

" دراسة مقارنة بين طريقة (لاسو - ماف) وطريقة (لاسو التكيفيه - ماف) لاختيار المتغير في نماذج المؤشر الواحد شبه المعلميه "

م.د. طارق عزيز صالح

جامعة واسط/كلية الادارة والاقتصاد - قسم الاحصاء

المستخلص:

ان نماذج المؤشر الواحد شبه المعلميه هي ادوات مهمة واساسية لمعالجة مشكلة الابعاد العالية اذ تلعب دوراً مهماً في عملية بناء الانموذج واختيار المتغيرات المعنويه . وفي هذا البحث تم استعمال بعض اساليب اختيار المتغير التلقائي الحديثة والتي تعمل على تقدير متجه المعلمات β ودالة الربط $g(X^T\beta)$ واختيار المتغير في آن واحد لنماذج المؤشر الواحد شبه المعلميه وهي طريقة (LASSO – MAVE) وطريقة (Adaptive LASSO –MAVE) بهدف تحسين دقة وتنبؤ الانموذج ومن اجل تحقيق هذا الهدف تم اجراء تجارب المحاكاة لبيان افضلية الطرائق المستعملة في تقدير واختيار المتغير للانموذج قيد الدراسة وباستعمال نماذج مختلفة ، تباينات مختلفة ، وحجوم عينات مختلفة وقيم ارتباط مختلفة فضلاً عن استخدام البيانات الحقيقية المتمثلة بالعوامل المؤثرة في القيمة السوقية للسهم لقطاع المصارف في سوق العراق للاوراق المالية لغرض المقارنة والتحقق من اداء هذه الطرائق في الواقع العملي . وتم التوصل عن طريق تجارب المحاكاة والبيانات الحقيقية الى استنتاجات بينت افضلية طريقة (LASSO –MAVE) اذ اعطت نتائج افضل من طريقة (LASSO – MAVE) (Adaptive) بالاعتماد على المعيارين معدل متوسط مربعات الخطا (AMSE) ومعدل متوسط الخطا المطلق (AMAE) اساساً للمقارنة وتم الحصول على النتائج بالاعتماد على برنامج (R-package).

- المصطلحات : انموذج المؤشر الواحد ، اختيار المتغير ، مشكلة الابعاد ، طريقة ماف ، طريقة لاسو - ماف ، طريقة لاسو التكيفية - ماف .

"A comparative study between LASSO–MAVE method and Adaptive LASSO–MAVE method for variable selection in semi–parametric single index models "

- ABSTRACT

The semi–parametric single – index model (SSIM) are important tools and basic to treatment the problem of high – dimensional , As it plays an important role in the process of model building and variable selection of significant . in this research has been the use some methods variable selection of automatic modern and that work on estimation vector of parameters β and link function $g(X^T\beta)$ With variable selection at the same time for semi–parametric single–index model are LASSO –MAVE method and Adaptive LASSO – MAVE method for aim to improve the accuracy and predict of the model . in order to achieve this aim , it was conducted simulation experiment to show methods preference used in estimation and variable selection for model under study by using different models , different variances , different sample sizes and different correlation values as well as the use of a real data of influencing factors on market value share for the banks sector in the iraqi stock exchange for purpose of comparison and a check from performance these methods in practice . it was reached through simulation experiments and a real data to conclusion showed favorite Adaptive LASSO – MAVE method as it gave better results from LASSO–MAVE method depending on the two criteria Average mean squared error (AMSE) and Average

mean absolute error (AMAE) basically for Comparison , and were obtained on results depending on program R- package.

Keywords: single index model , variable selection , curse of dimensionality , mave method , lasso-mave method , adaptive lasso mave method .

(introduction)

1. المقدمة :

يعد انموذج المؤشر الواحد شبه المعلمي امتداد طبيعي لانموذج الانحدار الخطي العام وهذا الانموذج يكون اكثر مرونة من النماذج المعلمية وله مركبة خطية (P) من معاملات الانحدار والمتغيرات التوضيحية . كما انه يتجنب مشكلة الابعاد العالية في البيانات من خلال هيكل المؤشر اذ يلخص تاثيرات المتغيرات التوضيحية ضمن متغير واحد (single variable) يدعى بالمؤشر (index) المتمثل في $X^T \beta$ للتغلب على مشكلة الابعاد العالية بسبب ان هذه القيمة هي مؤشر واحد على الرغم من ان X هو متجه . واكتسب انموذج المؤشر الواحد الكثير من الاهتمام بسبب استعماله في العديد من المجالات منها المال والاعمال ، الطب ، الهندس، البيئه ، الاحصاء الحيوي وغيرها .

اذ ان الغاية الاساسية من صياغة هذا الانموذج هي تخفيض الابعاد عن طريق تحديد المتغيرات المعنوية (المهمة) ووضعها في مؤشر واحد مجتمعة في اسلوب للحد من البعد وهذا الاسلوب يجعل تحديد اختيار المتغير اسهل من الاساليب المعتمدة على انموذج متعدد المؤشرات ، اذ تلعب عملية اختيار المتغير دوراً مهماً في عملية بناء الانموذج عندما يكون متجه المؤشر ابعاد عالية ويتم اختيار المتغيرات التي لديها القدرة على التنبؤ في النماذج المعتمدة على جميع المتغيرات ومن المنطقي استبعاد المتغيرات غير المعنوية في انموذج المؤشر الواحد شبه المعلمي وبغية تحقيق هذه الغاية تم استخدام طرائق شبه معلمية حديثة تعتمد على دوال الجزاء والتي من خلالها يتم اختيار المتغيرات المعنوية وتقدير معاملات الانحدار ودالة الربط في آن واحد لنماذج المؤشر الواحد و من اجل تحليل نماذج المؤشر الواحد شبه معلمية (SSIM) تم استعمال بعض الطرائق شبه المعلمية في هذا البحث وهي طريقة (LASSO-MAVE) و (Adaptive LASSO-MAVE) والتي تعمل على تقدير متجه المعلمات ودالة الربط و اختيار المتغيرات في آن واحد للانموذج .

2. انموذج المؤشر الواحد شبه المعلمي :

(semi-parametric single index model)

ان انموذج المؤشر الواحد (SIM) هو واحد من النماذج شبه المعلمية الاكثر شيوعاً في مجال الاقتصاد القياسي والمقترح من لدن الباحثين (Hardle & Stocker) عام (1989) وتم تطبيقه واقتراح طرائق شبه معلمية لتقديره من قبل الباحث (Ichimura) عام (1993) . وهذا الانموذج يسمح لمتوسط الاستجابة ليكون دالة لامعلمية من التركيبات الخطية للمتغيرات التنبؤية (predictive variables) . ويمكن وصف

انموذج المؤشر الواحد شبه المعلمي رياضياً بالشكل الاتي : [3]، [4]

$$Y = g(X^T \beta) + \epsilon \quad \dots \dots \dots (1)$$

$$E[Y|X] = g(X^T \beta) \quad \dots \dots \dots \text{ودالة التوقع الشرطي (دالة الربط) له :}$$

اذ ان :

$$Y = (Y_1, Y_2, \dots, Y_n)^T \quad \dots \dots \dots \text{Y: يمثل المتغير المعتمد (متغير الاستجابة) من درجة } n*1 .$$

$$X^T = (X_1, X_2, \dots, X_p) \quad \dots \dots \dots \text{X: يمثل متجه صفي للمتغيرات التوضيحية من درجة } p*1 .$$

β : يمثل متجه المعلمات غير المعلومة من درجة $P*1$ والتي تمثل الجزء المعلمي للانموذج وتحقق الشرط $\beta^T \beta = 1$ او $\|\beta\| = 1$ لغرض تشخيص الانموذج .

$$\beta = (\beta_1, \beta_2, \dots, \beta_p)^T$$

$g(X^T\beta)$: يمثل دالة الربط غير المعلومة قابلة للقياس والتي تمثل الجزء اللامعلمي للانموذج.

E : يمثل الخطأ العشوائي ذو توزيع طبيعي بمتوسط صفر وتباين محدد σ^2 ويحقق :

$$E[\epsilon | X^T\beta] = 0$$

ولهذا الانموذج مركبة خطية مفردة للمتغيرات التوضيحية والتي يمكن الحصول عن طريقها على معظم المعلومات حول العلاقة بين متغير الاستجابة (المعتمد) والمتغيرات التوضيحية ومن ثم تجنب مشكلة الابعاد ويمكن تقدير انموذج المؤشر الواحد شبه المعلمي (SSIM) من خلال استعمال اسلوب للتقدير بخطوتين ، الخطوة الاولى تتمثل بتقدير متجه المعلمات β وايجاد قيمة المؤشر $(X_i^T\hat{\beta})$ والخطوة الثانية يتم استخدام قيم المؤشر لكل مشاهدة لتقدير دالة الربط $g(X_i^T\hat{\beta})$ باستعمال الانحدار اللامعلمي احادي المتغير كدالة تمهيد تعتمد على البيانات $(X_i^T\hat{\beta}, Y_i)$. [10]، [12]

٣. مزايا انموذج المؤشر الواحد :

(Advantages of single index model)

يمتاز انموذج المؤشر الواحد (SIM) بمزايا عديدة و قد درست هذه المزايا من العديد من الباحثين و لعدد من المجالات منها الاقتصادية والاجتماعية و من هؤلاء الباحثين (Duan , Ichimura , Hall , Hardle , Powell , Stock , Stocker , Fan , Horowitz & Carroll) ، و يمكن توضيحها بالشكل الاتي :

١. ان انموذج المؤشر الواحد (SIM) لا يفترض ان تكون دالة الربط $g(\cdot)$ معلومة و من ثم تكون أكثر مرونة و أقل تعقيداً من النماذج المعلمية لدوال التوقع الشرطي مثل النماذج الخطية و نماذج الاحتمال الثنائي . [1]

٢. ان استعمال أنموذج المؤشر الواحد (SIM) يقلل من مخاطر التوصل الى نتائج مضللة . [1]

٣. على الرغم من ان التقدير اللامعلمي لدالة التوقع الشرطي يزيد من المرونة و يقلل من مخاطر خطأ التوصيف (Specification error) ولكن لا يلغيها و قيمة هذه المرونة يمكن أن تكون عالية لعدة أسباب و هي :

أ. تتناقص دقة التقديرات اللامعلمية بسرعة مع تزايد أبعاد X و للحصول على دقة تقدير مقبولة عندما يكون X متعدد الأبعاد قد يكون هناك حاجة إلى عينات كبيرة .

