

المقدار الأفضل لأنموذج العامل الديناميكي (DFM)

أ.م.د رواء صالح محمد

الجامعة المستنصرية- كلية الإدراة والاقتصاد- قسم الاحصاء

rawaaalsaffar@uomustansiriyah.edu.iq

omar.khamis@uomustansiriyah.edu.iq

مستخلص البحث:

يمتاز انموذج العامل الديناميكي (DFM) بتحليل البيانات بشكل ديناميكي ويركز على تفسير التغيرات المشتركة في مجموعة من المتغيرات عبر الزمن، ويعد مناسباً للبيانات الكبيرة التي تحتوي على العديد من المتغيرات ويمكن استخدامه للتنبؤ بالمتغيرات الاقتصادية ومراقبتها، وهدف البحث تقليص بيانات السلسل الزمنية التي تمتاز بحركة مشتركة (Co-Movement) خلال الزمن نتيجة لوجود عوامل مشتركة بينها، من خلال استعمال نماذج (DFMs)، للوصول الى انموذج كفوء وتحديد عدد العوامل المشتركة وتقدير معلمات الانموذج (DFM) باستعمال طريقة الإمكان الأعظم (Maximum likelihood) . وفي هذا البحث تم تقدير انموذج العامل الديناميكي باستخدام طريقة الامكان الاعظم حيث اظهرت نتائج المحاكاة بالاعتماد على حجم العينات (20 ، 50 ، 125) ومعاملات الارتباط (0.5 ، 0.1 ، 0.9) ان افضل قيمة لمتوسط جذر مربعات الخطأ RMSE هي 0.6309 عند حجم عينة 125 ومعامل ارتباط هو (0.1) وتمت ملاحظة من خلال النتائج التي تم الحصول عليها ان افضل قيمة لـ (RMSE) عندما تكون حجم العينات كبيرة ومعامل الارتباط قليل اي كلما قل معامل الارتباط كلما قلت قيمة متوسط جذر مربعات الخطأ RMSE اي التنااسب يكون طردياً، وكلما ازدادت حجم العينات قلت قيم (RMSE) اي التنااسب يكون عكسياً.

الكلمات المفتاحية: العامل الديناميكي، طريقة الامكان الاعظم، متوسط جذر مربعات الخطأ، افضل مقدر

1- المقدمة [4]

نماذج العوامل الديناميكية (DFM) توفر وسيلة فعالة لتلخيص العلاقات المعقدة بين متغيرات السلسل الزمنية، مما يجعلها أدوات مفيدة في التنبؤ بأنواع مختلفة من البيانات، مثل الاقتصادية، البيئية، والصحية. تعتمد هذه النماذج على منهجية التحليل العامل، التي تقلل أبعاد المتغيرات وتحدد مصادر التباين بينها. تعود جذور التحليل العامل إلى دراسات علم النفس التي أجرتها Spearman في عام 1904، حيث استخدم عوامل غير مرصودة لوصف القدرات المعرفية، لاحقاً، تم توسيع التحليل العامل ليشمل بيانات السلسل الزمنية من قبل Geweke في عام 1977، مما أتاح دراسة الحركات المشتركة بين هذه البيانات. السلسل الزمنية تمتاز بخصائص مثل الاتجاهات، الدورية، الموسمية، والارتباط المتسلسل، والتي يجب أخذها بعين الاعتبار عند تحليل حركتها، واحدة من أهم التحديات في بناء نماذج التنبؤ هي زيادة أبعاد البيانات، سواء كانت اقتصادية أو صحية، عبر فترات زمنية معينة، مما يؤدي إلى مشاكل سوء توصيف النموذج. نماذج العوامل الديناميكية (DFMs) تساعده في تقليل هذه الأبعاد وتحديد العوامل المشتركة. كما يتم تقدير معلمات النموذج باستخدام طريقة الإمكان الأعظم، مع إجراء تجارب محاكاة للوصول إلى أفضل تقدير لتحسين دقة التنبؤ الآني.

