

التنبؤ ببيانات الاقتصاد الكلي في سورية باستخدام التحليل الهيكلي البيزي الهرمي لنموذج شعاع الانحدار الذاتي

د. خضر العكاري*

د. بشرى علي**

(تاريخ الإيداع 2022 / 10 / 27. قُبل للنشر في 2022 / 12 / 14)

□ ملخص □

يتم تقدير نماذج شعاع الانحدار الذاتي الهيكلي (VARs) على نطاق واسع عندما يتعلق الموضوع ببيانات الاقتصاد الكلي والتنبؤ بها. ومع ذلك، في الأبعاد العالية ينتج عنها مشاكل إفراط في تقدير المعلمات Over fitting، حيث أظهرت الأساليب البيزية من خلال فرض المعلومات الأولية Prior نجاح في تحسين أداء التنبؤ. لذلك يقترح هذا البحث تقنية بيزية هرمية هيكلية لنموذج شعاع الانحدار الذاتي لبيانات الاقتصاد الكلي في سورية، لتخفيف حالة عدم التأكد من جانبيين: جانب إحصائي: الناتجة عن إدراج عدد كبير من المتغيرات في النموذج مع التوافر الزمني المحدود لها، جانب اقتصادي: من خلال توفير تنبؤات أنية لبيانات الاقتصاد الكلي مع التأخر في النشر الرسمي لها مع إمكانية التقييم في ظل سيناريوهات مختلفة. أشارت نتائج التنبؤ داخل العينة إلى أن نموذج VAR الهيكلي البيزي الهرمي يعمل بشكل جيد من حيث الدقة التنبؤية وتوضيح خصائص البيانات المستخدمة في التحليل. كما أظهرت نتائج تقييم التنبؤات خارج العينة تقارباً بين القيم الفعلية والقيم المقدرة لبيانات الاقتصاد الكلي باستخدام النموذج مع سلوكها نفس الاتجاه. يوفر النموذج المقترح من خلال تحليل السيناريو أداة هامة لتخطيط السياسات الاقتصادية من خلال إدراج معلومات جديدة حول المسار المستقبلي لمتغير واحد أو عدة متغيرات ودراسة مدى انعكاسها على باقي المتغيرات.

الكلمات المفتاحية: الأبعاد العالية - إفراط المعلمات - المعلومات الأولية الهرمية - عدم التأكد - تحليل السيناريو.

* دكتوراه في الإحصاء والبرمجة - قسم الإحصاء والبرمجة - كلية الاقتصاد - جامعة تشرين طرطوس- سورية -
khderalakkari1990@gmail.com

** مدرس متمرّن- قسم العلوم المالية والمصرفية - كلية الاقتصاد - جامعة طرطوس - طرطوس- سورية -
BushraAli@tartous.univ.edu.sy

Forecasting Macroeconomic Data in Syria with Hierarchical Bayesian Structural VAR Model

Dr. Khder Al-Akkari*

Dr. Bushra Ali**

(Received 27 / 10/ 2022. Accepted 14 / 12 / 2022)

□ ABSTRACT □

Structural vector auto regressive models (VARs) are widely estimated when it comes to macroeconomic data and forecasting. However, at high dimensions this results in problem of over fitting, whereas Bayesian methods improving the prediction performance. Therefore, this article proposes a structural hierarchical Bayesian VAR model for macroeconomic data in Syria, to mitigate uncertainty from two aspects: a statistical aspect as a result of including a large number of variables in model with their limited time availability, an economic aspect: by providing real time forecasts of macroeconomic data with the delay in its official publication with the possibility of evaluation under different scenarios. The in sample prediction results indicated that BVARs model performs well in terms of predictive accuracy and clarifying properties of data used in analysis. The results of evaluating out of sample forecasts also showed a convergence between actual and forecast values of macroeconomic data using in model, with their behavior in the same trend. The proposed model, through scenario analysis, provides an important tool for planning economic policies by including new information about the future path of one or several variables and studying the extent to which they are reflected on the rest of the variables.

Key word: High dimensions – Over fitting – Hierarchical prior information – Uncertainty – Scenario analysis.

* PhD in Statistics and Programming - Department of Statistics and Programming - Faculty of Economics - Tishreen University – Tartous, Syria. khderalakkari1990@gmail.com

** Assistant Professor, Department of Financial and Banking Sciences - Faculty of Economics - Tartous University – Tartous, Syria. BushraAli@tartous-univ.edu.sy.

1- المقدمة:

تُشير الأدبيات الحديثة إلى أنّ تنبؤات الاقتصاد الكلي تستفيد من المجموعات الكبيرة للبيانات بسبب تعدد الأنماط المؤثرة (Silver, 2012). خاصةً نماذج شعاع الانحدار الذاتي المقترحة من قبل (Sims, 1980) الذي أصبح أدوات لا غنى عنها ضمن أبحاث الاقتصاد الكلي التجريبية (Kilian and Lütkepohl, 2017). بالمقابل يؤدي العدد الكبير من المعلمات المستخدمة في النموذج مع مشكلة التوافر الزمني المحدود لبيانات الاقتصاد الكلي في سورية إلى مشاكل في التقدير الاحتمالي وتحديد المعايير (Over fitting – curse of dimension) والتي يمكن التخفيف منها من خلال استخدام الطرق البيزية Bayesian وفرض بنية هيكلية فعّالة على النموذج وبالتالي تخفيف حالة عدم التأكد عند تقدير المعلمات (Kastner and Huber, 2020) (Giannone et al., 2015).

تُعدُّ مشكلة التأخر الكبير في نشر بيانات الاقتصاد الكلي من قبل المكتب المركزي للإحصاء في سورية أحد أكثر المشاكل التي تواجه القائمين على وضع السياسات النقدية واتخاذ القرارات الاقتصادية الفعّالة، بسبب حالة عدم التأكد الناجمة عن نقص المعلومات، كما أنّ نشر هذه البيانات مع التأخر الكبير يتم بشكل نقطي دون أي إشارة إلى منهجية التقدير ومقدار الخطأ الذي قد يحتويه البيانات. بالإضافة إلى مشكلة التوافر الزمني المحدود للبيانات وبالتالي صعوبة تجنب المشاكل الإحصائية عند إدراج عدد كبير من المتغيرات. وفقاً لذلك، يظهر لدينا التساؤل حول مساهمة استخدام نموذج VAR البيزي الهيكلي الهرمي المقترح في تحسين نمذجة والتنبؤ ببيانات الاقتصاد الكلي في سورية؟ ومع اتساع التطبيقات البيزية في تحسين النمذجة الإحصائية، والحاجة إلى نموذج على مستوى الاقتصاد الكلي في سورية، تأتي أهمية البحث من خلال اقتراح تقنية بيزية هرمية هيكلية لنموذج شعاع الانحدار الذاتي، ومنه إمكانية تجنب المشاكل الإحصائية الناتجة عن إدراج عدد كبير من المتغيرات في النموذج مع التوافر الزمني المحدود لها والتي تتمثل بمشكلة لعنة الأبعاد (Curse of dimension) والإفراط في تقدير المعلمات (Over parameterization) ومنه تحسين جودة الاستدلال ودقة التنبؤ خارج العينة، وإمكانية استخدام النموذج كأداة لتقييم والتنبؤ بمتغيرات الاقتصاد الكلي في سورية. وبالتالي يهدف البحث إلى:

- 1- اقتراح نموذج إحصائي على مستوى الاقتصاد الكلي في سورية.
- 2- فرض بنية هيكلية (Structure) على النموذج ضمن روح النمذجة الهرمية (Hierarchical) لتجنب المشاكل الإحصائية وتخفيف حالة عدم التأكد الإحصائي الناتجة عن التقدير.
- 3- استخدام النموذج المقترح في الاستدلال والتنبؤ ببيانات الاقتصاد الكلي السوري في ظل سيناريوهات مختلفة.
- 4- تخفيف حالة عدم التأكد من الناحية الاقتصادية بسبب النشر النقطي والتأخر في النشر لبيانات الاقتصاد الكلي في سورية (آخر مجموعة إحصائية توضح بيانات عام 2020).

2- مراجعة الدراسات السابقة

1- دراسة (علي وعمر، 2017) بعنوان: استخدام الشبكات العصبية الاصطناعية للتنبؤ في نموذج للاقتصاد الكلي متعدد الأبعاد في العراق للمدة 1996-2007:

هدفت الدراسة إلى تقديم آلية جديدة في تحديد كمية العلاقات بين المتغيرات الاقتصادية، من خلال دراسة أثر الاستثمار على الناتج المحلي الإجمالي، ثم دراسة أثره على كل من الدخل القومي ومعدل نمو متوسط الفرد. تمّ تحقيق

أهداف الدراسة من خلال تصميم شبكة عصبية مناسبة، وتصميم خوارزمية أوتوماتيكية تقوم بتعليم وتدريب الشبكة لتقليل معامل الخطأ إلى أدنى مستوى من خلال ضبط قيمة الأوزان المقابلة.

توصلت الدراسة إلى أنّ الشبكة العصبية هي وسيلة لتحسين الحل والتنبؤ بالنتائج المحلي الإجمالي أو الدخل، من خلال ادخالات متعددة لتقدير الحجم الأمثل. كما تعمل على تخفيض أوزان المدخلات وتنظيمها ضمن ديناميكية معينة لتحسين الإخراج بنسبة كبيرة.

2- دراسة (Forero, 2021) بعنوان:

Forecasting Peruvian Macroeconomic Variables with Bayesian Vector Auto regressions with Time-Varying in the mean

التنبؤ بمتغيرات الاقتصاد الكلي في بيرو باستخدام شعاع الانحدار الذاتي البيزي مع المتوسط المتغير زمنياً

تستخدم هذه الورقة تقنية VAR البيزي بمتوسط متغير بمرور الزمن وتقلب عشوائي، من أجل وضع توقعات تفصيلية لاقتصاد بيرو، النموذج من بدرجة كافية للنظر في التغييرات الهيكلية التي من المحتمل أن تحدث في الاقتصاد. يتم إنشاء التنبؤات بشكل أساسي للمتغيرات مثل التضخم ونمو الناتج المحلي الإجمالي، على الرغم من إمكانية تكييف النموذج ليشمل متغيرات أخرى. تُظهر النتائج ملائمة جيدة للنموذج، وتعيد التأكيد على الفكرة المرتبطة باستخدام استطلاعات التوقعات لتقليل عدم التأكد على المدى الطويل، بينما تعمل المعلمات المتغيرة مع الزمن على تحسين القدرة التنبؤية للنموذج.