ب. نتائج التقدير اللامعلمي يمكن أن تكون صعبة التفسير عندما يكون X متعدد الأبعاد .

ج. التقدير اللامعلمي لا يسمح بالاستقراء و أنه لا يوفر التنبؤات لـ $E[Y|X]$ في نقاط x التي ليست ضمن بيانات X و هذا من العيوب الخطيرة في التحليل و التنبؤ على النقيض من ذلك فأن أنموذج المؤشر الواحد يسمح باستقراء الحدود و انه يعطي تنبؤات لـ $E[Y|X]$ في قيم X التي ليست ضمن بيانات X ولكن هي من ضمن بيانات $X^T\beta$. [8]

٤. لانموذج المؤشر الواحد شبه المعلمي القدرة على التغلب على مشكلة تعدد الابعاد (Curse of dimensionality) من خلال هيكل المؤشر لأن $X^T\beta$ هي مؤشر لمجاميع أبعاد X . و في نفس الوقت فأن متجه المعلمات β يمكن تقديرها مع نفسه نسبة معدل التقارب \sqrt{n} المتحقق في الأنموذج المعلمي فهو دقيق كالأنموذج المعلمي في تقدير متجه المعلمات β ودقيق كالانموذج اللامعلمي ذات البعد الواحد في تقدير دالة الربط $g(X_i^T\beta)$. [12]

٤. بعض المفاهيم الأساسية :

(Variable selection)

٤.١ اختيار المتغير :

ان تقنية اختيار المتغير هو موضوع مهم جداً في العديد من انواع النمذجة الاحصائية ومنها النمذجة شبه المعلمية لانها تسعى في آن واحد الى اختزال فرص البيانات غير المناسبة والتقليل من آثار التحيز [14]. ففي العديد من التطبيقات التي تمتلك بيانات كبيرة نحن بحاجة الى تحديد عدد من المتغيرات المهمة (المعنوية) ومن مجالات هذا التطبيق المال والاعمال والطب والهندسة والبيئة وعلم الاجتماع وغيرها وان عملية اختيار المتغير هو جزء مهم في معظم التطبيقات و تظهر اهمية اختيار المتغير عندما تكون الدالة الحقيقية هي غير خطية و مجموعة البيانات غالباً ما تحتوي على مشكلة تعدد خطي او قيم متطرفة ومن المعلوم ان ادخال عدد كبير من المتغيرات في معادلة الانحدار لاي ظاهرة او دراسة يكلف وقتاً وجهداً وثمناً ووجود بعض المتغيرات غير الاساسية في تأثيرها المتغير المعتمد او يكون تأثيرها مماثل لتاثير متغيرات اخرى او يكون لهذه المتغيرات ارتباط داخلي عال فيما بينها مما يجعل تأثيرها غير معنوي مما يدعو الى استبعاد مثل هذه المتغيرات وفي هذا البحث تم استخدام تقنيات حديثة في عملية اختيار المتغيرات المعنوية المعتمدة على دوال جزاء مختلفة وهي دالة جزاء لاسو ودالة جزاء لاسو التكيفية . اذ برزت هذه التقنية منذ عام (١٩٩٠) والتي تدعى بالطرائق الجزائية (Penalization Method) و هو اسلوب بديل لاختيار المتغير في نماذج الانحدار الخطي و هذه الطرائق تم توصيفها على النمذج شبه المعلمية ومنها انموذج المؤشر الواحد التي لها سلوك في تقدير و اختيار المتغير في عملية النمذجة نفسها اي تعمل على تقدير متجه المعلمات β و دالة الربط $g(\cdot)$ و الاختيار التلقائي للمتغيرات المعنوية في آن واحد [20].

(Penalty function)

4.2 دالة الجزاء :

ان مهمة دالة الجزاء هي انها تمنع حدوث مشكلة التحيز الى الاعلى (Over fitting) بمعنى ان الانموذج مع العديد من المتغيرات الداخلة قد تكون دون المستوى الامثل (غير مهمة) عندما يكون الانموذج الصحيح مبعثر (sparse) اي ان المتغير المعتمد يعتمد فقط على عدد قليل من المتغيرات الداخلة (المعنوية) ، اذ ان دالة الجزاء تعتمد على معلمة الجزاء (λ) ومن خلال هذه المعلمة يتم وضع حد جزاء وهذا الحد سوف يدفع باتجاه الحصول على معلمات كبيرة جداً والمعلمات الصغيرة والاقبل من قيمة معلمة الجزاء تكون قيمتها صفر وبالتالي يكون اختيار الانموذج المناسب تلقائياً . [١١]، [١٣]

ففي عام (٢٠٠١) بين الباحثان (Fan & Li) ان دالة الجزاء الجيدة ينبغي ان تؤدي الى مقدر له ثلاث خصائص اساسية وهي عدم التحيز (unbiasedness) والتبعثر (sparsity) والاستمرارية (continuity) ودوال الجزاء المستخدمة في هذا البحث هي :

(Lasso – penalty function)

١. دالة جزاء - لاسو [١٤]

و هي مقترحة من قبل الباحث (Tibshirani) عام (١٩٩٦) و تسمى ايضاً بدالة جزاء - L_1 و لها الصيغة الآتية :

$$P_{\lambda} (|\beta_j|) = \lambda |\beta_j|$$

(Adaptive lasso – penalty function)

٢. دالة جزاء - لاسو المتكيفة [٢٠]

و هي مقترحة من الباحث (Zuo) عام (٢٠٠٦) و لها الصيغة الآتية :

$$P_{\lambda} (|\beta_j|) = \lambda \sum_{j=1}^p w_j |\beta_j|$$

إذ أن w_j : تمثل الأوزان المعتمدة على البيانات وتحسب بالشكل الآتي :

$$w_j = \frac{1}{|\hat{\beta}_{ols}|^{\gamma}}, \quad \gamma > 0$$

γ : تمثل معلمة الأنكماش

(panalty parameter selection)

٤.٣ اختيار معلمة الجزاء:

معلمة الجزاء تدعى كذلك بمعلمة الضبط (tuning parameter) ويرمز لها بالرمز (λ) . اذ ان معلمة الجزاء تلعب دوراً مهماً في عملية اختيار المتغير المعنوي كما انها تسيطر على درجة الانكماش للمقدر لذا من المهم تحديدها بشكل دقيق و مناسب [١٨]. فعند تحليل البيانات في الجانب العملي فان قيمة معلمة الجزاء تكون مجهولة لذا استعمل الباحث (Anderos. A) وآخرون عام (٢٠١٢) معيار معلومات بيز (BIC) لغرض تحديد معلمة الجزاء (λ) المثلى و تم أستعمال هذا المعيار لأنه يتطلب أقل جهد حسابي ويحسب من خلال الصيغة الآتية : [١٣]، [١٧]

$$BIC(\lambda) = \ln(\hat{\sigma}) + df(\lambda) \frac{\ln(n)}{n} \quad \text{-----} \quad (2)$$

اذ أن :

$\hat{\sigma}$: تمثل القيمة التقديرية للأحرف المعياري للخطأ العشوائي و يحسب وفق الصيغة الآتية :

$$\hat{\sigma} = \sqrt{\frac{1}{n-d} \sum_{i=1}^n [y_i - \hat{g}(X_i^T \hat{\beta})]^2} \quad \text{-----} \quad (3)$$

d : تمثل البعد ل $\hat{\beta}$

$\hat{g}(X_i^T \hat{\beta})$: تمثل القيمة التقديرية لدالة الربط .

$df(\lambda)$: تمثل درجة حرية الأنموذج و تحدد من خلال عدد المعالم المقدر غير الصفرية في $\hat{\beta}$

n : يمثل حجم العينة .

λ : تمثل معلمة الجزاء أو معلمة الضبط .

ونتائج معلمة الجزاء أو معلمة الضبط المثلى تعرف عن طريق $BIC \hat{\lambda}$.

(kernel function selection)

٤.٤ اختيار الدالة اللبية :

ان اختيار دالة (kernel) لايهم كثيراً من حيث الحصول على تقريب جيد الى دالة الكثافة الصحيحة اذ ان اختيارها يؤثر على شكل كثافة التقدير .

