المجلة العراقية للعلوم الإحصائية

www.stats.mosuljournals.com

التنبؤ لبيانات تلوث الهواء باستخدام الطريقة الهجينة MLR–RNN مع طريقة التراصف الزمني

ختام وليد قادر و اسامة بشير شكر

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

معلومات النشر

تاريخ المقالة:
تم استلامه في7 اذار 2021
تم القبول في 17 نيسان 2021
متاح على الإنترنت في 1 كانون الاول 2021

الكلمات الدالة:
الانحدار الخطي المتعدد (MLR) ،
الطبقية الزمنية (TS) ،
المواد الخاصة (PM10) ،
التنبؤ ،
تلوث الهواء ،
MLR-RNN الهجين

المراسلة:
ختام وليد قادر
khetamalzubaidy86@gmail.com

الخلاصة

ان دراسة الجسيمات المعلقة ((Particular matter (PM10) والتكهن بها ضروري للتقليل والسيطرة على الأضرار البيئية وصحة الانسان. هنالك العديد من مصادر التلوث او ما يسمى بالملوثات والتي ربما تؤثر على متغير PM10. كل هذه المتغيرات تصنف بياناتها كغير خطية. تم اخذ بيانات الدراسة من محطة مناخية في ماليزيا. تم استخدام نماذج الانحدار الخطي المتعدد Multiple linear regression (MLR) كطريقة إحصائية خطية للتنبؤ بمتغير PM10 من خلال تأثره بمتغيرات الأرصاد الجوية المقابلة، لذلك فقد يعكس نتائج غير دقيقة عند استخدامه مع مجموعات البيانات غير الخطية. طريقة التراصف الزمني في أنماط مختلفة تم استخدامها لتحسين تلك النتائج وتحقيق التجانس ويتضمن مراصفة المواسم المتشابهة في السنوات المختلفة سوية لتكوين متغير جديد مختلف عن الاصلي. لتحسين نتائج التنبؤ تم اقتراح الشبكات العصبية المعاودة Recurrent neural network (RNN) لتستخدم بعد التوفيق مع نموذج MLR ضمن الطريقة الهجينة MLR–RNN. ان نتائج التنبؤ بشكل عام كانت الافضل باستخدام أسلوب التراصف الزمني. وكذلك عكست النتائج افضلية تنبؤات الطريقة الهجينة مقارنة مع نموذج MLR. وكاستنتاج في هذه الدراسة فمن الممكن استخدام الشبكات العصبية المعاودة وأسلوب التراصف الزمني كأساليب فعالة للحصول على افضل نتائج التنبؤ مع البيانات غير الخطية متعددة المتغيرات.

DOI: https://doi.org/10.33899/iqjoss.2021.169962 , ©Authors, 2021, College of Computer and Mathematical Science, University of Mosul.
This is an open access article under the CC BY 4.0 license (http://creativecommons.org/licenses/by/4.0/).

1. المقدمة

في هذه الدراسة تم التطرق إلى دراسة التنبؤ بتلوث الهواء والتي تكمن اهميتها من خلال معرفة تأثيرها على الإنسان والحيوان والنبات وسائر الكائنات الحية على سطح الكرة الأرضية . تم استخدام بيانات متغير PM_{10} كمتغير معتمد لقياس تلوث الهواء والمتأثر بعدة متغيرا تفسيرية تتعلق بالأحوال والتغيرات الجوية حيث ان هنالك علاقة وثيقة بين تركيز تلوث الهواء والمتغيرات التي تؤثر في حالة الطقس. تم استخدام نموذج الانحدار الخطي المتعدد MLR واستخدامه في التنبؤ بتلوث الهواء مع الأخذ في الاعتبار تأثيرات متغيرات الأرصاد الجوية المقابلة له. قام Vlachogianni *et al.* (2011) بدراسة لتطوير نماذج التنبؤ باستخدام الانحدار الخطي المتعدد ومقارنة التنبؤات من نموذج MLR مع تلك الناتجة من استخدام الشبكة العصبية الاصطناعيةANN. ان نتائج تنبؤات الشبكات العصبية كانت أفضل من تلك المستحصلة من نموذج MLR. واستخدم Janssen *et al.* (2011) نماذج الانحدار الخطي المتعدد لنمذجة بيانات PM10 لمدينة باريس للمستويات اليومية. كما وقدر Ahmad *et al.* (2019) تركيز الجسيمات الدقيقة $PM_{2.5}$ باستخدام اسلوب هجين للانحدار الخطي والشبكة العصبية الاصطناعية وأظهرت النتائج أن كلا من الانحدار الخطي وANN متفقان تمامًا وقادران على تقدير تركيزات $PM_{2.5}$ مع

دقة اكبر للشبكات العصبية الاصطناعية ANN. وفي مسار الدراسات السابقة ومن اجل تحسين دقة نتائج التنبؤ بالجسيمات المعلقة في الهواء PM_{10} والتي تعد بيانات بتاثيرات غير خطية وبوجود مؤثرات جوية اخرى، تم في هذه الدراسة تقديم عدة طرائق مقترحة للتنبؤ اضافة لنموذج الانحدار الخطي المتعدد (MLR) كطريقة تقليدية احصائية فقد تم اقتراح احد الطرق الذكائية وهي الشبكات العصبية المعاودة(Recurrent Neural Network (RNN لتحسين نتائج التنبؤ من خلال تهجينها مع الطريقة التقليدية. تم التطبيق على بيانات سلسلة مُعدلات تلوث الهواء المتمثلة بالجُسيمات المعلقة PM_{10} بواقع (1034) مشاهدة حيث تتكون هذه السلسلة من المتغير المعتمد PM_{10} ومتغيرات مستقلة وعددها (9) متغيرات. تم اختزال المتغيرات التفسيرية الى (4) متغيرات لان هذه المتغيرات الاربعة اعطت افضل نموذج انحدار وهذه المتغيرات هي (CO,SO_2,NO,O_3) حيث CO هو احادي اوكسيد الكاربون(Carbon Monoxide) وان SO_2 هو ثنائي اوكسيد الكبريت(Sulphur Dioxide) و NO هو احادي اوكسيد النيتروجين(Nitric oxide) وo_3 هو الاوزون(Ozoon) اما المتغيرات الاخرى فاعطت معلماتها قيما مقدرة غير معنوية اعتمادا على قيمة P-value مما جعل من حذفها الحل الامثل للوصول الى النموذج الافضل. تم استخدام برنامج (Minitab) وبرنامج Excel للحصول على نموذج الانحدار الخطي المتعدد وتنبؤاته لمرحلتي التدريب والاختبار. ان البيانات التي تمت دراستها تم اخذها بحالتين الاولى تم اخذها كاملة اي بفترتها الكلية وتبدأ من(1/1/2013) وتنتهي الى (31/10/2015) وفي الحالة الثانية تم فيها استخدام اسلوب التراصف الزمني حيث تم تقسيم هذه البيانات الى اربعة مواسم لكي تصبح كل مجموعة من المجموعات الاربعة اكثر تجانسا وتلاؤما مع الطرق المقترحة. ستتم عملية المراصفة الزمنية على شكل فصول موسمية حيث تحدد اربع مجاميع متراصفة زمنياً بالاعتماد على الفصول الموسمية في كل سنة ومراصفتها زمنيا مع جميع الفصول المشابهة في السلسلة الزمنية ومن الممكن صياغة منهجية اسلوب التراصف الزمني المستخدم وكما هو مدرج ادناه:

