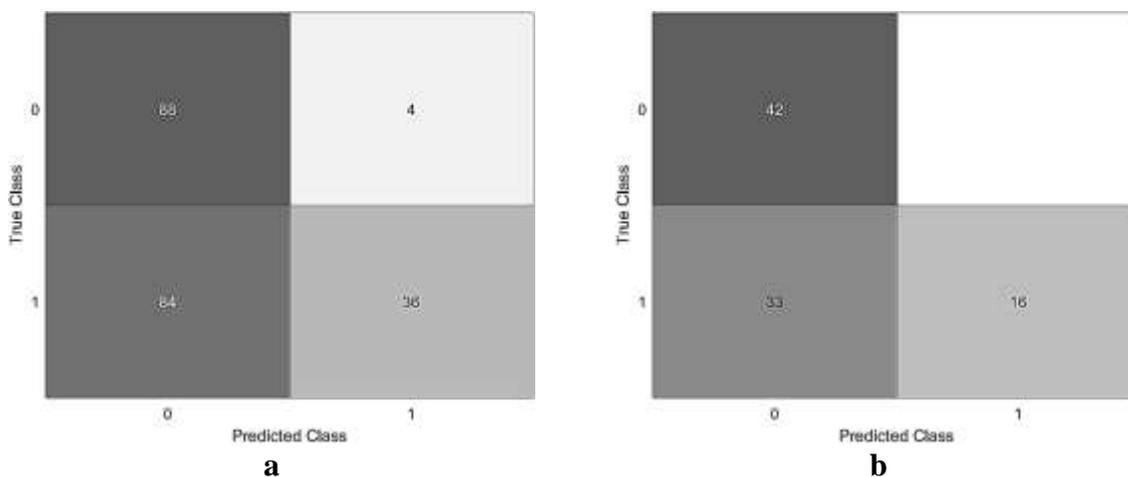
ان دقة الاختبار في الشكل 5 اعلاه تساوي 79.39% و 66.36% لفترتي التدريب والاختبار على التوالي.

الشكل 6: مخطط مصفوفة الارباك التصنيفية (CCMC) لبيانات الموسم الحار باستخدام متغيرات ادخال مستمرة ودالة التحويل (hardlim) ودالة التعلم (learnpn): a لفترة التدريب، b: لفترة الاختبار



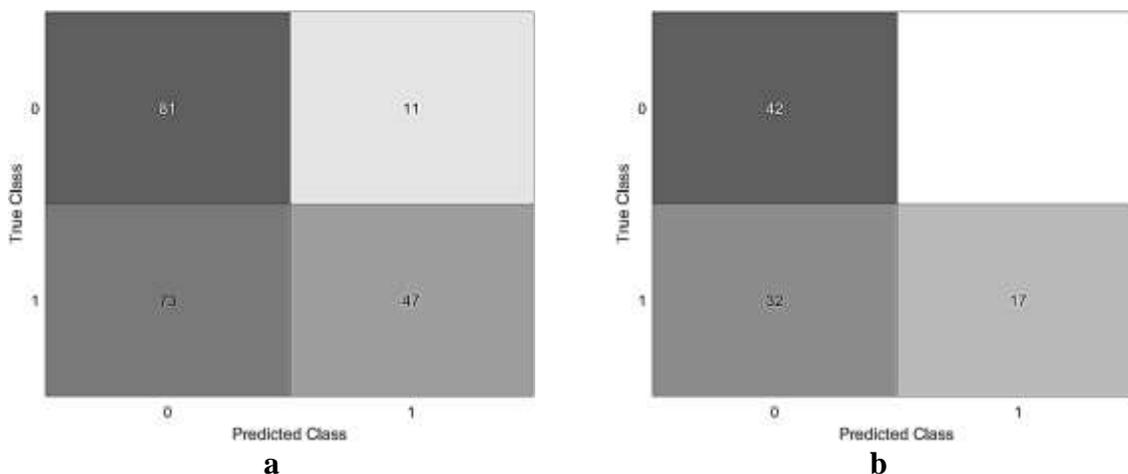
ان دقة الاختبار في شكل (6) اعلاه تساوي %62.21 و %80.00 لفترتي التدريب والاختبار على التوالي.

