

مجلة كلية التراث الجامعة

مجلة علمية محكمة
متعددة التخصصات نصف سنوية
العدد الحادي والأربعون

30 نيسان 2025
ISSN 2074-5621



رئيس هيئة التحرير

أ.د. جعفر جابر جواد

مدير التحرير

أ.م. د. حيدر محمود سلمان

رقم الايداع في دار الكتب والوثائق 719 لسنة 2011

مجلة كلية التراث الجامعة معترف بها من قبل وزارة التعليم العالي والبحث العلمي بكتابها المرقم
(ب 3059/4) والمؤرخ في (2014/ 4/7)

اختيار أفضل متغيرات انموذج الانحدار الذاتي AR(p) بأستعمال طرق الجزاء

رنين رافد محي الدين أ.د. فراس احمد محمد

جامعة بغداد /كلية الادارة والاقتصاد / قسم الإحصاء

المستخلص

يعتبر سوق العراق للأوراق المالية مصدر تمويل المشاريع الاستثمارية ومخزن ادخار رؤوس الاموال ومؤشرات سوق الأوراق المالية بشكل خاص تهم المستثمرين اضافة الى العديد من الاطراف التي تتعامل في اسواق رأس المال، وأن مشكلة الأبعاد الكبيرة تُعدّ من المشاكل المهمة التي تعاني منها البيانات وبيانات مؤشر السوق لقطاع لمصارف بشكل خاص ، وعملية تحديد المتغيرات التي تؤثر فعلياً بصورة عامة ومتغيرات الانحدار الذاتي في السلاسل الزمنية بصورة خاصة في البيانات الكبيرة (ذات الابعاد العالية) ، يساعدنا كثيراً في دقة النتائج التحليلية للأساليب والنماذج المستخدمة حيث يقلل من الأخطاء كونه يحقق الهدف المنشود، سيتم التطرق في هذا البحث الى اختيار افضل المتغيرات الموجودة في السلسلة الزمنية بالإضافة الى التقليل من ابعادها عن طريق اختيار المتغيرات التي تمثل النموذج، حيث يعتبر اصعب جانب من ناحية التعامل مع بيانات السلسلة الزمنية هو اختيار النموذج وتحديد متغيراته ومعلماته . وبصورة عامة، تكون الغاية الاساسية هو تحديد المتغيرات المهمة في مجموعة البيانات وتجاهل المتغيرات الاخرى من خلال اعتبارها غير ذات صلة او زائدة عن الحاجة ، حيث يتم ذلك عن طريق استخدام طرق الجزاء والمتمثلة بطريقة الجزاء Lasso وطريقة Adaptive Lasso وطريقة Double Adaptive Lasso وتم العمل على بيانات اسبوعية والفترة من 2017-2021 حسب مامتوفر وبأستخدام برنامج لغة (Python) ومن خلال النتائج التي ظهرت تفوقت طريقة (Double Adaptive Lasso) على نظيرتها بالاعتماد على اقل قيمة لمعايير المقارنة والمتمثلة بـ (RMSE)

الكلمات المفتاحية: سوق العراق للأوراق المالية ، اختيار افضل المتغيرات ، Lasso ، Double Adaptive Lasso ، Adaptive Lasso

1- المبحث الاول : منهجية البحث

1-1 المقدمة Introduction

مع التقدم التكنولوجي، أصبح الوصول إلى المعلومات أكثر سهولة في الوقت الحاضر، من خلال جمع وتحليل كميات كبيرة من البيانات خلال فترة زمنية معينة ، وتُعدّ مشكلة الأبعاد الكبيرة من المشاكل المهمة التي تعاني منها البيانات، حيث أن عملية تحديد المتغيرات التي تؤثر فعلياً بصورة عامة ومتغيرات الانحدار الذاتي في السلاسل الزمنية بصورة خاصة في البيانات الكبيرة (ذات الابعاد العالية) ، يساعد هذا في دقة النتائج التحليلية للأساليب والنماذج المستخدمة من خلال التقليل من الأخطاء كونه يحقق الهدف المنشود (الوصول الى نموذج أكثر دقة من النموذج الاعتيادي) ، سيتم التطرق في هذه الرسالة الى اختيار افضل المتغيرات المكونة للسلسلة الزمنية بالإضافة الى التقليل من ابعادها عن طريق اختيار المتغيرات التي تمثل الانموذج، حيث يعتبر اصعب جانب من ناحية التعامل مع بيانات السلسلة الزمنية هو اختيار النموذج وتحديد متغيراته ومعلماته ، حيث اجتذب موضوع اختيار المتغيرات في المساحات عالية الابعاد (غالباً ما تكون بالمئات أو الالاف من الابعاد) اهتماماً في السنوات السابقة، وهو شائع في العديد من المشكلات الحقيقية ، إذ أن عملية اختيار مجموعة فرعية مثالية من البيانات او المتغيرات وفق لمعيار محدد وميزات وخصائص معينة من مجموعة من البيانات يجب ان تكون وفقاً للغرض من اختيار الخاصية او الميزة ، حيث تهدف هذه العملية الى تحسين دقة التنبؤ لأستخراج البيانات المستخدمة . وبصورة عامة ، تكون الغاية الاساسية هو تحديد الميزات المهمة في مجموعة البيانات وتجاهل الميزات الاخرى من خلال اعتبارها غير ذات صلة او زائدة عن الحاجة.