في الموسم الاول ورمزه (S_1) حيث سيكون عدد المشاهدات (239) مشاهدة وعدد الشهور (8 شهور) والاشهر التي سوف يتم أخذها هي: (كانون الثاني، شباط، كانون الاول) ولثلاث سنوات (2015،2014،2013) وعلى التوالي. اما في الموسم الثاني ورمزه (S_2) سيكون عدد المشاهدات (276) مشاهدة وعدد الشهور (9 اشهر) والاشهر التي سوف يتم أخذها هي: (اذار، نيسان، ايار) ولثلاث سنوات (2015،2014،2013) وعلى التوالي. وفيما يخص الموسم الثالث ورمزه (S_3) حيث سيكون عدد المشاهدات (276) مشاهدة وعدد الشهور(9 اشهر) والاشهر التي سوف يتم أخذها هي: (حزيران، تموز، اب) ولثلاث سنوات (2015، 2014، 2013) وعلى التوالي. وكذلك بالنسبة للموسم الرابع ورمزه (S_4) سيكون عدد المشاهدات (243) مشاهدة وعدد الشهور (8 اشهر) والاشهر التي سوف يتم أخذها هي: (ايلول، تشرين الاول، تشرين الثاني) ولثلاث سنوات (2015، 2014، 2013) وعلى التوالي. ان الطرق المقترحة لتحسين التنبؤ بتلوث الهواء من خلال المتغير PM_{10} تم مقارنتها مع الانحدار الخطي المتعدد MLR ، اي مقارنة MLR-RNN مع نموذج MLR وستتم المقارنة في حالة البيانات الكلية والبيانات المتراصفة زمنيا.

2. الطرق المستخدمة للتنبؤ

في هذا الجانب تم التطرق إلى طرق التنبؤ الشائعة الاستخدام بالبيانات متعددة المتغيرات ومن بينها نموذج الانحدار الخطي المتعدد MLR. ورغم ما يوفره نموذج الانحدار الخطي المتعدد من جودة في نمذجة البيانات الا انه قد يكون غير ملائم للتنبؤ بالبيانات غير الخطية على اعتبار ان نموذج MLR نموذج خطي مما يؤدي إلى ظهور بعض النتائج والتنبؤات بدقة قليلة أحياناً في حالة استخدام نمذج خطية مثل نموذج الانحدار الخطي المتعددMLR . ولذلك يفضل استخدام طرق غير خطية مثل الشبكات العصبية المعاودة RNN مما يؤدي للحصول على نتائج اكثر دقة للتنبؤ والتحليل (Jahandideh *et al.*, 2009).

2.1 نموذج الانحدار الخطي المتعدد (MLR)

ان نموذج الانحدار الخطي المتعدد يعتبر من الأساليب الإحصائية شائعة الاستخدام والمستخدمة في التنبؤ خصوصا لبيانات السلاسل الزمنية عن طريق الاستخدام الأمثل للبيانات في إيجاد علاقات سببية بين بيانات الدراسة ويعرف الانحدار الخطي المتعدد بشكل عام بأنه أسلوب رياضي لتوضيح العلاقة بين المتغير المعتمد Dependent Variable ومتغيرات أخرى تسمى المتغيرات التفسيرية Explanatory Variables ويهتم تحليل الانحدار بوصف العلاقة بين المتغيرات على هيئة نموذج وقد يحتوي هذا النموذج على متغير تفسيري واحد فيسمى في هذه الحالة بنموذج الانحدار الخطي البسيط أما في حاله احتواء النموذج على عدة متغيرات تفسيرية عدة فإنه يسمى بنموذج الانحدار الخطي المتعدد (Honarasa *et al.*, 2015). كما ويعرف نموذج الانحدار الخطي المتعدد MLR بأنه عبارة عن انحدار

للمتغير المعتمد y على العديد من المتغيرات التفسيرية $X_1, X_2, X_3 \ldots\ldots, X_m$ لذا فهو يستخدم في التنبؤ. إذ يتم استخدام MLR لشرح العلاقة بين متغير معتمد ومتغيران تفسيريان أو أكثر تتخذ المعادلة الخطية في الانحدار الخطي المتعدد الشكل التالي (Abrougui *et al.*, 2019)

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \ldots + \beta_m x_m + ei \qquad (1)$$

اذ أن y يرمز الى المتغير المعتمد و α ترمز الى القيمة الثابتة و X_1 يرمز الى المتغير التفسيري الأول و X_2 يرمز الى المتغير التفسيري الثاني و X_m يرمز الى المتغير التفسيري الاخير ويرمز β_1 يرمز الى المعلمة الخاصة بالمتغير التفسيري الاول X_1 ويرمز β_2 الى المعلمة الخاصة بالمتغير التفسيري الثاني X_2 ويرمز β_m الى المعلمة الخاصة بالمتغير التفسيري الاخير X_m و ei يرمز الى الخطأ العشوائي.

