



## استخدام نماذج ARIMA والغابة العشوائية للتنبؤ ببيانات الانواء الجوية

عدي زكي جرجيس الجبو리 و أسامة بشير الحنون

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

### الخلاصة

ان التغيرات المناخ دولاً مؤثراً قد يؤدي الى مشكلات كثيرة على صحة الإنسان وبقية الكائنات الحية لذا فانه من الضروري دراستها والتنبؤ بها للحد او للقليل من اضرارها من خلال التخطيط لها والسيطرة عليها. ان المشكلة الرئيسية تكمن في عدم خطية هذا النوع من البيانات وفوضويتها. ومن اشهر اساليب السلسل الزمنية استخداما هي نماذج الانحدار الذاتي والمتوسطات المتحركة المندمجة Integrated Autoregressive and Moving Average (ARIMA) model. كنماذج سلاسل زمنية تقليدية احادية المتغير. ان مثل هذه النماذج لا يمكنها التعامل بصورة سلية مع البيانات غير الخطية فتُظهر نتائج تنبؤ قليلة الدقة. في هذه البحث تم استخدام بيانات الانواء الجوية متمثلة بدرجات الحرارة الصغرى وكميات التبخر لاحظ مطرادات الانواء الجوية الزراعية في محافظة نينوى. تهدف هذه البحث الى تحقيق التجانس في البيانات خلال الموسما المختلفة وايجاد نموذج يتعامل مع البيانات غير الخطية ويعطي اقل خطأ للتنبؤ مقارنة بالنماذج التقليدي ARIMA. لذلك فقد تم استخدام نموذج اكثر تلاواماً مع بيانات الانواء الجوية ليعطي تنبؤات غاية في الدقة يدعى نموذج الغابة العشوائية (RF). ان من اهم اسباب تحسين نتائج التنبؤ هو اعتماد نموذج RF في اتخاذ القرار على العديد من اشجار الانحدار غير المترابطة والتي يؤدي كل منها الى قرار مستقل وأن القرار النهائي سيكون بالغالبية المطلقة لمجاميع اشجار الانحدار. تم الحصول على نتائج تنبؤ اكثر دقة باستخدام نموذج RF مقارنة بنتائج تنبؤات ARIMA في مرحلتي التدريب والاختبار. من ذلك فانه تم استنتاج افضلية مطلقة لنموذج RF اذا ما قورن مع نموذج ARIMA التقليدي عند التنبؤ بالبيانات المناخية.

### معلومات النشر

#### تاريخ المقالة:

تم استلامه في 25 ايار 2022  
تم القبول في 23 تموز 2022  
متحاً على الانترنت في 1 كانون الاول 2022

#### الكلمات الدالة:

نموذج الانحدار الهرمي بواسون مع اعتراض عشوائي ، وطريقة الاحتمال الأقصى الكامل ، ومعامل الارتباط داخل الفصل ، والتأثيرات الثابتة والعشوائية

#### المراسلة:

عدي زكي جرجيس الجبو리  
[alastadhdhyeljbwry@gmail.com](mailto:alastadhdhyeljbwry@gmail.com)

DOI: [10.33899/IQJOSS.2022.176203](https://doi.org/10.33899/IQJOSS.2022.176203) , ©Authors, 2022, College of Computer Science and Mathematics, 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 البحث تم التطرق الى دراسة التنبؤ ببعض متغيرات الانواء الجوية اذ تكمن أهمية هكذا تنبؤات من خلال معرفة مدى تأثيرها على الانسان والحيوان والنبات وسائر الكائنات الحية والتخطيط لمستقبل خالي من مشاكل التأثيرات السلبية لمتغيرات الانواء الجوية المختلفة وغنى بتأثيراتها الإيجابية. تم استخدام نموذج ARIMA كأسلوب تقليدي شائع الاستخدام وبعد عدة محاولات تم الحصول على افضل نموذج ARIMA يلائم بيانات الدراسة. في هذه البحث تم استخدام بيانات الانواء الجوية متمثلة بدرجات الحرارة الصغرى وكميات التبخر لاحظ مطرادات الانواء الجوية الزراعية في محافظة نينوى للفترة من 15/5/2018 (ولغاية 19/7/2020). ان العديد من الباحثين في دراسات سابقة استخدمو بيانات الانواء الجوية على اختلافها للتنبؤ واستنتجوا عدم خطية بيانات الانواء الجوية على الاطلاق ولذلك قد يكون نموذج ARIMA غير دقيق في نتائج التنبؤ لوجود تلك المشكلة في البيانات ولذلك الأسباب يقترح غالباً استخدام اساليب أخرى غير خطية تتعامل مع هكذا نوع من البيانات بشكل أفضل وبالتالي تعطي نتائج أفضل في التنبؤ مقارنة بنماذج ARIMA. تعتبر نماذج الغابة العشوائية Random Forest طريقة دقيقة وقوية للغاية في التنبؤ بسبب اعتمادها في اتخاذ القرار على العديد من اشجار القرار حيث تكون اشجار القرار هذه غير مترابطة وكل منها تؤدي الى قرار مستقل وفي نهاية الامر فإن القرار النهائي لأسلوب الغابة العشوائية RF سيكون بالغالبية المطلقة لقرارات اشجار الانحدار التي تكون منها الغابة العشوائية مما يجعل من اسلوب الغابة العشوائية اسلوباً حصيناً ضد عدم خطية البيانات وكذلك عدم تجانسها.

ان بيانات الانواع الجوية تعد بشكل عام أحد أنواع السلاسل الزمنية التي تحتوي على العديد من المتغيرات الموسمية وكذلك الدورية التي قد تؤثر سلبا في جعل هذا النوع من البيانات غير متجانسة وكذلك تؤثر في نتائج التنبؤ ودقها. لذلك ولتحقيق التجانس الى حد كبير في بيانات الدراسة الممتثلة بدرجات الحرارة الصغرى وكذلك كميات التبخر فقد قسمت البيانات الى قسمين وفقا لطبيعة الأجزاء في محافظة نينوى. القسم الأول من البيانات يضم الأشهر الحارة ومشاهداتها في حين يضم القسم الثاني الأشهر الباردة. تضم الأشهر الحارة بيانات الأشهر (أيار، حزيران، تموز، آب، أيلول) فيما تضم الأشهر الباردة (تشرين الثاني، كانون الأول، كانون الثاني، شباط، اذار).

قام (Shukur and Lee, 2015) باستخدام أنموذج ARIMA للتتبؤ ببيانات السلسلة الزمنية الخاصة بسرعة الرياح وكذلك استخدم أنموذج ARIMA مع أساليب أخرى ذكائية ضمن نماذج هجينه للتتبؤ وكذلك لتقدير القيم المفقودة في السلسلة الزمنية وقد حصل الباحث على نتائج جيدة عند استخدامه أنموذج ARIMA. واقتراح (Chen et. at, 2012) أنموذج للتتبؤ والذي اعتمد على طريقة الغابة العشوائية للتتبؤ ببيانات السلسلة الزمنية المؤشر هطول الامطار في حوض نهر هايخة- الصين حيث أظهرت النتائج ان التتبؤ بأنموذج الغابة العشوائية RF يعطي قدرات تنبؤية افضل من أنموذج ARIMA. كما قدم (Kane et. at, 2015) مقترن بتطبيق أنموذج ARIMA وأنموذج RF وأنموذج الغابة العشوائية RF للتتبؤ ببيانات السلسلة الزمنية الخاصة بعرض انفلونزا الطيور (H1N5) في مصر حيث أظهرت نتائج الدراسة ان أنموذج RF تفوق في الأداء على أنموذج ARIMA .

تناولت هذه البحث التتبؤ لبيانات درجات الحرارة الصغرى وكميات التبخر للموسمين الحار والبارد ولفترتي التدريب والاختبار. توعدت الأساليب المستخدمة في هذه البحث بهدف حل المشاكل. ان بيانات الانواع الجوية تعد وكما ذكرت دراسات سابقة من البيانات غير الخطية مما يتطلب الامر اقتراح أساليب أكثر تلائماً مع بيانات الدراسة ذلك ان استخدام الأساليب الشائعة مثل أنموذج ARIMA قد يؤدي غالباً الى نتائج غير دقيقة. كذلك فان عدم التجانس في بيانات الدراسة نتيجة لاحتواها على العديد من الأنماط الموسمية والدورية قد يؤدي كذلك الى الحصول على نتائج غير سليمة.