الشكل 7 : مخطط مصفوفة الاريك التصنيفية (CCMC) لبيانات الموسم البارد باستخدام متغيرات ادخال فنوية ثنائية ودالة التحويل (hardlim) ودالة التعلم (learnpn) a: لفترة التدريب، b: لفترة الاختبار



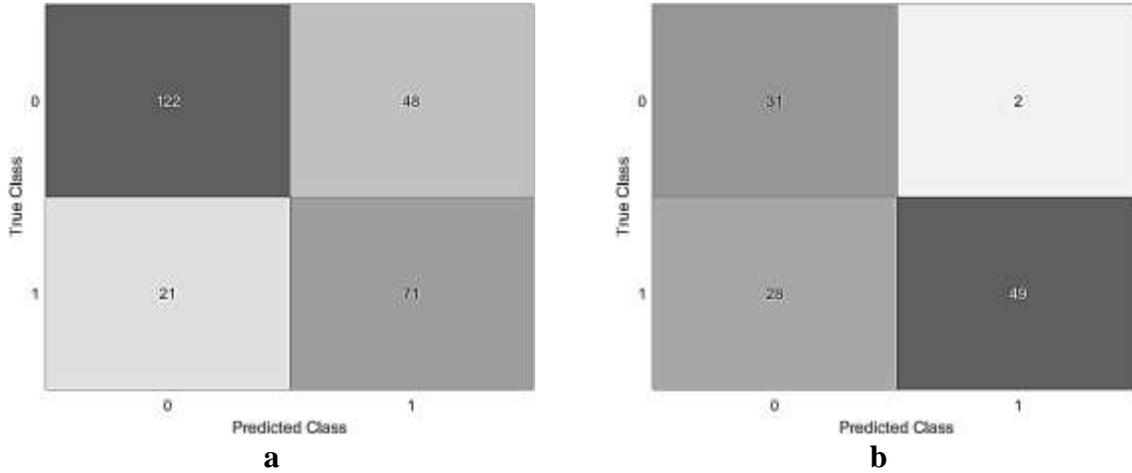
ان دقة الاختبار في الشكل 7 اعلاه تساوي %58.49 و %63.74 لفترتي التدريب والاختبار على التوالي.

الشكل 8 : مخطط مصفوفة الاريك التصنيفية (CCMC) لبيانات الموسم البارد باستخدام متغيرات ادخال مستمرة ودالة التحويل (hardlim) ودالة التعلم (learnpn) a: لفترة التدريب، b: لفترة الاختبار



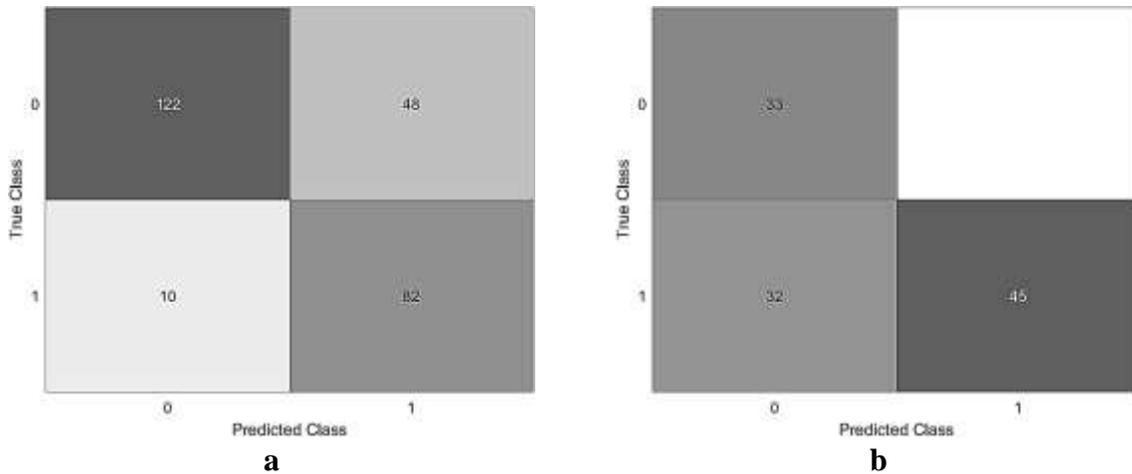
ان دقة الاختبار في الشكل 8 اعلاه تساوي %60.38 و %64.84 لفترتي التدريب والاختبار على التوالي.