2.2 الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)

تعد الشبكات العصبية الاصطناعية أحد أهم طرق الذكاء الاصطناعي والتي تستخدم في التنبؤ بالمتغير المعتمد للحصول على دقة اكبر، و تتمحور فكرتها حول محاكاة قدرة العقل البشري على التعرف على الأنماط وتمييز الأشياء باستخدام الحاسب الآلي، والتي يتم فيها الاستفادة من الخبرات السابقة في سبيل الوصول إلى أفضل نتائج في المستقبل(Lin *et al.*, 2020). تتكون الشبكات العصبية الاصطناعية من مجموعةٍ من الخوارزميات يتم من خلالها محاكاة الدماغ البشري المتطور، وتصنيع أدمغة إلكترونية قادرة على التعلم والتطور كما الدماغ البشري. والمميز في الشبكات العصبية الاصطناعية هو وجود طبقات عديدة تعمل على ما يسمى التعلم العميق، كل طبقة مختصة بعمل معين (Zhou *et al.*, 2020). توجد عدة أنواع من الشبكات العصبية الشائعة الاستخدام واهم هذه الانواع والتي تؤدي غالبا الى نتائج اكثر دقة هي الشبكات العصبية المعاودة Recurrent Neural Network (RNN) (Torkashvand *et al.*, 2017). ان الشبكات العصبية المعاودة تستخدم مخرجات طبقة معينة وتعيدها مرة أخرى للشبكة لكن كمدخلات ونتيجة لذلك يمكن أن يساعد ذلك في التنبؤ بالعديد من النتائج المحتملة خلال أي طبقة من طبقات الشبكة فتحتفظ كل طبقة بذاكرة من الخطوة السابقة فيتذكر النظام التنبؤات الخاطئة ويتعلم منها لتحسين تنبؤاته التالية ولذلك تسمى باسم الشبكات المعاودة لمعاودتها نفس الخطوات حتى الوصول إلى النتائج المطلوبة وبالتالي تستطيع شبكات RNN التعلم من كل خطوة للتنبؤ بالنتيجة في الخطوة التالية. تحتوي RNN على طبقة واحدة او اكثر وهذا بدروه يعالج غير خطية البيانات ويحسن نتائج التنبؤ وكذلك تحوي على Daley Layer وهذا يحسن كثيراً التعامل مع مشكلة عدم تجانس البيانات وعدم الخطية لانه يحتوي على ذاكرة اطول بقليل من خوارزمية الشبكة العصبية المغذية Feed-Forward Back Propagation والشكل التالي يمثل الشبكة وما تحتويه من ادخالات واخراجات وطبقات .

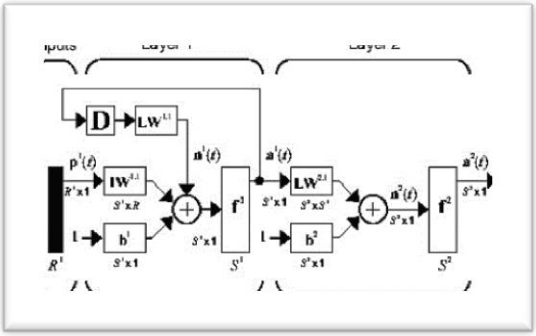

الشكل(1) : يوضح الشبكة العصبية المعاودة RNN

في الشكل (1) فأن R هي الادخالات وLW1 هي وزن عشوائي للعصبون حيث يتم جمعها مع الجزء المتحيز b1(التشويش الابيض) وناتجهما سيكونان الدالة f1. حيث ان اخراج الدالة f1 سيعود كادخال ثالث في الطبقة الاولى وقبلها سوف يمر على دالة التاخير(Delay) لتكون وزنا عشوائيا اخر وفي الطبقة الثانية فأن اخراج الدالة f يكون الوزن العشوائي للخلية العصبية LW مجموع مع b وبالتالي تخرج لنا مصفوفة احادية. تحتوي RNN في هذه الدراسة على طبقتين بالاضافة الى طبقة الادخال، الاولى تكون مخفية والثانية تكون طبقة الاخراج. حيث في طبقة الادخال سيكون هناك (R) من الادخالات وهذه الادخالات غالبا ماتكون توزن عشوائيا في كل طبقة مخفية وكذلك M من العصبونات.حيث يتم حساب العدد الامثل للعصبونات في الطبقة المخفية كما يلي:

عدد العصبونات= R*2+1 (2)

(Palit & Popovic, 2006; Sheela & Deepa, 2013)

كل متغير ادخال Z موزون عشوائيا. وان اوزان N من الادخالات و M من العصبونات تجمع مع القيمة المتحيزة b بواسطة دالة التحويل. مجموع ادخالات المتغيرات في دالة التحويل F يمكن صياغتها كما ياتي:

$$net_j(t) = \sum_{i=1}^{N} w_{i,j} Z_j(t) + b_j \qquad (3)$$

وان اكثر دوال التحويل استخداما في الطبقة المخفية وطبقة الاخراج هي التحويل الزاوي (tan-sigmoid) والتحويل اللوغارتمي(log-sigmoid) ودالة التحويل الخطي (linear). ان عملية اختيار الدالة للطبقتين امر مهم جدا يؤدي الى تحسين دقة النتائج بالاعتماد على طبيعة البيانات والدالة المختارة ومدى التجانس بينهما، الشكل(2) يوضح الاختلافات بين دوال التحويل الممكن استعمالها للشبكة RNN.

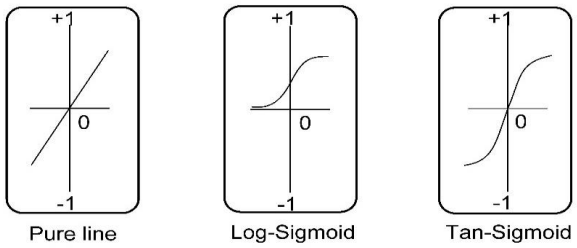

الشكل(2) : انواع دوال التحويل في RNN

تستعمل دوال التحويل في الطبقة المخفية لتعكس نوعية العلاقة بين الادخالات والاخراجات في حين تستعمل دوال التحويل في طبقة الاخراج لتعطي افضل وادق النتائج. والصيغ الرياضية للدوال الخطية واللوغارتيمية والزاوية هي كما يلي وعلى التوالي:

$$f(SUM) = SUM \qquad (4)$$

$$f(SUM) = \frac{1}{1+e^{-SUM}} \qquad (5)$$

$$f(SUM) = \frac{2}{1+e^{-2SUM}} - 1 \qquad (6)$$

(Dawson & Wilby, 2001; Shrestha *et al.*, 2005; Yonaba *et al.*, 2010)