2- الدراسات السابقة

❖ في عام (1983) قدم كل من الباحثان [7] (Mark W. and Robert F.) بحثاً درساً فيه المنهجية العامة لصياغة وتقدير نماذج (DFM) بوجود المتغيرات الكامنة في مصفوفة العوامل اذ

قدما تعرضا بـ بالنموذج العام ثم عرض طريقتين لتقدير الانموذج اولهما طريقة الامكان الاعظم (ML) استناداً لمرشح كالمان (Kalman Filter) وطريقة (EM). كما اقترح الباحثان استعمال طريقة (EM) نتيجة لكفاءة المقدرات مقارنة بطريقة (MLE).

❖ في عام (2019) قدم كل من الباحثان [5] (Barigozzi, M., and M. Lucian) بحثاً استعرضوا به تقدير نماذج (DFM) للمتغيرات عالية الابعاد باستعمال طرائق (MLE, EM) استناداً لمرشح كالمان (Kalman Filter) وقد بين الباحثان عندما تزداد عدد المشاهدات (n) وقيم العينة (T) الى ما لا نهاية فإن المقدرات تصبح أكثر اشتقاقة وقد تم استعمال برامج المحاكاة وفق منهجية Monte Carlo وثبتت النتائج افضلية طريقة (EM) عند حجوم (n) و (T).

3- توصيف انموذج العامل الديناميكي (Specification of Dynamic Factor Models) [8][3]

الهيكل العام للنموذج (DFM) يستعمل على متغيرات مشاهدة (x_t) والتي يمكن تمثيلها كدالة من العوامل غير المشاهدة (العوامل المشتركة) لتكن (F_t) مضاف اليه حد الخطأ العشوائي (الضوابط) \in_t . ويمكن صياغة (n) من المتغيرات المشاهدة اذ ان ($i = 1, 2, \dots, n$) عند فترة زمنية (T) اذ ان ($t = 1, 2, \dots, T$) وفق انموذج (DFM) ، كالاتي .

$$X_t = \Lambda F_t + \epsilon_t \quad \dots \dots \dots (1)$$

$$F_t = \Psi F_{t-1} + \varepsilon_t \quad \dots \dots \dots (2)$$

اذ ان .

X_t : متجة المتغيرات المشاهدة (المقاسة) وان

$$X_t = (x_{1t}, x_{2t}, \dots, x_{it})$$

F_t : متجة من العوامل الكامنة (Latent Variables) او العوامل المشتركة (C.F) ذات البعد ($r \times 1$) وهي تمثل عوامل غير مشاهدة (مخفية) وهي ثابتة عبر الزمن t . وان

$$F_t = (f_{1t}, f_{2t}, \dots, f_{rt})$$

وان $r < n$. وتشير (r) الى عدد العوامل المشتركة .

Λ : مصفوفة التسبيعات (التحميلات) والتي تحدد تأثير كل عامل مشترك (كامن) على كل متغير وابعادها ($n \times r$) ، وان [13][9]:

$$\Lambda = (\lambda_{i1}, \lambda_{i2}, \dots, \lambda_{ij})$$

اذ ان : ($j = 1, 2, \dots, r$)

ϵ_t : متجة الاخطاء العشوائي (الضوابط) ذي البعد ($n \times 1$) ، وان

$$\epsilon_t = (\epsilon_{1t}, \epsilon_{2t}, \dots, \epsilon_{nt})$$

Ψ : مصفوفة ابعادها ($r \times r$) وتمثل مصفوفة المعاملات (الانتقالات) التي تحدد كيفية تطور العوامل بمرور الزمن (t) .

ϵ_t : متجه الاخطاء العشوائي (الضوابط) وهو غير مرتبط زمنيا ويمثل (Whit noise) وابعاده ($1 \times r$) وهي تشرح الاضطرابات التي عدت في العوامل المشتركة .