الشكل 9 : مخطط مصفوفة الاريك التصنيفية (CCMC) لبيانات الموسم الحار باستخدام متغيرات ادخال فنوية ثنائية ودالة التحويل (hardlim) ودالة التعلم (learnpn) :a لفترة التدريب، b: لفترة الاختبار



ان دقة الاختبار في الشكل 9 اعلاه تساوي 73.66% و 72.73% لفترتي التدريب والاختبار على التوالي.

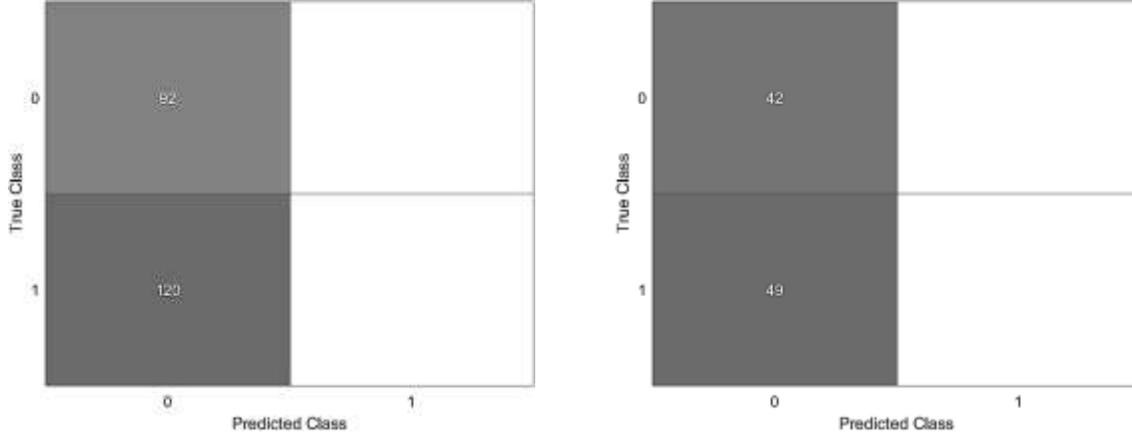
الشكل 10 : مخطط مصفوفة الاريك التصنيفية (CCMC) لبيانات الموسم الحار باستخدام متغيرات ادخال مستمرة ودالة التحويل (hardlim) ودالة التعلم (learnpn) :a لفترة التدريب، b: لفترة الاختبار



ان دقة الاختبار في الشكل 10 اعلاه تساوي 77.86% و 70.91% لفترتي التدريب والاختبار على التوالي.