أن الحل المناسب لتسهيل عملية تحليل ودراسة بيانات كهذه هو استعمال مجموعة من طرائق الجراء التي تساعدنا على الاختيار منها طريقة Least Absolute Shrinkage and Selection Operator أقل انكماش مطلق وعامل التحديد والتي يشار إليها بصورة مختصرة بالرمز بـ (LASSO) ، اقترحت هذه الطريقة عام 1996 من قبل العالم (Tibshirani) حيث تعتبر من أكثر الطرق التي يتم استخدامها في اختيار المتغيرات وتقدير النموذج للبيانات ذات الأبعاد العالية وكطريقة جديدة للتقدير في النماذج الخطية، حيث يعتبر هذا الأسلوب واسع الانتشار نسبياً، إذ تم تطبيقه في العديد من الأبحاث البيولوجية والطبية لاكتشاف الارتباطات المحتملة بين عوامل الخطر والأمراض ذات الصلة ، فضلاً عن تحسين التنبؤ والتحقق من صحة النتائج .

في هذا البحث سيتم التطرق إلى طرق تحليل البيانات عالية الأبعاد والنماذج المعقدة، باستعمال طريقة (lasso) وطريقة (adaptive lasso) وطريقة (Double adaptive lasso) وسيتم المقارنة بين الطرق الثلاثة واستعراض أهم ميزات استخدام كلٍّ منهم في تحليل البيانات عالية الأبعاد.

2-1 مشكلة البحث Problem of the Research

أن مشكلة البيانات عالية الأبعاد موجودة في مختلف المجالات ومنها في مجال الإحصاء والتعلم الآلي وتحليل البيانات، وأن في كثير من الأحيان تعاني نماذج السلاسل الزمنية من الإفراط في عدد المراتب التي من الممكن أن تكون بعضها غير معنوية مما يتطلب التركيز على المعالم المعنوية واستبعاد وإزاحة المعالم الغير معنوية .

3-1 هدف البحث Objective of the Research

الوصول الى نموذج سلسلة زمنية أكثر كفاءة من النموذج الاعتيادي من خلال استبعاد المتغيرات التي ليس لها تأثير بالنموذج ، وهذا يُحسن النماذج الإحصائية، التي يمكن رؤيتها ليس فقط في التنبؤ ولكن أيضاً في تفسير النموذج وتقليل العمليات الحسابية. كما يلعب إختيار المتغيرات دوراً مهماً في النمذجة الإحصائية عندما يكون هناك عدد معين من المتغيرات ذات الأهمية في النموذج من بين مجموعة كبيرة من متغيرات المرتدة زمنياً .

المبحث الثاني : الجانب النظري :

1-2 نموذج الانحدار الذاتي The Autoregressive Model (AR)

نموذج الانحدار الذاتي هو احدى النماذج الرياضية المهمة التي تسعى الى تحقيق افضل تمثيل للبيانات، ويُعبر هذا النموذج عن القيمة الحالية للسلسلة y_t بدلالة القيم السابقة للسلسلة $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ والقيمة الحالية للخطأ ε_t [4][7]، حيث يستعمل هذا النموذج في العديد من المجالات ، منها تفسير ظاهره معينة سواء كانت اقتصادية او طبيعية. ان الهدف الرئيسي من تحليلنا لنماذج السلاسل الزمنية هو امكانية الوصول الى نموذج رياضي يعبر عن البيانات ، وان نموذج الانحدار الذاتي (AR) من ضمن النماذج حين تصبح قيمة السلسلة الحالية (دالة) في قيمتها السابقة بالإضافة الى بعض الاخطاء، فأن النماذج التي تكونت خلال هذه المرحلة تسمى نماذج انحدار ذاتي، فأذ كانت y_t تعبر عن قيمة السلسلة الحالية و $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ تمثل نفس القيم للسلسلة في فترات السابقة ، حيث ان y_t تتأثر بالقيم السابقة لها ويمكننا توضيح هذه العلاقة للسلسلة الزمنية المنفصلة $y = [y_t]_{t=1}^n$ لنموذج الانحدار الذاتي للرتبة (p) [3][16] والذي يعرف بالصيغة الآتية:-

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (1-1)$$

ويمكننا اعادة كتابة المعادلة اعلاه بدلالة الارتداد الخلفي [9]:-

$$(1 - \phi_1 \beta_1 - \dots - \phi_p \beta_p) Y_t = \varepsilon_t$$

$$\phi_p(\beta) Y_t = \varepsilon_t \quad (2-1)$$

حيث ان:-

Y_t : قيمة مشاهدات الظاهرة المدروسة بالزمن t

ϕ_0 : الحد الثابت

$(\phi_1, \phi_2, \dots, \phi_p)$: هي معلمات النموذج

Y_{t-k} : قيم الظاهرة المرندة زمنيا خلال الزمن t و $k=1,2,3,\dots,p$

ε_t : الخطأ العشوائي او التشويش الذي يتوزع توزيع طبيعي بمعدل (صفر) وتباين ثابت (σ_ε^2) اذ أن $(\varepsilon_t \sim \text{iid.N}(0, \sigma_\varepsilon^2))$

$$E(\varepsilon_t) = 0$$

$$E(\varepsilon_t^2) = \sigma_\varepsilon^2$$

$$E(\varepsilon_t, \varepsilon_j) = 0 \text{ for } t \neq j$$

2-2 اختيار المتغيرات Variables selection

أن موضوع اختبار المتغيرات من المواضيع التي تمحور اهتمام الكثير حولها في وقتنا الحالي ، حيث يتم استخدامها في تقليل عدد المتغيرات المستخدمة في التحليل الاحصائي وازالة أو استبعاد المتغيرات الغير ذات اهمية والتي لا تؤثر بدرجة كبيرة على النتائج ، في العديد من المجالات التي تمتلك بيانات كبيرة تكون بحاجة الى تحديد عدد المتغيرات المعنوية (المهمة) حيث ويساعدنا ذلك في تقليل الكلفة والجهد وبالأضافة لتحسين جودة التحليل . ومن بين هذه المجالات (الهندسة الوراثية ، المالية ، المجالات الطبية ، الزراعة ، البيئة ، علم الاجتماع) وغيرها من المجالات الاخرى .