ان كلام حدي الاخطاء (ϵ_t) و (n_t) غير مترابطين (متعاملين) زمنيا عند جميع قيم (i) و (t) وفي كل الارتدادات الزمنية (j) .

$$E(\epsilon_t | \epsilon_{t-j}) = 0$$

في المعادلة (1) المتغيرات (X_t) تتحلل الى مركبتين

- المركبة الاولى : ناتجة عن العوامل المشتركة ($F.C$) او المتغيرات الكامنة ($L.V$) وهو مركبة ديناميكية كما يتضح من معادلة (2) كما ان كل فرع (F_{t-1}) و (ϵ_t) هما متعمدان على بعضهم البعض (عند كل قيم t). كما ان (F_t) تصاغ وفق انموذج الانحدار الذاتي من الدرجة الاولى ($AR(1)$) مما يشير على انه عملية ديناميكية.

- المركبة الثانية : فيتمثل بحد الخطأ العشوائي (ϵ_{it}) ويطلق عليه بالمركبة المميزة (*Idiosyncratic Component*) وهو يتمتع الصدمات الناتجة عن كل متغير (x_{it}) ، ويمكن صياغته وفق المعادلة :

$$(3) \epsilon_{it} = \mu_i + \eta_{it} \dots \dots$$

اذ ان :

μ_i : المتوسط للمتغير (x_i) عند الزمن t .

η_{it} : الاخطاء العشوائية ذات البعد ($n \times 1$)

المركبة المميزة (ϵ_t) قد تكون متراقبة زمنيا (*Serially Correlated*). وهذا لها تداعيات عند تفسير الانموذج (DFM). ولتلafi تلك الاشكالات، يمكن تحديد سلوك (ϵ_t) كأنموذج معلم يفسر الديناميكيات المميزة ، وبالتالي يمكن افتراض ان (ϵ_t) ينتج انموذج ($AR(1)$ اي ان: [5][4]

$$(4) \epsilon_{it} = \epsilon_{it-1} + V_{it} \dots \dots$$

اذ ان

V_{it} : حد الخطأ العشوائي غير متراقب زمنيا .

ان الافتراضات الاساسية لأنموذج (DFM) تنص على ان كل من X_t و F_t هي غير متراقبة كما ان المركبات المميزة (ϵ_t) ايضا غير متراقبة مع بعضها البعض عند اي نقطة زمنية (t). وبالتالي فأن مصدر الارتباطات بين المتغيرات اي انها متراقبة مع بعضها البعض و يرجع الى العوامل المشتركة

(F_t).

4- انموذج العامل الديناميكي الدقيق (Exact DFM)

[14][11]

قدم الباحث Sperman عام (1904) بتعريف انموذج العامل الدقيق (Exact DFM) هذا الانموذج يفترض ان يكون المركب المميز (ϵ_t) غير مرتبط زمنياً وبالتالي فان V_{ks} هي متعمدة بشكل تام عند كل قيم $k \neq i$ صغيرة ولجميع الفترات (s, t) عليه فان جميع الارتباطات بين المتغيرات المشاهدة (المقاسة) المصدر المتحكم بها يرجع الى العوامل المشتركة (المتغيرات الكامنة) (F_t).

يعتمد انموذج (Exact DFM) على مبدأ ان المتغيرات المشاهدة (X_t) يمكن ان تفسر من خلال عدد محدد من العوامل ($n < r$) او المتغيرات الكامنة والتي بدورها تتغير بمرور الزمن .

يمكن صياغة انموذج (Exact DFM) وفق الاتي :-

$$x_{it} = \mu_i + \lambda'_{ij} f_{jt} + \epsilon_{it} \dots \dots \quad (5)$$

$i=1,2,\dots,n$

$t=1,2,\dots,T$

$j=1,2,\dots,r$

ان كل من (\mathbf{f}_{it} , \mathbf{E}_{it} , \mathbf{E}_{kt}) متعامدة (غير مرتبطة) عند جميع قيم (i , j) كما ان (\mathbf{A}_{ij} , \mathbf{J}^{it}) متعامدة عند جميع قيم ($i \neq k$) تشير (λ_{ij}) الى مصفوفة ابعادها ($n \times r$) التحميلات لـ (\mathbf{i}^{th}) العوامل في (\mathbf{i}^{th}) من المتغيرات.