يهدف هذا البحث على نحو رئيسي الى استخدام أساليب تؤدي للوصول الى تنبؤات أفضل دقة لمتغيرات الدراسة وتتألخص اهم الاهداف في استخدام اسلوب تقسيم البيانات الى قسمين أصغر لضمان تجانس البيانات وإعطاء نتائج ادق ويسمى هذا الأسلوب غالباً أسلوب التراصف الزمني Time stratified. كذلك يعد استخدام أنموذج الغابة العشوائية كطريقة تضمن تحسين دقة نتائج التتبؤ وذلك لاعتمادها في اتخاذ القرار النهائي على غالبية القرارات الفرعية للعديد من أشجار القرار المسقولة عن بعضها اي ان أنموذج الغابة العشوائية يعد اسلوباً محضناً في التعامل مع البيانات غير الخطية وقليلة التجانس مثل بيانات هذه الدراسة.

## 2. نموذج ARIMA وأنموذج الغابة العشوائية

### 1.2. نموذج ARIMA(p, d, q)

سيتم التطرق هنا الى التتبؤ باستخدام أنموذج (ARIMA) وأنموذج الغابة العشوائية. يعد اسلوب بوكس جنكير (Box-Jenkins) اساسا في تحليل السلاسل الزمنية والتعرف على أنموذج (ARIMA) للتتبؤ في بيانات السلسلة الزمنية. ومن ثم التطرق الى مفهوم الغابة العشوائية والطرق المستخدمة للتتبؤ مع كيفية استخدام بعض المقاييس لحساب دقة التنبؤات (Box, et. at, 2015).

تعرف السلاسل الزمنية بأنها مجموعة من المشاهدات يتم جمعها من ظاهرة معينة في فترات زمنية معينة وغالباً ما تكون هذه الفترات متساوية كأن تكون (يوم، أسبوع شهر، سنة، ، ... الخ) وتكون من متغيرين احدهما (مستقل) وهو متغير الزمن والأخر تابع (معتمد) حسب الظاهرة المدروسة، حيث ان الهدف من تحليل السلاسل الزمنية هو تكوين أنموذج لتقسيم سلوك السلاسل الزمنية واستحصل النتائج وذلك بالتبؤ بسلوك السلسلة المستقلة وبالاعتماد على البيانات الماضية. يعد أنموذج ARIMA (p,d,q) من ابرز واشهر السلاسل الزمنية الغير المستقرة (2006, wei) حيث ان (p) يشير الى رتبة أنموذج الانحدار الذاتي (d) يمثل الفروق اللازمة لتحقيق الاستقرارية و (q) يمثل الى رتبة المتوسطات المتحركة والصيغة العامة له:

$$\emptyset_p(B)(1 - B)^d Z_t = \theta_q(b)a_t \quad (1)$$

$$\emptyset(B)W_t = \theta(B)a_t \quad (2)$$

اذ ان

$$W_t = (1 - B)^d Z_t \quad (3)$$

حيث ان  $\emptyset_p$  هي معلمة أنموذج الانحدار الذاتي (MA) وان  $B$  هو عامل الازاحة الخلفي وان  $a_{t-k}$  تمثل الأخطاء او التغيرات العشوائية اعتماداً على  $a_t$  بفرض ان التغيرات العشوائية هي عمليات تشويش ابيض بوسط حسابي صفر وتبين ثابت ويمكن كتابته:

$$(1 - \emptyset_1B - \emptyset_2B^2 - \dots - \emptyset_pB^p)W_t = (1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q)a_t \quad (4)$$

Or

$$W_t = \emptyset_1W_{t-1} + \emptyset_2W_{t-2} + \dots + \emptyset_pW_{t-p} - \theta_1a_{t-1} - \theta_2a_{t-2} - \dots - \theta_qa_{t-q} + a_t \quad (5)$$

حيث تعتبر النماذج AR و MA حالات خاصة من نماذج (ARIMA) على فرض السلسلة الزمنية مستقرة بثبات التباين وخلوها من الاتجاه العام. ويمكننا ان نعبر عن أنموذج AR(p) بأنه أنموذج ARIMA(p, 0, 0) وعن أنموذج MA(q) بأنه أنموذج ARIMA(0, 0, q) وبعد اخذ الفروق الملائمة

وبرتبة ملائمة لها يتم اللجوء الى استخدام الأساليب نفسها لنماذج السلاسل الزمنية المستقرة (Wei, 1990) (Liu, 2006).

### 2.2. نموذج ARIMA( $P, D, Q$ ) الموسمي



تحقيق الاستقرارية للسلسلة الزمنية: تكون السلسلة الزمنية مستقرة إذا امتلكت وسطاً حسابياً وتبايناً ثابتاً في كثير من الحالات تكون السلسلة الزمنية غير مستقرة ويعود السبب في ذلك أما في سبب تغير في الوسط الحسابي عبر الزمن أي تملك اتجاهها عاماً أو بسبب تغير في تباين السلسلة عبر الزمن. فإذا كانت السلسلة الزمنية غير مستقرة يمكننا تحقيق الاستقرارية الضعيفة فيها أو في بعض الأحيان نسميها الاستقرارية من الدرجة الثانية (Chan, 2004; kitagawa; 2007; palma; 2010)

ويمكن تلخيص شروط الاستقرارية الضعيفة بالنقاط التالية:

- أ- استقرارية الوسط الحسابي واستقلاليته عن الزمن:

$$E(Z_t) = \mu_t = \mu_{t+k} \mu = \frac{1}{n} \sum_{t=1}^n Z_t \quad (11)$$

حيث أن  $\mu$  هو الوسط الحسابي و  $\mu_{t-k} = \mu$  هو الوسط الحسابي لكل من  $Z, Z_{t+k}$

ب- استقرار التباين واستقلاله عن الزمن

$$E(Z_t - \mu)^2 = Var(Z_t) = \sigma_{Z_t}^2 = \sigma_{Z_{t+k}}^2 = \sigma_Z^2 = \frac{1}{n} \sum_{t=1}^n (Z_t - \mu)^2 \quad (12)$$

حيث أن  $\sigma_Z^2$  هو التباين المحدد وإن  $\sigma_{Z_{t+k}}^2$ ,  $\sigma_{Z_t}^2$  يمثلان التباين للمتغيرين  $Z_{t-k}, Z_t$

ت- استقرار دالة التغایر الذاتي بحسب الزمن واعتمادها فقط على الفجوة الزمنية بين المشاهدات.

$$E[(Z_t - \mu)(Z_{t+k} - \mu)] = Cov(Z_t, Z_{t-k}) = \gamma_k \quad (13)$$

$$\gamma_{(k)} = Cov(Z_t, Z_{t-k}) = \gamma_{(k)} = \gamma \quad (14)$$

حيث ان  $\gamma$  هي التباين المشترك وان  $\gamma_{(k)}$  هي التباين المشترك بين المتغيرين  $Z_t, Z_{t-k}$

3- تحديد رتب متعدد الحدود (q,p): بعد تحقيق استقرارية السلسلة يتم البدء بالتعرف على ملامح السلسلة وتحديد رتب متعددات الحدود في أنموذج

(ARIMA) وعدد المعلمات (p, q, P, Q) والجدول أدناه يوضح منهجهية مبسطة لتحديد رتب متعددات الحدود في (ARIMA) وعدد المعلمات في الأنماذج

من خلال ذاتي (ACF) (PACF)

جدول (1) ذاتي الارتباط الذاتي والارتباط الذاتي الجزئي لأنواع نماذج (ARMA)

(PACF)	(ACF)	الأنموذج
تساوي الصفر فجأة بعد الفجوة الزمنية p	تقرب من الصفر تدريجياً وتساوي الصفر بعد الارتباط الذاتي (q)	AR (P)
تقرب من الصفر تدريجياً	تساوي الصفر فجأة بعد الفجوة الزمنية q	MA(q)
تقرب من الصفر تدريجياً وتقطع الفجوة الزمنية p بعد اخذ d من الفروق	تقرب من الصفر تدريجياً وتقطع الفجوة الزمنية q بعد اخذ d من الفروق	ARMA(p, q)

جدول (2) ذاتي الارتباط الذاتي والارتباط الذاتي الجزئي لأنواع نماذج (ARMA) الموسمي

(PACF)	(ACF)	الأنموذج
تقطع إلى الصفر فجأة بعد الارتباطات الذاتية الجزئية (PS)	تقرب من الصفر تدريجياً	AR (P)
تقرب من الصفر تدريجياً	تقطع إلى الصفر فجأة بعد الارتباطات الذاتية (QS)	MA(Q)
تقطع إلى الصفر فجأة بعد الارتباطات الذاتية (QS)	تقطع إلى الصفر فجأة بعد الارتباطات الذاتية الجزئية (PS)	SARMA(P,Q)

قدم (Box and Jenkins 1976) الارتباط الذاتي الجزئي كأداة ضرورية لتحديد افضل رتب لنماذج (ARIMA) ينطوي بمفهوم الارتباط الذاتي الجزئي على الارتباط الشرطي بين  $Z_t, Z_{t-k}$  فقط بوجود وبثبوت بقية المتغيرات أي من دون تأثيرات ويرمز له بالرمز  $\phi_{kk}$ .