3- دراسة (Crump et al., 2020) بعنوان:

A Large Bayesian VAR of the United States Economy:

شعاع الانحدار الذاتي البيزي الكبير لاقتصاد الولايات المتحدة

هدفت هذه الدراسة إلى نمذجة الاقتصاد الكلي والقطاعات المالية في الولايات المتحدة الأمريكية باستخدام نموذج اقتصاد قياسي موحد، من خلال إعدادات التقييد التي فُرضت على النموذج، يوفر نموذج VAR البيزي المقترح إطاراً مرناً لنمذجة 31 متغيراً. يعمل الباحثون على عرض كيفية استخدام النموذج لفهم السمات الرئيسية للبيانات، وبناء سيناريوهات معاكسة، وتقييم بيئة الاقتصاد الكلي بأثر رجعي ومستقبلي. بيّنت نتائج البحث أن تقنية VAR المستخدمة في هذا البحث تنتج تنبؤات موثوقة للتوزيع المشترك لمجموعة كبيرة من مؤشرات الاقتصاد الكلي والمالي التي يراقبها موظفو الاحتياطي الفيدرالي والمتنبؤون المحترفون.

تُسهّم الدراسة الحالية مقارنةً بالدراسات السابقة من خلال التحليل الهيكلي البيزي الهرمي لنموذج شعاع الانحدار الذاتي بالتطبيق على بيانات الاقتصاد الكلي في الجمهورية العربية السورية، وهو ما يُقدم معالجة لمشكلة الفترة الزمنية المحدودة لبيانات الاقتصاد السوري وإدراج عدد أكبر من المتغيرات لأخذ الأنماط المختلفة للبيانات.

3- الحدود المكانية والزمانية للبحث:

تم تطبيق الدراسة على بيانات الاقتصاد الكلي في سورية خلال الفترة الزمنية 1980-2020 وتشمل متغيرات البحث وترميزها كما يُظهر الجدول (1):

جدول 1: متغيرات الاقتصاد الكلي في سورية وترميزها.

المتغير	الناتج المحلي الإجمالي	الاستثمار	التوظيف	الإنتاج الصناعي	الاستهلاك	التضخم
الرمز	GDP	INV	EMP	IPR	CPS	INF

المصدر: إعداد الباحثين.

4- منهجية البحث:

يتبع البحث منهج التحليل الإحصائي لتحقيق هدف البحث، بدءاً من توصيف السلاسل الزمنية لمعدلات نمو متغيرات الاقتصاد الكلي بالاعتماد على الإحصاءات الوصفية والتصوير المرئي للبيانات Visualization ومن ثم تحليل نموذج Bayesian VAR بالاعتماد على نهج النمذجة الهرمية لاختيار المعلومات السابقة Prior وفق خصائص بيانات الاقتصاد الكلي في سورية باستخدام لغة البرمجة الإحصائية R. وفقاً للمنهجية المتبعة في البحث يتضمن سير العمل الخطوات التالية: 1- إطار الاقتصاد القياسي للنموذج، 2- التحليل الاستكشافي 3- إدراج المعلومات السابقة للنموذج، 4- تقدير النموذج، 5- الاستدلال باستخدام النموذج (الصدّات)، 6- التنبؤ وتقييم جودة التنبؤ، 7- تحليل السيناريو.

4-1 إطار الاقتصاد القياسي:

يتم في هذا القسم شرح خصائص النموذج المستخدم في التحليل، حيث نهدف إلى اتباع خطوات إدراج الخصائص البيزية والهرمية والهيكلية لمعالجة مشكلتين إحصائيتين أساسيتين عند إدراج عدد كبير من المتغيرات مع التوافر الزمني المحدود لها وهي:

مشكلة الأبعاد العالية (Curse of Dimension): تعني لعنة الأبعاد أساساً أن الخطأ يزداد مع زيادة عدد الميزات (المتغيرات)، يسمح عدد أكبر من الأبعاد نظرياً بتخزين المزيد من المعلومات، ولكنه نادراً ما يساعد بسبب الاحتمال الأكبر للضوضاء والتكرار في بيانات العالم الحقيقي. قد يؤدي جمع عدد كبير من البيانات إلى مشكلة الأبعاد حيث يمكن الحصول على أبعاد شديدة الضوضاء مع عدد أقل من المعلومات وبدون فائدة كبيرة بسبب البيانات الكبيرة. تنصدر الطبيعة المتفجرة للحجم المكاني سبب لعنة الأبعاد. تنتج صعوبة تحليل البيانات عالية الأبعاد من اقتران تأثيرين:

- تتميز المساحات عالية الأبعاد بخصائص هندسية غير بديهية وبعيدة عن الخصائص التي يمكن ملاحظتها في المساحات ثنائية أو ثلاثية الأبعاد.

- غالباً ما يتم تصميم أدوات تحليل البيانات مع مراعاة الخصائص والأمثلة المعروفة في المساحات منخفضة الأبعاد، وعادةً ما يتم توضيح أدوات تحليل البيانات بشكل أفضل في المسافات ثنائية أو ثلاثية الأبعاد. تكمن الصعوبة

في أن هذه الأدوات تُستخدم أيضاً عندما تكون البيانات عالية الأبعاد وأكثر تعقيداً، وبالتالي هناك احتمال لفقد حدس سلوك الأداة وبالتالي استخلاص استنتاجات غير صحيحة.

تحدث لعنة الأبعاد عندما يزداد التعقيد بسرعة وهو ناتج عن العدد المتزايد من التوليفات الممكنة من المدخلات. أي ارتفاع عدد المجاهيل (المعلمات) مقارنة بعدد المشاهدات، يفرض m تدل على البعد، فإن مصفوفة التباين المشترك المقابلة لديها $m(m+1)/2$ درجة حرية، وهو مصطلح تربيعي في m (Kastner et al, 2017). مما يؤدي إلى مشكلة الأبعاد العالية. وفقاً لذلك نهدف من خلال فرض بنية هيكلية من خلال المعلومات الأولية للتحليل البيزي إلى تقليل الأبعاد وتحويل المتغيرات عالية الأبعاد إلى متغيرات ذات أبعاد أقل دون تغيير المعلومات المحددة للمتغيرات. بحيث يتم تقليل الأبعاد لتقليل مساحة الميزة مع مراعاة مجموعة من الميزات الرئيسية.

مشكلة تقدير المعلمات (Over Parametezation): تكاملاً مع مشكلة الأبعاد العالية، تُعرف هذه المشكلة إحصائياً على أنها إضافة معلمات زائدة عن الحاجة، والتأثير هو تقدير مصفوفة تباين مشترك واحدة (Singular Matrix) لا يمكن عكسها (مقلوب المصفوفة) (Simon and Jason, 2018). هذه المشكلة خطيرة لطرق التقدير والمعايرة الإحصائية التي تتطلب مقلوب المصفوفة. حيث يبدأ النموذج بملاءمة الضوضاء مع بيانات ومعلمات التقدير أي درجة ارتباط مرتفعة في مصفوفة الارتباط المشترك للبواقي، وبالتالي إنتاج تنبؤات مع أخطاء كبيرة خارج العينة، بمعنى آخر تزداد حالة عدم التأكد في تقديرات المعلمات والأخطاء وتصبح غير قابلة للتفسير أو بعيدة عن التقدير الواقعي. تتم معالجة هذه المشكلة من خلال فرض بنية هيكلية على النموذج وبالتالي تحويله إلى نموذج مختصر Parsimony وبالتالي فرض قيود تسمح بالتفسير الاقتصادي الصحيح للمتغيرات (identification restrictions) تقلل من عدد المعلمات غير المعروفة للنموذج الهيكلي وتؤدي إلى إجراء تعديل لمصفوفة الارتباط المشترك للبواقي بحيث تصبح غير مرتبطة مع بعضها، وبمعنى آخر تصبح مصفوفة قطرية (diagonal matrix) (خليل، 2020).

4-2 خصائص النموذج:

أصبحت نماذج VAR التي وضعها (Sims, 1980) عنصراً أساسياً في أبحاث الاقتصاد الكلي التجريبية، وتعد هذه النماذج كتعميم لنماذج الانحدار الذاتي (AR)، تستخدم نماذج الانحدار الذاتي كأدوات لدراسة الصدمات الاقتصادية، حيث تستند إلى مفهوم السلوك الديناميكي بين قيم التأخر المختلفة (lagged) لجميع المتغيرات في النموذج. نموذج VAR من الرتبة (p) يُشار إليه بنموذج VAR_p ويمكن التعبير عنه على النحو التالي:

$$y_t = C + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \epsilon_t \quad \epsilon_t \sim (0, \Sigma) \quad (1)$$

حيث y_t هو متجه $1 \times K$ للمتغيرات الداخلية endogenous variables، β_p : مصفوفة المعاملات المقابلة لتأخر محدد lag في y_t ، ϵ_t : حد الخطأ العشوائي مع توقع 0 يمثل الصدمات الخارجية، Σ : مصفوفة تباين - تباين مشترك. عدد المعلمات المستهدف تقديرها $K + K^2 p$ ، حيث يرتفع تربيعياً مع عدد المتغيرات المراد تضمينها وخطياً بترتيب التأخر. غالباً ما تؤدي هذه المعلمات الكثيفة إلى عدم الدقة فيما يتعلق بالتنبؤ خارج العينة، والاستدلال الهيكلي خاصة بالنسبة للنماذج عالية الأبعاد. يشار إلى هذه الظاهرة عادةً باسم لعنة الأبعاد ومشاكل في تقدير المعلمات (Koop and Korobilis 2010). يعالج النهج البيزي لتقدير نموذج VAR هذه المشاكل من خلال فرض بنية إضافية Structure على النموذج، تسمح المعلومات السابقة المترافقة للاستدلال البيزي بحل هذه المشاكل (Alakkari et al., 2022) (العكاري، 2022) والسماح بتقدير النماذج الكبيرة (Banbura et al., 2010) حيث تدفع معلمات

النموذج نحو معيار مختصر Parsimony، وتحسين دقة التنبؤ خارج العينة (Alakkari and Ali, 2022) (Koop, 2013). هذا النوع من الانكماش يرتبط بمقاربات التنظيم المتكررة (De frequentist regularization mol et al., 2008). يتيح لنا التحليل البيزي استيعاب مجموعة واسعة من القضايا الاقتصادية من خلال إضافة المعلومات الأولية بشكل طبيعي، ويمكن أن تفسر طبقات عدم التأكد Uncertainty من خلال النمذجة الهرمية (Gelman et al., 2013).