μ_i : المتوسط للمتغير X_i وهو متوجه ابعاده $1 \times n$ والذي يفترض غالباً يساوي صفرأً أي ان $(\mu_i = 0)$ وذلك لجعل البيانات أكثر ملائمة.

يمكن اعادة صياغة الانموذج معادلة (5) وفق الاتي :-

$$X_t = \Lambda_0 F_t + \Lambda_1 F_{t-1} + \cdots + \Lambda_s F_{t-s} + \epsilon_t \quad \dots \quad (6)$$

اذا تمثل (s) عدد الارتدادات الزمنية (Lags) الانموذج في المعادلة (6) يفترض ان F_t و $t \in$ غير مستقرة ويمكن اعادة صياغته وفق صيغة المصفوفات وكما يلى :-

$$X_t = \Lambda F_t + \epsilon_{it} \quad \dots \dots \dots (7)$$

$$F_t = \Psi F_{t-1} + \eta_t \quad \dots \dots \dots (8)$$

ويشترط في النموذج (Exact DFM) أن يكون ($n < T$) محدد.

5- تقدير انموذج العامل الديناميكي الدقيق Estimat of Exact Dynamic Factor Model
 ان تقدير انموذج (Exact DFM) يهدف الى تحليل وتقسيم التفاعلات الديناميكية بين مجموعة من المتغيرات المشاهدة بوجود عدد من العوامل المشتركة (المتغيرات الكامنة غير المشاهدة) لاستخراج التأثيرات الكامنة من البيانات العالية الابعاد من خلال الزمن (t).

وسيتم دراسة طريقة لتقدير الانموذج وهي طريقة الامكان الاعظم لانموذج العامل الديناميكي فانموذج (Exact DFM) يمكن تعريفه كما في المعادلات (1) ، (2)

6-طريقة الامكان الاعظم Maximum Likelihood Method

اقرَح الباحث (Molenaar) عام (1985) تقدير انموذج (Exact DFM) باستعمال طريقة الامكان الاعظم (Maximum Likelihood) بافتراض معيارية البيانات ان ($\mu=0$) فيمكن اعادة صياغتها وحسب معادلة (2) (1)

في المعادلة (2) نفترض ان العوامل المشتركة تتبع عملية انحدار ذاتي من درجة (1) اي $AR(1)$ وان ϵ_t هي حد الضوضاء الابيض . وبوجود الافتراضات الآتية :-

$$1) \quad \epsilon_t \sim i.i.d. N(\mathbf{0}, \Sigma)$$

$$\Sigma = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2) = \sigma_{In}^2$$

$$2) \varepsilon_t \sim i.i.d. N(0, \Omega)$$

$$\Omega = \Lambda\Lambda' + \Sigma$$

$$3) X_t \sim i.i.d. N(0, \Lambda \Lambda' \sigma_{in}^2)$$

4) $\Lambda\Sigma\Lambda'$

دالة الامكان الاعظم واستنادا الى توزيع X_t تكتب كالتالي : [12].

$$p_r(X_t | \Lambda, \sigma^2) = \frac{n}{\sqrt{2\pi}} |\Lambda\Lambda' + \sigma_{In}^2|^{-1/2} *$$

$$\exp \left\{ \frac{-1}{2} X'_t (\Lambda \Lambda' + \sigma_{In}^2)^{-1} X_t \right\} \dots \dots \dots (9)$$

ارقام المعادلتين Λ و σ^2 تعظمات دالة الامكان الاعظم اذ ان

$$\{\Lambda, \sigma^2\} = \operatorname{argmin} L(X_t, \Lambda, \sigma^2) \dots \dots \dots (10)$$

$$L(X_t, \Lambda, \sigma^2) = \frac{T}{2} \log(|\Lambda \Lambda' + \sigma_{In}^2|)$$

$$- \frac{1}{2} \left(\sum_{t=1}^T X_t (\Lambda \Lambda' + \sigma_{In}^2)^{-1} X_t \right) \dots \dots \dots (11)$$

$$= \frac{T}{2} \log(|\Lambda \Lambda' + \sigma_{In}^2|)$$

$$- \frac{T}{2} \operatorname{tr}(\Lambda \Lambda' + \sigma_{In}^2)^{-1} \Gamma_X \dots \dots \dots (12)$$