الخطوة الثانية: تقديرات معلمات الأنماذج: Estimating the parameters of the model

بعد قيامنا بالمرحلة او الخطوة الأولى وهي التعرف على أنماذج (ARIMA) الافتراضي بطريقة بوكس جنكيرز بعد ذلك سوف نقوم بالخطوة الثانية الا وهي تقيير معلمات الأنماذج وذلك بتتنظيم دالة الإمكان (Likelihood Function) للأنموذج، يشار الى مثل هذه التقديرات بتقديرات الإمكان الأعظم (Maximum Likelihood Estimates) حيث يمكن كتابة أنماذج (ARIMA) بالصيغة العامة له:

$$W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \quad (15)$$

حيث ان  $W_t = (1 - B)^d Z_t$  للسلسلة غير المستقرة  $Z_t$  ويسخدم المتجه (W) لـ (n) من المشاهدات حيث ان (n) تمثل عدد المشاهدات بعد تحقيق استقرارية السلسلة. والأنموذج السابق يمكن كتابته بالصيغة التالية:

$$a_t = W_t - \phi_1 W_{t-1} - \phi_2 W_{t-2} - \dots - \phi_p W_{t-p} + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (16)$$

حيث ان ( $a_t$ ) يمثل التشويش الأبيض او الخطأ العشوائي عندما يكون التباين ثابتاً والوسط الحسابي صفرًا حيث ان دالة الكثافة الاحتمالية للأخطاء هي:

$$P(a|\phi, \theta, \sigma_a^2) = (2\pi\sigma_a^2)^{-\frac{n}{2}} \exp\left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2\right] \quad (17)$$

حيث ان

$$\begin{aligned}\phi &= \phi_1, \phi_2, \dots, \phi_p, \\ \theta &= \theta_1, \theta_2, \dots, \theta_q \\ a &= a_1, a_2, \dots, a_n,\end{aligned}$$

وان دالة الكثافة الاحتمالية لـ  $W$  يمكن كتابتها بالصيغة التالية:

$$P(W|\phi, \theta, \sigma_a^2) = (2\pi\sigma_a^2)^{\frac{-n}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left[-\frac{1}{2\sigma_a^2} W' \Sigma^{-1} W\right] \quad (18)$$

حيث ان ( $\Sigma$ ) هي دالة  $\theta$  و  $\Phi$  وان ( $w^{-1} \Sigma^{-1} w$ ) هي مجموعة المربعات للدالة التي تحوي  $\phi$  ويرمز لها بالرمز ( $\emptyset, \theta$ )  $S(\emptyset, \theta)$  وان ( $\sum = E(ww')$  هي مصفوفة التباين والتبابن المشتركة للمتجه ( $w$ ) حيث يتم الحصول على مقدرات الإمكان الأعظم ( $MLE$ ) بتعظيم دالة الإمكان او نحصل عليها بعد اخذ اللوغاريتم الطبيعي لدالة الإمكان:

$$\ln L(\phi, \theta, \sigma_a^2 | W) = \frac{-n}{2} \ln(2\pi\sigma_a^2) - \frac{1}{2} \ln |\Sigma| - \frac{1}{2\sigma_a^2} S(\phi, \theta) \quad (19)$$

(Cryer and Chan,2008)

#### الخطوة الثالثة: الفحص التشخيصي: Diagnostic checking

بعد ان تعرفنا على الأنماذج وتم تقدير معلماته ففي هذه الخطوة س يتم التأكيد من دقة الأنماذج وملائمته ومعرفة فيما إذا كانت المعلمات الأنماذجية معنوية حيث ان هناك العديد من الأدوات للفحص التشخيصي منها:

-1 معنوية المعلمات المقيدة من الجانب الاحصائي يشتهر معيار  $t$  معنوية مقدرات معلمات الأنماذج جميعها حيث ان المعلمات غير المعنوية تعتبر من الأسباب المخلة بدقة الأنماذج حيث س يتم اختبار فرضية العدم والتي تنص على ان مقدرات المعلمات لا تختلف معنويًا عن الصفر أي تساوي الصفر اذ ان القيمة الحرجة لاختبار ( $t$ ) هي القيمة الجدولية مضروبة بالخطأ المعياري المقرر للمعلمة، وان القيم الجدولية تختلف باختلاف مستوى المعنوية والذي يختلف باختلاف حجم السلسلة الزمنية، وغالبًا ما تستخد (0.05) ما و غالباً ما تستخد (0.96) في الاختبارات والتي تناسب البيانات الكبيرة جداً فإذا كانت القيمة المطلقة لقيمة المحسوبة لاختبار ( $t$ ) لكل مقدر تساوي على الأقل القيمة الحرجة فعند ذلك سوف نرفض فرضية العدم أي ان (المقدر المعنوي)، اما اذا كانت القيمة المحسوبة لاختبار ( $t$ ) اكبر من القيمة الحرجة فعند ذلك سوف ترفض فرضية العدم وتقبل الفرضية البديلة. وبالتالي يعتبر هذا مؤشر على إمكانية تبسيط الأنماذج وذلك بتخفيض عدد معلماته من خلال حذف المعلمات غير المعنوية من الأنماذج (المقدر غير المعنوي) وهو المقدر ذو الرتبة الأعلى في الأنماذج فيتم تبسيط الأنماذج وذلك بحذف هذا المقدر.

-2 حالة الارتباط الذاتي لسلسلة الباقي: SACF of Residuals Series

من الممكن ان نستخدم (ACF) للباقي وذلك لاختبار فيما إذا كانت سلسلة الباقي مطابقة وموافقة لعملية التشويش الأبيض من الممكن ان نستخدم (ACF) للباقي وذلك لاختبار فيما إذا كانت سلسلة الباقي مطابقة وموافقة لعملية التشويش الأبيض [  $a_t \sim i.i.d N(0, \sigma_a^2)$  ] فإذا كانت سلسلة الباقي ذات تشويش أبيض فيتوجب ذلك بان دالة الارتباط الذاتي للباقي ان لا تحتوي على معاملات ارتباط معنوية كذلك لاختبار معنوية معاملات الارتباط الذاتي يجب تقدير الانحراف المعياري لمعاملات الارتباط الذاتي للباقي ثم بعد ذلك ضربها بالقيمة الجدولية (0.96) لتحديد مدى المعنوية عند ثقة (0.95). (Shukur,2015)

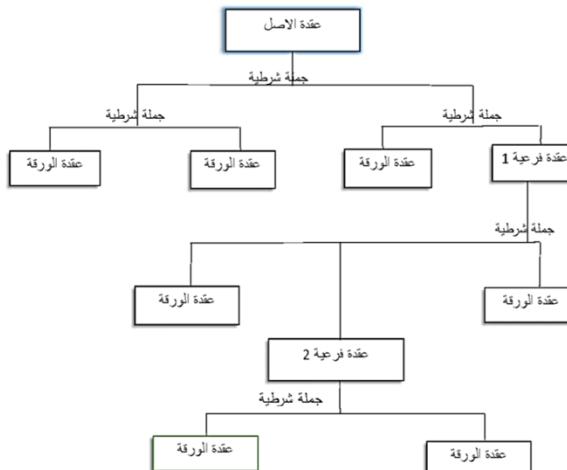
#### الخطوة الرابعة: التنبؤ Forecasting

في هذه المرحلة سوف نقوم بالتبؤ بالمشاهدات المستقبلية للسلسلة الزمنية بعد عبور او اجتياز مرحلة الفحص التشخيصي بنجاح. على فرض ان ( $n$ ) تشير او تمثل الفترة الزمنية الحالية لذا يجب ان يكون التنبؤ لمشاهدة لما حدث بعد (1) فترة زمنية الى الامام وان هذه المشاهدة سوف يرمز لها بالرمز ( $Z_{n+1}$ ) والتي لم تحدث بعد، علماً ان التنبؤ لقيمة منفردة لكل فترة زمنية يسمى بـ (التنبؤ نقطة Point Forecasting) كما يمكن تنبؤ بحدود ثقة حول كل تنبؤ نقطي والذي يدعى (التنبؤ بفترة Interval Forecasting) وسوف نختار طريقة تنبؤات اقل متوسط مربعات خطأ (MMSE) (Minimum Mean Squares Error) والتي تستخدم أنماذج (p, d, q) ARIMA العام.