3-4 المعلومات الأولية:

الشرط الأساسي لبدء أي عملية تحليل وفق المنهج البيزي تحتاج إلى إدراج معلومات أولية، ويُعدّ تحديدها بشكل صحيح بالغ الأهمية، والدراسات التي تحاول عدم فرض معلومات سابقة تؤدي إلى تقديرات غير مقبولة وإلى استدلال ضعيف (Banbura et al., 2010). تُعدّ النظرية الاقتصادية مصدراً مفصلاً للمعلومات السابقة، ولكنها تفتقر إلى العديد من الإعدادات وخاصةً في النماذج عالية الأبعاد. بسبب ذلك، قام (Villani, 2009) بإعادة صياغة النموذج ووضع المعلومات على حالة مستقرة، والتي غالباً ما تركز عليها النظرية الاقتصادية والتي فهمها الاقتصاديون بشكل أفضل. تم اقتراح تحديد المعلمات الأولية للنموذج بطريقة قائمة على البيانات، أي بمعالجتها كمعاملات إضافية يتم تقديرها (Giannone et al, 2015). وفق النهج الهرمي يتم تعيين المعلمات السابقة Hyperpriors، حيث يمكن التعبير عن ذلك من خلال قانون بيز التالي:

$$\begin{aligned} p(\gamma|y) &= p(\gamma|\theta, \gamma)p(\theta|\gamma)p(\gamma) \\ p(\gamma|\gamma) &= \int p(\gamma|\theta, \gamma)p(\theta|\gamma)d\theta \end{aligned} \quad (2)$$

حيث $y = (y_{p+1} + \dots + y_T)^T$. معاملات الانحدار الذاتي والتباين لنموذج VAR يشار إليها ب θ . والمعلمات الفائقة (معلمات التوزيع الأولي) ب γ . يتم تهميش الجزء الأول من المعادلة الأولى فيما يتعلق بالمعلمات θ في المعادلة الثانية، ينتج عن ذلك كثافة للبيانات كدالة للمعلمات الفائقة. وتسمى أيضاً الاحتمال الهامشي (ML). يتم دمج الاحتمال الهامشي (ML) للنموذج واستخدامه كمعيار قرار لاستكشاف خصائص المعلمة. يُظهر (Giannone et al, 2015) عبر الأمثلة التجريبية، دقة هذا النهج في تقدير وظائف الاستجابة النبضية. وأن دقة الأداء والتنبؤ في هذه النماذج تتفوق على نماذج VAR القياسية.

تُعدّ التوزيعات الأولية (Gaussian Inverse Wishart) الأكثر استخداماً:

$$\begin{aligned} \beta/\Sigma &\sim N(b, \Sigma \otimes \Omega) \\ \Sigma &\sim IW(\Psi, d) \end{aligned} \quad (3)$$

حيث b, Ω, Ψ, d هي دالة منته منفض الأبعاد للمعلمات الفائقة (Hyper parameters) γ . بسبب اقتران المعادلتين السابقتين يمكن حساب (ML) للنموذج بكفاءة وذلك كدالة (γ). يقدم (Giannone et al, 2015) ثلاثة تصاميم رئيسية للمعلومات الأولية، تُسمى ب Minnesota Litterman Prior، والتي يتم استخدامها كأساس، مجموع المعلمات الأولية (Litterman, 1980) وجذر الوحدة الواحدة (Single unit root prior) (Sims, 1993). المعلومات الأولية السابقة، تفترض بشكل أساسي أن المتغيرات الاقتصادية تتبع جميعاً عملية السير العشوائي (Random walk)، تؤدي هذه المواصفات إلى أداء جيد في توقع السلاسل الزمنية الاقتصادية. وغالباً ما تُستخدم كمعيار للدقة، وهي تتبع العزوم التالية:

$$\mathbb{E}[(A_s)_{ij}|\Sigma] = \begin{cases} 1 & \text{if } i = j \text{ and } s = 1 \\ 0 & \text{if otherwise} \end{cases}$$

$$\text{cov}((A_s)_{IJ}, (A_r)_{kl}|\Sigma) = \begin{cases} \lambda^2 \frac{1}{s^\alpha} \frac{\Sigma_{ik}}{\psi_j / (d - M - 1)} & \text{if } l = j \text{ and } r = s \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

المعلمة الرئيسية هي λ والتي تتحكم بمقدار تأثير التوزيع الأولي، أي أنها تزن الأهمية النسبية للبيانات الأولية، فعندما $\lambda \rightarrow 0$ يتم فرض التوزيع الأولي تماماً، وفي حال $\lambda \rightarrow \infty$ سوف يقترب تقدير التوزيعات اللاحقة من تقديرات المربعات الصغرى العادية (OLS). يتم من خلال α التحكم في تخفيف تأثير المشاهدات المتطرفة (Break)، ويستخدم ψ للتحكم في الانحراف المعياري الأولي عند استخدام فترات التأخير (lags).

يتم تنفيذ توزيعات Minnesota السابقة، وذلك بهدف تقليل أهمية المكون الحتمي الذي تتطوي عليه نماذج VAR المقدرة للتكيف مع الملاحظات السابقة. وهي منهجية تعتمد على التحليل العشوائي لتقييم الأنظمة في ظل سيناريوهات غير حتمية (عشوائية) عندما تكون الحلول التحليلية معقدة (Giannone et al, 2015)، حيث تقوم هذه الطريقة على سحب عينات من المتغيرات المستقلة عن طريق توليد أرقام عشوائية وهمية. أولها، مجموعة المعاملات السابقة (SOC) Sum-of-coefficients (Doan et al., 1984)، والذي يفرض فكرة أن التنبؤ بعدم التغيير في بداية السلسلة الزمنية هو الأمثل. يتم تنفيذه هنا عبر تقدير Theil mixed عن طريق إضافة ملاحظات وهمية فوق مصفوفة البيانات، والتي يتم انشاؤها على النحو التالي:

$$y_{M \times M}^+ = \text{diag} \left(\frac{\bar{y}}{\mu} \right)$$

$$x_{M \times (1+Mp)}^+ = [0, y^+, \dots, y^+] \quad (5)$$

حيث \bar{y} هي $M \times 1$ متجه من المتوسطات فوق أول p مشاهدة من كل متغير، تُستخدم المعلمة الرئيسية μ للتحكم في التباين وبالتالي في تأثير المعلومات السابقة. فعندما $\mu \rightarrow \infty$ تصبح المعلومات السابقة غير مهمة uninformative، وعندما $\mu \rightarrow 0$ يتم تشكيل النموذج نحو صيغة تتكون من عدد كبير من جذور الوحدة كمتغيرات وبدون تكامل مشترك. وهو ما يتطلب استخدام جذر الوحدة المفردة السابق (Sims Single-Unit-Root (SUR) (Sims and Zha, 1998)، مما يسمح بعلاقات التكامل المشترك في البيانات. التوزيعات السابقة تدفع المتغيرات نحو المتوسط غير المشروط أو نحو وجود جذر وحدة واحد على الأقل. تكون الملاحظات الوهمية المرتبطة بها:

$$y_{1 \times M}^{++} = \frac{\bar{y}}{\delta}$$

$$x_{1 \times (1+MP)}^{++} = \left[\frac{1}{\delta}, y^{++}, \dots, y^{++} \right] \quad (6)$$

حيث \bar{y} هي $M \times 1$ متجه من المتوسطات فوق أول p مشاهدة من كل متغير، تُستخدم المعلمة الرئيسية δ للتحكم في التباين وبالتالي في تأثير المعلومات السابقة. نلاحظ من منظور الاستدلال البيزي، أن اختيار المعلمات بهذه الطريقة ملائم من الناحية المفاهيمية للاستدلال على أي معلمة في النموذج. وبالتالي من الممكن التعامل مع النموذج على أنه نموذج هرمي، مع احتمال هامشي للبيانات، في ضوء المعلمات الأولية المتوفرة بشكل مغلق لنماذج VAR مع توزيعات مترافقة conjugate priors، تقدير هذه المعلمات الفائقة hyperparameters يتم من خلال تعظيم

ML (هي طريقة بيز التجريبي Empirical Bayes (المعادلة 6) مع تفسير تكراري واضح (Giannone et al, 2015).

4-4 دالة الاستجابة النبضية:

تُعد دالة الاستجابة النبضية، غير خطية للمعاملات في نموذج VAR، الهدف الرئيسي منها هو وصف تطور متغيرات النموذج كرد فعل لصدمة في متغير واحد أو أكثر. تسمح هذه الميزة بتتبع انتقال صدمة واحدة داخل نظام معادلات يحوي ضوضاء كبيرة (Noisy)، وبالتالي تجعلها أداة مفيدة للغاية في تقييم السياسات الاقتصادية.