وفي عام (٢٠١٢) بين الباحثان (J.Blarchet and J.Wodsworth) نقطة مهمة حول اختيار دالة (kernel) والمنتظمة ان اي اختيار معقول لدالة (kernel) تنتج نتائج معقولة وبالتالي فان اختيارها هي ليست في غاية الاهمية . ويتم اختيار الدالة اللبية التي تحقق الشروط التالية : [٤]، [٧]

$$1. \int_{-\infty}^{\infty} K(u)du = 1 \text{ is pdf}$$

$$2. K(u)=K(-u) \text{ is symmetric}$$

$$3. \int_{-\infty}^{\infty} uK(u)du = 0$$

$$4. \int_{-\infty}^{\infty} u^2K(u)du = \mu_2(K) \neq 0 \text{ moments of kernel}$$

$$5. K(u) \geq 0$$

(Bandwidth parameter selection)

٤.٥ اختيار معلمة عرض الحزمة :

يرمز لمعلمة عرض الحزمة بالرمز (h) وهي تعمل للسيطرة على مستوى التمهيد للتقدير [٤]. ان تحديد القيمة المناسبة لمعلمة عرض الحزمة هو امر بالغ الاهمية للمنحنى المطابق (curve fitting) اذ تلعب هذه المعلمة دوراً اساسياً في أداء المقدر اللبي (kernel estimation) اذ يتطلب اختيارها التوازن بين التحيز (bias) والتباين (variance) والتحكم به عن طريق متوسط مربعات الخطأ (MSE) فاذا كانت قيمة معلمة عرض الحزمة صغيرة جداً فان التحيز يكون قليل ولكن بتباين كبير ويكون تقدير دالة الكثافة هي ليست ممهدة جيداً واذا كان اختيار قيمة

معلمة عرض الحزمة كبير للغاية فان التحيز يكون كبيراً ولكن بتباين قليل ونحصل على دالة كثافة فوق التمهيد (over smoothing) وهذا يشوه شكل دالة الكثافة الصحيح . [13]

اذ ان الفكرة الاساسية لاختيار معلمة عرض الحزمة هو تقليل متوسط مربعات الخطأ (MSE) وفي هذا البحث تم استعمال طريقة التقاطع الشرعي (cross - validation) لسهولة حسابها وهيكلها قابل للتطبيق لاي انموذج انحدار ويتم حسابها من خلال بناء دالة التقاطع الشرعي (CV) باستبعاد مشاهدة واحدة في كل مرة و بالشكل الآتي :

$$CV(h) = n^{-1} \sum_{i=1}^n [Y_i - \hat{g}_{-i}(X_i^T \hat{\beta})]^2 \quad (4)$$

اذ يتم احتساب تقدير دالة الربط $\hat{g}_{-i}(X_i^T \hat{\beta})$ لجميع المشاهدات وفي كل مرة يتم استبعاد مشاهدة واحدة ثم يتم اختيار القيمة المهيبة (عرض الحزمة) المقابلة لاصغر (CV) . [15]

٥. طرائق التقدير شبه المعلمية لانموذج المؤشر الواحد .

٥.١ طريقة (MAVE - LASSO) .

Minimum average variance estimation (MAVE) Method with lasso penalty function .

طريقة تقدير اقل معدل تباين مع دالة جزاء لاسو :

في عام (٢٠٠٢) أقتراح الباحثون (Xia , Tang , Li & Zhu) طريقة تقدير عامة تدعى طريقة تقدير اقل معدل تباين (MAVE) و تعني (Minimum average variance estimation) للنماذج شبه المعلمية (Semiparametric models) و من ضمن هذه النماذج هو أنموذج المؤشر الواحد (Single index model) إذ بين الباحثون أن هذه الطريقة مرنة لتتحد مع غيرها من الطرائق من أجل أدمج المتطلبات الأحصائية الإضافية . و أظهروا أن لها ميزة مهمة وهي أنها سهلة التنفيذ مع توافر الخوارزميات لها . [19]

إن التقدير للنماذج شبه المعلمية و خاصة تلك التي تحتوي على مؤشر واحد تحتاج إلى حل معقد لمسألة التقليل غير الخطية و التي يمكن أن تكون صعبة والأسلوب المستعمل هو طريقة نيوتن رافسن (Newton - Raphson method) وهي التي نحتاجها ومع ذلك فاننا نعلم ان تقدير المشتقات يمكن ان تكون معقدة ولذلك فان طريقة نيوتن رافسن لا تعمل بشكل جيد عوضاً عن ذلك فان طريقة (MAVE) توفر اسلوب بسيط جداً للحساب من خلال التقريب الخطي الموضوعي (Local linear approximation) بحيث يتم في النهائية تحويلها إلى مسائل للتقليل الخطي (Linear minimization) و الحساب للأخير هو سهل جداً و العديد من الخوارزميات هي كفوءة و متاحة.

و في عام (٢٠٠٨) أقتراح الباحث (Chen Lei Leng) طريقة تقدير (MAVE) مع دالة جزاء (Lasso) لأنموذج المؤشر الواحد لتقدير و اختيار المتغير في آن واحد .

اذ أن دالة جزاء (Lasso) تدعى أيضاً بدالة جزاء L_1 وهي شائعة وتستخدم لأختيار المتغير (Variable selection) لطريقة (Lasso) و تعني (Least absolute shrinkage and selection operator)

ان جميع حلول تقديرات Lasso تعتمد على قاعدة مستوى العتبة (Soft - thresholding) عندما يكون X هو (Orthonormal) أي أن : $X^T X = I$ وبالشكل الآتي :- [16] , [5]

$$\hat{\beta}^{Lasso} = \text{sign}(\hat{\beta}_j^{OLS}) (\hat{\beta}_j^{OLS} - \lambda/2) + \quad , j = 1, 2, \dots, p$$

$$\hat{\beta}^{Lasso} = \begin{cases} \hat{\beta}_j^{OLS} - \lambda/2 & \text{if } \hat{\beta}_j^{OLS} > \lambda/2 \\ 0 & \text{if } |\hat{\beta}_j^{OLS}| \leq \lambda/2 \\ \hat{\beta}_j^{OLS} + \lambda/2 & \text{if } \hat{\beta}_j^{OLS} < -\lambda/2 \end{cases} \quad (5)$$

اذ أن :

λ : تمثل معلمة الضبط و يتم أيجادها من خلال أستعمال طريقة - (BIC) .

أشارة + : تدل على الجزء الموجب داخل القوسين .

وعليه يمكن تطبيق فكرة (Lasso) لأنموذج المؤشر الواحد شبه المعلمي (SSIM) و الحصول على تقديرات متجه المعلمات ودالة الربط في آن واحد من خلال الصيغة الآتية :

$$Q(\hat{g}, \hat{\beta}) = \operatorname{argmin} \left\{ \sum_{i=1}^n (Y_i - g(X_i^T \beta))^2 + \lambda \sum_{j=1}^p |\beta_j^{\text{Lasso}}| \right\} \quad (6)$$

و عندما يكون البعد P- كبيراً تظهر مشكلة تعدد الابعاد (Curse of dimensionality) ودائماً تكون المعاملات مبعثرة (Sparse) ونتيجة لذلك فان العديد من المعاملات تكون أصفار و لتحديد المتغيرات مع المعاملات غير الصفريّة تلقائياً و الى تقدير أنموذج المؤشر الواحد شبه المعلمي (SSIM) تم دمج طريقة ماف (MAVE) مع دالة جزاء لاسو (Lasso) وهي فكرة الباحث (Chen Lei Leng) عام (٢٠٠٨) عن طريق تقدير متجه المعلمات بموجب الصيغة الآتية :-

$$\hat{\beta}^{\text{LASSO-MAVE}} = \operatorname{argmin} \left\{ \sum_{j=1}^n \sum_{i=1}^n \{Y_i - a_j - b_j X_{ij}^T \beta\}^2 \cdot w_{ij} + \lambda \sum_{k=1}^p |\beta_k| \right\} \quad (7)$$

$$\beta: \|\beta\|=1$$

$$a_j, b_j, j = 1, 2, \dots, n$$

اذ أن :

w_{ij} : تمثل وزن (kernel) و هو دالة للمسافة بين $(X_j$ و $X_i)$ و يحقق $(\sum w_{ij}) = 1$.

$\|\cdot\|$: تمثل القاعدة الأقليدية و ان : $|\beta_k| = |\beta_1| + \dots + |\beta_p|$

والحساب لمسألة التقليل المذكورة آنفاً يمكن أن تحلل الى تقليل مسألتين :

وفق الخوارزمية (LASSO - MAVE) لأنموذج المؤشر الواحد شبه المعلمي (SSIM). [2],[9]

الخطوة (٠) : نفرض تقدير أولى (أبتدائي) للمعلمة $\beta^{(0)}$ بأستعمال طريقة المربعات الصغرى الأعتيادية (OLS) أو أي متجه أعتباطي من درجة (P).