تعتبر عملية اختيار المتغير جزء مهم في العديد من المجالات ، حيث تظهر اهميته متى ما تكون الدالة الحقيقية دالة غير خطية ومن المعروف أن ادخال عدد كبيراً من المتغيرات بمعادلة الانحدار لأي دراسة او ظاهرة يكلف جهداً ووقتاً وثنياً ووجود بعض المتغيرات غير الاساسية في تأثيرها المتغير المعتمد أو يكون تأثيرها مشابهة لتأثير متغيرات اخرى ، أو كون لهذه المتغيرات ارتباط عالي فيما بينها حيث يجعل تأثيرها غير معنوي مما يدعونا الى ازالة (استبعاد) مثل هذه المتغيرات

هناك نوعان اساسيان من طرائق اختبار المتغيرات منها ما تعرف بأسم الطرائق التقليدية والتي تتضمن طريقة الحذف العكسي حيث تبدأ هذه الطريقة بأعتماد جميع المتغيرات في معادلة الانحدار ومن ثم يتم تباعاً حذف تلك المتغيرات بأستخدام قيمة F الجدولية ، أما الطريقة الثانية فتعرف بطريقة الاختبار الامامي المباشر حيث يتم من خلال هذه الطريقة ادخال المتغيرات واحداً تلو الآخر الى معادلة الانحدار ، أما الطريقة الثالثة فتعرف بطريقة الاختبار التدريجي ، بالاضافة الى معيارين مهمين هما (معيار اكاكي المعلومات AIC ، معيار بيز للمعلومات BIC) وهي عادة ما تستخدم في السلاسل الزمنية في تحديد افضل رتبة او افضل متغيرات توضيحية

و بالنسبة للنوع الثاني من طرائق اختبار المتغير فتعرف بطرائق التنظيم أذ تقوم هذه الطرائق بفرض حداً للجراء على المعلمات ليتم تسهيل عملية تقديرات المعلمات وتقليص المتغيرات ومن هذه الطرق هي طريقة لاسو وطريقة لاسو المكيف ولاسو المكيف المزوج وغيرها من الطرق .

3-2 دالة الجزاء (Penalty Function)

قام العالم (Tibshirani) عام 1996 بأقتراح طريقة تقليص عرفت بأسم (اقل انكماش مطلق لأختيار العامل)^[12] ومصطلح (LASSO) يرمز الى الحروف الاولى لمفهوم " Least Absolute Shrinkage and Selection Operator " تقوم هذه الطريقة بمنع حدوث مشكلة التحيز الى الاعلى (Over fitting) أي أن النموذج مع العديد من المتغيرات الداخلة تكون دون المستوى الأمثل أي (غير مهمة) عندما يكون النموذج الصحيح مبعثر (sparse) بمعنى أن المتغير المعتمد فقط يعتمد على عدد قليل من المتغيرات الداخلة أي (المعنوية) ، أن دالة الجزاء تعتمد على معلمة الجزاء (α) وعن طريق هذه المعلمة يتم وضع حد جزاء والذي من خلاله يتم الحصول على عدد كبير من المعلمات و بالنسبة للمعلمات الاقل من قيمة معلمة الجزاء تكون قيمتها مساوية الى الصفر عندها يكون اختيار النموذج المناسب تلقائياً^{[10][6]}

4-2 طريقة لاسو Lasso Method^{[4][11]}

لاسو هي تقنية جذابة للتنظيم واختيار المتغيرات للبيانات عالية الابعاد^[8] ، وهي احدى طرق التنظيم التي تعرف بأنها (اضافة دالة جزاء للتحكم بتعقيد النموذج ، حيث يعبر عنه بـ (penalty) وأن عمل هذا الجزاء يكون بتقليل تباين النموذج مع الزيادة الكبيرة في التحيز) ، تلقت هذه الطريقة الكثير من الأهتمام للدراسات النظرية والتطبيقات الواقعية نظراً لقدرتها على إجراء تقدير المعلمة واختيار النموذج في وقت واحد ، كما انها تعتبر من الطرق الفعالة حيث تعمل هذه الطريقة على اختيار المتغيرات اضافة لتقدير المعالم ، بالإضافة الى انها تعمل بمبدأ تصغير مجموع مربعات الخطأ تبعاً للقيود الذي يمثل (المجموع المطلق للمعلمات)^[5] ، كما أن دالة الجزاء (Lasso) تقوم بجعل بعض المعالم مساوية الى الصفر في حال كانت معلمة الجزاء كبيرة ليتم تقليصها تبعاً لمقدار معين بالأعتماد على معلمة الجزاء (α) لغرض التحكم بمقدار التقليص (الانكماش) (shrinkage)^[17]

ويمكن كتابته بالشكل الاتي:-

$$\hat{\phi}_{lasso} = \underset{\phi}{\operatorname{argmin}} \left\{ \sum_{t=p+1}^n (y_t - \sum_{j=1}^p \phi_j y_{t-j})^2 + \alpha \sum_{j=1}^p |\phi_j| \right\} \quad (3-1)$$

α : معلمة الجزاء

$\alpha \sum_{j=1}^p |\phi_j|$: دالة الجزاء

أن مقدر لاسو يعمل على جعل قيمة المعلمات الغير معنوية مساوية الى الصفر ويعمل على انكماش او تقليص باقي المعلمات بمقدار معين ، اضافة الى تقدير معالم النموذج ويقوم بأختيار المتغيرات الداخلة في النموذج لزيادة القدرة التفسيرية لنموذج الانحدار الذاتي الذي تم استخدامه في تفسير الظاهرة المدروسة .