$$\Gamma_X = T^{-1} \sum_{t=1}^T X_t X'_t \dots \dots \dots (13)$$

اذ ان

سيتم استعمال مرشح كالمان (K.F) وسبب وجود عوامل مخفية (غير مقاسة) اذ تساعد هذه التقنية لتقدير لتلك العوامل المتمثلة بـ (F_t, Λ) وللبدء في التقدير العوامل المخفية وفق مهمة (K.F) استناداً للخطوات الموضحة سابقاً يتم تقدير (F_0) وهي تمثل قيمة ابتدائية ويتم تحديد قيمة (Ω_0) والتي تمثل مصفوفة التباين - والتباين المشترك للعوامل المشتركة (المخفية) (الابتدائية).

بعد تحديد القيم الابتدائية (F_0, Ω_0) يتم ايجاد توقع الحالة وفق الصيغة

$$F_t^* = \Psi F_{t-1} \dots \dots \dots (14)$$

وتوقع مصفوفة التباين

$$\Omega_t^* = \Psi \Omega_{t-1} \Psi' + \varepsilon_t \dots \dots \dots (15)$$

بعدها يتم حساب منفعة كالمان (Kalman Gain) للبيانات المشاهدة.

ونذلك لتحسين تقديرات الحالة (F_t) ويمثل مدى تأثير القيمة المقاسة الجديدة على التقدير الحالي للحالة.

ويحسب وفق المعادلة :

$$K_t = \Omega_t^* \Lambda' (\Lambda \Omega_t^* \Lambda' + \Sigma)^{-1} \dots \dots \dots (16)$$

اذ ان :

K_t : مصفوفة التباين المتوقعة

Λ' : مصفوفة التحميلات (المقاسة)

Σ : مصفوفة حد الضوضاء والتي تعكس عدم التأكيد في القياسات

إذا كانت قيمة (K_t) قريبة من (1) فإن التقدير يعتمد بشكل كبير على القياس الجديد

اما اذا كانت قيمة (K_t) قريبة من الصفر (0) فإن التقدير سيعتمد على القيمة السابقة

ان قيمة (K_t) تساهم في تحسين التقديرات بشكل دوري عند ايجاد قياسات جديدة

في حالة ان $(K_t) = 1$ يتم تحديد التقدير استناداً للمعادلة الآتية .

$$\tilde{F}_t = F_t^* + K_t (X_t - \Lambda F_t^*) \dots \dots \dots (17)$$

اما لتحديث مصفوفة التباين ل F_t

$$\Omega_t = (I_t - K_t \Lambda) \Omega_t^* \dots \dots \dots (18)$$

ان (K.F) يتطلب ان تكون جميع المعادلات خطية اما في حالة عدم تحقق ذلك الشرط يتم استعمال (Extended Kalman Filter) ويمكن بناء مصفوفة التحميلات وفق الصيغة التالية :

$$\widehat{\Lambda} = V(D - \sigma_{Ir}^2)^{1/2} \dots \dots \dots (19)$$

اذ ان

V : مصفوفة المتجهات المميزة (كل عمود فيها يمثل متجه مميز) (j)
 B : مصفوفة قطرية عناصر القطر الرئيسي تمثل القيم المميزة (ترتيب تلك القيم يتم من اكبر الى اصغر قيمة مميزة والتي تقابل المتجهات المميزة التابعة لها)
 اما تقدير σ^2 فتحسب كالاتي [1][5]:

$$\widehat{\sigma}^2 = \frac{1}{n} \text{tr}(\Gamma_X - \widehat{\Lambda} \widehat{\Lambda}') \dots \dots \dots (20)$$

حيث ان $\Gamma_X D = VD$ وان

$$D_{(r \times r)} = \begin{pmatrix} d_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & d_r \end{pmatrix}$$

D : مصفوفة قطرية تمثل (r) اعلى قيم مميزة للمصفوفة (Γ_X) كما ان

$$V_{(n \times r)} = [v_1, \dots, v_r]'$$

$V_{(n \times r)}$: تمثل المتجهات المميزة المرتبطة بالقيم المميزة (r)