ان الاوزان العشوائية $w_{i,j}$ للادخالات يمكن كتابتها كمصفوفة وعلى النحو التالي

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{M,1} & w_{M,2} & \cdots & w_{M,R} \end{bmatrix} \qquad (7)$$

في حين تصاغ متغيرات الادخال كما يلي :

$$Z = \begin{bmatrix} Z_{t1} & Z_{t2} & \cdots & Z_{tR} \end{bmatrix}' \qquad (8)$$

حيث ان الهيكل العام للشبكة RNN يحتوي على طبقة واحدة مخفية واخرى للاخراج، حيث الطبقة المخفية تحتوي على ثلاث مدخلات الوزن العشوئي والتشويش الابيض بالاضافة الى الوزن الناتج من الخطوة السابقة اما الطبقة الخارجية فمدخلاتها ستكون الوزن الناتج من الطبقة المخفية مع التشويش الابيض ويمكن تمثله كما في الشكل (3) :

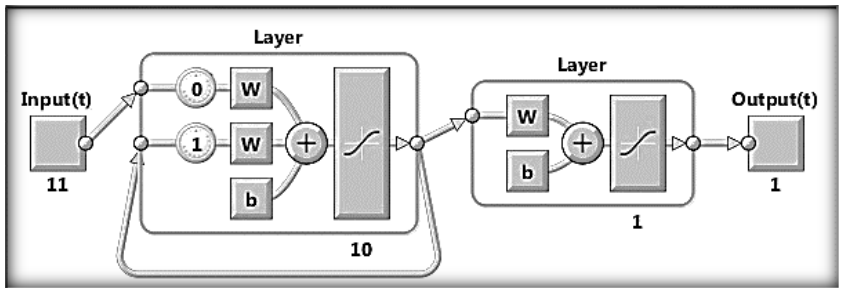

الشكل (3) : الهيكل العام للشبكة العصبية المعاودة RNN

2.3 الطريقة الهجينة(MLR-RNN)

تتضمن هذه الطريقة تهجين الطريقتين التقليدية (MLR) والذكائية (RNN) من خلال الاستفادة من هيكلية المتغيرات التفسيرية في MLR لبناء الشبكة RNN وكما هو مدرج في الخطوات التالية:

أ. يتم ضرب كل متغير تفسيري في قيمة المعلمة المناظرة له واعتماد المتغيرات الناتجة كمدخلات للشبكة العصبية المعاودة (RNN) وبناء طبقة الادخال .

ب. تحديد عدد العصبونات المستخدمة في الطبقة المخفية.

ج. بعد اعتماد هيكلية نموذج MLR لطبقة الادخال للشبكة العصبية حيث تتم عمليتي التدريب والاختبار للحصول على افضل التنبؤات وتسمى مخرجات شبكة RNN في هذه الحالة هذه بتنبؤات لطريقة الهجينة للشبكات العصبية MLR-RNN، حيث كلما تكررت التدريبات وكانت اكثر كلما كانت النتيجة ادق.

د. يتم تدريب الشبكة على جميع دوال التحويل الخطية واللوغارتمية والزاوية في كلا الطبقتين المخفية والاخراج وبأخذ جميع الاحتمالات الممكنة .

3. التراصف الزمني(Time-stratified (TS:

ان اسلوب التراصف الزمني هو وسيلة تحليلية تقوم بمراصفة البيانات زمنيا تبعا للتأثيرات الموسمية التي تظهر بشكل واضح كتأثيرات على سلوك السلسلة الزمنية وسلوك النتائج التنبؤية ويضمن دقة تقديرات معلمات الانحدار الخطي المتعدد ويتجنب التحيز بسبب اتجاه التاثيرات الزمنية في السلسلة الزمنية، ويمكن تطبيق التراصف الزمني على السلاسل الزمنية المختلفة في حالة كانت تظم اتجاهات زمنية موسمية متكررة بنفس السياق والتأثير ويعمل على الوصول الى بيانات اكثر تجانسا من البيانات الكلية وبالتالي الحصول على نتائج ادق (Malig *et al.*, 2015; Tobias *et al.*, 2014)

أ. ويمكن ايجاز الخطوات التي يتم بها التراصف الزمني بالنقاط الاتية: رسم بيانات السلسلة الزمنية المحددة للبيانات.

ب. تحديد الفترات الموسمية وفي نمط الموسم.

ج. سحب البيانات في هذه الفترات من السلسلة ومراصفتها.

4. مقياس خطأ التنبؤ Forecasting Error Measurement

سيتم استخدام واقتراح العديد من الطرائق والاساليب، وللمقارنة بينها سيتم استخدام متوسط النسبة المئوية المطلقة للخطأ (MAPE) Mean Absolute Percentage Error. ويعرف الخطأ بأنه هو تقدير للفرق بين القيمة الحقيقية والقيمة المقدرة حيث كلما كان الخطأ قليل فستكون الدقة اكبر. ويحسب مقياس الخطأ MAPE على النحو التالي:

$$MAPE = \frac{1}{n}\left[\sum\left|\frac{e_i}{y_i}\right|\right]\times 100 \qquad (9)$$

حيث e_i: تمثل خطأ التنبؤ، n : هي عدد المشاهدات، $i= 1,2,3,\ldots\ldots,m$

yi : هو السلسلة الحقيقة او الاصلية المستعلمة كمتغير هدف. ويحسب خطأ التنبؤ كما يلي:

$$e_i = y_i - \hat{y}_i \qquad (10)$$

5. النتائج والمناقشات

في هذه الدراسة تم استخدام طريقة احصائية تقليدية شائعة الاستخدام متمثلة بنموذج MLR للتنبؤ بالجسيمات المعلقة بالهواء المتمثل بمقياس (PM_{10}). وكذلك تم اقتراح طريقة اخرى لتحسين التنبؤ بتلوث الهواء لمتغير PM_{10} بعد تهجينها مع الطريقة التقليدية. وقد تمت مقارنتها مع الانحدار الخطي المتعدد MLR في حالة البيانات الكلية وفي حالة البيانات المتراصفة زمنيا ورغم ما يوفره الانحدار الخطي المتعدد من امكانية نمذجة البيانات لاستخدامه في التنبؤ بالمتغير المعتمد إلا أن بيانات التلوث الجوي والأرصاد الجوية تأخذ نمطاً غير خطياً مما يؤدي إلى ظهور بعض النتائج والتنبؤات بدقة قليلة أحياناً وقد حسنت الطريقة الهجينة المقترحة من نتائج التنبؤ من خلال ما تضمنته من حلول وامكانات للتعامل مع البيانات غير الخطية. (Jahandideh *et al.*, 2009). تم تقسيم البيانات الى قسمين قسم تدريب وقسم اخر للاختبار وكما مدرج ادناه:

1. بيانات التدريب : ستبدأ من الفترة(1/1/2013) الى (31/5/2015)

2. بيانات الاختبار: ستبدأ من الفترة (1/6/2015) الى (31 /10/2015) والتي تقارب نسبة 15% من البيانات وهو ضمن المعدل الذي تناولته معظم البحوث في مجال الدراسة.