#### 5.2. الغابة العشوائية Random Forest (RF)

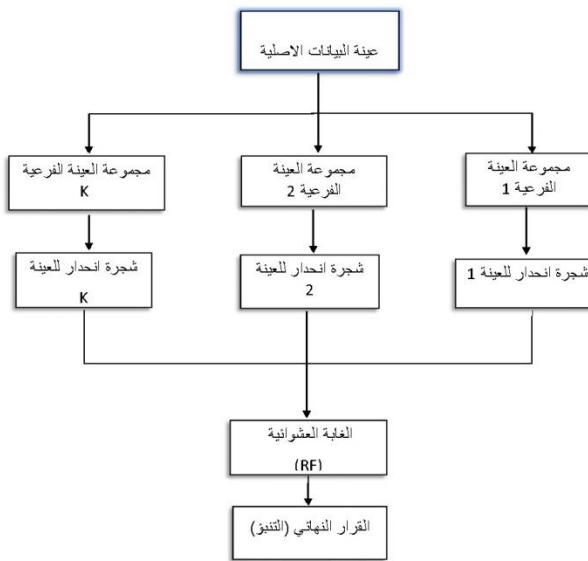
الغابة العشوائية هي احدى خوارزميات التعلم الخاضعة للأشراف Supervised أي ان مخرجات الغابة العشوائية يجب ان تتطابق مع متغيرات الهدف وبمقارنتها تنتج أخطاء التنبؤ وتعتمد على مبدأ تقنيات أشجار التصنيف والانحدار ومن مميزاتها انها دقيقة حسابياً وتعمل بسرعة وذلك عبر بيانات كبيرة نسبياً وهي من التقنيات الحديثة حيث يتم استخدامها في العديد من التطبيقات في مجالات متعددة لاعتمادها على مبدأ التصنيف والانحدار فهي عبارة عن مخطط لمجموعة

أشجار تستخدم لبناء نموذج يعطي تنبؤات من خلال أوراقها الناتجة عن مساحات وتقعرات مختارة عشوائياً من البيانات بمبدأ مشابه لبيانات أشجار الانحدار (الشكل 1) يوضح هيكلية الغابة العشوائية كأحد أنواع أشجار الانحدار . (Shumway et. At. 2010)



شكل (1): هيكلية الغابة العشوائية كأحد أنواع أشجار الانحدار

كل تفرع في الشكل (1) يمثل نقطة قرار تم اتخاذها على أساس جملة شرطية وهكذا تستمر التقعرات لحين الوصول الى القرارات النهائية المتمثلة بعقد الأوراق حيث ان كل ورقة تعتبر كعقدة منفصلة من قرار منفصل عن باقي الأوراق وان هذه الأشجار تعطي تطابق امثل بين المخرجات المتمثلة بالتنبؤات بالمقارنة مع المتغير الأصلي الذي تم اعتباره كمتغير هدف، أي سيمت تطوير أسلوب التنبؤ والحصول على تنبؤات مثلى بأقل خطاء للتنبؤ عند استخدام أسلوب (RF) كأحد تقنيات أشجار التصنيف والانحدار مقارنة بالأساليب التقليدية للتنبؤ. توفر نمذجة السلسل الرزمية باستخدام الغابات العشوائية قدرة تنبؤية معززة وأكثر دقة مقارنة بنماذج السلسل الرزمية التقليدية للتنبؤ خصوصاً ببيانات الأرصاد الجوية وبيانات أخرى كثيرة على العموم. ان الشكل (1) السابق يوضح مبدأ عمل خوارزمية الغابة العشوائية كأحد أشجار التصنيف والانحدار الذي يستخدم في التنبؤ اما الإطار الاشمل الذي يتميز به أسلوب الغابة العشوائية فهو أكثر تعتميماً عن أشجار الانحدار والتصنيف وذلك لاعتماده على مبدأ تقسيم عينة بيانات الدراسة الى عدة عينات فرعية (Bootstrap Sample Sets) وذلك لإخذ جميع الأنماط السلوكية لعينة الدراسة في جميع الفترات المختلفة والحصول على شجرة انحدار لكل عينة فرعية ومن ثم فإن مجاميع هذه الأشجار سوية سوف تمثل ما يسمى بالغابة العشوائية (RF) وان القرار النهائي يكون مستنبطاً من خلال غالبية عقد الأوراق لجميع أشجار الانحدار ، الشكل (2) يوضح الإطار العام لخوارزمية عمل الغابة العشوائية (RF) .



الشكل (2): الإطار العام لخوارزمية عمل الغابة العشوائية (RF) .

هناك احتمال ان تكون الأشجار في الغابة العشوائية مترابطة فيما بينها بحسب الشكل (2) فأنها عائدة الى نفس نوع البيانات وكذلك تم اعتماد مبدأ التعبيبة (bagging principle) الذي اساسه هو عملية المعاينة التمهيدية (Bootstrap Sampling) اذ تعمل طريقة التعبيبة على تحسين أداء أشجار التصنيف والانحدار وتجعل (RF) أكثر حسانة عند تجمعيها مع بعضها. يتم معالجة ذلك بجعل الاشجار في الغابة العشوائية غير مترابطة مع بعضها (مختلفة) لذلك فقد

قدم (Breiman, 2001) مقتراً لـ ان تنمو كل شجرة بشكل منفصل وكذلك بشكل عشوائي وباجتماع هذين المبدأين ستحدد ملامح وعدد مجموعات العينات الفرعية المشار إليها في الشكل (2). بعد تحويل الأشجار في الغابة العشوائية من متربطة إلى غير متربطة (مختلفة) مما سيضمن زيادة ملحوظة في دقة تنبؤ الغابة العشوائية.

يتم بناء خوارزمية الغابة العشوائية باستخدام الخطوات الثلاثة أدناه:

1- من بيانات التدريب يتم استخراج  $B$  من العينات التمهيدية والتي هي في الأصل متربطة فيما بينها اذ ان  $B$  تمثل حجم الغابة او عدد الأشجار المتعددة المشار إليها في الشكل (2)

2- لكل مجموعة من مجموعات البيانات  $B$  فأن نمو الشجرة  $T_b$  سيت باتباع خطوات متسلسلة في كل عقدة من عقد الشجرة لحين الوصول الى  $n_{min}$  والتي تمثل الحد الأدنى من أوراق الأشجار او عدد العقد وكما يلي:

أ- اختيار  $m$  والتي تمثل العدد المختار عشوائياً من التنبؤات في كل قسم من العدد الكلي للمتغيرات  $p$ .

ب- اختيار أفضل التنبؤات من التنبؤات المختارة في (أ) وقد تم الإشارة إليها بالرمز  $m$  مع اختيار القسم العائد اليه بهدف تقليل قيمة  $Mse$  للتنبؤات المختارة في (أ).

ج- فصل العقدة الى عقدتين فرعيتين تبعاً للمعيار المستخدم او القيم التنبؤية الأفضل التي تم اختيارها في (ب).

3- استخلاص المخرجات من جميع الأشجار من خلال إيجاد المجموعة  $\{T_b\}_1^B$  وأخيراً فإنه عند نقطة معينة  $X$  فإن التنبؤ ممكن ان حسب المعادلة التالية: (Noureen,et,at.2019)

$$f_{RF} = \frac{1}{B} \sum_{b=1}^B T_b(x) \dots \quad (20)$$

## 2.8 مقاييس خطأ التنبؤ Foracasting Error Measurements

للمقارنة بين الطائق المفترحة سيتم استخدام العديد من مقاييس الخطأ وفي اغلب الدراسات يتم استخدام مقياس للخطأ RMSE الجذر التربيعي لمتوسط المربعات الخطأ وMAE متوسط الخطأ المطلق النسبي.

وهذه المقاييس يمكن ان تقسم الى مقاييس تصف تشتت البيانات وأخرى تصف الدقة والنسبة المئوية للخطأ. RMSE يقيس عادة التشتيت و MAPE يمثل عادة النسبة المئوية لخطأ التكهن ودقته.