بعد ايجاد كل من \widehat{F}_t و $\widehat{\Lambda}$ يمكن ايجاد القيم المتوقعة (المقدرة) لـ X_t وكالاتي :
 $\widehat{X}_t = \widehat{\Lambda} \widehat{F}_{t(new)} \dots \dots \dots (21)$

7 - مقاييس المقارنة (Comparison Measurements)

جذر مربع متوسط الخطأ (RMSE) Root Mean Square Error (RMSE)
 يشبه (RMSE) مقاييس مجموع الخطأ المطلق (TAE) ولكنها يستخدم مجموع مربعات الخطأ وبعد مقاييس فعال عندما تقترب الاخطاء من التوزيع الطبيعي ويتم حسابه كالاتي :

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

8- المحاكاة: [١]

المحاكاة بأنها عملية بناء انموذج افتراضي لنظام معقد او ظاهرة واقعية وتشغيل هذا الانموذج على مدى فترة زمنية محددة لمحاكاة سلوكه واستجابته لمجموعة محددة من الظروف والفاعلات، وبالتالي تتيح المحاكاة فهم المتغيرات والعلاقات وتحليل تأثيرها في النظام او الظاهرة قيد الدراسة، اذ تتطلب المحاكاة استخدام الحوسية البرمجية لتنفيذ نماذج المحاكاة وتوليد البيانات اللازمة.

9- مراحل بناء تجارب المحاكاة [٧] [١٠] [١١]

Stages of building simulation experiment

المرحلة الأولى :

1- تحديد حجم العينة n حيث تم اخذ ثلات حجوم هي (20، 50، 125)

2- تحديد عدد التكرارات لكل تجربة ($r=500$)

3- تحديد القيم الابتدائية لمعلمة الارتباط الذاتي

$$\Psi = 0.1, 0.5, 0.9$$

4- تحديد القيم الابتدائية لمصفوفة التشبعتات (التحميلات) Λ وكالاتي:

$$\Lambda = (\lambda_{i1}, \lambda_{i2}, \dots, \lambda_{ij})$$

$$\Lambda = \begin{pmatrix} 0.7 & 0.2 & 0.4 \\ 0.3 & 0.5 & 0.1 \end{pmatrix}$$

وتم اختيارها استناداً لأفضل التكرارات التي تم الحصول عليها.

المرحلة الثانية :

في هذه المرحلة يتم توليد مصفوفة المعاملات غير المرئية F_t والخطأ العشوائي والمتغيرات المشاهدة

X_t

1- توليد الخطأ العشوائي من خلال التوزيع الطبيعي بمتوسط صفر وتباعين (1)، وكما يأتي:

$$\epsilon_t \sim N(0, 1)$$

2- توليد مصفوفة المعاملات غير المرئية F_t من خلال معادلة رقم (2) في فقرة (3) من خلال

(1) AR(1) انموذج الانحدار الذاتي من الدرجة الاولى وكالاتي:

$$F_t = \Psi F_{t-1} + \epsilon_t$$

وتم توليد مصفوفة متكونة من ثلاثة معاملات.

3- توليد المتغيرات المشاهدة X_t من خلال معادلة رقم (1) في فقرة (3) وكالاتي:

$$X_t = \Lambda F_t + \epsilon_{it}$$

وتم توليد متغيرين.