الخطوة (١) : يتم تثبيت $\hat{\beta}^{(0)} = \hat{\beta}$ و نحسب متجه الحل إلى (a_j, b_j) من خلال الصيغة الآتية :-

$$\begin{pmatrix} \hat{a}_j \\ \hat{b}_j \end{pmatrix} = \left\{ \sum_{i,j} w_{ij}^{\hat{\beta}^{(0)}} \begin{pmatrix} 1 \\ X_{ij}^T \hat{\beta} \end{pmatrix} \begin{pmatrix} 1 \\ X_{ij}^T \hat{\beta} \end{pmatrix}^T \right\}^{-1} \cdot \sum_{i,j} w_{ij}^{\hat{\beta}^{(0)}} \begin{pmatrix} 1 \\ X_{ij}^T \hat{\beta} \end{pmatrix} Y_i \quad (8)$$

اذ ان :

$$w_{ij}^{\hat{\beta}^{(0)}} = k_h(X_{ij}^T \hat{\beta}^{(0)}) = \frac{k\left(\frac{X_i^T \hat{\beta}^{(0)} - X_j^T \hat{\beta}^{(0)}}{h}\right)}{\sum_{i=1}^n k\left(\frac{X_i^T \hat{\beta}^{(0)} - X_j^T \hat{\beta}^{(0)}}{h}\right)}$$

الخطوة (٢) : يتم تحديد (\hat{a}_j, \hat{b}_j) و تقدير متجه المعلمات β وفق الصيغة الآتية :

$$\hat{\beta}^{\text{LASSO-MAVE}} = \operatorname{argmin} \left\{ \sum_{j=1}^n \sum_{i=1}^n \{Y_i - \hat{a}_j - \hat{b}_j X_{ij}^T \beta\}^2 w_{ij}^{\hat{\beta}^{(0)}} + \lambda \sum_{k=1}^p |\beta_k| \right\}$$

$$a_j, b_j, \beta: \|\beta\| = 1$$

للتبسيط نقوم بتحويل البيانات الى :

$$Y_{ij}^* = Y_i (w_{ij}^{\hat{\beta}^{(0)}})^{1/2} - \hat{a}_j (w_{ij}^{\hat{\beta}^{(0)}})^{1/2}$$

$$X_{ij}^* = \hat{b}_j X_{ij} (w_{ij}^{\hat{\beta}^{(0)}})^{1/2}$$

لتصبح المسألة التي نحل بالشكل الآتي :

$$\hat{\beta}^{\text{LASSO-MAVE}} = \operatorname{argmin} \left\{ \sum_{i,j=1}^n \{Y_{ij}^* - X_{ij}^{*T} \beta\}^2 + \lambda \sum_{k=1}^p |\beta_k| \right\}$$

β

الخطوة (٣): يتم تكرار الخطوتين (١) و (٢) مع $(\hat{\beta}^{(0)} = \text{sign}(\hat{\beta}_1) \frac{\hat{\beta}}{\|\hat{\beta}\|})$ حتى التقارب و المتجه الأخير هو متجه مقدر (LASSO) $\hat{\beta}^{(0)}$ و يعرف من خلال $\hat{\beta}^{\text{LASSO-MAVE}}$ و تقدير دالة الربط $g(\cdot)$ النهائي يكون: $\hat{\alpha}_j = \hat{g}(u, \hat{\beta}^{\text{LASSO-MAVE}})$.
٥.٢ طريقة (Adaptive LASSO – MAVE).

Minimum average variance estimation (MAVE) method With Adaptive least absolute shrinkage and selection operator (Alasso) penalty function.

طريقة تقدير اقل معدل تباين مع دالة جزاء لاسو التكيفية :

بين الباحث (Tibshirani) في عام (١٩٩٦) أن أسلوب (Lasso) يفتقر إلى خصائص أوراكل (Oracle properties) وهذه الخصائص تتمثل بالاتساق في اختيار المتغير اي ان تقدير المعلمات يكون مساوي بالضبط صفراً وهذا يعني ان احتمال استبعاد المتغير غير المعنوي يميل الى الواحد عندما $n \rightarrow \infty$ وتدعى هذه الخاصية بخاصية التبعر (sparsity) والخاصية الثانية تتمثل بان المعلمات غير الصفرية يتم تقديرها بكفاءة عندما يكون الانموذج الصحيح معروف وتدعى هذه الخاصية بتقارب الامثلية . كما توصل الباحثان (Fan & Li) عام (٢٠٠١) أن هذا الأسلوب لديه تحيز في تقدير المعاملات غير الصفرية الكبيرة و أظهروا أيضاً انه لا يمتلك خصائص أوراكل مما دفع الباحث (Zou) عام (٢٠٠٦) إلى اقتراح أسلوب جديد يدعى لاسو التكيفية (Adaptive Lasso) للانموذج الخطي العام إذ أن فكرة هذا الأسلوب يعمل على تعيين أوزان تكيفية مختلفة للمعاملات المختلفة الجزائية في دالة جزاء L_1 مما يؤدي إلى زيادة الجزاء للمعاملات التي تقترب من الصفر و من ثم أختزال التحيز في تقدير الدالة و تحسين دقة اختيار المتغير . [١٠]، [٦]

و بين الباحث (Zou) عام (٢٠٠٦) أن طريقة لاسو التكيفية (ALasso) هي طريقة وزن جزائية لدالة جزاء L_1 لتقدير واختيار الأنموذج في آن واحد و لها خصائص أوراكل المتمثلة بنسبة التقارب المثلى و الأتساق في اختيار المتغير .
وصيغة مقدر (Alasso) لمتجه المعلمات β لأنموذج الخطي العام (GLM) من خلال تقليل المعادلة الآتية :

$$\hat{\beta}^{\text{ALASSO-MAVE}} = \underset{\beta}{\operatorname{argmin}} \left\{ \sum_{i=1}^n (Y_i - X_i^T \beta)^2 + \lambda \sum_{k=1}^p \hat{w}_k |\beta_k| \right\} \quad (9)$$

وبناءً على ما تم ذكره آنفاً فإن مقدر لاسو التكيفية (Alasso) $\hat{\beta}$ و لأنموذج المؤشر الواحد شبه المعلمي (SSIM) يمكن الحصول عليه من خلال الصيغة الآتية :-

$$\hat{\beta}^{\text{ALASSO-MAVE}} = \underset{\beta}{\operatorname{argmin}} \left\{ \sum_{i=1}^n (Y_i - g(X_i^T \beta))^2 + \lambda \sum_{k=1}^p \hat{w}_k |\beta_k| \right\} \quad (10)$$

اذان:

$$P_\lambda(|\beta_k|) = \lambda \sum_{k=1}^p \hat{w}_k |\beta_k| \quad \text{مع معلمة الضبط } (\lambda).$$

$w = (w_1, w_2, \dots, w_p)$: تمثل الأوزان التكيفية (Adaptive weight) و بين الباحث (Zou) أنه إذا كان اختيار الأوزان (W_k) بكفاءة وبطريقة تعتمد على البيانات فإن طريقة لاسو التكيفية (Alasso) يمكن أن نحقق خصائص أوراكل بحيث ينفذ كما لو كان الأنموذج الصحيح معروف و قد أقتراح استعمال الأوزان المقدره وبالشكل الآتي :-

$$\hat{w}_k = \frac{1}{|\hat{\beta}_k|^\gamma}, \quad k = 1, 2, \dots, p$$

عن طريق استعمال تقديرات المربعات الصغرى الاعتيادية (OLS) لأختيار \hat{w}_k اذان $\hat{\beta}_k$ تمثل تقديرات (OLS) و هي مقدر أبندائي متسق $\beta \downarrow \sqrt{n}$ (يحتوي على \sqrt{n} نسبة التقارب) . [١٨]

و أن γ : يمثل معلمة الأنكماش و قيمتها أكبر من الصفر و نفترض أن تكون قيمتها تساوي واحد ($\gamma = 1$) .

وبناءً على فكرة الباحثان (Zho & Zang He) في عام (٢٠١١) اللذان أستعم b طريقة النوع - (Lasso) و طريقة - (SCAD) لتقدير وأختبار المتغير لأنموذج المؤشر الواحد شبه المعلمي (SSIM) تم اقتراح خوارزمية من الباحث لطريقة (AdaptiveLASSO-MAVE) من

خلال دمج دالة الخسارة لطريقة - (MAVE) مع دالة جزاء - (Adaptive LASSO) وتوظيفها لتقدير و اختبار المتغير لأنموذج المؤشر الواحد في المعادلة الآتية :-

$$\min_{a,b, \beta, \|\beta\|=1} = \sum_{j=1}^n \sum_{i=1}^n [Y_i - a_j - b_j \beta^T (X_i - X_j)]^2 W_{ij} + \lambda \sum_{k=1}^p \hat{w}_k |\beta_k| \quad (11)$$

نلاحظ أن الجزء الأول للمعادلة المذكور انفا هو دالة الخسارة إلى طريقة - (MAVE) لتقدير قيمة المعلمات β ولها و الجزء الثاني لها يمثل دالة جزاء لاسوالتكيفية (Adaptive lasso penalty function) وهذا الجزء يجعل $\hat{\beta}$ متناثرة (Sparsity) و من ثم يؤدي إلى اختيار المتغير (Variable selection).

و يمكن تلخيص الخوارزمية المقترحة لطريقة (MAVE - ALASSO) لأنموذج المؤشر الواحد شبه المعلمي (SSIM) و التي تعمل على تقدير و اختيار المتغير في آن واحد بالخطوات الآتية :- [19]، [20]

الخطوة (٠) : نحصل على تقدير أولي (أبتدائي) ل β وليكن $\hat{\beta}^{(0)}$ بطريقة المربعات الصغرى الاعتيادية (OLS) و نفرض ان :

$$\hat{\beta} = \text{sign}(\hat{\beta}_1^{(0)}) \frac{\hat{\beta}^{(0)}}{\|\hat{\beta}^{(0)}\|}$$

اذ ان :

$\text{sign}(\hat{\beta}_1^{(0)})$: يمثل إشارة العنصر الأول ل $\hat{\beta}^{(0)}$ وان $\|\hat{\beta}\| = 1$ لغرض التشخيص.