الشكل 11 : مخطط مصفوفة الارتباك التصنيفية (CCMC) Classification Confusion Matrix Chart لبيانات الموسم البارد

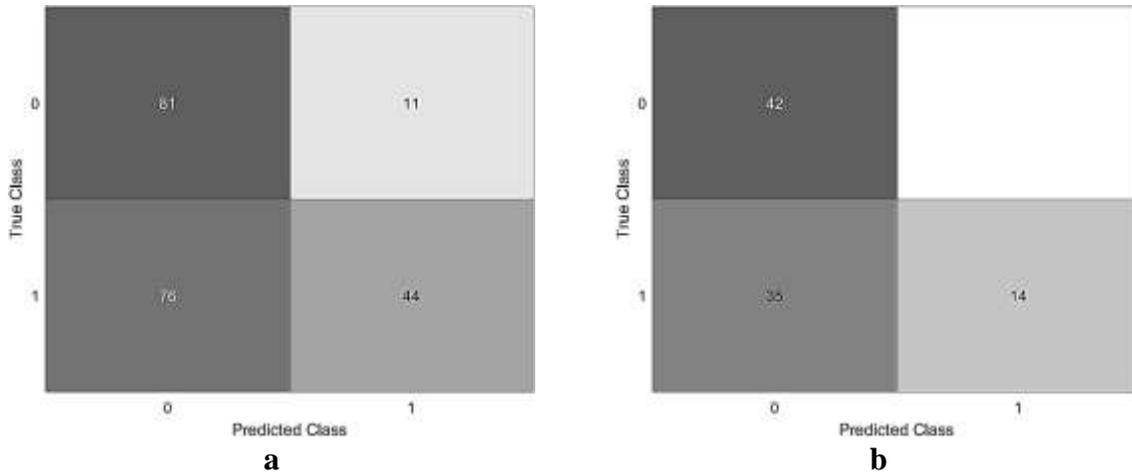
باستخدام متغيرات ادخال فنوية ثنائية ودالة التحويل (hardlim) ودالة التعلم(learnnpn) :a لفترة التدريب، b: لفترة الاختبار



ان دقة الاختبار في الشكل 11 اعلاه تساوي 43.40% و 46.15% لفترتي التدريب والاختبار على التوالي.

الشكل 12 : مخطط مصفوفة الارتباك التصنيفية (CCMC) Classification Confusion Matrix Chart لبيانات الموسم البارد

باستخدام متغيرات ادخال مستمرة ودالة التحويل (hardlim) ودالة التعلم (learnnpn) :a لفترة التدريب، b: لفترة الاختبار



ان دقة الاختبار في الشكل 12 اعلاه تساوي 58.96% و 61.54% لفترتي التدريب والاختبار على التوالي.

ومن الشكل 5 الى الشكل 12 اعلاه يتبين إجمالاً أفضلية النتائج التصنيفية لمتغير التبخر باستخدام دالة التعلم Learnnp بالمقارنة مع النتائج التصنيفية لدالة التعلم Learnpn في معظم النتائج. وكذلك يتبين إجمالاً أفضلية النتائج التصنيفية لمتغير التبخر باستخدام متغيرات الادخال الفئوية الثنائية بالمقارنة مع النتائج التصنيفية لمتغيرات الادخال المستمرة على الأغلب.

وكانت نتائج قياس دقة نموذج التصنيف لبيانات التدريب والاختبار وبشكل اجمالي كما في الجدول 2 ادناه.

الجدول 2: دقة التصنيفات باستخدام اسلوب شبكة المدرك العصبية PNN لتصنيف متغير كميات التبخر

| الموسم | الموسم البارد | | | | الموسم الحار | | | |
|----------------------|---------------|----------|---------|----------|--------------|----------|---------|----------|
| | Learnp | | Learnpn | | Learnp | | Learnpn | |
| دالة التعلم | التدريب | الاختبار | التدريب | الاختبار | التدريب | الاختبار | التدريب | الاختبار |
| الفترة | | | | | | | | |
| متغيرات ادخال فنوية | 58.49% | 63.74% | 43.40% | 46.15% | 79.39% | 66.36% | 73.66% | 72.73% |
| متغيرات ادخال مستمرة | 60.38% | 64.84% | 58.96% | 61.54% | 62.21% | 80.00% | 77.86% | 70.91% |

اذ من الواضح تباين الدقة وتفاوتها من اسلوب لآخر ومن فترة لأخرى ولكن دقة التصنيف هي العنوان الابرز لغالب النتائج بشكل عام. ولهذا من الافضل عدم القول بالتفوق المطلق لاحد التحديدات دون الآخر ولكن الركازة والرصانة هي من نصيب شبكة المدرك العصبية PNN لأنها تعمل مثل اساليب التعلم العميق من خلال عدد غير منتهي من الاوزان العشوائية لمتغيرات الادخال وبعدها كبرر جدا من التكرارات.