10- نتائج عملية المحاكاة

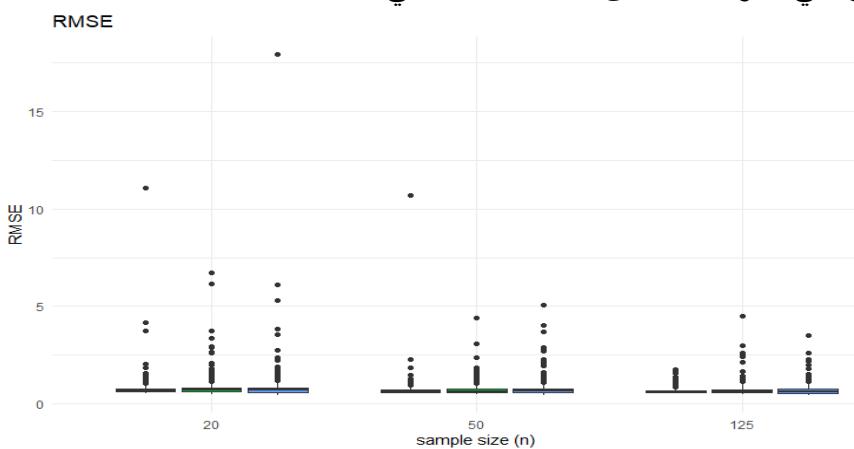
سيتم عرض النتائج التي تمثل متوسط RMSE لمقدرات الانموذج الديناميكي باستخدام طريقة الامكان الأعظم (MLE) وحسب المعادلات من (10) الى (13) التي تم ذكرها في الفقرة (6)، وتم استعمال مرشح كالمان بسبب وجود عوامل خفية، والناتج كما مبينة في ادناه:

جدول (1) في حالة حجوم العينات (20, 50, 125) والقيم الابتدائية لمعامل الارتباط الذاتي ($0.9, 0.5, 0.1$)

n	Ψ	RMSE
20	0.1	0.744786
50		0.680046
125		0.63092
20	0.5	0.803434
50		0.700794
125		0.684749
20	0.9	0.817323
50		0.73355
125		0.672145

ومن خلال جدول رقم (1) يتبيّن ان افضل قيمة لمتوسط جذر مربعات الخطأ RMSE تساوي (0.63092) عندما $n=125$ وقيمة معامل الارتباط $\Psi = 0.1$ وعندما كان معامل الارتباط $\Psi = 0.5$ كانت افضل نتيجة لـ RMSE تساوي (0.684749) عند حجم عينة $n=125$ وعندما كان معامل الارتباط $\Psi = 0.9$ كانت افضل نتيجة لـ RMSE تساوي (0.672145) عندما $n=125$. تليها قيم متوسط (RMSE) عند حجم $n=50$ ، ونلاحظ من خلال نتائج متواضع جذر مربعات الخطأ RMSE تكون افضل عندما يكون حجم العينة كبير اي ان انها تناسب عكسياً اي كلما زادت حجوم العينات قلت قيمة RMSE، ونلاحظ كلما قلت قيمة معامل الارتباط نحصل على افضل قيمة لمتوسط جذر مربعات الخطأ.

ولكي نبيّن ما تم ذكره في جدول أعلاه من خلال الشكل الآتي:



شكل (1) قيم (RMSE) لأنموذج العامل الديناميكي

من خلال الشكل (1) يتبيّن ان قيم متوسط جذر مربعات الخطأ (RMSE) تقل بازدياد حجم العينة وتقترب من بعضها وخاصة عندما تكون قيمة معامل الارتباط (0.1) وكما موضحة بالشكل حيث دل الخط الافقى من الشكل الى حجوم العينات اما الخط العمودى الى قيم (RMSE)، كما ان المربع

الأحمر يشير إلى قيمة معامل الارتباط 0.1 واللون الأخضر إلى قيمة معامل الارتباط 0.5 وهكذا للبقية، أما النقاط تمثل قيم (RMSE).

11- الاستنتاجات

- يتضح من خلال المحاكاة قيم متوسط جذر مربعات الخطأ RMSE بطريقة الامكان الاعظم MLE لتقدير انموذج العامل الديناميكي DFM
- 1- افضلية عندما تكون حجوم العينات كبيرة
 - 2- ان قيم متوسط جذر مربعات الخطأ RMSE تقل عندما تكون حجوم العينات كبيرة
 - 3- هنالك تناسبًا عكسيًا بين قيم متوسط جذر مربعات الخطأ RMSE وحجوم العينات وتناسبًا طرديًا بين معامل الارتباط وقيم مربعات الخطأ
 - 4- يكون هنالك تشتيت في القيم كلما قلت حجوم العينات