الخطوة (١) : نحدد $\hat{\beta}$ و يتم الحصول على $\{\hat{a}_j, \hat{b}_j\}_{j=1}^n$ من خلال حل المعادلة الآتية :-

$$(\hat{a}_j, \hat{b}_j) = \underset{a,b}{\text{argmin}} \left\{ \sum_{i=1}^n [Y_i - a_j - b_j (X_i^T \hat{\beta} - u)]^2 \cdot K_h(X_i^T \hat{\beta} - u) \right\}$$

اذ ان :

$K(\cdot)$: تمثل دالة kernel المتماثلة و تم أستعمال دالة (Gaussian).

h : تمثل معلمة عرض الحزمة (Bandwidth) و نختارها لتكون الأمثل و تحسب عن طريق طريقة العبور (التقاطع) الشرعي (CV).

الخطوة (٢) : نحدد $\{\hat{a}_j, \hat{b}_j\}_{j=1}^n$ للحصول على $\hat{\beta}^{\text{ALASSO-MAVE}}$ من خلال حل المعادلة الآتية:-

$$\hat{\beta}^{\text{ALASSO-MAVE}} = \underset{\beta}{\text{argmin}} \left\{ \sum_{j=1}^n \sum_{i=1}^n [Y_i - \hat{a}_j - \hat{b}_j (X_i - X_j)^T \beta]^2 w_{ij} + \lambda \sum_{k=1}^p \hat{w}_k |\beta_k| \right\}$$

للتبسيط نقوم بتحويل البيانات الى:

$$Y_{ij}^* = Y_i - \hat{a}_j \quad \text{and} \quad X_{ij}^* = \hat{b}_j (X_i - X_j)^T$$

وتصبح المسألة التي تقلل بالشكل الآتي :

$$\hat{\beta}^{\text{ALASSO-MAVE}} = \underset{\beta}{\text{argmin}} \left\{ \sum_{j=1}^n \sum_{i=1}^n [Y_{ij}^* - X_{ij}^{*T} \beta]^2 w_{ij} + \lambda \sum_{k=1}^p \hat{w}_k |\beta_k| \right\}$$

اذ ان :

في الخطوة الثانية يتم تقدير β للملاحظات $\{Y_{ij}^*, X_{ij}^*\}_{i,j=1}^n$ مع الأوزان $\{w_{ij}^*\}_{j=1}^n$.

الخطوة (٣) : يتم الأستمرار ب تكرار الخطوتين (١) و (٢) حتى التقارب و يكون التقدير النهائي ل $\hat{\beta}^{\text{ALASSO-MAVE}}$.

و التقدير النهائي ل $g(\cdot)$ هو $g(u) = \hat{g}(u, \hat{\beta}^{\text{ALASSO-MAVE}})$ و يتم الحصول عليه من خلال حل المعادلة الآتية :-

$$(\hat{a}, \hat{b}) = \underset{\hat{a}, \hat{b}}{\text{argmin}} \left\{ \sum_{i=1}^n [Y_i - a - b(X_i^T \hat{\beta}^{\text{ALASSO-MAVE}} - u)]^2 k \left(\frac{X_i^T \hat{\beta}^{\text{ALASSO-MAVE}} - u}{h} \right) \right\}$$

٦. الجانب التجريبي :

في هذا المبحث تم استخدام اسلوب المحاكاة لغرض مقارنة الطرائق المستعملة في تقدير واختيار المتغير لنماذج المؤشر الواحد شبه المعلمية ولوصف تجارب المحاكاة تم وضع الافتراضات الاتية :

١. حجوم العينات : $n = 25, 50, 100$

٢. توزيع الخطأ : يتوزع الخطأ العشوائي توزيعاً طبيعياً بمتوسط صفر وبتباينات مختلفة $\sigma^2 = (1, 5, 9)$ لجميع النماذج المستعملة .
 $ei \sim N(0, \sigma^2)$

٣. قيم X مكونة من ثمانية متغيرات $(p=8)$. $X^T = (X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8)$

موزعة توزيعاً طبيعياً بمتوسط صفر وتباين واحد $X \sim N(0, 1)$ لكل متغير ولجميع النماذج . مع مصفوفة الارتباط الاتية : $\dots, 8, \dots$ ،
 $\text{Corr} = \rho^{|i-j|}$ ، $i, j = 1, 2$ ، وافتراض قيم $(\rho = 0.1, 0.9)$.

وان العلاقة بين X, e مستقلة (independent) .

٤. الدالة اللبية المستعملة هي دالة كاوس (Gaussian) الاتية :

$$K_h(X^T \beta) = \frac{1}{h\sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{X^T \beta}{h} \right)^2 \right] , \quad -\infty < X^T \beta < \infty$$

٥. المعلمة التمهيدية (عرض الحزمة) h المستعملة يتم ايجادها بطريقة العبور الشرعي (CV) .

٦. النماذج المستعملة (تم استعمال ثلاث نماذج شبه معلمية للمؤشر الواحد) الاتية : [١٨]، [٣]، [١٢]

$$1) Y = 1 + 2(X^T \beta + 3) \log(3 |X^T \beta| + 1) + \epsilon$$

$$2) Y = 5 \cos(X^T \beta) + \exp(-X^T \beta) + \epsilon$$

$$3) Y = \sin(X^T \beta) + \epsilon$$

٧. قيم متجه المعلمات β الابتدائية تم افتراضها بالشكل الاتي بحيث تحقق شرط تشخيص الانموذج $\|\beta\| = 1$

$$\beta = (0.4, -0.4, 0.8, -0.2, 0, 0, 0, 0)^T$$

٨. عدد تكرارات التجربة (٢٠٠) تكرار .

٩. تمت المقارنة بين طريقة (LASSO-MAVE) وطريقة (Adaptive LASSO - MAVE) بالاعتماد على المعيارين معدل متوسط

مربعات الخطأ (AMSE) Average mean squared error ومعدل متوسط الخطأ المطلق (Average mean absolute

error(AMAE) الاتيين :

$$AMSE = \frac{1}{n} E \sum_{i=1}^n (Y_i - \hat{g}(X_i^T \hat{\beta}))^2$$

$$AMAE = \frac{1}{n} E \sum_{i=1}^n |Y_i - \hat{g}(X_i^T \hat{\beta})|$$

تفسير النتائج:

تم الاعتماد على برنامج (R-Package) في الحصول على نتائج تجارب المحاكاة والمبينة في الجداول رقم (1) ، (2) و(3) المعروضة ادناه :

جدول رقم (1)

يمثل قيم معدل متوسط مربعات الخطأ (AMSE) ومعدل متوسط الخطأ المطلق (AMAE) لطرائق التقدير المستعملة لانموذج المؤشر الواحد الاول $Y = 1 + 2(X^T\beta + 3) \log(3|X^T\beta| + 1) + \epsilon$ لمختلف حجوم العينات وتباينات الاخطاء في حالة وجود ارتباط واطى وعال عندما $p=8$.

من الجدول رقم (1) والخاص بانموذج المؤشر الواحد شبه المعلمي الاول :

Criteria	method	n	Low correlation=0.1			High correlation =0.9		
			$\sigma^2=1$	$\sigma^2=4$	$\sigma^2=9$	$\sigma^2=1$	$\sigma^2=4$	$\sigma^2=9$
AMSE	LASSO-MAVE	25	6.8509	14.0423	26.6820	4.6546	12.0804	21.0170
		50	9.0513	11.8676	21.5820	4.7616	11.3049	19.1851
		100	7.4010	11.5609	23.2700	6.2383	16.4842	30.7720
	Adaptive LASSO-MAVE	25	5.3128	9.6691	25.8587	19.6871	27.8321	44.3165
		50	9.2211	12.8632	26.8678	13.5045	34.3220	54.3051
		100	7.5979	11.9979	23.8989	16.5834	46.8015	61.6182
AMAE	LASSO-MAVE	25	0.8242	1.3104	1.8888	0.6474	1.1915	1.6355
		50	0.9395	1.1737	1.6776	0.6551	1.1935	1.6022
		100	0.8437	1.1715	1.6808	0.7449	1.3117	1.9206
	Adaptive LASSO-MAVE	25	0.7659	1.1235	1.8486	1.9071	2.3834	3.0157
		50	0.9520	1.2078	1.8775	1.3597	2.3830	3.2741
		100	0.9244	1.1860	1.7390	1.6358	2.9661	3.5452

فقد اظهرت النتائج تفوق طريقة (Adaptive LASSO-MAVE) في حالة حجم العينة الصغيرة (25) ولمختلف تباينات الاخطاء وحالة وجود ارتباط واطى (low correlation) لكونها تعطي اقل قيم للمعيارين (معدل متوسط مربعات الخطأ (AMSE) ومعدل متوسط الخطأ المطلق (AMAE)) مقارنة مع طريقة (LASSO-MAVE) ، في حين حققت طريقة (LASSO-MAVE) تفوق واضح في حالة حجوم العينات المتوسطة (50) والكبيرة (100) .