وفقاً لذلك، التطبيق الرئيسي لنماذج Bayesian VAR هو التحليل الهيكلي (Structural Analysis) للأنظمة الاقتصادية، باستخدام دالة الاستجابة النبضية. هذه الدوال بمثابة تمثيل للصدمة التي تضرب النظام الاقتصادي وتستخدم لتحليل رد فعل متغيرات النموذج. يتم تقدير BVAR بشكل مختزل، أي بدون علاقة لحظية (contemporaneous) بين المتغيرات الداخلية في النظام. بينما يلخص النموذج البيانات، لسنا قادرين على تحديد كيفية تأثير المتغيرات على بعضها البعض لأنّ البواقي المختزلة ليست متعامدة (orthogonal). يتطلب استعادة المعاملات الهيكلية وتحديد الانتشار الدقيق للصدمة قيوداً تسمح بالتفسير الاقتصادي الصحيح للنموذج (identification restrictions) تقلل من عدد المعاملات غير المعروفة للنموذج الهيكلي وتؤدي إلى إجراء تعديل لمصفوفة الارتباط المشترك للبواقي بحيث تصبح غير مرتبطة مع بعضها، وبمعنى آخر تصبح مصفوفة قطرية (diagonal matrix) (خليل، 2020). يضم BVAR نوعين من القيود الأكثر استخداماً: short term zero restriction) والذي يُعرف أيضاً باسم التحديد العودي (recursive identification) ويتم تحقيقه من خلال تحليل Cholesky لمصفوفة التباين والتباين المشترك للبواقي Σ (Higham, 1999)، لا يتطلب هذا التحليل أي افتراضات قائمة على النظرية حول سلوك المتغير، لكن يُعد هذا التحليل مقبولاً فقط بالنظر إلى سلسلة واضحة من السببية. في تطبيقات الاقتصاد من الصعب تفسير ذلك، لا سيما بالنظر إلى تواتر البيانات حيث أنه وحسب مفهوم (Sims, 1990) للسببية يدرس وجود علاقة سببية باتجاه واحد مع الأخذ بعين الاعتبار لأكثر من متغير آخر في النموذج (خليل، 2020). النوع الثاني قيود الإشارة (sign restrictions) يعود هذا النهج إلى (Uhlig, 2005)، ضمن هذا النهج هناك حاجة لتحديد بعض الافتراضات حول سلوك المتغير بعد صدمة معينة، بالمقابل لا يتطلب تحديد متسلسل للسببية ضمن النموذج. حيث تستجيب جميع المتغيرات للصدمة في وقت واحد.

نفترض لدينا نموذج VAR (1) وفق المعادلة:

$$y_t = \beta_0 y_t + \beta_1 y_{t-1} + \epsilon_t \quad (7)$$

حيث β_0 توضح الارتباطات المتزامنة contemporaneous، β_1 مصفوفة المعاملات عند درجة تأخر (1)، وذكرنا أنّ ϵ حدّ الخطأ العشوائي (White noise) وأنّ $\epsilon \sim N(0,1)$ و $\sum \epsilon = E(\epsilon_t \epsilon_t') = I$ ، لتقدير المعادلة السابقة نحتاج للاستغناء عن العلاقات المتزامنة بين المتغيرات الداخلية y_t حيث نقوم بنقلها للطرف الآخر:

$$\begin{aligned} (I - \beta_0)y_t &= A_1 y_{t-1} + \epsilon_t \\ B_0^* &= I - \beta_0 \text{ حيث } B_0^* y_t = A_1 y_{t-1} + \epsilon_t \\ y_t &= B_0^{*-1} A_0 y_{t-1} + B_0^{*-1} \epsilon_t \end{aligned} \quad (8)$$

الآن يمكن تقدير نموذج VAR (1) بشكل مختصر:

$$y_t = A_1 y_{t-1} + u_t \quad (9)$$

حيث أن A_1 هي معاملات الشكل المختزل، u_t : تمثل المتوسطات المرجحة للمعاملات الهيكلية β_1 و ϵ_t ، حيث أن $A_1 = B_0^{*-1} A_t$ و $u_t = B_0^{*-1} \epsilon_t$ ، حيث u_t سلسلة غير مرتبطة وخارجية، مصفوفة التباين والتباين المشترك $\sum u$ ليست مصفوفة قطرية، وبالتالي تفقر الأحداث (u_t innovation) إلى تفسير هيكلي حيث أنه ومن حيث المبدأ ليس لها أي تفسير اقتصادي لأن عناصر u_t لا تزال مترابطة عبر المعادلات. تقترح النظرية الاقتصادية أن أخطاء التنبؤ المتأخرة بخطوة واحدة لنموذج VAR المختزل reduced تأخذ الدالة التالية:

$$\sum_u = E(u_t u_t') = B_0^{*-1} E(\epsilon_t \epsilon_t') B_0^{*-1'} = B_0^{*-1} B_0^{*-1'} \quad \text{and} \quad \sum_\epsilon = I$$

لاسترداد المعلمات الهيكلية، نحتاج إلى معلومات إضافية حول العلاقات الآنية (B_0^* contemporaneous) نحتاج لتحقيق $n(n-1)/2$ قيود لتحديد المعلمات الهيكلية بدقة B_0^* ، β_1 و ϵ_t . كما ذكرنا إما أن يتم تحديد المعلمات الهيكلية باستخدام تحليل Cholesky لمصفوفة التباين - التباين المشترك \sum_u ، أو قيود محددة طويلة أو قصيرة الأجل حسب النظرية الاقتصادية (Sims et al., 1998).

بسبب العدد الكبير من المتغيرات فإن استخدام قيود الإشارة بنطوي على العديد من المصاعب (نحتاج إلى ادخال مصفوفة من 36 إشارة وهو صعب مع عدم توفر المعلومات لإدخالها بشكل رئيسي)، لذلك يتم استخدام تحليل Cholesky وهو ما يقودنا إلى فرض هيكل عودي Recursive لحل مشكلة identification، لنفرض بأنه وبحسب معادلة VAR السابقة نقوم بإدخال المتغيرات y, x, z على الترتيب:

$$\begin{pmatrix} y_t \\ x_t \\ z_t \end{pmatrix} = \begin{pmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \\ b_{31} & b_{32} & b_{33} \end{pmatrix} \begin{pmatrix} y_{t-1} \\ x_{t-1} \\ z_{t-1} \end{pmatrix} + \begin{pmatrix} a_{11} & 0 & 0 \\ a_{21} & a_{22} & 0 \\ a_{13} & a_{23} & a_{33} \end{pmatrix} \begin{pmatrix} \epsilon_{yt} \\ \epsilon_{xt} \\ \epsilon_{zt} \end{pmatrix} \quad (10)$$

من الواضح بأنه لدينا 6 معادلات و 9 معالم مجهولة وبالتالي يتم تعيين 3 عناصر من المصفوفة A إلى الصفر ليصبح لدينا 6 معادلات و 6 معالم مجهولة مما يسمح بتقدير النموذج. وفي هذه الحالة عند دراسة الصدمات فإن ترتيب المتغيرات له أهمية كبيرة، من خلال كتابة المعادلة السابقة بالشكل:

$$\begin{aligned} y_t &= \dots + a_{11} \epsilon_{yt} \\ x_t &= \dots + a_{21} \epsilon_{yt} + a_{22} \epsilon_{xt} \\ z_t &= \dots + a_{31} \epsilon_{yt} + a_{32} \epsilon_{xt} + a_{33} \epsilon_{zt} \end{aligned} \quad (11)$$

وبالتالي يتتبع مسار الصدمات نجد أن:

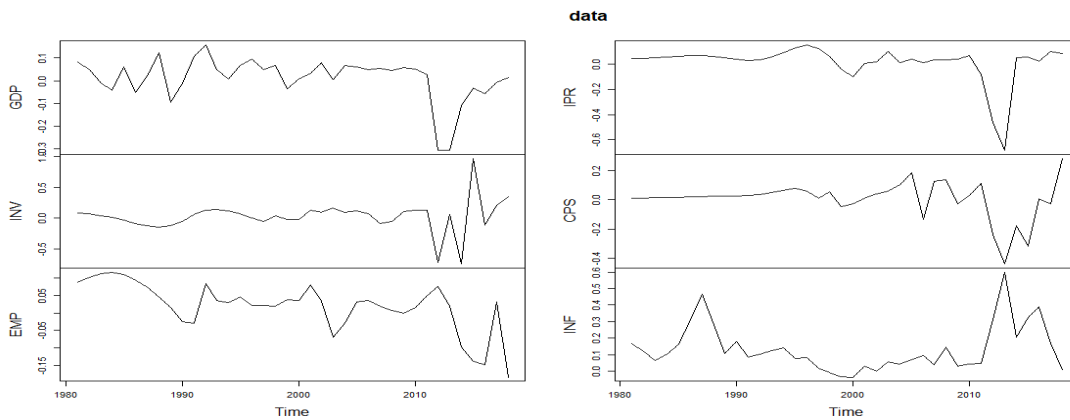
ϵ_{yt} : يؤثر أنياً contemporaneously في جميع المتغيرات.

ϵ_{xt} : يؤثر أنياً في كل من x_t و z_t ولا يؤثر في y_t .

ϵ_{zt} : يؤثر أنياً فقط في z_t ولا يؤثر في y_t و x_t . ومنه نجد أن المتغير في الأعلى هو الأكثر خارجية exogenous (أي أنه يسبب صدمة ذاتية فقط).

5- نتائج البحث ومناقشتها:

الهدف من التطبيق التجريبي هو التنبؤ ببيانات الاقتصاد الكلي في سورية المستمدة من المكتب المركزي للإحصاء، والممتدة خلال الفترة السنوية 1980-2020، نستخدم بيانات الفترة 1980-2018 للتدريب (Training) وآخر سنتين لاختبار مدى كفاءة النموذج في التنبؤ خارج العينة. تُستخدم معدلات النمو في هذه الحالة أو تسمى \log بدلاً من الأسعار نظراً لخصائصها الإحصائية. تُسمى هذه الخصائص حقائق مجردة (Stylized facts): أولاً: لا تتبع توزيع طبيعي، ففي معظم الحالات ينحرف التوزيع إلى اليسار ويتفرطح مرتفع أي لها قمة عالية (Mandelbrot, 1963) وذيول ثقيلة (Fama, 1965). ثانياً: لها خاصية الاستقرار (Stationary) ولا يوجد تقريباً ارتباط بين السنوات المختلفة. يتوضح من الرسم البياني تطور معدلات نمو متغيرات الاقتصاد الكلي في سورية خلال الفترة السنوية 2018-1980:



الشكل 1: تطور معدلات نمو متغيرات الاقتصاد الكلي في سورية خلال الفترة المدروسة.

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R وبيانات المكتب المركزي للإحصاء.