وبهذا سيكون هناك (881) مشاهدة للتدريب و(153) مشاهدة للاختبار وسيتم استخدام طريقة الانحدار MLR حيث تم حذف المتغيرات غير المعنوية اعتمادا على قيمة P-value كما سنشاهده في النتائج ادناه وقد تم اختيار افضل معادلة نموذج انحدار خطي متعدد اعتمادا على افضل تفسير للعلاقة والتأثير ومعنوية المعلمات حيث ان افضل نموذج انحدار خطي متعدد في حالة البيانات الكلية كما مدرج ادناه:

$$y = 79.01x_1 + 3501x_2 - 2029x_3 + 197.6x_4 \qquad (11)$$

حيث يمكن تعريف متغيرات ومعلمات نموذج الانحدار الخطي المتعدد في (11) كما هو ادناه:

y : هو متغير الاستجابة PM_{10} و x_1 : يمثل متغير احادي اكسيد الكاربون CO و x_2: يمثل متغير ثنائي اكسيد الكبريت SO_2 و x_3: يمثل متغير احادي اكسيد النيتروجين NO و x_4: يمثل متغير الاوزون O_3. نلاحظ من خلال المعادلة (11) التي تمثل نموذج الانحدار الخطي المتعدد ان معاملات المتغيرات التفسيرية β_1 , β_2 , β_3 , β_4 تساوي (79.01)،(179.60)،(−2029)،(3501) على التوالي والتي تمثل قيمتها قوة تأثير المتغير التفسيري على المتغير المعتمد بينما توضح الاشارة اتجاه ذلك التأثير.

ان جميع المعلمات المقدرة معنوية لان قيم p−value هي اقل من مستوى المعنوية(0.05) مما يدل على معنوية المعلمات وكفاءة النموذج ولذلك فيعتبر النموذج الامثل. ان نتائج تنبؤات مرحلتي التدريب والاختبار من حيث دقتها مقاسة من خلال قيمة MAPE كما في الجدول(2).

الجدول(2): قيم(MAPE) في حالة البيانات الكلية باستخدام نموذج MLR

بيانات الاختبار	بيانات التدريب
28.011285	27.223691

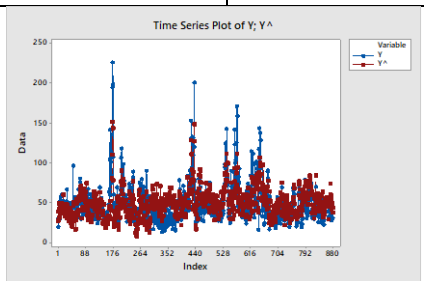

الشكل (4): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) خلال الفترة الكلية لبيانات التدريب في MLR.

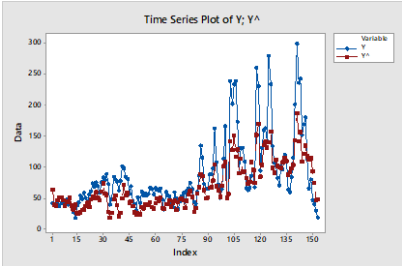

الشكل (5): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) خلال الفترة الكلية لبيانات الاختبار باستخدام MLR.

الجدول(3): قيم(MAPE) في حالة البيانات الكلية باستخدام MLR−RNN

بيانات الاختبار	بيانات التدريب
29.6825	22.0665

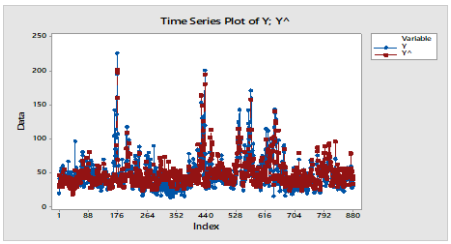

الشكل(6): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) للفترة الكلية لبيانات التدريب باستخدام-MLR RNN .

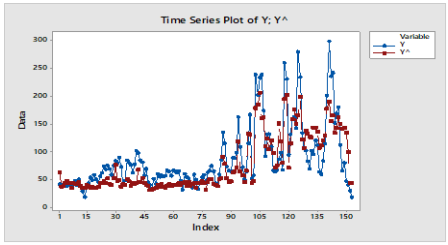

الشكل(7): التطابق بين البيانات الاصلية مع البيانات التقديرية للمتغير المعتمد(PM_{10}) للفترة الكلية لبيانات الاختبار باستخدام -MLR RNN.

حيث تم بناء افضل النماذج من خلال استخدام بيانات التدريب ثم التنبؤ بها اما بيانات الاختبار فتم التنبؤ بها باستخدام نفس النموذج الذي تم انشاؤه من بيانا التدريب، ولهذا السبب فأن دقة التنبؤ لبيانات التدريب علميا(التنبؤ داخل العينة In of sample forecasting) سيكون ادق من التنبؤ بالمشاهدات المستقبلية للسلسلة في حين لايمكن مقارنة النتائج للتنبؤ لبيانات التدريب والاختبار لاختلاف حجم العينة بينهما، ولنفس السبب فأن افضلية نتائج التنبؤ لبيانات التدريب باستخدام MLR-RNN مقارنة مع MLR وهي التي يمكن الحكم بها على الطريق الافضل وليس من خلال نتائج بيانات الاختبار. يلاحظ من الجدولين(2 و3) والأشكال(4−7) ان هنالك تقارب وانسجام بين القيم الحقيقية والقيم المقدرة التنبؤية باستخدام MLR-RNN وبصورة اكثر انسجاما مما كانت عليه في نموذج MLR وهذا يدل على ان الطريقة الهجينة RNN-MLR افضل من الطريقة التقليدية وهي نموذج MLR. بعد الحصول على التنبؤات لبيانات التدريب والاختبار للبيانات في الفترة الكلية فسيتم تقسيم البيانات الى اربعة مواسم من خلال استخدام التراصف الزمني وسيتم اتخاذ الاجراءات نفسها التي تم انجازها مع البيانات الكلية لكل موسم على حدة باستخدام الطرق نفسها MLR و MLR-RNN وكذلك سيتم تقسيم البيانات الى مجموعتين بيانات تدريب وبيانات اختبار لكل موسم. بعد تقسيم البيانات الى بيانات تدريب وبيانات اختبار سيتم استخدام بيانات التدريب لايجاد افضل نموذج انحدار خطي متعدد لاربع مواسم S_1 وS_2 وS_3 وS_4 يعبر عنها وكما هو في المعادلات ادناه.