وفي حالة وجود ارتباط عالٍ (high correlation) اظهرت النتائج تفوق طريقة (LASSO-MAVE) لجميع حجوم العينات ولمختلف تباينات الاخطاء اعتماداً على قيم المعيارين (AMSE) و (AMAE) اذ اعطت اقل قيم من الطريقة الاخرى .

جدول رقم (2)

يمثل قيم معدل متوسط مربعات الخطأ (AMSE) ومعدل متوسط الخطأ المطلق (AMAE) لطرائق التقدير المستعملة لانموذج المؤشر الواحد الثاني $Y = 5\cos(X^T\beta) + \exp(-X^T\beta) + \epsilon$ لمختلف حجوم العينات وتباينات الاخطاء في حالة وجود ارتباط واطى وعالٍ عندما $p=8$.

Criteria	method	n	Low correlation=0.1			High correlation =0.9		
			$\sigma^2=1$	$\sigma^2=4$	$\sigma^2=9$	$\sigma^2=1$	$\sigma^2=4$	$\sigma^2=9$
AMSE	LASSO-MAVE	25	1.7880	6.1800	11.3249	1.0341	13.3039	23.1176
		50	2.0744	6.7423	20.0142	0.8771	5.1804	23.1756
		100	1.6820	6.8341	18.5076	1.2119	5.9839	22.8770
	Adaptive LASSO-MAVE	25	2.0609	5.7050	16.1975	1.6693	8.5959	11.8131
		50	2.1977	4.4176	14.3637	7.3798	9.8492	10.4245
		100	1.6803	5.4687	18.5073	2.8265	8.8200	53.1656
AMAE	LASSO-MAVE	25	0.4228	0.8722	1.1935	0.3172	1.0811	1.7255
		50	0.4448	0.9319	1.6363	0.2819	0.8048	1.6788
		100	0.3847	0.9257	1.0587	0.3250	1.1967	1.6526
	Adaptive LASSO-MAVE	25	0.6322	0.8792	1.4726	0.4099	0.9605	1.1806
		50	0.4355	0.7386	1.4488	0.7233	1.1070	1.3181
		100	0.3847	0.8152	1.0549	0.5130	1.0289	1.9191

من الجدول رقم (2) والخاص بانموذج المؤشر الواحد شبه المعلمي الثاني:

فقد اظهرت النتائج ولحالة وجود ارتباط واطى (low correlation) تفوق طريقة (LASSO-MAVE) لجميع حجوم العينات ولمختلف تباينات الاخطاء باستثناء حالة تباين الخطأ ($\sigma^2=4$) ولمختلف حجوم العينات فكانت الافضلية لطريقة (Adaptive LASSO-MAVE) بالاعتماد على المعيارين (AMSE) و (AMAE) . ولحالة وجود ارتباط عالٍ (high correlation) اظهرت طريقة (LASSO-MAVE) تفوقها لجميع حجوم العينات ولمختلف تباينات الاخطاء لكونها تعطي قيم اقل للمعيارين (AMSE) و (AMA) مقارنة مع الطريقة الاخرى .

جدول رقم (٣)

يمثل قيم معدل متوسط مربعات الخطأ (AMSE) ومعدل متوسط الخطأ المطلق (AMAE) لطرائق التقدير المستعملة لانموذج المؤشر الواحد الثالث $Y = \sin(X^T\beta) + \epsilon$ لمختلف حجوم العينات وتباينات الاخطاء في حالة وجود ارتباط واطى وعالٍ عندما $p=8$.

Criteria	method	n	Low correlation=0.1			High correlation=0.9		
			$\sigma^2=1$	$\sigma^2=4$	$\sigma^2=9$	$\sigma^2=1$	$\sigma^2=4$	$\sigma^2=9$
AMSE	LASSO-MAVE	25	0.3720	4.9102	16.4182	0.2907	4.6606	17.6666
		50	0.3891	4.9690	14.3990	0.3134	4.9498	17.2342
		100	0.3436	5.0809	16.3113	0.3232	5.2195	16.5857
	Adaptive LASSO-MAVE	25	0.4886	3.2426	17.6090	0.2653	4.4637	17.7358
		50	0.3724	3.7461	16.9034	0.3379	5.0454	17.6875
		100	0.3575	3.2986	16.3082	0.3501	5.1055	16.1002
AMAE	LASSO-MAVE	25	0.2197	0.8367	1.4419	0.1921	0.8056	1.4940
		50	0.2250	0.7796	1.3569	0.1982	0.7847	1.4954
		100	0.2099	0.8046	1.4418	0.2006	0.8159	1.4539
	Adaptive LASSO-MAVE	25	0.2340	0.7222	1.4816	0.1822	0.7412	1.4789
		50	0.2210	0.7693	1.4544	0.2111	0.8391	1.4872
		100	0.2136	0.7574	1.4416	0.2131	0.8062	1.4361

من الجدول رقم (٣) والخاص بانموذج المؤشر الواحد شبه المعلمي الثالث :

فقد اظهرت النتائج ولحالة وجود ارتباط واطى (low correlation) تفوق طريقة (Adaptive LASSO-MAVE) لمختلف حجوم العينات عند تباين الخطأ ($\sigma^2=4$) وكما حققت افضليتها عند حجم العينة المتوسطة (50) لحالة تباينات الاخطاء ($\sigma^2=1$) و ($\sigma^2=9$) بينما حققت طريقة (LASSO-MAVE) في الحالات الاخرى وبالاعتماد على المعيارين (AMSE) و (AMAE) . ولحالة وجود ارتباط عالٍ (high correlation) فقد حققت طريقة (Adaptive LASSO-MAVE) الافضلية لحالة حجم العينة الصغيرة (25) ولجميع تباينات الاخطاء باستثناء حالة تباين الخطأ ($\sigma^2=9$) فكانت الافضلية لطريقة (LASSO-MAVE) بالاعتماد على المعيار (AMSE) . ولحالة حجوم العينات المتوسطة (50) والكبيرة (100) ولحالة تباينات الاخطاء ($\sigma^2=1$) و ($\sigma^2=4$) فكانت الافضلية لطريقة (LASSO-MAVE) بالاعتماد على المعيار (AMAE) باستثناء حالة تباين الخطأ ($\sigma^2=9$) .

وبشكل عام عن طريق النتائج المبينه في الجداول المذكورة آنفاً نلاحظ الاتي :-

١. من خلال نتائج المحاكاة المبينه في الجداول المذكورة آنفاً نلاحظ تزايد قيم المعيارين (AMSE) و (AMAE) مع تزايد قيم تباينات الاخطاء ولجميع نماذج المؤشر الواحد شبه المعلميه وللطريقتين .

٢. نلاحظ تذبذب في قيم المعيارين (AMSE) و (AMAE) لمختلف حجوم العينات ولجميع النماذج وللطريقتين ويعود سبب ذلك الى سلوك الدوال المستعملة المتذبذب .

٣. بشكل عام تكون طريقة (LASSO-MAVE) والخاصة بتقدير واختيار المتغير لنماذج المؤشر الواحد هي الافضل مقارنة مع طريقة (Adaptive LASSO-MAVE) لكونها تعطي قيم اقل وللمعيارين (AMSE) و (AMAE) ولمختلف النماذج المستعملة .

٤. نلاحظ ان نموذج المؤشر الواحد شبه المعلمي الثالث هو افضل النماذج المستعملة في هذا البحث لكونه يعطي اقل قيم للمعيارين (AMSE) و (AMAE) مقارنة مع النماذج الاخرى .

٧. الجانب التطبيقي :

من اجل التحقق من اداء الطرائق المستعملة في هذا البحث تم تطبيقها على بيانات حقيقية لسوق العراق للاوراق المالية اذ يتكون مجتمع الدراسة من كافة الشركات المدرجة في سوق العراق للاوراق المالية لعام (٢٠١١م) والتي تتكون من (٧٣) شركة نظامية ضمن (٨) قطاعات مختلفة وهي قطاع المصارف (٢١) شركة ، قطاع التأمين (٤) شركات ، قطاع الاستثمار (٢) شركة ، قطاع الفنادق والسياحة (١٠) شركات ، قطاع الزراعة (٥) شركة وقطاع الاتصالات (١) شركة .

اما عينة الدراسة فتم اختيار قطاع المصارف (٢١) شركة وهي تشكل (٢٩%) من المجتمع الاصلي وهذا الاختيار تم وفق الشروط التالية وهي ان تكون مدرجة في السوق ويتم تداول اسهمها خلال العام (٢٠١١م) فضلاً عن امكانية الحصول على كافة المعلومات اللازمة والخاصة بهذا البحث ، اذ تم استعمال نموذج المؤشر الواحد شبه المعلمي لتحديد العوامل المؤثرة على القيمة السوقية للسهم لقطاع المصارف في سوق العراق للاوراق المالية والمبينة بالشكل الاتي والبيانات المستعملة موضحة في الجدول رقم (٤) .

٧: يمثل القيمة السوقية للسهم (دينار) .

x_1 : يمثل نسبة دوران السهم (%) .

x_2 : يمثل العائد على السهم (دينار) .

x_3 : يمثل نسبة الملكية (%) .

x_4 : يمثل مكرر الارباح (مرة) .

x_5 : يمثل نسبة التداول (مرة) .

x_6 : يمثل القيمة الدفترية للسهم (دينار) .

x_7 : يمثل سعر الاغلاق السنوي للسهم (دينار) .