5-2 طريقة لاسو التكيفي Adaptive Lasso

اللاسو التكيفي هو تطوير لطريقة لاسو LASSO التي تُستخدم في اختيار المتغيرات وتنظيم النماذج الاحصائية ، لقد تطرقت العديد من الدراسات الى تحسين اداء LASSO ، وفي عام 2006 اقترح العالم (Zou)^[18] نسخة جديدة من LASSO والمعروفة بأسم لاسو التكيفي LASSO Adaptive وكالاتي:-

$$\hat{\phi}_{lasso(1)} = \underset{\phi \in R^p}{\operatorname{argmin}} \left\{ \sum_{t=p+1}^n (y_t - \sum_{j=1}^p \phi_j y_{t-j})^2 + \alpha \sum_{j=1}^p w_j |\phi_j| \right\} \quad (4-1)$$

أذ أن

$$\alpha \sum_{j=1}^p w_j |\phi_j|$$

$$j=1, \dots, p \text{ و } w_j \in w \text{ و } w_j \geq 0$$

w : يعرف بالاوزان المكيّفة (Adaptive weight) والتي تعتمد على تقديرات اولية لمعاملات النموذج وهذه الاوزان تسمح للعقوبة بأن تكون أكثر مرونة حيث يؤدي ذلك الى تحسين أداء النموذج في اختيار المتغيرات وتقليل التحيز (bias) في التقديرات ، كما بين العالم (Zou) أنه اذا تم اختيار الاوزان (w_j) بكفاءة وبطريقة يعتمد فيها على البيانات فإن طريقة لاسو التكيّفية يمكن أن تحقق ما يسمى بـ (*oracle properties*) وخاصية الكفاءة (*Efficient*) بحيث ينفذ بطريقة كما لو كان النموذج الصحيح معروف ، وتم اقتراح استعمال الاوزان المقدرّة بالصيغة الآتية:-

$$w_j = \frac{1}{|\hat{\phi}_j|^\gamma} \quad (5 - 1)$$

حيث أن :-

$$\hat{\phi}_j \text{ تمثل تقديرات (OLS) وهي مقدر اولي متنسق لـ } \phi_j^{[13]}$$

γ : قيمة معلمة التحكم في قوة العقوبة وقيمتها أكبر من الصفر بمعنى $\gamma > 0$ وعادة ما تكون $\gamma = 1$ أو $\gamma = 2$ أن اختيار الاوزان w_j مهم جداً لذا قام العالم (Zou) باستعمال تقديرات المربعات الصغرى الاعتيادية لحسابها ($\hat{\phi}_{j \text{ ols}}$)

6-2 طريقة لاسو التكيّفي المزدوج Double Adaptive Lasso

لاسو التكيّفي المزدوج هو امتداد لطريقة اللاسو التكيّفي Adaptive Lasso حيث يتم تحسين عملية اختيار المتغيرات وتقدير المعاملات في النماذج الاحصائية عن طريق استخدام (اوزان تكيّفية مزدوجة) حيث تعزز هذه الطريقة من قدرة النموذج على التعامل مع البيانات المعقدة وتحسين دقة التقديرات خاصة في نماذج الانحدار الذاتي مثل $AR(p)^{[14]}$ ، أن الفكرة الاساسية لاستخدام هذه الطريقة هي تقدير المعاملات $\phi_1, \phi_2, \dots, \phi_p$ المذكورة في المعادلة (1-1) بدقة ، اضافة الى تقليل عدد المعاملات غير المعنوية (اجبار بعضها على الصفر)

نبدأ بالحصول على تقديرات اولية لمعاملات الانموذج $\hat{\phi}_1, \hat{\phi}_2, \dots, \hat{\phi}_p$ باستخدام طريقة المربعات الصغرى الاعتيادية (OLS) ليتم استخدامها في حساب الاوزان التكيّفية الاولى $w_j^{(1)}$ لكل معامل ϕ_j وكالاتي:-

$$w_j^{(1)} = \frac{1}{|\hat{\phi}_j|^\gamma} \quad (6 - 1)$$

نقوم بتقدير المعاملات باستخدام لاسو المكيف Adaptive Lasso حيث نضيف عقوبة تكيّفية الى دالة الجراء:

$$\hat{\phi}_{lasso(1)} = \arg \min_{\phi \in R^p} \left\{ \sum_{t=p+1}^n (y_t - \sum_{j=1}^p \phi_j y_{t-j})^2 + \alpha \sum_{j=1}^p w_j^{(1)} |\phi_j| \right\} \quad (7 - 1)$$

بعد الحصول على تقديرات جديدة $\hat{\phi}_j^{(1)}$ من المعادلة (7-1) نقوم بحساب الاوزان التكيّفية الثانية $w_j^{(2)}$ وكالاتي:-

$$w_j^{(2)} = \frac{1}{|\hat{\phi}_j^{(1)}|^\gamma} \quad (8-1)$$

نقوم بعدها بتطبيق عقوبة مزدوجة عن طريق استخدام الاوزان التكميفية الثانية في دالة الجزاء المعدلة وكالاتي:-

$$\hat{\phi}_{lasso(2)} = \arg \min_{\phi \in R^p} \left\{ \sum_{t=p+1}^n (y_t - \sum_{j=1}^p \phi_j y_{t-j})^2 + \alpha \sum_{j=1}^p w_j^{(2)} |\phi_j| \right\} \quad (9-1)$$

ليتم بعدها تقدير المعاملات النهائية $\phi_1, \phi_2, \dots, \phi_p$ عن طريق تقليل دالة الجزاء المعدلة $\hat{\phi}_{lasso(2)}$.

المبحث الثالث : الجانب التطبيقي

بالاعتماد على برنامج لغة python تم تطبيق طرق اختيار المتغيرات (طريقة لاسو و طريقة لاسو التكميفية وطريقة لاسو التكميفية المزدوج) على بيانات حقيقة متمثلة بمؤشر السوق الاسبوعي لقطاع المصارف، تم الحصول عليها من [1] والمأخوذة من الموقع الرسمي لسوق العراق للأوراق المالية [2] للمدة من 2017-2021 حسب توافر البيانات وبواقع (260) مشاهدة.