$$y = 16.46x_1 + 4357x_2 + 210x_3 + 954x_4 \quad (12)$$

$$y = 81.56x_1 + 1887x_2 - 2194x_3 + 308.3x_4 \quad (13)$$

$$y = 122.76x_1 - 3117x_2 - 2179x_3 + 358x_4 \quad (14)$$

$$y = 82.02x_1 + 6149x_2 - 2387x_3 - 120x_4 \quad (15)$$

ولغرض اجراء المقارنة مع البيانات الكلية فسيتم القبول بالنماذج(12−15) اعلاه على الرغم من عدم معنوية بعض معلماته لاثبات هيكلية موحدة للمتغيرات كوجه للتشابه ليصح اجراء المقارنات على التوالي حتى في حال كانت بعض المعلمات غير معنوية وذلك لانه تم استخدام نموذج للانحدار الخطي المتعدد بنفس المتغيرات للبيانات الكلية . والجدول (4) سيوضح قيم مقياس الخطأ.

الجدول(4): قيم (MAPE) في حالة استخدام نموذج MLR.

	بيانات التدريب	بيانات الاختبار
S_1	25.317	25.027
S_2	20.739	22.057
S_3	24.823	19.028
S_4	31.627	29.683

الأشكال (8−15) ادناه توضح الانسجام بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات التدريب والاختبار للبيانات المتراصفة زمنياً باستخدام نموذج (MLR).

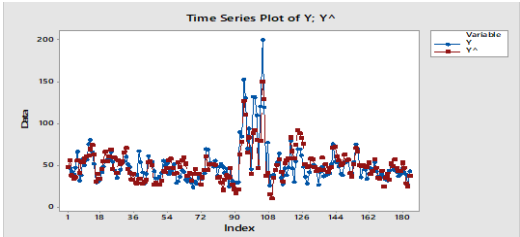

الشكل(9): التطابق بين البيانات الاصلية مع البيانات التقديرية(سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات الاختبار للموسم (S_1) باستخدام(MLR)

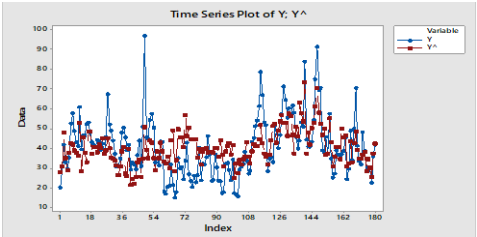

الشكل (8) التطابق بين البيانات الاصلية مع البيانات التقديرية(سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات التدريب للموسم الاول (S_1) باستخدام(MLR)

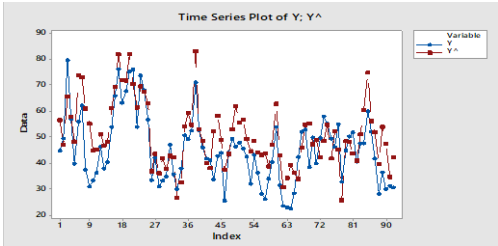

الشكل(11): التطابق بين البيانات الاصلية مع البيانات(سلسلة التنبؤ) التقديرية للمتغير المعتمد(PM_{10}) لبيانات الاختبار للموسم(S_2) باستخدام(MLR)

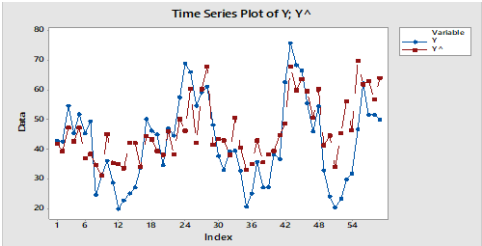

الشكل(10): التطابق بين البيانات الاصلية مع البيانات التقديرية(سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات التدريب للموسم(S_2) باستخدام (MLR)

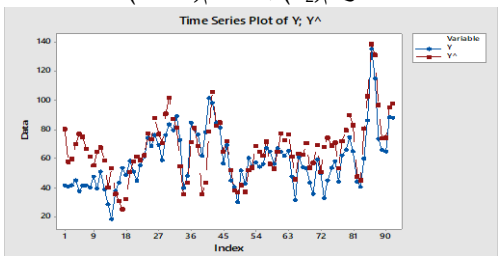

الشكل(13): التطابق بين البيانات الاصلية مع البيانات التقديرية(سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات الاختبار للموسم(S_3) باستخدام (MLR)

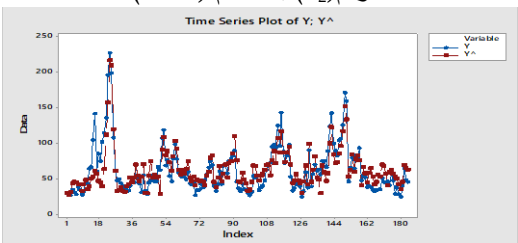

الشكل(12): التطابق بين البيانات الاصلية مع البيانات التقديرية(سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات التدريب للموسم (S_3) باستخدام(MLR)

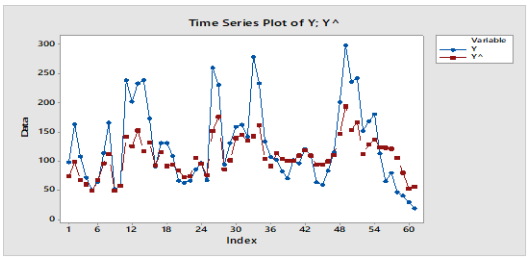

الشكل(15): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات الاختبار للموسم (S_4) في (MLR)