X_8 : يمثل معدل السعر السنوي للسهم (دينار) .

جدول رقم (٤)

يمثل البيانات الحقيقية للعوامل المؤثرة في القيمة السوقية السهم لقطاع المصارف في سوق العراق للاوراق المالية لعام ٢٠١١م

N	Yi	X1	X2	X3	X4	X5	X6	X7	X8
1	١٢٧.٠٠٠	١٩.٤٠	٠.٠٧	٥٤.٦٣	١٨.١٤	٢.١٩	١.٣٥	١.٢٧٠	١.٣٠٠
2	٣٩٢.٨٩٢	١٠	٠.١٩	١٥.٩٥	١٨.٣٢	١.١٤	١.٢٤	٣.٤٨٠	٣.١٣٠
3	١٠٣.٤٠٧	٣٩.٨٠	٠.٠١	٣٦.٩٨	٩١.٨٢	١.٥٢	١.٠٠	١.٠١٠	٠.٩٩٠
4	١٨٢.٠٠٠	٦٢.٦٩	٠.١٨	٢٠.٨٤	١٠.٦٧	١.١٣	١.٣٨	١.٩٢٠	١.٦٤٠
5	٩٥.٠٠٠	٢٩.٢٩	٠.١٠٠	٣٥.٧٣	٩.٥٠	١.٤٩	١.١٧٠	٠.٩٥٠	١.٠٨٠
6	٨٥.٠٠٠	١.٤٠	٠.٠٢	٥٧.٠٩	٤٢.٥٠	٢.٢٨	١.٠٥	٠.٨٥٠	١.٠٢٠
7	٣٥٠.٠٠٠	٦.٤٢	٠.١٦	٣٤.٢٢	٢٢.٥٠	١.٥٢	١.٥٢	٣.٦٠٠	٣.٥٠٠
8	٤٤٩.٦٥٠	٠.٨٨	٠.١٠	١٣.٩٠	٤٢.٥٠	١.١٥	١.٠٥	٤.٢٥٠	٥.٥٩٠
9	٨٢.٠٠٠	١.٨٨	٠.٠٠٣	٦٣.٠٦	٢٧٣.٣٣	٢.٥٦	١.٠٦	٠.٨٢٠	٠.٣٤٠
10	٨١.٠٠٠	٧.٠٨	٠.٠٦	٣٩.٤١	١٦.٢٠	١.٤٩	١.٠٧	٠.٨١٠	٠.٩٢٠
11	١٤٩.٠٠٠	٢٣.٢٣	٠.١٠٠	٣١.٠٠	١٤.٩٠	١.٢٨	١.٢٢٠	١.٤٩٠	٠.٢٧٠
12	١٠٤.٩٨٩	١٤.٢٥	٠.١١	٣٣.٣٨	١٩.١٨	١.٤٢	١.١٤	١.٠١٠	١.٠٩٠
13	١٠١.٢٥٠	١٤.٣٩	٠.١٤	٣٤.٤٨	٩.٦٤	١.٤٨	١.١٩	١.٣٥٠	١.٣١٠
14	٦٢.٧٩٠	٢.٨٣	٠.٠٦٤	٤٤.٥٣	١٦.٤١	١.٧٠	١.٠٨	١.٠٥٠	١.٠٣٠
15	٥١.٧٥٠	١٣.٨٩	٠.٢٠	٢٣.٦٩	١٠.٠٥	١.١٤	١.٢٤	٢.٠١٠	٢.٨٤٠
16	٣٧٥.٠٠٠	٢.٢٦	٠.١٦٠	٣١.١٩	١٦.٦٣	١.٤٦	١.٣٧	٢.٥٠٠	٢.٠٩٠
17	٦٦.٠٣٣	٠.٠٦	٠.١٢٠	٤٩.٩٨	٨.٢٥	١.٨٤	١.٢٦٨	٠.٩٩٠	٠.٩٩٠
18	١٢٩.٠٠٠	٧.١٦	٠.٠٨	٤٠.٢٧	١٦.١٣	١.٦٣	١.٠٩	١.٢٩٠	١.٤٣٠
19	٣٨.٠٠٠	٥٨.٣٥	٠.٢٢	٣٧.٧٣	١٢.٢٣	١.٥٧	١.٢٤	٢.٦٩٠	٢.٤٠٠
20	٤٢.٥٠٠	٣.٤٢	٠.١٠٨	٢٠.٩٩	٧.٨٧	١.١٦	١.١٤٧	٠.٨٥٠	٠.٩٠٠
21	٩٧.٠٠٠	٥.٣٨	٠.٢١٠	٣٤.٨٧	٤.٦٢	١.٤١	١.٢٣	٠.٩٧٠	٠.٩٨٠

جدول رقم (٥)

يمثل تقديرات متجه المعلمات $\hat{\beta}$ والمقدرة بواسطة طريقة LASSO-MAVE و ALASSO-MAVE اعتماداً على البيانات الحقيقية .

method	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$	$\hat{\beta}_5$	$\hat{\beta}_6$	$\hat{\beta}_7$	$\hat{\beta}_8$
LASSO-MAVE	٠.٢٦٧٤ ١	٠.٢٦٩٠٤	٠.٠٠٠٠٠	٠.٣٥٢٩ ٨	٠.٥٣٣٩ ٨	٠.٣٠٢٠ ١	٠.٥٨٧٠٤	٠.١٠٢٩٧
ALASSO-MAVE	٠.٢٩١٥ ٨	٠.٤٥٨٧٩	٠.٠٠٠٠٠	٠.٥٣٨٠٠	٠.٣٢٢٥٤	٠.٠٠٠٠٠	٠.٥٥٧٦٧	٠.٠٠٠٠٠

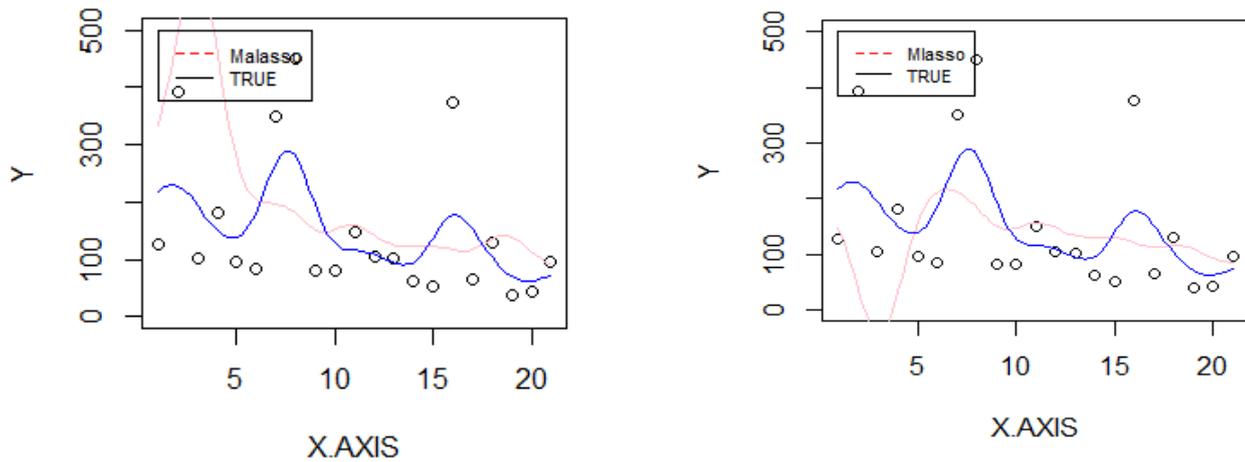
جدول رقم (٦)

يمثل متوسط مربعات الخطأ (MSE) ومتوسط الخطأ المطلق (MAE) لانموذج المؤشر الواحد شبه المعلمي والمقدر بواسطة طريقة LASSO-MAVE و ALASSO-MAVE اعتماداً على البيانات الحقيقية .

method	MSE	MAE
LASSO-MAVE	٢٥٦١٣.٠٣	١٠٤.٢٤٦٦
ALASSO-MAVE	٧٧١٠.٥١٩	١٣١.٣٠٩٨

شكل رقم (١)

يمثل شكل انموذج المؤشر الواحد شبه المعلمي والمقدر بواسطة طريقة LASSO-MAVE و ALASSO-MAVE اعتماداً على البيانات الحقيقية .