يبين الشكل (1) تطور نمو متغيرات الاقتصاد الكلي، نلاحظ عدم وجود اتجاه عشوائي يمثل تطور هذه المتغيرات، وبالتالي استقرار هذه المتغيرات حول ثابت (Constant)، مع ملاحظة عدم وجود ثبات في تباين المتغيرات بسبب اختلاف التقلب تبعاً لفترات زمنية مختلفة، حيث نلاحظ وجود ارتفاع متوسط في تقلب المتغيرات قبل عام 2000، وذلك كون الاقتصاد السوري ما زال معتمداً على الصناعات الاستخراجية وعلى الزراعة بالدرجة الأولى وهو ما يجعل حالة عدم التأكد كبيرة للمتغيرات، الفترة الثانية تمتد بين عامي 2000-2010 ونلاحظ أنها فترة أكثر استقراراً مع توسع الصناعات والقطاعات الإنتاجية والمدن الصناعية مما أدى إلى متغيرات أقل تقلباً، ثم نلاحظ المرحلة الممتدة بعد عام 2010 والتي ترتفع فيها تقلبات معدلات نمو المتغيرات نتيجة تغير الأوضاع الاقتصادية بسبب الحرب في سورية وحالة عدم التأكد الكبيرة في الاقتصاد التي رافقتها (Alakkari, 2022) ونلاحظ وجود القيم المتطرفة بشدة، والتي تظهر من خلال عرض الإحصاءات الوصفية والتي تُبين مدى ابتعاد توزيع هذه البيانات عن التوزيع الطبيعي بالاعتماد على اختبار Jarque – Bera:

$$Jarque - Bera = \frac{n}{6} \left(S^2 + \frac{1}{4} (K - 3)^2 \right) \quad (12)$$

حيث n : عدد المشاهدات، S : الالتواء، K : التفرطح. من خلال الجدول (2) نحصل على النتائج التالية:

جدول 2: الإحصاءات الوصفية والتوزيع الطبيعي لبيانات الاقتصاد الكلي في سورية.

Variables	Normality J-B	Mean	Standard Deviation	Maximum	Minimum	Skewness	Kurtosis
GDP	34.15***	1.65	8.73	17.09	-26.33	-1.57	6.32
INV	487.1***	6.21	30.8	163.4	-52.82	-3.21	19.1
EMP	8.433***	2.43	6.92	12.51	-16.48	-1.04	3.92
IPR	227.1***	2.73	11.9	16.45	-49.41	-3.08	13.08
CPS	15.32***	1.54	11.91	32.92	-35.47	-0.81	5.61
INF	44.81***	15.76	17.95	82.35	-3.57	1.86	6.69

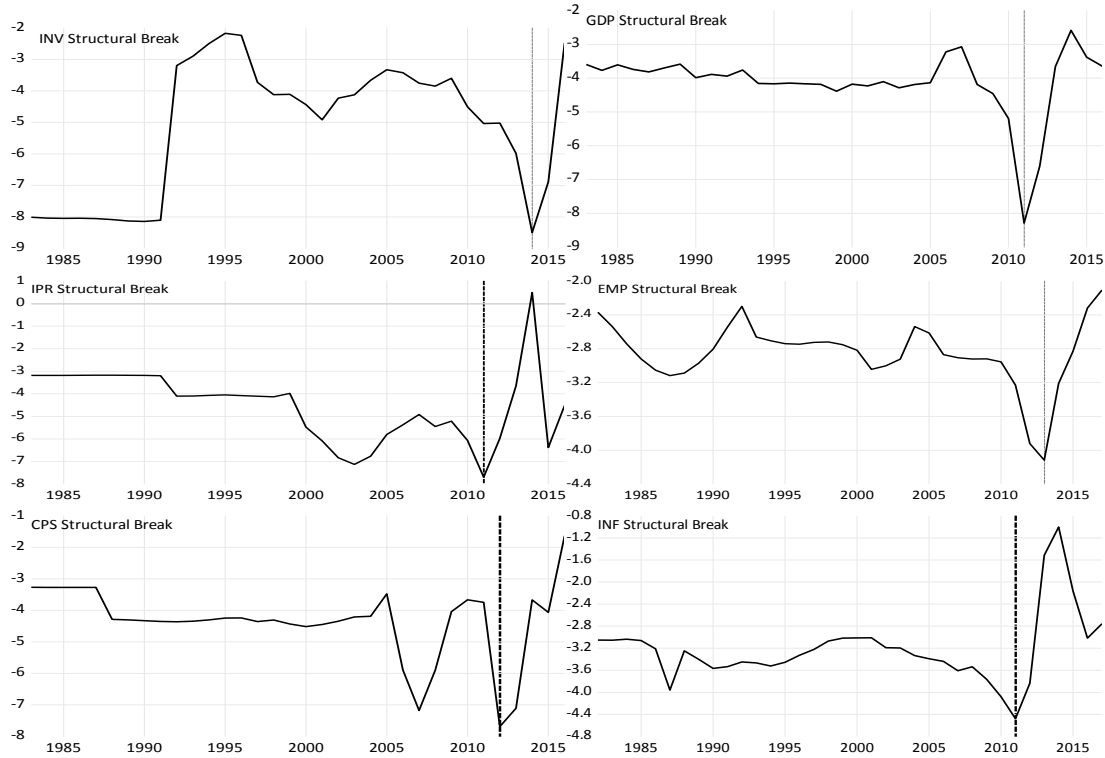
المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

تشير *** إلى معنوية القيمة الإحصائية عند 1%. ** عند 5%. * عند 10%.

يبين الجدول (2) أنّ القيمة الاحتمالية لإحصائية اختبار التوزيع الطبيعي معنوية عند 1%، وبالتالي نستنتج أنّ بيانات معدلات نمو الاقتصاد الكلي لا تتوزع وفق التوزيع الطبيعي، حيث أنّ كل من المتوسط والانحراف المعياري هي غير صالحة للتوقع في هذه الحالة لأنهما أصبحا نقطتان انهيار (Break Down Point). كما نلاحظ من الجدول (2) القيمة السلبية لمعامل الالتواء لجميع المتغيرات (ما عدا معدل التضخم) وبالتالي تأثر معدلات نمو متغيرات الاقتصاد الكلي بالصدمات السلبية والتواء التوزيع نحو اليسار. كما نجد أنّ قيمة معامل التفرطح مرتفعة (أكبر من 3 لجميع المتغيرات) مما يشير إلى تدبب قمة التوزيع من نوع (Leptokurtic). كما نلاحظ أنّ أكبر فرق بين أكبر وأصغر قيمة للمتغيرات هو لمعدل الاستثمار مما يدل على النقلب الكبير فيه بسبب انخفاض ثقة المستثمرين مع ارتفاع حالة عدم التأكد بعد بداية الحرب في سورية (العكاري، 2022). من الخصائص الرئيسية لمعدلات النمو أيضاً هي أنها مستقرة (أي لا تحتوي جذر الوحدة)، وبما أنّ التغيرات الهيكلية تؤثر على التوقعات، وكما لاحظنا من خلال الشكل (1) وجود تحول في مسار المتغيرات بعد بداية الحرب في سورية، فنستخدم اختبار جذر الوحدة الهيكلية (Breakpoint Unit Root) المقترح من قبل (Perron and Pierre, 2006) (Perron and Vogelsang, 1992)، حيث نفترض أنّ التغيرات الهيكلية تتبع مسار الأحداث Innovation، ونختبر نقاط التغير الهيكلية وفقاً للمعادلة التالية:

$$y_t = c + at + \theta DU_t(T_b) + \gamma DT_t(T_b) + \omega D_t(T_b) + \delta y_{t-1} + \sum_{i=1}^p \varphi_i \Delta y_{t-i} + \varepsilon_t \quad (13)$$

حيث $\alpha, \theta, \gamma, \omega$ هي معاملات الاتجاه والتغيرات الهيكلية، DU_t, DT_t, D_t هي متغيرات وهمية تعبر عن التغيرات الهيكلية على مستوى الاتجاه والقاطع، c : القاطع، p : درجة التأخير لنموذج الانحدار الذاتي وفق المعادلة (2). يتم إجراء الاختبار وفقاً للفرضية العدم $\delta = 0$ (غير مستقرة بدون أو مع تغير هيكلية)، والفرضية البديلة $\delta < 0$ (مستقرة بدون أو مع تغير هيكلية)، ونحصل على النتائج التالية:



الشكل 2: نقاط التغير الهيكلي لمعدلات نمو متغيرات الاقتصاد الكلي في سورية خلال الفترة المدروسة.
المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R وبيانات المكتب المركزي للإحصاء.

يشير الفاصل الهيكلي إلى حدوث تحول في سلوك متغير بمرور الزمن، مما يؤدي إلى تحول الروابط بين المتغيرات. يبين الشكل (2) أن جميع متغيرات الاقتصاد الكلي تعرضت لتغيرهيكلي ولكن بأشكال مختلفة وأوقات مختلفة ولو أنها تدل على التأثير من نفس الحدث وهو الحرب في سورية والحصار الاقتصادي من الدول العربية والغربية الناتج عنها حيث أن جميع الفواصل الهيكلية حدثت بعد عام 2011، نلاحظ وأنه بالنسبة لمعدل النمو الاقتصادي ومعدل نمو الإنتاج الصناعي فقد أظهر تأثيراً سريعاً بسبب المكونات والأنماط العديدة الداخلة في حسابهم، وكذلك معدل التضخم بسبب حساسية التغير فيه للأحداث، نلاحظ أنه وبالنسبة لمعدل الاستثمار والاستهلاك والتوظيف فقد ظهرت التغيرات الهيكلية خلال أعوام 2014 - 2012 - 2014 على التوالي، إن التغيرات الهيكلية أدت إلى تغيرات في الموقع Location Shifts (على مستوى المتوسط) وفي الانحراف Drift (على مستوى التباين) حيث أصبحت المتغيرات أكثر تقلباً بعد التغير الهيكلي، يؤدي ذلك إلى تحول في العلاقات بين المتغيرات وبالتالي تغير في طرق التقدير وهو ما يمكن أخذه بعين الاعتبار في نموذج التقدير من خلال المعلومات الأولية Prior.

5-1 إدراج المعلومات الأولية:

استناداً إلى نتائج التحليل الاستكشافي، يتم تنفيذ توزيعات Minnesota السابقة كخط أساس وتضمن المعلمة الرئيسية λ في النمذجة الهرمية، ونستخدم الدالة $bv_minnesota()$ ضمن لغة البرمجة الإحصائية* لتحديد التوزيعات السابقة للمعلمات λ و α وتحديد القيم العليا والدنيا للقيم المقترحة. تمثل المعلومات الأولية توزيعات غاما

* جميع الأكواد مدرجة في الملحق (1).