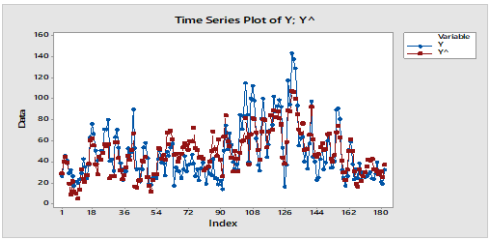

الشكل(14): التطابق بين البيانات الاصلية مع البيانات التقديرية للمتغير المعتمد(PM_{10}) لبيانات التدريب للموسم(S_4) باستخدام (MLR)

ومن الاشكال (8–15) اعلاه فممن الممكن استنتاج انه باستخدام عملية التراصف الزمني وتقسيم البيانات الى مواسم فأن الفرق بين الاخطاء الحقيقية والاخطاء التقديرية تكون اقل مما كانت عليه في حالة البيانات الكاملة باستخدام MLR. بعد ان تم تطبيق(MLR) على البيانات الموسمية سيتم تهجين للشبكات العصبية المعاودة (RNN) باستخدام نموذج(MLR) وتسمى هذه الطريقة MLR-RNN الهجينة وكل موسم من هذه المواسم على حدة والجدول (5) يوضح قيم مقياس الخطأ MAPE لبيانات التراصف الزمني للتدريب والاختبار باستخدام طريقة MLR-RNN الهجينة .

الجدول(5): قيم (MAPE) في حالة استخدام طريقة MLR-RNN الهجينة .

	بيانات التدريب	بيانات الاختبار
S_1	21.486	20.641
S_2	15.942	18.203
S_3	16.433	20.239
S_4	23.950	37.750

وعند مقارنة نتائج الخطأ (MAPE) للطريقة الهجينة(MLR-RNN) مع نتائج (MAPE) لنموذج الانحدار(MLR) في الجدولين (4 و5) يتبين ان معظم نتائج الطريقة الهجينة خصوصا لبيانات التدريب تفوقت على نتائج نموذج MLR واعطت نتائج اكثر دقة .

الأشكال (16–23) ادناه توضح مدى التطابق والانسجام بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) للمتغير المعتمد(PM_{10}) لبيانات التدريب والاختبار لجميع البيانات المتراصفة زمنياً للمواسم الاربعة باستخدام الطريقة الهجينة (MLR-RNN).

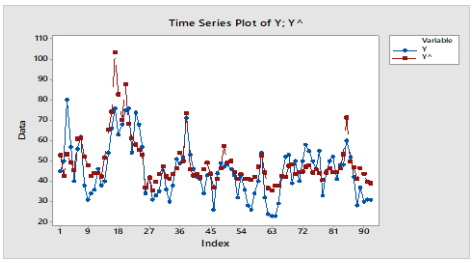

الشكل(19): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات الاختبار للموسم (S_2) باستخدام (MLR-RNN).

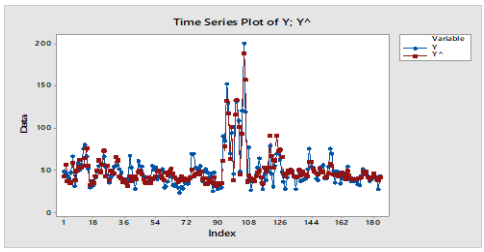

الشكل(18): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات التدريب للموسم (S_2) باستخدام(MLR-RNN).

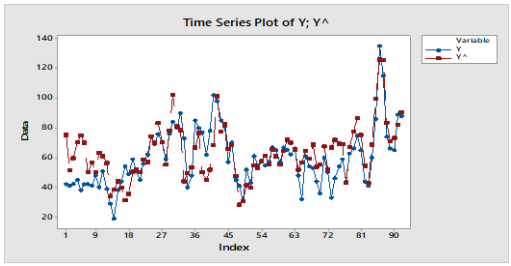

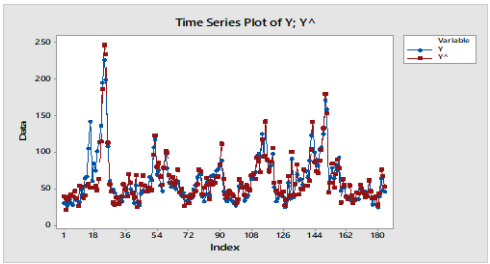

الشكل(20): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات التدريب للموسم (S_3) باستخدام (MLR-RNN).

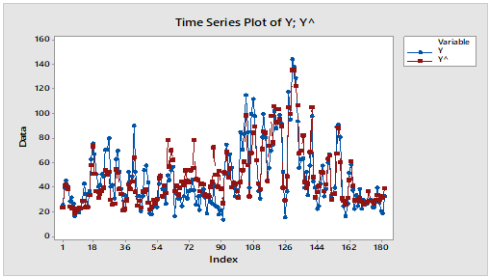

الشكل(21): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات الاختبار للموسم (S_3) باستخدام (MLR-RNN).

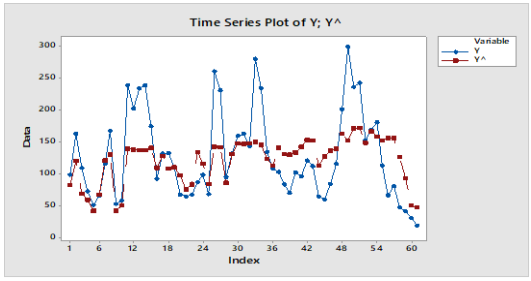

الشكل(22): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات التدريب للموسم (S_4) باستخدام MLR-RNN.

الشكل(23): التطابق بين البيانات الاصلية مع البيانات التقديرية (سلسلة التنبؤ) (PM_{10}) لبيانات الاختبار للموسم (S_4) باستخدام MLR-RNN.

ومن الاشكال (16–23) اعلاه وكذلك من خلال المقارنة بين الطريقتين المقترحتين فأن التطابق بين السلسلتين باستخدام MLR-RNN افضل من النموذج MLR للبيانات المتراصفة زمنياً وكذلك افضلية نتائج التنبؤ للبيانات المتراصفة زمنيا مع حالة البيانات الكلية حيث تم بناء افضل النماذج من خلال استخدام بيانات التدريب ثم التنبؤ بها اما بيانات الاختبار فتم التنبؤ بها باستخدام نفس النموذج الذي تم انشاؤه من بيانا التدريب، ولهذا السبب فأن دقة التنبؤ لبيانات التدريب سيكون ادق من التنبؤ بالمشاهدات المستقبلية للسلسلة في حين لا يمكن مقارنة النتائج للتنبؤ لبيانات التدريب والاختبار لاختلاف حجم العينة بينهما، ولنفس السبب فأن افضلية نتائج التنبؤ لبيانات التدريب باستخدام MLR-RNN مقارنة مع MLR وهي التي يمكن الحكم بها على الطريق الافضل وليس من خلال نتائج بيانات الاختبار.