بحسب مقياس (MAPE) mean absolute percentage error (MAPE) متوسط القيمة المطلقة النسبية المئوية للخطأ على النحو التالي:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{z_i} \right| \times 100 \quad (21)$$

اذ ان  $r$  تمثل خطأ التكهن،  $n$  عدد المشاهدات و  $z_i$  هو السلسلة الحقيقة او الاصلية المستعملة كهدف. اما معياري (MAE) mean absolute error (MAE) متوسط القيمة المطلقة للخطأ و (RMSE) root mean squares error (RMSE) الجذر التربيعي لمتوسط مربعات الخطأ فيمكن كتابة الصيغة الرياضية لها كما يلي: (Hyndman & Koehler, 2006)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i)^2} \quad (22)$$

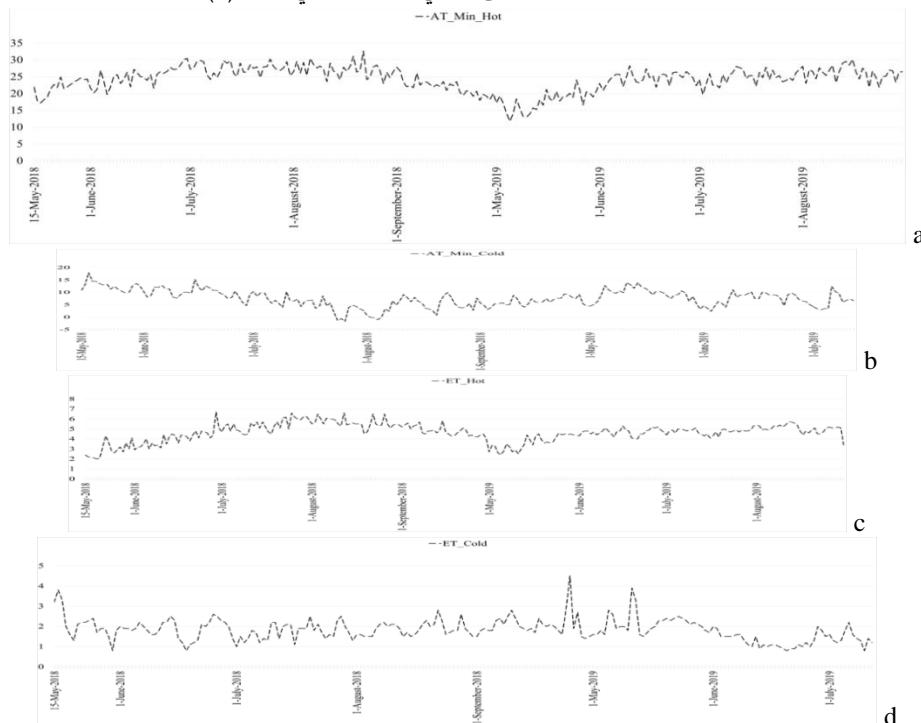
$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (23)$$

عندما  $N$ : عدد مشاهدات العينة و  $e_i$  مقدار الخطأ والذي يمثل الفرق بين متغير القيم الحقيقية ومتغير القيم التنبؤية.

## 3. النتائج والمناقشة

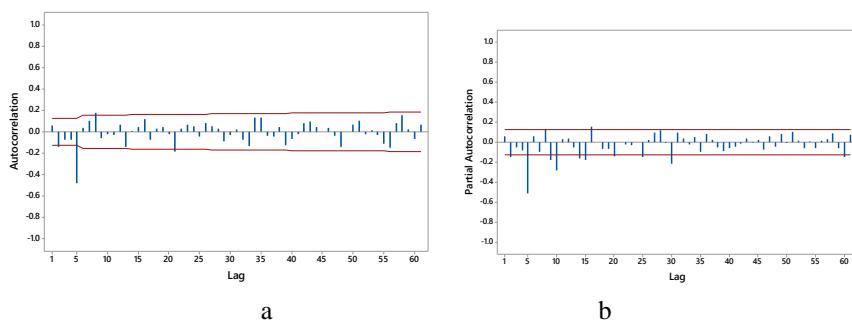
تم تناول نوعين من البيانات تضمنت المجموعة الأولى درجات الحرارة الصغرى لمدينة الموصل والتي تم اخذها من مركز الأرصاد الجوية الزراعية/محافظة نينوى/محطة الموصل التابعة لوزارة الزراعة في الموقع المحدد بخط الطول  $E: 43.16$  وخط العرض  $N: 36.33$ . وتضمنت المجموعة الثانية كمية التبخر (mm) مأخوذة من نفس المحطة المشار إليها سابقاً تضمنت مجموعتي البيانات (675) مشاهدة للفترة من (15/5/2018) ولغاية (19/7/2020) ولوحظ احتواها على بيانات يمكن وصفها بأنها غير متجانسة وذلك للتتواء الذ تحيوي البيانات يمكن وصفها بأنها غير متجانسة وذلك للتنوع الذي تحيوي البيانات من خلال مرورها بالفصول الرسمية الأربع ونقلابتها من حيث البرودة والحرارة وغيرها من التقلبات الجوية كما ان ذلك واضح بعد رسم الاتجاه العام. ولتحقيق انسجام أكبر للبيانات فقد تم تقسيمها الى مجموعتين الأولى للموسم البارد ويضم الأشهر (تشرين الثاني-كانون الأول-كانون الثاني-شباط-اذار) والمجموعة الثانية خاصة بالموسم الحار والذي يضم الأشهر (أيار-حزيران-تموز-آب-أيلول). تم تقسيم البيانات في كل مجموعة الى مجموعتين جزئيتين هما التدريب والاختبار وذلك للتحقق من صحة ثبوتها من خلال اختبار الأنماذج الذي يتم بناء بيانات بالتدريب وذلك باستخدام بيانات مجموعة الاختبار للتحقق من صحة أداء الأنماذج عادة ما يتم افتراض النسبتين 70% و 30% لمجموعتي بيانات التدريب والاختبار على التوالي من العدد الكلي لمشاهدات السلسلة الزمنية. لذلك تم تقسيم بيانات الموسم البارد الذي يضم (303) مشاهدة الى (212) مشاهدة لمجموعات التدريب و (91) مشاهدة لمجموعات الاختبار. اما فيما يخص الموسم الحار فقد تم تقسيم بياناته التي تضم (372) مشاهدة الى (262) مشاهدة لمجموعة التدريب و (110) مشاهدة لمجموعة الاختبار. أن استقرارية الأنماذج يتم التحقق منها من خلال رسم السلسلة الزمنية وكل من دالتي الارتباط الذاتي والارتباط الذاتي الجزئي. اما رسم السلسلة وتقديرها بيانياً يجب ان تظهر من خلالها

السلسلة الزمنية منسجمة ومتناهية وخلالية من القيم الشاذة والمترددة ويكون فيها المتوسط والتباين مستقرتين اما دالتي الارتباط الذاتي والارتباط الذاتي الجزئي فتستخدمان لتأكيد التحقيق من الاستقرارية من خلال نوع الاضمحلال فعندما يكون الاضمحلال عند نحو عدم المعنوية بطيناً أي بعد أكثر من (6) ارتباطات فعندئذ تتأكد ان السلسلة غير مستقرة اما الاضمحلال السريع فغالباً ما يدل على استقرارية السلسلة. التوقع البياني للسلسلات الزمنية لفترات التدريب لدرجة الحرارة الصغرى في الموسمين الحار والبارد وكمية التبخر للموسدين الحار والبارد على التوالي مدرجة كما في الشكل(3) أدناه.

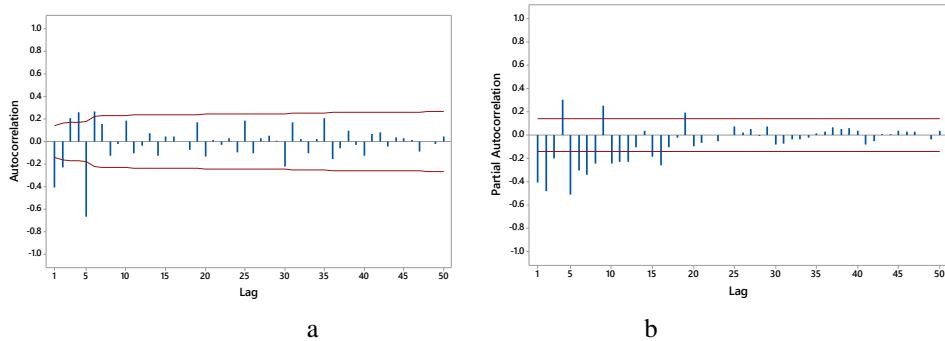


الشكل (3) التوقع البياني لفترات التدريب لدرجة الحرارة الصغرى في الموسمين الحار والبارد وكمية التبخر للموسدين الحار والبارد على التوالي بعد اخذ العديد من الفروقات الاعتيادية والموسمية مع اختبار السلسل بعده كل فرق فقد تم التوصل الى الفروقات التالية التي تكفي للوصول الى الاستقرارية للسلسلات الزمنية ولما يلي:

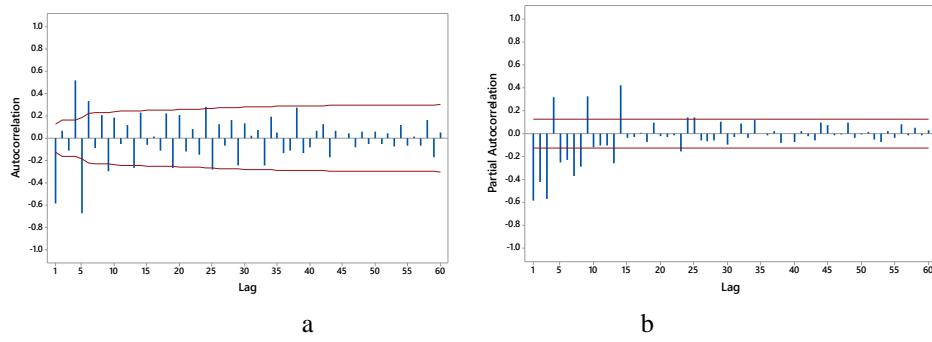
- 1- السلسلة الزمنية لدرجات الحرارة الصغرى/ الموسم الحار: فرق اعتيادي اول  $d=1$  بالإضافة الى فرق موسمي اول  $S=5$  عند  $D=1$
  - 2- السلسلة الزمنية لدرجات الحرارة الصغرى/ الموسم البارد: فرق اعتيادي ثاني  $d=2$  بالإضافة الى فرق موسمي ثاني  $S=5$  عند  $D=2$
  - 3- السلسلة الزمنية لكميات التبخر/ الموسم الحار : فرق اعتيادي ثان  $d=2$  بالإضافة الى فرق موسمي ثان  $S=5$  عند  $D=2$
  - 4- السلسلة الزمنية لكميات التبخر/ الموسم البارد: فرق اعتيادي ثان  $d=2$  بالإضافة الى فرق موسمي ثان  $S=5$  عند  $D=2$
- الشكل (4) (5) (6) (7) تمثل دالتي الارتباط الذاتي والارتباط الذاتي الجزئي لدرجة الحرارة الصغرى في الموسمين الحار والبارد وكمية التبخر للموسدين الحار والبارد على التوالي للسلسلات الزمنية بعد اخذ الفروقات المشار اليها أعلاه أي بعد تحقيق الاستقرارية للسلسلات الزمنية.



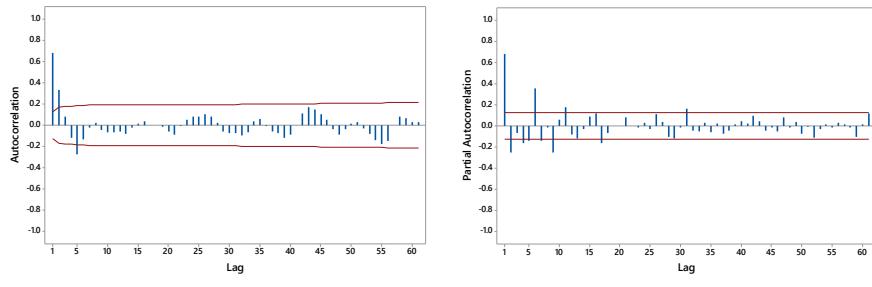
الشكل (4): دالتي الارتباط الذاتي والارتباط الذاتي الجزئي للموسدين الحار على التوالي لدرجة الحرارة الصغرى عندما  $S=5$ ,  $D=1$ ,  $d=1$



الشكل (5): دالة الارتباط الذاتي والارتباط الذاتي الجزئي للموسم البارد على التوالى لدرجة الحرارة الصغرى عندما  $S=5, D=2, d=2$



الشكل (6): دالة الارتباط الذاتي والارتباط الذاتي الجزئي للموسم الحار على التوالى لكمية التبخر عندما  $S=5, D=2, d=2$



الشكل (7): دالة الارتباط الذاتي والارتباط الذاتي الجزئي للموسم البارد على التوالى لكمية التبخر عندما  $S=5, D=2, d=2$

من خلال الاشكال (4) الى (7) من الممكن استنتاج نماذج ARIMA المناسبة لكل مجموعة من البيانات وكما يلي :

الأنموذج الأول: -ان الأنماذج المناسب درجة الحرارة الصغرى للموسم الحار من الممكن استنتاجه من خلال الشكل(4) a و b حيث تشير دالة الارتباط الذاتي إلى إمكانية معنوية معلمة واحدة للمتوسطات المتحركة الاعتيادية ومعلمة واحدة لمتوسطات المتحركة الموسمية. أما دالة الارتباط الذاتي الجزئي فتشير إلى إمكانية وجود معلمة واحدة معنوية للانحدار الذاتي الموسمي عندما  $S=5$  وبذلك فإن الأنماذج المناسب هو  $(0, 1, 1)(1, 1, 1)$ ARIMA  $(0, 1, 1, 1)$  والذي يمكن تمثيله حسب الصيغة في المعادلة ادناه:

$$(1 - \Phi_1 B^5)(1 - B)^d (1 - B)^D Z_t = (1 - \theta_1 B)(1 - \theta_1 B^S) a_t \quad (24)$$

عندما  $\Phi_1 = -0.0415, \theta_1 = 0.6610, \theta_1 = 0.9574, d = 1, D = 1, S = 5$

حيث ظهر ان المعلمات  $\Phi_1, \theta_1$  معنوية.

الأنموذج الثاني: -ان الأنماذج المناسب درجة الحرارة الصغرى للموسم البارد من الممكن استنتاجه من خلال الشكل(5) a و b حيث تشير دالة الارتباط الذاتي إلى إمكانية معنوية معلمتين للمتوسطات المتحركة الاعتيادية ومعلمته واحد للمتوسطات المتحركة الموسمية. أما دالة الارتباط الذاتي الجزئي فتشير إلى إمكانية وجود معلمتين معنويتين للانحدار الذاتي الاعتيادي ومعلمتين للانحدار الذاتي الموسمي عندما  $S=5$  وبذلك فإن الأنماذج المناسب هو:  $ARIMA (2, 2, 2), (2, 2, 1)$  والتي يمكن تمثيله حسب الصيغة في المعادلة ادناه:

$$(1 - \phi_1 B_1 - \phi_2 B_2)(1 - \Phi_1 B^2 - \Phi_2 B^{2S})(1 - B)^d (1 - B)^D Z_t = (1 - \theta_1 B - \theta_2 B)(1 - \Theta_1 B^S) a_t \quad (25)$$

$$\phi_1 = -0.5011, \phi_2 = -0.1416, \Phi_1 = -0.7405, \Phi_2 = -0.4169, \theta_1 = 0.5674, \theta_2 = 0.434, \Theta_1 = 0.9489 \quad \text{عندما}$$

حيث ظهر ان جميع المعلمات معنوية.

الأنموذج الثالث: - ان الأنموذج المناسب لكمية التبخر للموسم الحار من الممكن استنتاجه من خلال الشكل(6) a و b حيث تشير دالة الارتباط الذاتي الى إمكانية معنوية معلمة واحدة للمتوسطات المتحركة الاعتيادية وثلاث معلمات للمتوسطات المتحركة الموسمية اما دالة الارتباط الذاتي الجزئي فتشير الى إمكانية وجود ثلاث معلمات معنوية للانحدار الذاتي الموسمي عند  $S=5$  وبذلك فإن الأنموذج هو  $ARIMA(3, 2, 1)(3, 2, 3)_5$  يمكن تمثيله حسب الصيغة في المعادلة أدناه:

$$(1 - \phi_1 B_1 - \phi_2 B_2 - \phi_3 B_3)(1 - \Phi_1 B^S - \Phi_2 B^{2S} - \Phi_3 B^{3S})(1 - B)^d (1B)^D Z_t \\ = (1 - \theta_1 B)(1 - \Theta_1 B^S - \Theta_2 B^{2S} - \Theta_3 B^{3S})a_t \quad (26)$$

حيث ان

$$\phi_1 = -0.4294, \phi_2 = -0.3807, \phi_3 = -0.2638, \Phi_1 = -1.1653, \\ \Phi_2 = -0.4914, \Phi_3 = -0.1948, \theta_1 = 0.9796, \Theta_1 = 0.7858, \\ \Theta_2 = 0.6548, \Theta_3 = -0.4706, d = 2, D = 2, S = 5$$

حيث ظهر ان جميع المعلمات معنوية.