عن طريق البيانات الحقيقية والمبينة في الجدول رقم (٤) واعتماداً على انموذج المؤشر الواحد شبه المعلمي (SSIM) المستعمل للتنبؤ بالقيمة السوقية للسهم في سوق العراق للاوراق المالية لقطاع المصارف والمتمثل بالصيغة الاتية :-

$$Y_i = g(x_{i1}\beta_1 + x_{i2}\beta_2 + x_{i3}\beta_3 + x_{i4}\beta_4 + x_{i5}\beta_5 + x_{i6}\beta_6 + x_{i7}\beta_7 + x_{i8}\beta_8) + \epsilon_i$$

تم التوصل الى نتائج البيانات الحقيقية المبينة في الجدولين رقم (٥) و (٦) والشكل رقم (١) بالاعتماد على برنامج (R-Package) والحصول على تقديرات متجه المعلمات β ودالة الربط $g(X^T \beta)$ لدالة القيمة السوقية للسهم وللطريقتين (LASSO-MAVE) و (Adaptive LASSO-MAVE) نلاحظ الآتي :-

١. عملت طريقة (LASSO-MAVE) على استبعاد المتغير الثالث فقط المتمثل بنسبة الملكية باعتباره متغير غير معنوي واختارت هذه الطريقة المتغيرات الاخرى باعتبارها متغيرات لها تأثير معنوي على المتغير المعتمد المتمثل بالقيمة السوقية للسهم وبذلك يكون الانموذج التنبؤي بطريقة (LASSO-MAVE) هو :-

$$\widehat{Y}_i = \widehat{g}_7(0.26741 x_{i1} + 0.26904 x_{i2} + 0.35298 x_{i4} + 0.53398 x_{i5} + 0.30201 x_{i6} + 0.58700 x_{i7} + 0.10297 x_{i8})$$

٢. عملت طريقة (Adaptive LASSO-MAVE) استبعاد ثلاث متغيرات وهي المتغير الثالث والمتمثل بنسبة الملكية والمتغير السادس المتمثل بالقيمة الدفترية للسهم والمتغير الثامن المتمثل بمعدل السعر السنوي للسهم باعتبارها متغيرات غير معنوية واختارت المتغيرات المتبقية الاخرى باعتبارها متغيرات لها تأثير معنوي على القيمة السوقية للسهم وبذلك يكون الانموذج التنبؤي بطريقة (Adaptive LASSO-MAVE) هو :-

$$\widehat{Y}_i = \widehat{g}_5(0.29158 x_{i1} + 0.45897 x_{i2} + 0.53800 x_{i4} + 0.32254 x_{i5} + 0.55767 x_{i7})$$

٣. اظهرت النتائج ان طريقة (LASSO-MAVE) هي الافضل في تقدير متجه المعلمات ودالة الربط (دالة القيمة السوقية) لقطاع المصارف في سوق العراق للاوراق المالية واختيار المتغيرات المعنوية لانموذج المؤشر الواحد شبه المعلمي لكونها تعطي اقل قيمة لمتوسط مربعات الخطأ (MSE) واقل قيمة لمتوسط الخطأ المطلق (MAE) مقارنة مع طريقة (Adaptive LASSO-MAVE) وهذا يعني ان طريقة (LASSO-MAVE) قادرة على تمثيل دالة القيمة السوقية لقطاع المصارف في سوق العراق للاوراق المالية . وان هذه النتائج بدورها تطابقت مع نتائج تجارب المحاكاة .

٨. الاستنتاجات والتوصيات :

٨.١ الاستنتاجات :

١. بينت النتائج من الجانب التجريبي والبيانات الحقيقية تفوق طريقة (LASSO-MAVE) في تقدير متجه المعلمات (الجزء المعلمي) ودالة الربط (الجزء اللامعلمي) واختيار المتغير المعنوي في آن واحد على طريقة (Adaptive LASSO-MAVE) لجميع نماذج المؤشر الواحد شبه المعلمية المستعملة فضلاً عن تقدير متجه المعلمات ودالة الربط المتمثلة بدالة القيمة السوقية للسهم في سوق العراق للاوراق المالية لقطاع المصارف .

٢. اظهرت طريقة (LASSO-MAVE) افضليتها وكفاءتها بشكل واضح في حالة وجود ارتباط عالٍ بين المتغيرات التوضيحية .

٣. يمكن الاستنتاج الى امكانية استعمال طريقة (LASSO-MAVE) لتقدير واختيار المتغير لاي انموذج مؤشر واحد شبه معلمي .

٤. نلاحظ من خلال الجدول رقم (٥) والشكل رقم (١) ان دالة القيمة السوقية للسهم اخذت شكل متذبذب وهذا يعني ان اي زيادة في مؤشرات المتغيرات التوضيحية المعنوية يؤدي الى زيادة في القيمة السوقية للسهم مما يشير الى وجود علاقة طردية بينهما بالاعتماد على المعادلة التنبؤية لامتداد المؤشر الواحد شبه المعلمي التي تم الحصول عليها بواسطة استعمال طريقة (LASSO-MAVE) .

٨.٢ التوصيات :

في ضوء الجانب النظري وبناءً على ماتم التوصل اليه من استنتاجات ادناه اهم التوصيات :-

١. اوصي باستعمال طريقة (LASSO-MAVE) في تقدير واختيار المتغيرات المعنوية لامتداد المؤشر الواحد شبه المعلمي لكفاءتها العالية في تعاملها مع حالة وجود ارتباط عالٍ بين المتغيرات التوضيحية وفي ظل وجود تباينات اخطاء مختلفة .

٢. اوصي باستعمال صيغ اخرى من دوال اللب (kernel) فضلاً عن استعمال طرائق مختلفة في حساب المعلمة التهيدية وتوظيفها في طرائق التقدير شبه المعلميه الخاصة بتقدير نماذج المؤشر الواحد .

٣. اوصي باستعمال المعيار معدل متوسط الخطأ المطلق (AMAE) في تجارب المحاكاة واعتماده كأساس للمقارنة بين طرائق التقدير .

٤. اوصي باستعمال جميع المؤشرات المالية باستثناء المؤشر (نسبة الملكية) لعدم تأثيره على القيمة السوقية للسهم والذي تم استبعاده من خلال طريقة التقدير (LASSO-MAVE) . اذ ان ارتفاع قيم هذه المؤشرات يؤدي الى زيادة القيمة السوقية للسهم وانخفاضها يؤدي الى تناقص القيمة السوقية للسهم وعلى ضوء ذلك يمكن للمستثمر اتخاذ القرار الصحيح والمناسب في عملية بيع وشراء الاسهم .

المصادر:

1. حمود ، مناف يوسف ، (٢٠١٣) ، " حول الانموذج احادي المؤشر شبه المعلمي " ، قبول للنشر في مجلة العلوم الاحصائية ، المعهد العربي للبحوث الاحصائية .

2. شهاب ، طارق عزيز صالح ، (٢٠١٦) ، " بعض الطرائق شبه المعلميه في تقدير واختيار المتغير لانموذج المؤشر الواحد " ، اطروحة دكتوراه فلسفة في الاحصاء ، كلية الادارة والاقتصاد ، جامعة بغداد .

3. Al – kenani ,A ., and Yu , K . (2013) , “Penalized single Index

quantile regression “ . International Journal of statistics and probability, vol.2 , No.3 , pp. 12–30 .

4. Akkus ,O . (2011) , “ Xplore package for the popular parametric and semi-parametric single index models “ .Journal of science ,vol.24 , No.4, pp. 753–762 .

5. Cassotti , M., and Grisoni , F.(2012) , “ variable selection methods : an introduction “ . Milano chemometrics and QSAR . research group ,department of environmental sciences , University of Milano–Bicocco. (Italy) .www.molecular descriptors .eu

6. Chand , S., and Kamal , S .(2011) , “ variable selection by lasso – type method “ . Pakistan Journal of statistics and operation research , pp. 451–464

7. Chen , S.X.(2002) , “ local linear smoothers using asymmetric kernels “ . Annals of the institute of statistical mathematics , vol.54 , No.2 , pp. 312–323

8. Hardle ,W., Hall , P., and Ichimura ,H.(1993) , “ optimal smoothing in single index models “ . the Annals of statistics , vol.21 , pp. 157–178 .
9. Huang , J., Ma , S., and Zhang , C.H. (2008) , “ Adaptive lasso for sparse high– dimensional regression models “ . statistica sinica 18 , pp . 1603– 1618 .
- 10.Kong , E ., Xia , Yi . (2007) , “ variable selection for the single index model “ . Biometrika 94 , pp. 217–229 .
- 11.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 .
- 12.Naik , P.A., and Tsai, C.L. (2001) , “ single index model selections “ . Biometrika 88 , pp. 821–832 .
13. Peng , H., and Huang ,T.(2011) , “ penalized least squares for single index models “ . Journal of statistical planning and inference 141 , pp. 1362–1379 .
- 14.Su , L., and Zhang , Y . (2013) , “ variable selection in non– parametric and semi–parametric regression model “ . school of Economics , Singapore Management university .
- 15.Thomas , J.F. (2006),“ Simulation study for single index model” . submitted to the Department of Mathematical sciences of Clemson university , in partial fulfillment for The requirements for The degree of Master of science in Mathematical sciences .
16. Tibshirani , R . (1996) , “ Regression shrinkage and selection via The lasso “ . Journal of The Royal statistical society , series B , 58 , PP. 267–288 .
- 17.Wang , H., Li,R.Z., and Tsai . C.L. (2007) , “Tuning parameter selectors for the smoothly clipped absolute deviation method “ . Guanghua school of management , peking university , Beijing , China , pp. 553–568 .
18. Wang , T., Xu .P.,and Zhu , L.(2013) ," Penalized Minimum Average Variance Estimation " . statistics sinica 23 ,pp.543–569.
- 19.Xia ,Y. , Hardle , W . , and Linton, O . (2009) , “ optimal smoothing For a computationally and statistically Efficient single index Estimators ”. Exploring Research Frontiers in contemporary Statistic and Econometrics , pp. 229 – 261.
- 20.Zou, H. (2006) , “ The Adaptive lasso and Its Oracle properties”
Journal of the American statistical Association (JASA) 101,
PP .1418 – 1429.