6. الاستنتاجات

من خلال ما تم عرضه من نتائج ومناقشات للطرق المقترحة وتطبيقها على بيانات الدراسة فمن الممكن استنتاج افضلية لاستخدام منهجية الطريقة الهجينة المقترحة MLR-RNN لتحسين نتائج التنبؤ لتلوث الهواء وخصوصا في حالة استخدام اسلوب التراصف الزمني لبيانات الدراسة والذي يحسن نتائج التنبؤ لتلوث الهواء.

7. Reference

1. Abrougui, K., Gabsi, K., Mercatoris, B., Khemis, C., Amami, R., & Chehaibi, S. (2019). Prediction of organic potato yield using tillage systems and soil properties by artificial neural network (ANN) and multiple linear regressions (MLR). *Soil and Tillage Research*, *190*, 202-208 .
2. Ahmad, M., Alam, K., Tariq, S., Anwar, S., Nasir, J., & Mansha, M. (2019). Estimating fine particulate concentration using a combined approach of linear regression and artificial neural network. *Atmospheric Environment* .117050 ،219 ،
3. Dawson, C., & Wilby, R. (2001). Hydrological modelling using artificial neural networks. *Progress in physical Geography*, *25*(1), 80-108 .
4. Honarasa, F., Yousefinejad, S., Nasr, S., & Nekoeinia, M. (2015). Structure–electrochemistry relationship in non-aqueous solutions: predicting the reduction potential of anthraquinones derivatives in some organic solvents. *Journal of Molecular Liquids*, *212*, 52-57 .
5. Jahandideh, S., Jahandideh, S., Asadabadi, E. B., Askarian, M., Movahedi ،M. M., Hosseini, S., & Jahandideh, M. (2009). The use of artificial neural networks and multiple linear regression to predict rate of medical waste generation. *Waste management*, *29*(11), 2874-2879 .
6. Janssen, N. A., Hoek, G., Simic-Lawson, M., Fischer, P., Van Bree, L., Ten Brink, H., . . . Brunekreef, B. (2011). Black carbon as an additional indicator of the adverse health effects of airborne particles compared with PM10 and PM2. 5. *Environmental health perspectives*, *119*(12), 1691-1699 .
7. Lin ،L., Dekkers, I. A., Tao, Q., & Lamb, H. J. (2020). Novel artificial neural network and linear regression based equation for estimating visceral adipose tissue volume. *Clinical Nutrition* .
8. Malig, B. J., Pearson, D. L., Chang, Y. B., Broadwin, R., Basu, R., Green, R. S., & Ostro, B. (2015). A time-stratified case-crossover study of ambient ozone exposure and emergency department visits for

specific respiratory diagnoses in California (2005–2008). *Environmental health perspectives, 124*(6), 745-753 .

9. Palit, A. K., & Popovic, D. (2006). *Computational intelligence in time series forecasting: theory and engineering applications*: Springer Science & Business Media.
10. Sheela, K. G., & Deepa, S. N. (2013). Review on methods to fix number of hidden neurons in neural networks. *Mathematical Problems in Engineering, 2013* .
11. Shrestha, R. R., Theobald, S., & Nestmann, F. (2005). Simulation of flood flow in a river system using artificial neural networks. *Hydrology and Earth System Sciences Discussions, 9*(4), 313-321 .
12. Tobias, A., Armstrong, B., & Gasparrini, A. (2014). *Analysis of time-stratified case-crossover studies in environmental epidemiology using Stata*. Paper presented at the United Kingdom Stata Users' Group Meetings 2014.
13. Torkashvand, A. M., Ahmadi, A., & Nikravesh, N. L. (2017). Prediction of kiwifruit firmness using fruit mineral nutrient concentration by artificial neural network (ANN) and multiple linear regressions (MLR). *Journal of integrative agriculture, 16*(7), 1634-1 .644
14. Vlachogianni, A., Kassomenos, P., Karppinen, A., Karakitsios, S., & Kukkonen, J. (2011). Evaluation of a multiple regression model for the forecasting of the concentrations of NOx and PM10 in Athens and Helsinki. *Science of the total environment, 409*(8), 1559-1571 .
15. Yonaba, H., Anctil, F., & Fortin, V. (2010). Comparing sigmoid transfer functions for neural network multistep ahead streamflow forecasting. *Journal of Hydrologic Engineering, 15*(4), 275-283 .
16. Zhou, F., Liu, B., & Duan, K. (2020). Coupling wavelet transform and artificial neural network for forecasting estuarine salinity. *Journal of Hydrology*, 125127 .

Air Pollution Forecasting using Hybrid MLR-RNN Method with Time-Stratified Method

Khitam Walid Qader Osama Bashir Shukr
College of Computer and Mathematical Science, University of Mosul

Abstract

studying and forecasting Particular matter (PM_{10}) is necessary to control and reduce the damage of environment and human health. There are many pollutants as sources of air pollution may effect on PM_{10} variable. This type of dataset can be classified as anon-linear. Studied datasets have been taken from climate station in Malaysia. Multiple Linear Regression (MLR) is used as a linear statistical method for PM_{10} forecasting through its influencing by corresponding climate variables, therefore it may reflect inaccurate results when used with nonlinear datasets. Time stratified (TS) method in different styles is implemental for satisfying more homogeneity of datasets. It includes ordering similar seasons in different years together to formulate anew variable smoother than their original. To improve the results of forecasting, Recurrent Neural Network (RNN) has been suggested to be used after combining with MLR in hybrid MLR-RNN method in this study. In general, the results of forecasting were the best with using time stratified approach. In addition, the results of hybrid method were outperformed comparing to MLR model. As conclusion in this study, RNN and TS can be used as active approaches to obtain better forecasting results with nonlinear datasets in which PM_{10} is to dependent variable.

Keywords: Multiple linear regression (MLR), Time Stratified (TS), Particular Matter (PM_{10}), Forecasting, Air Pollution, hybrid MLR-RNN.