(Giannone et al, 2015) ويتم استخدام قيم الحدود لتجاهل القيم غير المعقولة أو المستحيلة (المتطرفة بشدة)، المستمدة من مقترح توزيع غاوسي والمستخدم في خطوة Metropolis-Hastings. تحدد الوسيطة var التباين الأولي للثابت في النموذج ويتم تعيينها لتكون منتشرة (أي بقيمة كبيرة) وذلك نتيجة التغيرات الكبيرة والفرق بين أكبر وأصغر قيمة لمتغيرات البحث كما تبيّن من خلال التحليل الاستكشافي، يتم ضبط Ψ تلقائياً على الجذر التربيعي لتباين الأحداث (البواقي) innovations بعد تقدير نماذج AR(p) للمتغيرات وذلك بسبب التغيرات الهيكلية التي تُظهر تغيراً في التباين بعد عام 2011 في التحليل الاستكشافي. تتضمن توزيعات Minnesota أيضاً تحديد المعلومات الأولية الوهمية لتقليل أهمية المكون الحتمي deterministic component: مجموع المعاملات الأولية SOC وذلك لفرض فكرة أن التنبؤ بعدم التغيير هو الأمثل في بداية سلسلة زمنية، حيث لاحظنا فترة استقرار نوعاً ما بين المتغيرات قبل عام 2011 مع عدم وجود تغيرات هيكلية على مستوى الموقع أو الانحراف. كما يتم فرض جذر الوحدة الواحدة SUR مما يسمح بعلاقات التكامل المشترك بين المتغيرات. يُفترض أن تكون المعلمات الأولية أيضاً تتبع توزيع غاما وأنّ الإعدادات المحددة تعمل بنفس طريقة عملها مع α و λ . يتم تنفيذ هذه المعلومات من خلال تقدير Theil mixed وذلك بإضافة مشاهدات وهمية أعلى مصفوفة البيانات.

الخطوة الأخيرة قبل تقدير النموذج تتضمن ضبط اعدادات خوارزمية MH، وذلك بهدف استكشاف التوزيعات اللاحقة Posterior لمعاملات النموذج بشكل صحيح، يتم ذلك من خلال دالة لغة البرمجة الإحصائية $bv_metropolis^*$ التي تعمل مع الوسيطة الأساسية $scale_hess$ وهي مقياس يعطينا معلومات عن تباين المعلمات inverse Hessian ويستخدم لرسم مقترحات للمعاملات المعالجة بشكل هرمي. ويمكن استكمالها من خلال ضبط $djust_acc = TRUE$ مما يتيح ضبط المقياس تلقائياً خلال فترة تكوين التوزيع والوصول إلى معدل سحب مقبول بين القيم المحددة في مدخلات لغة البرمجة الإحصائية acc_lower و acc_upper .

5-2 تقدير النموذج:

بعد تحضير البيانات وضبط الاعدادات يصبح النموذج جاهزاً للتقدير من خلال الدالة الرئيسية في لغة البرمجة الإحصائية R $bvar()$ ، يتم ضبط درجات الإبطاء على $Lags = 2$ بسبب أنّ البيانات سنوية، في الإعداد n_draw يتم تحديد عدد التكرارات في خوارزمية سلسلة ماركوف مونت كارلو MCMC، وفي الإعداد n_burn يتم تحديد السحوبات التي يتم تجاهلها في بداية التكرارات:

جدول 3: نتائج تقدير نموذج شعاع الانحدار الذاتي البيزي للمعاملات الأولية ومعلومات التوزيع اللاحق.

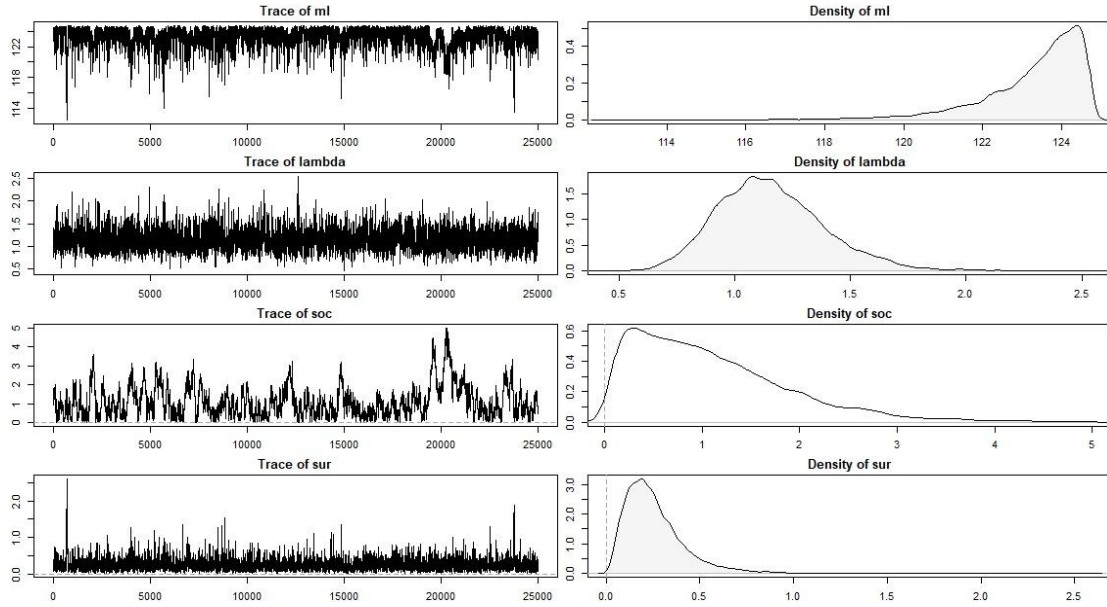
Bayesian VAR consisting of 36 observations, 6 variables and 2 lags.
Time spent calculating: 1.01 mins
Hyperparameters: lambda, soc, sur
Hyperparameter values after optimisation: 1.07151, 0.81611, 0.16726
Iterations (burnt / thinning): 50000 (25000 / 1)
Accepted draws (rate): 8206 (0.328)

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يبين الجدول (3) نتائج تقدير نموذج BVAR الهرمي، وبشكل خاص تقدير المعلمات الفائقة للتوزيع الأولي Prior بهدف تحقيق انكماش على مصفوفة التباين المشترك، كما نلاحظ أنه تمّ تنفيذ 50000 تكرار سلسلة ماركوف

* توضح طريقة كتابة الدالة في لغة البرمجة الإحصائية R في الملحق (1).

مونت كارلو MCMC لتقدير التوزيع اللاحق لمعاملات النموذج، حيث نلاحظ أنه تم إهمال 25000 تكرار وقبول 8206 بمعدل 32.8%. لتقييم جودة هذه المعلمات، نقوم بتقييم التقارب Convergence لمعاملات التوزيع الأولي واللاحق، وهو ضروري لاستقرار خوارزمية MCMC. نستخدم مخططات التتبع والكثافة Trace and density حيث نحصل على الشكل (3) التالي:



الشكل 3: مخططات التتبع والكثافة لمعاملات نموذج BVAR.

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

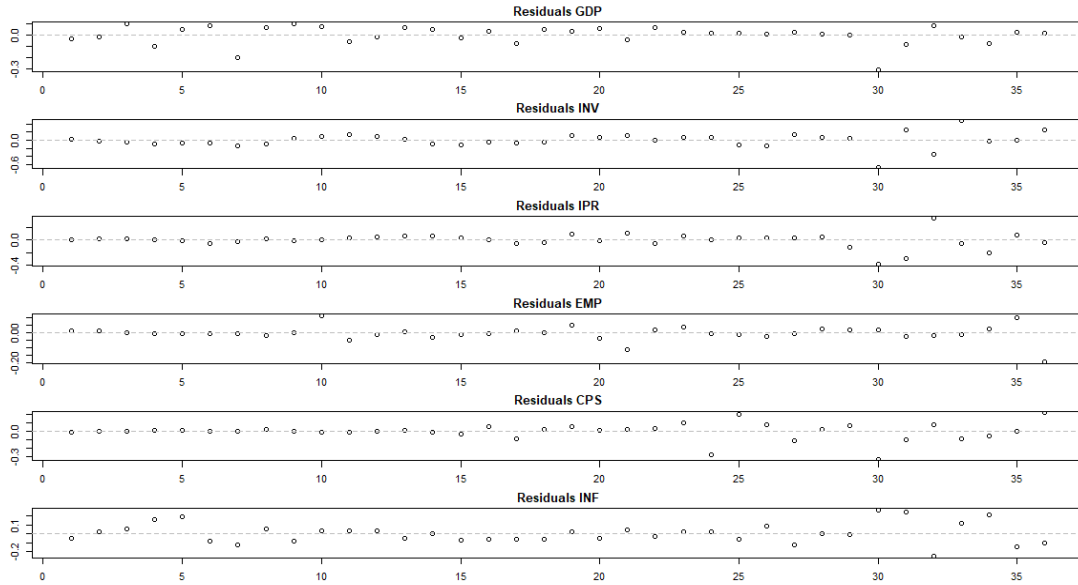
يبين الشكل (3) مخططات الكثافة (اللوحة اليمنى) ومخططات التتبع (اللوحة اليسرى) لمعاملات التوزيع اللاحق (ml) والتوزيع الأولي (lambda, soc, sur)، نلاحظ من الشكل (3) عدم وجود مشكلة تقارب عند تقدير النموذج (من خلال اختبار عدم وجود تباين داخل أجزاء معينة من سلسلة ماركوف مونت كارلو)، نلاحظ بأنه من غير الممكن التعرف على القيم المنطرفة والتي قد تؤدي إلى نتائج مضللة، وذلك نتيجة الانكماش الذي تم فرضه في المعلومات الأولية للنموذج Minnesota prior حيث أن معظم كثافة الاحتمال λ تقع بين 0.6 و 2، وللتأكد بشكل أكبر نقوم بتقييم التقارب من خلال الاختبارات التشخيصية التي اقترحها (Geweke, 1992). توفر حزمة coda تنفيذاً لهذه الإحصائية:

جدول 4: نتائج اختبار Geweke لتقييم التقارب.