1-3 تحليل البيانات باستخدام انموذج الانحدار الذاتي AR(p):


بعد أن قمنا برسم السلسلة الزمنية وظهرت عدم استقراريتها في الوسط الحسابي تم اجراء اختبار الاستقرار والمتمثل باختبار ديكي-فولر للتأكد من عدم الاستقرارية وقمنا بأعادة رسمها بعد أن اخذ الفروق لها ليتبين استقرارها عند الفرق الاول ، سيتم في هذه المرحلة تحليل بيانات السلسلة الزمنية المستقرة باستخدام انموذج الانحدار الذاتي AR(p) لغرض تحديد افضل رتبة (p) من خلال استخدام المعايير الثلاثة HQIC, AIC, BIC حيث ظهرت النتائج الموضحة في الجدول ادناه وكما يلي:-

p	AIC	BIC	HQIC
1	1597.869	1607.867	1601.912
2	1581.418	1594.729	1586.801
3	1568.643	1585.258	1575.363
4	1563.338	1583.247	1571.392
5	1557.093	1580.285	1566.476
6	1548.771	1575.237	1559.48
7	1543.822	1573.551	1555.852
8	1534.257	1567.241	1547.605
9	1526.365	1562.592	1541.027
10	1521.36	1560.819	1537.331
15	1492.054	1547.52	1514.516
20	1466.273	1537.475	1495.122
25	1437.181	1523.837	1472.307
30	1410.091	1511.908	1451.381
35	1375.87	1492.541	1423.203
40	1344.415	1475.621	1397.665
45	1317.592	1462.999	1376.626
50	1289.379	1448.634	1354.054
55	1262.225	1434.96	1332.393
60	1210.677	1396.504	1286.178


65	1181.604	1380.115	1262.269
----	----------	----------	----------

الجدول (1-3) يوضح عدد الارتدادات الزمنية (p) وقيم معياري AIC, BIC, HQIC

من خلال الجدول (1-3) يتضح أن الرتبة الصحيحة تقابل أقل قيمة لمعايير التشخيص ومن ملاحظتنا لنتائج الجدول اعلاه فإن أقل قيمة للمعايير الثلاثة ظهرت عندما كانت قيمة $p = 65$ حيث كلما زادت قيمة الرتبة قلت قيمة المعايير الثلاثة، وبسبب كثرة الارتدادات الزمنية التي تم العمل عليها سيتم استعراض جزء من النتائج والرسوم




الشكل (1-3) يوضح القيم الفعلية والقيم التنبؤية عند ($p=1$)




الشكل (2-3) يوضح القيم الفعلية والقيم التنبؤية عند ($p=2$)

لغرض توضيح الفرق بين قيم الرتب المأخوذة تم اضافة عندما كانت قيمة ($p=1$) و ($p=2$) حيث يتبين من خلال الشكل (1-3) و (2-3) أن القيم التنبؤية في الشكلين اعلاه لم تتأثر بالتغيرات الحاصلة حيث ظهرت وكأنها تسلك سلوك المتوسط ، اما عندما قمنا بتحسين قيمة الرتب وصولا الى الرتبة ($p=60$) و ($p=65$) فإن القيم التنبؤية بدأت تتحسن للتغيرات وكما موضحة بالشكل (3-3) و (4-3) ، حيث يدل ذلك على أنه كلما ازدادت قيمة الرتبة ازداد التذبذب بالقيم التنبؤية.



الشكل (3-3) يوضح القيم الفعلية والقيم التنبؤية عند (p=60)



الشكل (4-3) يوضح القيم الفعلية والقيم التنبؤية عند (p=65)

2-3 تحديد المعالم المعنوية الأفضل باستخدام طرق Lasso

1-2-3 المعالجة المسبقة للبيانات (Data Pre-Processing):

بعد أن تم تهيئة البيانات وتحديد المتغير التابع (مؤشر السوق) والمتغيرات المستقلة (عدد الاتدادات) و استخراج الارتدادات باستخدام انموذج الانحدار الذاتي (AR(p) تأتي مرحلة المعالجة المسبقة للبيانات التي بدورها تنقسم الى مرحلتين، الاولى (تقسيم البيانات (Data Splitting)) والثانية (تقييس البيانات (Features Scaling)) اذ تتم في المرحلة الاولى تقسيم البيانات الى مجموعتين تدريب (Training) واختبار (Testing) حيث (80%) تدريب و(20%) اختبار^[15] كما موضح بالشكل (4-3) عندما كانت

قيمة (p=65) ، ومن ثم يتم إجراء تقييس للبيانات (Features Scaling) باستخدام طريقة (standard scalar) حيث تقوم بتوحيد البيانات بحيث يكون المتوسط $\mu = 0$ وانحراف معياري $\sigma = 1$ والصيغة الرياضية له كالتالي:-

$$X_{scaled} = \frac{X - \mu}{\sigma}$$

ليتم تهيئتها لغرض ادخالها الى النماذج المستخدمة.