4. **الاستنتاجات:** من خلال ما تقدم من نتائج واستعراضات فانه من الممكن استنتاج امكانية الحصول على دقة تصنيفية عالية بخطأ تصنيفي صغير كما تم ملاحظته في النتائج. ولذلك فمن الممكن اقتراح استخدام شبكة المدرك العصبية PNN بتحديدات مختلفة لدوال التعلم ودوال التحويل وحسب طبيعة البيانات. وكذلك فان تحقيق التناسق والتجانس للبيانات من خلال مواصفاتها زمنياً الامر البالغ الاهمية الذي من الضروري تحقيقه قبل البدء باستخدام اي من الخوارزميات التصنيفية. كذلك فان استخدام العتبة المناسبة لتحديد الاصناف ومدى انتساب كل مشاهدة لصفها المناسب لجميع متغيرات الادخال وكذلك متغير الهدف للحصول على افضل التصنيفات وبأقل الاخطاء من خلال الاعتماد على مبدأ التنوع والتكرار والانحدار والتصنيف في ظل وجود خاصية الانحدار الذاتي والارتباط الذاتي لبيانات السلاسل الزمنية المتعددة.

المصادر References

1. Abbaskhah, A., Sedighi, H., & Marvi, H. (2023). Infant cry classification by MFCC feature extraction with MLP and CNN structures. *Biomedical Signal Processing and Control*, 86, 105261 .
2. Chaichan, M. T., Kazem, H. A., Al-Waeli, A. H., & Sopian, K. (2020). The effect of dust components and contaminants on the performance of photovoltaic for the four regions in Iraq: a practical study. *Renewable Energy and Environmental Sustainability*, 5, 3 .
3. Desai, M., & Shah, M. (2021). An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN). *Clinical eHealth*, 4, 1-11 .
4. Hosseinzadeh, M., Ahmed, O. H., Ghafour, M. Y., Safara, F., Hama, H. K., Ali, S . . . , Chiang, H.-S. (2021). A multiple multilayer perceptron neural network with an adaptive learning algorithm for thyroid disease diagnosis in the internet of medical things. *The Journal of Supercomputing*, 77, 3616-3637 .
5. Kiangala, K. S., & Wang, Z. (2020). An effective predictive maintenance framework for conveyor motors using dual time-series imaging and convolutional neural network in an industry 4.0 environment. *Ieee Access*, 8, 121033-121049 .

6. Luque, A., Carrasco, A., Martín, A., & de Las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216-231 .
7. Savalia, S., & Emamian, V. (2018). Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks. *Bioengineering*, 5(2), 35 .
8. Sekertekin, A., Arslan, N., & Bilgili, M. (2020). Modeling diurnal Land Surface Temperature on a local scale of an arid environment using artificial Neural Network (ANN) and time series of Landsat-8 derived spectral indexes. *Journal of Atmospheric and Solar-Terrestrial Physics*, 206, 105328 .
9. Sharma, R., Kim, M., & Gupta, A. (2022). Motor imagery classification in brain-machine interface with machine learning algorithms: Classical approach to multi-layer perceptron model. *Biomedical Signal Processing and Control*, 71, 103101 .
10. Singh, J., & Banerjee, R. (2019). *A study on single and multi-layer perceptron neural network*. Paper presented at the 2019 3rd International Conference on Computing Methodologies and Communication ICCMC.