الأنموذج الرابع: - ان الأنموذج المناسب لكمية التبخر للموسم البارد من الممكن استنتاجه من خلال الشكل(7) a و b حيث تشير دالة الارتباط الذاتي الى إمكانية معنوية معلمة واحدة للمتوسطات المتحركة الاعتيادية وثلاث معلمات للمتوسطات المتحركة الموسمية اما دالة الارتباط الذاتي الجزئي فتشير الى إمكانية وجود ثلاث معلمات معنوية للانحدار الذاتي الموسمي عندما  $S=5$  وبذلك فإن الأنموذج هو  $ARIMA(3, 2, 1)(3, 2, 3)_5$  يمكن تمثيله كما في المعادلة أدناه

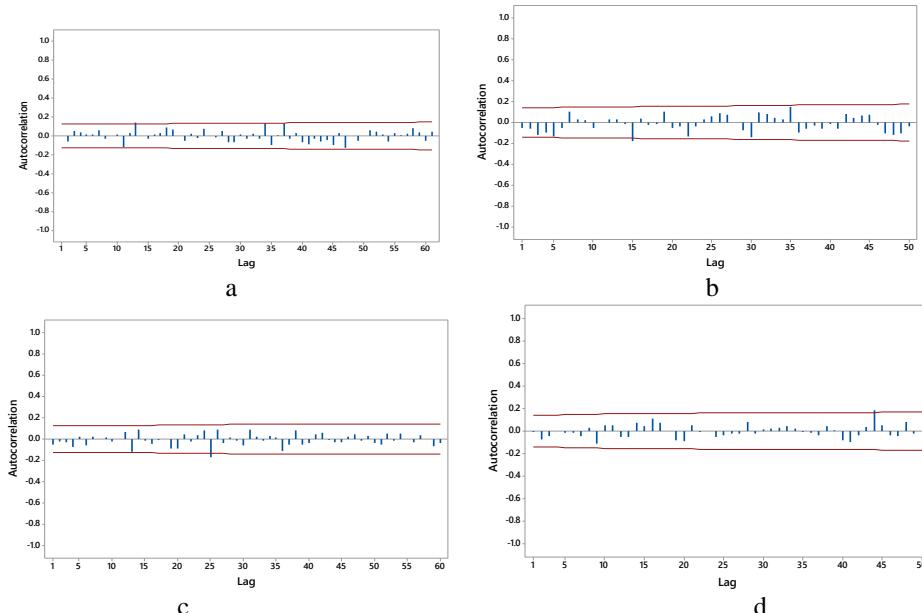
$$(1 - \phi_1 B_1 - \phi_2 B_2 - \phi_3 B_3)(1 - \Phi_1 B^S - \Phi_2 B^{2S} - \Phi_3 B^{3S})(1 - B)^d (1B)^D Z_t \\ = (1 - \theta_1 B)(1 - \Theta_1 B^S - \Theta_2 B^{2S} - \Theta_3 B^{3S})a_t \quad (27)$$

حيث ان:

$$\phi_1 = -0.3188, \phi_2 = -0.2658, \phi_3 = -0.1790, \Phi_1 = -0.8660, \\ \Phi_2 = -0.0617, \Phi_3 = -0.0472, \theta_1 = 0.9285, \Theta_1 = 1.1038 \\ \Theta_2 = 0.6046, \Theta_3 = -0.7220, d = 2, D = 2, S = 5$$

حيث ظهر ان جميع المعلمات معنوية.

الشكل(8) يوضح الارتباطات غير المعنوية للبواقي لنماذج بيانات درجات الحرارة الصغرى في الموسمين الحار والبارد على التوالي مما يجعل من هذا الفحص التشخيصي دليل على سلامة النماذج الاربعة أعلاه.



الشكل (8) للبواقي للنماذج الاربعة اعلاه على التوالي

تم احتساب قيم معيار متوسط القيمة المطلقة للنسبة المئوية للأخطاء Mean absolute percentage errors (MAPE) والجذر التربيعي لمتوسط مربعات الأخطاء Mean absolute errors (MAE) ومتوسط القيمة المطلقة للأخطاء Root of Mean squared errors (RMSE) الذي يقيس مدى دقة

التنبؤات أي هو مؤشر لمدى أخطاء التنبؤ . والجدول (3) ادناه يوضح قيم معايير الاخطاء للتنبؤات لفترتي التدريب والاختبار باستخدام نماذج ARIMA الأربعية المشار إليها أعلاه.

الجدول (3) معايير (MAPE, RMSE, MAE) للتنبؤات لفترتي التدريب والاختبار للنماذج الأربعية

AT Min	Hot		MAPE	RMSE	MAE
		تدريب	6.9928	2.0711	1.6465
		اختبار	30.9986	6.6103	5.7293
ET	Hot	تدريب	79.4920	2.2434	1.6802
		اختبار	733.4600	66.5931	49.0294
Cold	Hot	تدريب	7.8820	0.4866	0.3561
		اختبار	112.6959	10.8045	8.6510
	Cold	تدريب	19.2679	0.4664	0.3348
		اختبار	32.3209	1.1669	0.8229

سيتم الاعتماد على استخدام الایعاز (fitrensemble) في برنامج (MATLAB) لبناء نموذج الانحدار التجمعي (Regression Ensemble) للغابة العشوائية RF باستخدام عدة متغيرات تفسيرية ومتغير واحد معتمد. ان بيانات هذا البحث تتضمن بيانات سلاسل زمنية احادية المتغير (درجات الحرارة الصغرى وكميات التبخر) وسيتم اعتماد مبدأ الارتباط الذاتي في السلاسل الزمنية لانشاء متغيرات تفسيرية من كل متغير من متغيرات الدراسة وذلك من خلال استخدام التخلفات الزمنية للمتغير الاصلي كمتغيرات تفسيرية حيث سيكون لكل متغير من متغيرات الدراسة ثلاثة تخلفات زمنية (ثلاث تخلفات زمنية فيما سيكون نفس المتغير الاصلي هو المعتمد. مبدأ عمل الایعاز (fitrensemble) في برنامج (MATLAB) هو كما تم ذكره اففا في بناء نموذج انحدار تجمعي مع ملاحظة مايلي:

1- اعتماده على خوارزمية المربيات الصغرة التعزيزية Least-Squares Boosting والتي تتضمن ايجاد مجامي (Ensembles) لأفضل معدلات تلائم بيانات الدراسة. وفي كل خطوة من هذه الخوارزمية (LS Boost) سيتم انجاز تعلم جديد وايجاد معادلة انحدار جديدة ثم ايجاد الفرق بين البيانات الحقيقية للمتغير المعتمد والتنبؤ التجمعي المترافق من جميع خطوات التعلم السابقة. ان الفائدة المرجوة من هذه الخوارزمية هي تصغير مقياس (MSE) لأخطاء التنبؤ. ان اساس (LS Boost) يعتمد على مبدأ الخوارزمية التجريبية او التراكمية (Ensemble Algorithm) والتي تعرف بأنها احد تقنيات التعلم من خلال بناء نماذج عديدة وتوفيق تلك النماذج للحصول على نتائج افضل. عادة يؤدي استخدام النماذج المجمعة الى حلول ونتائج ادق مما لو استخدمت الاساليب التقليدية التي اساسها نموذج واحد منفرد.

2- نظرا الى ان الطريقة تعتمد على مبدأ التجميع والتوفيق بين النماذج فان اشجار الغابة العشوائية باستخدام (10) تجزئات للبيانات كعدد افتراضي للایعاز (fitrensemble) كحد اقصى والتي سيسقى من توفيقها باختلاص افضل النتائج. وسيتم استخدام (100) شجرة ثم توفيقها للحصول على افضل التنبؤات.

بعد الانتهاء من بناء نموذج الغابة العشوائية باستخدام ایعاز (fitrensemble) فالخطوة التالية هي التنبؤ باستخدام هذا الأنماذج الذي يعد هو الأنماذج الامثل للبيانات الدراسة وذلك باستخدام يعار (Bredict) والذي يتطلب الأنماذج الذي تم بنائه مع بيانات التدريب (المتغيرات التفسيرية فقط) للحصول على التنبؤات الداخلية المقابلة لفترة التدريب والتي تسمى تنبؤات التدريب (Training Forecast) وكذلك في خطوة تالية يتم ادخال نفس الأنماذج الذي تم بنائه مع بيانات الاختبار (المتغيرات التفسيرية فقط) للحصول على التنبؤات في فترة الاختبار والتي تسمى تنبؤات الاختبار (Testing Forecast) والجدول (4) يوضح قيم معايير اخطاء التنبؤ (MAPE) و (RMSE) و (MAE) لبيانات التدريب والاختبار .