2-2-3 نموذج لاسو Lasso :

بعد تهيئة البيانات واستخراج الارتدادات وإجراء المعالجة المسبقة ، تم بناء نموذج لاسو لغرض تحديد اي المتغيرات التي لها تأثير على دقة الانموذج وايها التي ليس لها تأثير، وبأستخدام عدة قيم من الفا (α) (0.001, 0.01, 0.05, 0.1, 0.5) ظهرت النتائج الموضحة بالجدول الاتي:-

	α	RMSE
lags_p=65	0.001	10.96413316
	0.01	10.96395921
	0.05	10.95398892
	0.1	10.93315823
	0.5	11.01855339

الجدول (2-3) يوضح بعض مقاييس الدقة لكل قيمة من قيم الفا لأنموذج لاسو

من نتائج الجدول (2-3) يتضح أن اقل قيمة لمقاييس الدقة ظهرت عندما كانت قيمة $\alpha = 0.1$ عندها سنقوم برسم القيم الفعلية والقيم التنبؤية عند (p=65) و ($\alpha = 0.1$) وكالاتي:



الشكل (5-3) يوضح القيم الفعلية والقيم التنبؤية عند (p=65) و ($\alpha = 0.1$)

من ملاحظتنا للرسم المبين في الشكل (5-3) يتبين بأن تأثير بالتقليص الحاصل واضح جداً بأستخدام طريقة لاسو حيث تم استبعاد عدداً من المتغيرات وكما مبينة في الجدول (3-3) وكالاتي:

الارتدادات الغير معنوية	α
-------------------------	----------

Lags p=65	0.001	[]
	0.01	['lag_46']
	0.05	['lag_6', 'lag_33', 'lag_42']
	0.1	['lag_3', 'lag_5', 'lag_8', 'lag_11', 'lag_17', 'lag_18', 'lag_19', 'lag_24', 'lag_32', 'lag_35', 'lag_39', 'lag_41', 'lag_49', 'lag_52', 'lag_53', 'lag_60', 'lag_61']
	0.5	['lag_14', 'lag_24', 'lag_25', 'lag_26', 'lag_34', 'lag_35', 'lag_36', 'lag_37', 'lag_38', 'lag_42', 'lag_46', 'lag_47', 'lag_48', 'lag_49', 'lag_50', 'lag_53', 'lag_56', 'lag_57', 'lag_58', 'lag_61', 'lag_65']

الجدول (3-3) يوضح الارتدادات الزمنية الغير معنوية لأنموذج لاسو لكل قيمة من قيم (α) عندما $p=65$

من الجدول (3-3) اعلاه نلاحظ عندما كانت قيمة $(\alpha = 0.1)$ فإن طريقة لاسو استبعدت المتغيرات

['lag_3', 'lag_5', 'lag_8', 'lag_11', 'lag_17', 'lag_18', 'lag_19', 'lag_24', 'lag_32', 'lag_35', 'lag_39', 'lag_41', 'lag_49', 'lag_52', 'lag_53', 'lag_60', 'lag_61']


3-2-3 : Adaptive lasso التكميلي

سنقوم في هذه المرحلة ببناء انموذج لاسو التكميلي عندما كانت قيمة $p=65$ ولنفس القيم من α ظهرت النتائج كما موضحة بالجدول الاتي:-

	α	RMSE
lags_p=65	0.001	12.47898
	0.01	15.1645
	0.05	14.13161
	0.1	15.17139
	0.5	14.7402

الجدول (4-3) يوضح مقاييس الدقة لكل قيمة من قيم α لأنموذج لاسو المكيف

من نتائج الجدول (4-3) يتضح أن اقل قيمة لمقاييس الدقة ظهرت عندما كانت قيمة $\alpha = 0.001$ عندها نقوم برسم القيم الفعلية والقيم التنبؤية عند $(p=65)$ و $(\alpha = 0.001)$ وكالاتي:-



الشكل (6-3) يوضح القيم الفعلية والقيم التنبؤية عند $(p=65)$ و $(\alpha = 0.001)$

من ملاحظتنا للرسم في الشكل (6-3) يتبين بأن تأثير بالتقليص الحاصل واضح جداً باستخدام طريقة لاسو التكيفي حيث تم استبعاد عدداً من المتغيرات الغير معنوية وكما مبينة في الجدول (5-3) وكالاتي:

	α	الارتدادات الغير معنوية
lags_p=65	0.001	['lag_8', 'lag_14', 'lag_23', 'lag_29', 'lag_33', 'lag_34', 'lag_37', 'lag_46', 'lag_47', 'lag_49', 'lag_51', 'lag_57', 'lag_61', 'lag_64']
	0.01	['lag_4', 'lag_7', 'lag_14', 'lag_25', 'lag_29', 'lag_31', 'lag_35', 'lag_37', 'lag_46', 'lag_49', 'lag_52', 'lag_56', 'lag_61', 'lag_63']
	0.05	['lag_12', 'lag_13', 'lag_21', 'lag_31', 'lag_33', 'lag_38', 'lag_41', 'lag_46', 'lag_48', 'lag_49', 'lag_52', 'lag_53', 'lag_54', 'lag_56', 'lag_59', 'lag_62']
	0.1	['lag_6', 'lag_7', 'lag_21', 'lag_28', 'lag_29', 'lag_30', 'lag_31', 'lag_32', 'lag_36', 'lag_41', 'lag_42', 'lag_44', 'lag_46', 'lag_49', 'lag_52', 'lag_53', 'lag_56', 'lag_58', 'lag_61', 'lag_64']
	0.5	['lag_1', 'lag_3', 'lag_4', 'lag_6', 'lag_7', 'lag_8', 'lag_9', 'lag_10', 'lag_11', 'lag_12', 'lag_13', 'lag_14', 'lag_15', 'lag_17', 'lag_20', 'lag_22', 'lag_24', 'lag_25', 'lag_26', 'lag_27', 'lag_28', 'lag_29', 'lag_30', 'lag_31', 'lag_32', 'lag_34', 'lag_35', 'lag_36', 'lag_39', 'lag_42', 'lag_43', 'lag_44', 'lag_45', 'lag_46', 'lag_47', 'lag_48', 'lag_49', 'lag_50', 'lag_51', 'lag_52', 'lag_53', 'lag_54', 'lag_55', 'lag_56', 'lag_58', 'lag_59', 'lag_60', 'lag_61', 'lag_62', 'lag_63', 'lag_64', 'lag_65']