المصادر

- 1- هادي، امين حسين،(2024)."مقارنة بعض طرائق تقدير انموذج المصفوفة الاباسية المكانية".
اطروحة دكتوراه في الاحصاء، كلية الادارة والاقتصاد، الجامعة المستنصرية.
- 2- Byoung-wook Ko,(2010); "An Application of Dynamic Factor Model to Dry Bulk Market".
- 3- Breitung, Eickmeier,(2014); "Dynamic factor models, Jörg Breitung (University of Bonn and Deutsche Bundesbank) Sandra Eickmeier (Deutsche Bundesbank and University of Cologne)".
- 4- Barhoumi, Darné and Ferrara,(2014); "Dynamic factor models: A review of the literature" , Karim Barhoumi, Olivier Darné and Laurent Ferrara.
- 5- Barlogozzi , M. and M.Lucian ,(2019); Quasi Maximum Likelihood Estimation of non-stationary Large approximate Dynamic Factor Model " . arxiv.1910.09841.
- 6- Doz, Peter Fuleky,(2019);" Dynamic Factor Models Catherine" .
- 7- Mark W. WATSON , Robert F. ENGLE,(1983); "Alternative Algorithms for the estimation of dynamic Factor , MIMIC and Varying Coefficient Regression Models ." Harvard University , Cambridge , M. A 02138. USA. 0304-4076/83/Elsevier Science publishers B.V. (North- Holland) .
- 8- M. Centoni, G. Cubadda,(2011); "Modelling Comovements of Economic time series": a selective survey. <https://doi.org/10.6092/issn.1973-2201/3625>
- 9- Miranda, S. ,(2017);" Factor Models ,Bank of England and CFM ,university of Surrey".
- 10- Marco Forti,(2021); Dynamic Factor Models: improvements and applications.
- 11- Mosley,L. , T.chan ,Gibberd, A. ,(2023); "Sparse DFM : An R Package to Estimate Dynamic Factor Models with Sparse Loading " ; Lancaster University , United Kingdom , Arxiv , 23023-14125,V.1 .

12- James H. Stock,(2010); "An Analysis of Core PCE Inflation"; Department of Economics, Harvard University and the National Bureau of Economic Research.

13- Sebastian Krantz,(2023); Dynamic Factor Models A Very Short Introduction.

14- Zhang , Zhiyong , Hamaker ,Ellen L and Nesselorade , John R .,(2008); "Comparisons of Four Method for Estimating a Dynamic Factor Model ", Structural Equation Modeling : A Multidisciplinary Journal , 15 : 3,377-402.
<https://doi.org/10.1080/10705510802154281> .

Best estimator for dynamic factor model (DFM)

Omar Dahir Khamees Asst. prof. Dr. Rawa Saleh Muhammad

Al-Mustansiriya University - College of Administration and Economics

Department of Statistics

rawaaalsaffar@uomustansiriyah.edu.iq omar.khamis@uomustansiriyah.edu.iq

Abstract:

The dynamic factor model (DFM) is characterized by analyzing data dynamically and focuses on explaining the common changes in a set of variables over time. It is suitable for large data that contain many variables and can be used to predict and monitor economic variables. The aim of the research is to reduce time series data that are characterized by a common movement (Co-Movement) over time due to the presence of common factors between them, by using DFM models. The aim of the research is to reach an efficient model, determine the number of common factors, and estimate the parameters of the model (DFM) using the maximum likelihood method. In this research, the dynamic factor model was estimated using the maximum likelihood method, where the simulation results showed, depending on the sample sizes (125, 50, 20) and the correlation coefficients (0.9, 0.5, 0.1), that the best value for the root mean square error (RMSE) is 0.6309 at a sample size of 125 and a correlation coefficient of (0.1). It was noted through the results obtained that the best value for (RMSE) is when the sample sizes are large and the correlation coefficient is small, i.e. the lower the correlation coefficient, the lower the value of the root mean square error (RMSE), i.e. the proportion is direct, and the larger the sample sizes, the lower the values of (RMSE), i.e. the proportion is inverse.

keywords: Dynamic factor, maximum likelihood method, root mean square error, best estimator.

Note: The research is based on a master's thesis.