الجدول(4) قيم معايير اخطاء التنبؤ (MAPE) و (RMSE) و (MAE) لبيانات التدريب والاختبار

البيانات	الموسم	الفترة	MAPE	RMSE	MAE
AT Min	Hot	تدريب	0.0912	0.0281	0.0215
		اختبار	13.0509	3.4350	2.6763
	Cold	تدريب	0.4544	0.0115	0.0085
		اختبار	75.1640	3.0296	2.4288
ET	Hot	تدريب	1.6726	0.1359	0.0739
		اختبار	20.7528	1.6414	1.4085
	Cold	تدريب	3.4651	0.1364	0.0635
		اختبار	29.9944	1.0435	0.7729

من خلال الجدولين (3) و (4) يتضح ان هنالك افضلية مطلقة لنتائج التنبؤ لبيانات درجة الحرارة الصغرى وكميات التبخر للموسمين الحار والبارد لفترتي التدريب والاختبار باستخدام أنموذج الغابة العشوائية مقارنة بنفس نتائج التنبؤ باستخدام الأنموذج التقليدي ARIMA اي ان أنموذج الغابة العشوائية اسهم كثيرا بتحسين نتائج التنبؤ وذلك لأنه يأخذ بنظر الاعتبار عدد اوسع من الاحتمالات باعتماده على اشجار تنبؤ عديدة ومن ثم اختيار افضل نتائج التنبؤ وبذلك يحقق تحسينا كبيرا في التنبؤ لبيانات الدراسة.

#### 4. الاستنتاجات

على الرغم من ان أنموذج ARIMA يعد من النماذج شائعه الاستخدام في تطبيقات واسعة ومتعددة للتنبؤ بالسلسل الزمنية الا انه يفتقر الى التعامل مع البيانات غير الخطية وبالتالي سيؤدي استخدامه مع هكذا نوع من البيانات الى نتائج تنبؤ غير دقيقه خصوصا ان استخدامه مع بيانات الانواء الجوية مثل درجات الحرارة وكميات التبخر وغيرها التي تعد من البيانات غير الخطية كما اشار الى ذلك الكثير من الدراسات السابقة.

ان استخدام أنموذج الغابة العشوائية مع بيانات الانواء الجوية خصوصا بيانات درجات الحرارة الصغرى وكميات التبخر التي تعتبر من البيانات غير الخطية سيؤدي الى تحسينات ملحوظه في دقه نتائج التنبؤ والحصول على تنبؤات دققيقه جدا مقارنه بنتائج التنبؤ باستخدام الطرائق التقليدية مثل أنموذج ARIMA وذلك لأن أنموذج الغابة العشوائية يعد من الاساليب غير الخطية بالإضافة الى اعتباره احد اساليب تعلم الآلة الحديثة لذلك سيعطي دقه عالية في التنبؤ من خلال الاعتماد على اشجار انحدار عديده في وقت واحد وأنموذج واحد واختيار افضل القرارات التي تعطيها غابه الاشجار في أنموذج الغابة العشوائية.

#### References

1. AL-Badrani, Thafer & Slewa ,Rehad .(2014)." Evaluation of time series prediction of temperature rates using neural networks",Iraqi Journal of Statistical Science, Issue 14,N.26,PP.1-19.
2. Vandel ,Walter, (1992)." Applied time series and Box-Jenkins models",Rayed , Arabic Sudia King.
3. Barker, N. D. (1998). *Basic concepts of statistics* (Vol. 30). Oxford University Press, NY, USA.
4. Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
5. Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control* (rev. ed.) Holden-Day. San Francisco, 575.
6. Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
7. Chan, N. H. (2004). *Time series: applications to finance*. John Wiley & Sons.
8. Chen, L., Omaye, S. T., Yang, W., Jennison, B. L., & Goodrich, A. (2001). A comparison of two statistical models for analyzing the association between PM10 and hospital admissions for chronic obstructive pulmonary disease. *Toxicology Methods*, 11(4), 233-246.
9. Chen, J., Li, M., & Wang, W. (2012). Statistical uncertainty estimation using random forests and its application to drought forecast. *Mathematical Problems in Engineering*, 2012.
10. Cryer, J. D., & Chan, K. S. (2008). *Time series analysis: with applications in R* (Vol. 2). New York: Springer.
11. Díaz-Robles, L. A., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., & Moncada-Herrera, J. A. (2008). A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile. *Atmospheric Environment*, 42(35), 8331-8340.
12. Fang, X., Liu, W., Ai, J., He, M., Wu, Y., Shi, Y., & Bao, C. (2020). Forecasting incidence of infectious diarrhea using random forest in Jiangsu Province, China. *BMC infectious diseases*, 20(1), 1-8.

13. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.
14. Kane, M. J., Price, N., Scotch, M., & Rabinowitz, P. (2014). Comparison of ARIMA and Random Forest time series models for prediction of avian influenza H5N1 outbreaks. *BMC bioinformatics*, 15(1), 1-9.
15. Kitagawa, G. (2010). Introduction to time series modeling. Chapman and Hall/CRC.
16. Liu, L. M. (2006). *Time Series Analysis and Forecasting*, 2<sup>nd</sup> ed. Scientific computing associates crop. Illinois, USA.
17. Noureen, S., Atique, S., Roy, V., & Bayne, S. (2019). A comparative forecasting analysis of ARIMA model vs random forest algorithm for a case study of small-scale industrial load. *International Research Journal of Engineering and Technology*, 6(09), 1812-1821.
18. Palma, W. (2007). Long-memory time series: theory and methods. John Wiley & Sons.
19. Pankratz, A. (1983). Forecasting with Univariate Box-Jenkins Models: Concepts and Cases. John Wiley & Sons. Inc. USA.
20. Petukhova, T., Ojkic, D., McEwen, B., Deardon, R., & Poljak, Z. (2018). Assessment of autoregressive integrated moving average (ARIMA), generalized linear autoregressive moving average (GLARMA), and random forest (RF) time series regression models for predicting influenza A virus frequency in swine in Ontario, Canada. *PloS one*, 13(6), e0198313.
21. Shukur, O. B. (2015). Artifical Neural Network and Kalman Filter Approaches Based on ARIMA for Daily Wind Speed Forecasting (Doctoral dissertation, Universiti Teknologi Malaysia).
22. Shumway, R. H., and Stoffer, D. S. (2000). Time series analysis and its applications (Vol. 3). New York: springer.
23. Shukur, O. B., & Lee, M. H. (2015). Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA. *Renewable Energy*, 76, 637-647.
24. Wei, W. W. S. (1990). Time series analysis: Univariate and multivariate methods. 478 pp. New York, Adisson-Wesley.
25. Wei, W. W. (2006). Time series analysis: univariate and multivariate. Methods. Boston, MA: Pearson Addison Wesley.
26. Zafra, C., Ángel, Y., & Torres, E. (2017). ARIMA analysis of the effect of land surface coverage on PM10 concentrations in a high-altitude megacity. *Atmospheric Pollution*

## **Using ARIMA and Random Forest Models for Climatic Datasets Forecasting**

Oday Aljuborey; Osamah Basheer Shukur

Department of Informatics & Statistic, College of Computer Science & Mathematics, University of Mosul, Mosul, Iraq

**Abstract:** The damages through planning and controlling for these changes in the future. The main problem can be summarized in the nonlinearity of climatic dataset and its chaotic changes. The common approach is the integrated autoregressive and moving average model (ARIMA) as traditional univariate time series approach. Therefore, more appropriate model for studying the climatic data has been proposed for obtaining more accurate forecasting, it can be called random forest (RF) model. This model cannot deal with nonlinear data correctly and that may lead to inaccurate forecasting results . In this thesis, climatic datasets are studied represented by minimum air temperature and rational humidity for agricultural meteorological station in Nineveh. This thesis aims to satisfy data homogeneity through different seasons and find suitable model deal with nonlinear data correctly with minimal forecasting error comparing to ARIMA as traditional model. The research found the adequate of the model for this type of data, as it was found that there are some factors that contribute to the increase in the number of deaths in the epidemic, such as the advanced age of the patient, the length of stay in the hospital, the percentage of oxygen in the patient's blood, in addition to the incidence of some chronic diseases such as asthma. The study recommended a more in-depth study of other types of these models, and the use of other estimation methods, in addition to paying attention to the methods of data recording by the city health department.

**Keywords:** hierarchical Poisson regression model with random intercept, full maximum likelihood method, intraclass correlation coefficient, fixed and random effects