الجدول (5-3) يوضح الارتدادات الزمنية الغير معنوية لأنموذج لاسو المكيف لكل قيمة من قيم (α) عندما $p=65$

من الجدول (3-5) اعلاه نلاحظ عندما كانت قيمة $(\alpha = 0.001)$ فإن طريقة لاسو التكيفي استبعدت المتغيرات $lag_8, 'lag_14', 'lag_23', 'lag_29', 'lag_33', 'lag_34', 'lag_37', 'lag_46', 'lag_47', 'lag_49', 'lag_51', 'lag_57', 'lag_61', 'lag_64$


4-2-3 نموذج لاسو التكيفي المزدوج Double Adaptive Lasso

سنقوم في هذه المرحلة ببناء نموذج لاسو التكيفي المزدوج عندما كانت قيمة $p=65$ ولنفس القيم من α ظهرت النتائج كما موضحة بالجدول الاتي:-

	α	RMSE
lags_p=65	0.001	11.27795
	0.01	11.11946
	0.05	10.81015
	0.1	10.90179
	0.5	10.9017

الجدول (3-6) يوضح مقاييس الدقة لكل قيمة من قيم الفا لأنموذج لاسو التكيفي المزدوج

من نتائج الجدول (3-6) يتضح أن اقل قيمة لمقاييس الدقة ظهرت عندما كانت قيمة $\alpha = 0.05$ عندها نقوم برسم القيم الفعلية والقيم التنبؤية عند $(p=65)$ و $(\alpha = 0.05)$ وكالاتي:-



الشكل (3-7) يوضح القيم الفعلية والقيم التنبؤية عند $(p=65)$ و $(\alpha = 0.05)$

من ملاحظتنا للرسم في الشكل (3-7) يتبين بأن تأثير بالتقليص الحاصل واضح جدا باستخدام طريقة لاسو المكيف المزدوج حيث تم استبعاد عدداً من المتغيرات الغير معنوية وكما مبينة في الجدول (3-7) وكالاتي:

	α	الارتدادات الغير معنوية
lags_p=65	0.001	[]

	0.01	['lag_19', 'lag_22', 'lag_26', 'lag_29', 'lag_33', 'lag_46', 'lag_49', 'lag_51']
	0.05	['lag_5', 'lag_10', 'lag_12', 'lag_13', 'lag_17', 'lag_18', 'lag_19', 'lag_20', 'lag_22', 'lag_24', 'lag_26', 'lag_27', 'lag_29', 'lag_33', 'lag_34', 'lag_36', 'lag_37', 'lag_39', 'lag_43', 'lag_45', 'lag_46', 'lag_49', 'lag_51', 'lag_53', 'lag_55', 'lag_57']
	0.1	['lag_2', 'lag_5', 'lag_6', 'lag_8', 'lag_12', 'lag_13', 'lag_15', 'lag_16', 'lag_17', 'lag_18', 'lag_19', 'lag_20', 'lag_22', 'lag_23', 'lag_24', 'lag_26', 'lag_27', 'lag_28', 'lag_29', 'lag_31', 'lag_33', 'lag_34', 'lag_36', 'lag_37', 'lag_38', 'lag_39', 'lag_40', 'lag_41', 'lag_42', 'lag_43', 'lag_45', 'lag_46', 'lag_48', 'lag_49', 'lag_50', 'lag_51', 'lag_53', 'lag_54', 'lag_55', 'lag_57', 'lag_59', 'lag_60', 'lag_61', 'lag_62', 'lag_63', 'lag_64', 'lag_65']
	0.5	['lag_2', 'lag_3', 'lag_4', 'lag_5', 'lag_6', 'lag_7', 'lag_8', 'lag_10', 'lag_11', 'lag_12', 'lag_13', 'lag_14', 'lag_15', 'lag_16', 'lag_17', 'lag_18', 'lag_19', 'lag_20', 'lag_21', 'lag_22', 'lag_23', 'lag_24', 'lag_25', 'lag_26', 'lag_27', 'lag_28', 'lag_29', 'lag_30', 'lag_31', 'lag_32', 'lag_33', 'lag_34', 'lag_35', 'lag_36', 'lag_37', 'lag_38', 'lag_39', 'lag_40', 'lag_41', 'lag_42', 'lag_43', 'lag_45', 'lag_46', 'lag_48', 'lag_49', 'lag_50', 'lag_51', 'lag_52', 'lag_53', 'lag_54', 'lag_55', 'lag_56', 'lag_57', 'lag_58', 'lag_59', 'lag_60', 'lag_62', 'lag_63', 'lag_64', 'lag_65']

الجدول (7-3) يوضح الارتدادات الزمنية الغير معنوية لأنموذج لاسو المكيف المزدوج لكل قيمة من قيم (α) عندما $p=65$

من الجدول (7-3) نلاحظ عندما كانت قيمة ($\alpha=0.05$) فإن طريقة لاسو التكيفي المزدوج استبعدت المتغيرات ['lag_5', 'lag_10', 'lag_12', 'lag_13', 'lag_17', 'lag_18', 'lag_19', 'lag_20', 'lag_22', 'lag_24', 'lag_26', 'lag_27', 'lag_29', 'lag_33', 'lag_34', 'lag_36', 'lag_37', 'lag_39', 'lag_43', 'lag_45', 'lag_46', 'lag_49', 'lag_51', 'lag_53', 'lag_55', 'lag_57']

3-3 تقييم النماذج (Result Evaluation) :

من خلال استخراجنا الرتبة ($P=65$) وبعد استخدامنا لطرق الجزاء الثلاثة وبالاعتماد على مقياس الدقة (RMSE) المستخدم لقياس دقة كل نموذج ظهرت النتائج الاتية :-

Model	α	RMSE	Nonzero parameter
Lasso	0.1	10.93315823	48
Adaptive Lasso	0.001	12.47898	51
Double Adaptive Lasso	0.05	10.81015	39

جدول (6-3) معايير الدقة لافضل النماذج التنبؤية

لمعرفة أي النماذج المستخدمة افضل في اختيار المتغيرات ، تم الاعتماد على مقياس الدقة الجذر التربيعي لمتوسط مربعات الخطأ RMSE حيث نلاحظ مايتي:-

من الجدول (6-3) نلاحظ أنه باستخدام انموذج (Double Adaptive Lasso) فإنه يعطي نتائج متقاربة للنتائج المستحصل عليها بأنموذج (Lasso) مع وجود افضلية نسبية لأنموذج (Double Adaptive Lasso) حيث بلغت قيمة الجذر التربيعي لمتوسط مربعات الخطأ باستخدام انموذج (Double Adaptive Lasso) ($RMSE=10.81015$) بينما ظهرت قيمة الجذر التربيعي لمتوسط مربعات الخطأ باستخدام انموذج (Lasso)

Adaptive (RMSE = 10.93315823) أما قيمة الجذر التربيعي لمتوسط مربعات الخطأ باستخدام انموذج (Lasso) فقد بلغت (RMSE = 12.47898) و بلغت قيمة معلمة الجزاء باستخدام انموذج (Double Adaptive Lasso) (α=0.05) وقيمة معلمة الجزاء باستخدام انموذج (Lasso) (α=0.1) بينما كانت قيمة معلمة الجزاء باستخدام انموذج (Adaptive Lasso) (α=0.001) أما عدد المعاملات غير الصفريّة فقد بلغت (39) معامل باستخدام انموذج (Double Adaptive Lasso) و (48) معامل باستخدام انموذج (Lasso) وبلغ (51) معامل باستخدام انموذج (Adaptive Lasso).

3-4 الاستنتاجات (Conclusion)

في هذا البحث، تم استخدام ثلاثة طرق الجزاء والمتمثلة بطريقة الجزاء Lasso وطريقة Adaptive Lasso وطريقة Double Adaptive Lasso والتي لها أهمية بالغه في اختيار افضل متغيرات نماذج السلاسل الزمنية حيث تم استخدام طريقة Double Adaptive Lasso المقترحة من قبل (Liu) في عام 2014 حيث تبين أن منهجية لاسو التكيفي المزدوج له دقة حسابية اعلى بكثير نظيرتيه . نستنتج ومن خلال نتائج الجانب التطبيقي أن النتائج المستحصل عليها باستخدام انموذج (Double Adaptive Lasso) متقاربة للنتائج المستحصل عليها بأنموذج (Lasso) حيث تفوق أنموذج (Double Adaptive Lasso) على نظيرتيه كونه يعطي افضلية نسبية عن طريق استعمال مقياس الدقة (RMSE) اقل عند المقارنة .

المصادر (References):

1- عبدالحسين , سما حيدر(2022)م " مقارنة بعض تقنيات التعلم العميق للتنبؤ بالمؤشرات المالية " رسالة ماجستير في تقنيات المعلوماتية الادارية

2- الصفحة الرسمية لسوق العراق للأوراق المالية

<http://www.isx-iq.net/isxportal/portal/aboutUs.ht>

3- Box, G. E. P., Jenkins, G. M., Ljung, G. M. & Reinsel, G. C. (2016). "Time Series Analysis Forecasting and Control", John Wiley & Sons.

4- Brockwell, P. J., & Davis, R. A. (2009). *Time series: theory and methods*: Springer science & business media

5- Jatherine, Stuart (2011) " Robust Regression", Springer

6- Liu, X. (2011), " penalized variable selection for semiparametric regression models ". submitted in partial fulfillment of the requirements for the degree doctor of philosophy – nuniversity of Rochester , new york .

7- Liu, Zi Zhen, (2014) " The Doubly Adaptive LASSO Methods for Time Series Analysis" Electronic Thesis and Dissertation Repository.

8- Meinshausen, N. and Yu, B. (2009). Lasso-type recovery of sparse representation for high-dimensional data. *The Annals of Statistics*, 37, 246.27



-
- 9- Montgomery, D. C., Jennings, C. L.& Kulahci, M. (2015). "Introduction to time series analysis and forecasting", John Wiley & Sons, Inc; Second Edition
- 10- Peng , H., and Huang ,T.(2011) , " penalized least squares for single index models " . Journal of statistical planning and inference 141 , pp. 1362-1379 .
- 11- Roth, Volker. (2004) "The generalized LASSO." IEEE transactions on neural networks, VOL (15), NO. (1): 16-28.
- 12- Tibshirani , Robert, (1996) ," Regression Shrinkage and Selection via the Lasso" , J. R. Statist. Soc. B 58, No. 1, pp. 267-288.
- 13- Wang, T., Xu.P.,and Zhu , L.(2013) ," Penalized Minimum Average Variance Estimation " . statistics sinica 23, pp.543-569.
- 14- Wang, H., & Leng, C. (2007). Unified LASSO estimation by least squares approximation. *Journal of the American Statistical Association*, 102(479), 1039-1048.
- 15- Yue, J., Wei, B.&Rao,Y.(2017)"A deep learning framework for financial time series using stacked autoencoders and long-short term memory" PLoS ONE 12(7):e0180944.
- 16- Yule, G.U (1927). On a Method of Investigating Periodicities in Disturbed series, With special Reference to wolfer's Sunspot Numbers. *Philosophical*
- 17- Zhang, C. H. and Zhang, S. (2014) Confidence intervals for low dimensional parameters in high-dimensional linear models. *Journal of the Royal Statistical Society, Series B*, 76.
- 18- Zou, H. (2006). The adaptive LASSO and its oracle properties. *J. American Statistical Association*, 101: 1418-1429