Parametres	ml	Lambda	soc	Sur
Z-Score	-2.752	0.2866	0.7752	0.5673

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

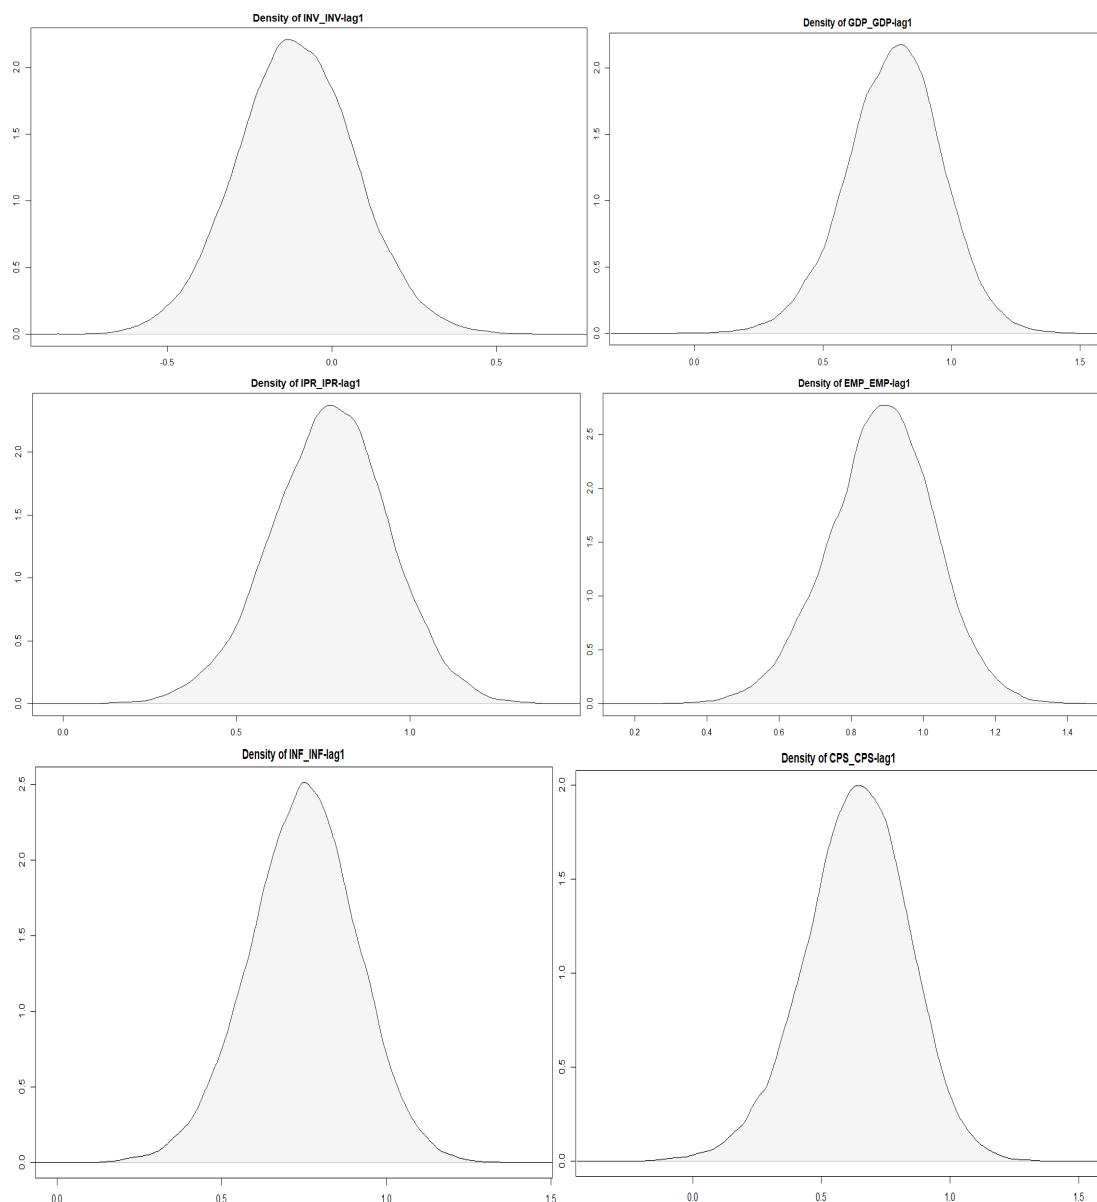
تمثل القيم الناتجة درجات Z-Score القياسية وتشير إلى التقارب المناسب بين جميع المعلمات (أصغر من ± 3)، وهي حدود التوزيع الطبيعي للمعاملات، يمكن أيضاً من خلال الرسم البياني للبواقي استنتاج مقدار الانحراف في بيانات التدريب المتوقعة، باستخدام لغة البرمجة الإحصائية R نجد ما يلي:



الشكل 4: تطور بواقي معدلات نمو متغيرات الاقتصاد الكلي في سورية المقدر باستخدام النموذج.

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يبين الشكل (4) مدى تقارب نقاط البواقي من خط المنتصف (صفر) لجميع المتغيرات، وبالتالي عدم وجود انحراف كبير للبيانات المقدر باستخدام النموذج عن البيانات الفعلية. وفقاً لذلك نستطيع استنتاج معاملات التأثير لمتغيرات النموذج والتي تتمثل بمخطط التوزيع الاحتمالي لمعامل الانحدار الذاتي المقابل لأول تأخير من كل متغير، باستخدام لغة البرمجة الإحصائية R نحصل على النتائج التالية:



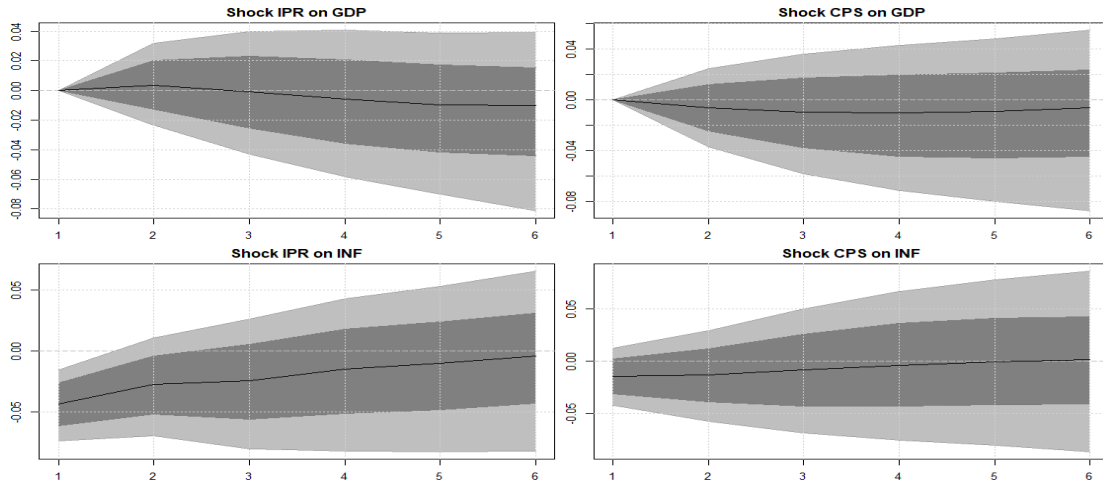
الشكل 5: التوزيع الاحتمالي لمعاملات الانحدار الذاتي المقابلة لدرجة تأخير واحدة لجميع المتغيرات.

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يُبيّن الشكل (5) للتوزيعات الاحتمالية أنّ جميع المتغيرات تستجيب بشكل طردي للصدمات داخل المعادلة المقدرة وهو ما يدلّ على وجود علاقات التكامل المشترك بين هذه المتغيرات على المدى الطويل، ما عدا متغير الاستثمار INV يستجيب بشكل سلبي حيث وجدنا من خلال الشكل (1) تأثيرات كبيرة للحرب في سورية على معدل الاستثمار من خلال التقلب الكبير في معدله والمعدلات السلبية الكبيرة المسجلة.

3-5 الاستدلال باستخدام النموذج (تحليل الصدمات):

تتمثل الأهداف الرئيسية للتحليل الهيكلي لنموذج VAR هو دراسة رد فعل (استجابة) أحد المتغيرات نتيجة صدمات المتغيرات المدخلة في النموذج، باستخدام لغة البرمجة الإحصائية نحصل على النتائج التالية:

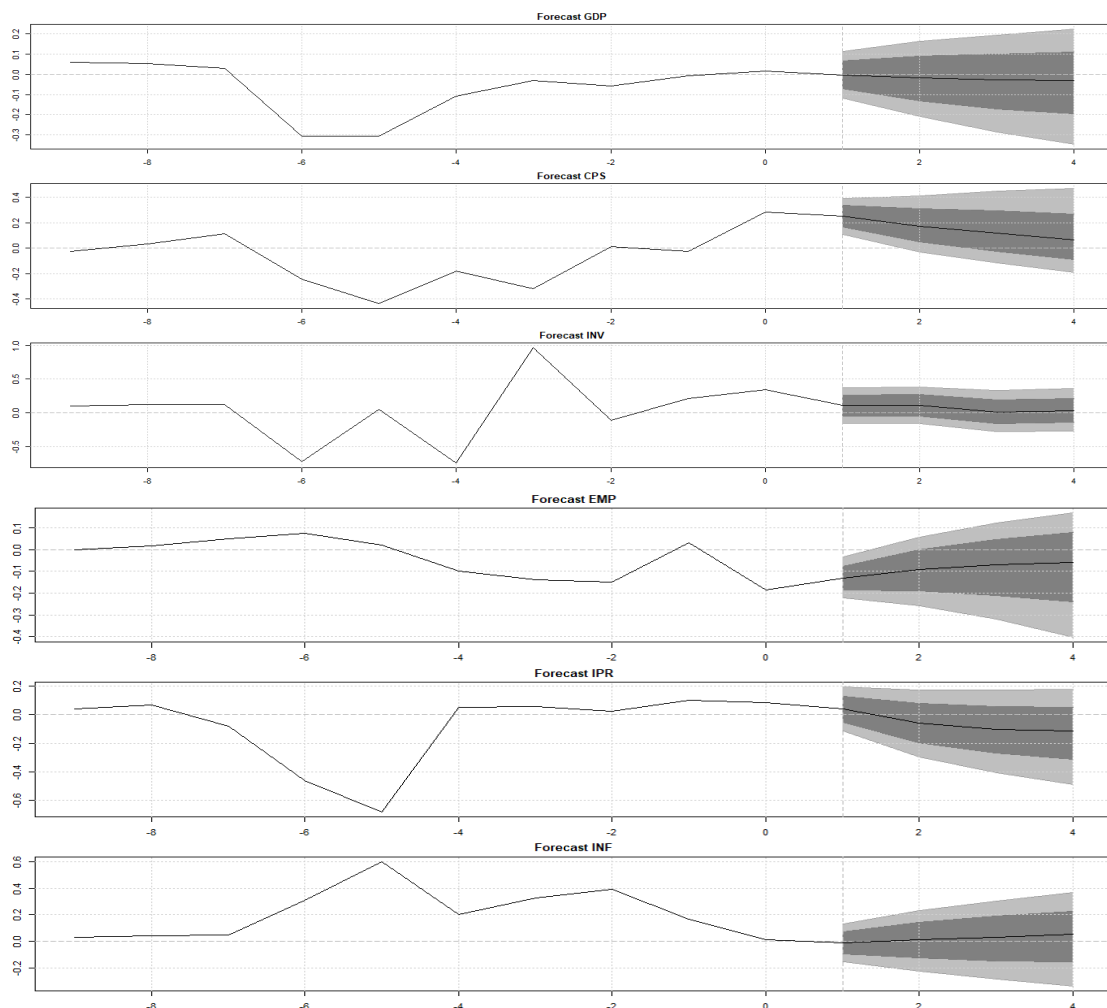


الشكل 6: استجابة معدلات النمو الاقتصادي والتضخم لصدمة الإنتاج الصناعي والاستهلاك الأسري.
المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يبين الشكل (6) استجابة كل من معدل النمو الاقتصادي GDP ومعدل التضخم INF لصدمة الإنتاج الصناعي والاستهلاك الأسري، حيث نلاحظ أنّ الصدمة في هذه المتغيرات تؤدي إلى انخفاض في معدل النمو الاقتصادي، حيث نلاحظ أنّ الإنتاج الصناعي يؤدي إلى ارتفاع طفيف في معدل النمو الاقتصادي حتى 3 سنوات ثم انخفاض بحوالي 2% بسبب القيود الاقتصادية وتراجع الإنتاج خلال الحرب في سورية، كما نلاحظ رد الفعل السلبي لمعدل النمو الاقتصادي لصدمة الاستهلاك الخاص نتيجة تراجع الإنفاق والتضخم الكبير وتآكل القوة الشرائية خلال فترة الحرب. كما نجد من الشكل (6) أنّ صدمات انخفاض مستويات الإنتاج الصناعي والاستهلاك يؤدي إلى ارتفاع مستمر في مستويات معدل التضخم.

4-5 التنبؤ وتقييم التنبؤ:

تتمثل الخطوة الرئيسية في تقدير النموذج هو التنبؤ ببيانات الاقتصاد الكلي في سورية من خلال المتغيرات التي تقود مسار متغير معين بعد الصدمة ضمن النموذج، وذلك من خلال تحليل تباين الخطأ المتوقع (Forecast error variance decomposition) لمدة 4 سنوات بعد فترة التدريب (2018 - 2022) مع تضمين حالة عدم التأكد إلى التنبؤ، باستخدام لغة البرمجة الإحصائية نحصل على النتائج التالية:



الشكل 7: تطور بواقى معدلات نمو متغيرات الاقتصاد الكلي في سورية المقدرة باستخدام النموذج.

المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يبين الشكل (7) أنّ جميع متغيرات الاقتصاد الكلي تسجل معدلات سلبية ونحو انخفاض خلال الفترة الزمنية التي تمّ التنبؤ بها، ما عدا معدل التضخم يسجل ارتفاعات خلال هذه الفترة، ولتقييم التنبؤ خارج العينة نستخدم اختبار الجذر التربيعي لمربع الخطأ (انحراف القيم المقدرة باستخدام النموذج عن القيم الفعلية) والذي يعطى:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}} \quad (14)$$

حيث \hat{y}_t القيم المقدرة باستخدام النموذج، y_t القيم الفعلية. N: عدد المشاهدات المقدرة. يبي الجدول التالي نتائج

التنبؤات ونتائج اختبار RMSE:

جدول 5: نتائج التنبؤ ببيانات الاقتصاد الكلي ضمن مجالات الثقة ونتائج اختبار RMSE لتقييم التنبؤ.

Var	GDP	INV	EMP	CPS	IPR	INF
2019	[-1, 6]%	[-5, 10]%	[-9, 6]%	[-16, -10]%	[-30, -20]%	[7, 14]%
Actual-2019	-0.79%	4.56%	-0.72%	-61.02%	-24.1%	13.43%
2020	[-13, -2]%	[-5, 11]%	[-6, 17]%	[-23, -13]%	[-10, 6]%	[14, 23]%
Actual-2020	-3.87%	10.78%	22.05%	-56.63%	0.62%	114.23%
2021	[-17, -3]%	[-16, 1]%	[-13, -4]%	[-29, -15]%	[-6, 8]%	[19, 30]%
2022	[-19, -3]%	[-14, 3]%	[-7, 12]%	[-34, -15]%	[-11, 5]%	[23, 37]%
RMSE	1.33	3.84	5.16	39.62	4.78	64.51

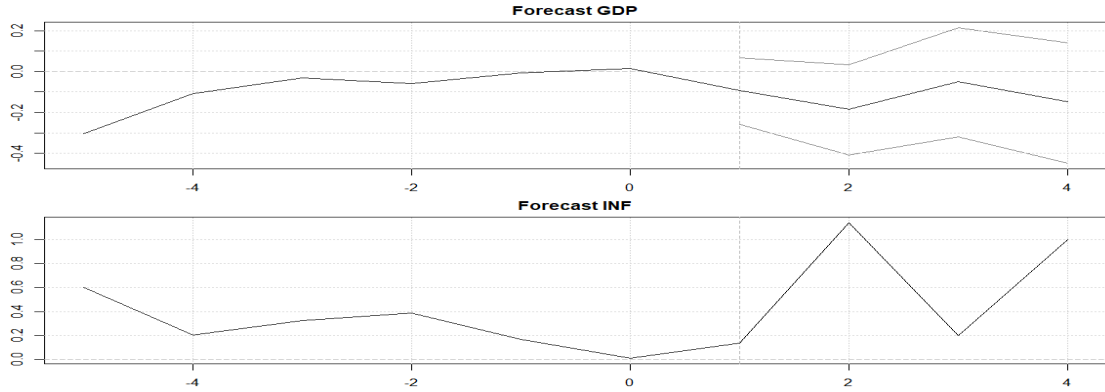
المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يبين الجدول (5) نتائج التنبؤ لمتغيرات الاقتصاد الكلي في سورية مع تضمين عدم التأكد إلى التوقعات، نلاحظ أنّ الاتجاه العشوائي المتوقع للمتغيرات سلبى ويشير إلى تضمين معدلات سالبة لنمو جميع المتغيرات ما عدا مؤشر تضخم أسعار المستهلك، ومن خلال حساب مقدار انحراف القيم المقدرة باستخدام النموذج عن البيانات الفعلية حسب المكتب المركزي للإحصاء (جودة التنبؤ خارج العينة)، نلاحظ أنّ النتائج تقع ضمن مجال الثقة لمتغيرات النمو الاقتصادي والاستثمار والإنتاج الصناعي، وبالتالي نتائج الاختبار أصغر حيث تشير إلى تقارب بين القيم المقدرة والفعلية، أما بالنسبة للاستهلاك الأسري ومعدل التضخم فنلاحظ أنّ التنبؤ يأخذ نفس الاتجاه ولكن ليس بالسرعة الفعلية التي انخفض فيها الاستهلاك وارتفع فيها التضخم، يمكن تحسين جودة التنبؤ من خلال إدراج معلومات جديدة إلى النموذج باستخدام تحليل السيناريو.

5-5 تحليل السيناريو:

يُعرف تحليل السيناريو ضمن التنبؤات الشرطية، حيث يكون المسار المستقبلي لمتغير واحد أو عدة متغيرات معروفاً، أو من الممكن تضمين مدى استهدافه بمعدل معين على باقي المتغيرات مما يجعله أداة مهمة لتخطيط السياسات الاقتصادية وتحسين دقة التنبؤات للنموذج من خلال المعلومات الإضافية. في نموذجنا المقترح نقوم بتكوين التنبؤات الشرطية باستخدام الدالة `bv-fcast()` حيث يتم توفير المسارات المستقبلية باستخدام الدالة `cond-path` كمتجه رقمي أو مصفوفة*. نقوم بتوفير المسارات المستقبلية لمعدل التضخم للأعوام 2019 و 2020 حسب المكتب المركزي للإحصاء، ولأعوام 2021 و 2022 يتم حسابه وفق تطور سعر الصرف للمصارف والصرافة حسب مصرف سورية المركزي ونفس ذلك نتيجة الارتباط المتغير مع الزمن الذي تمّ التوصل له في دراستنا السابقة (Alakkari et al., 2022). وفق لغة البرمجة الإحصائية نحصل على النتائج التالية:

* يتم توفير كافة الأكواد المدخلة في لغة البرمجة الإحصائية في الملحق (1).



الشكل 8: المسار المستقبلي لمعدل النمو الاقتصادي بعد إدخال معلومات حول معدل التضخم في سورية.
المصدر: إعداد الباحثين بالاعتماد على لغة البرمجة الإحصائية R.

يبين الشكل (8) ومع إدخال معلومات معدل التضخم قد ازداد تأكيدنا بتحقيق معدلات سالبة في النمو الاقتصادي خلال الأعوام (2019-2020-2021-2022) وبمجال ثقة تقع ضمنه البيانات الفعلية حيث بلغت دقة التنبؤ $RMSE = 0.99$ وهي أفضل من النتيجة السابقة، من المتوقع أن يحقق النمو الاقتصادي معدلات -5% ، -15% للأعوام 2021 و 2022 على التوالي مما يُظهر تحدياً لتصحيح مسار السياسات الاقتصادية في سورية.

6- الاستنتاجات والتوصيات:

6-1 الاستنتاجات:

- 1- اقترح هذا البحث نهج هيكلي هرمي قائم على محاكاة Bayesian بالكامل للاستدلال الإحصائي في نموذج VAR والتنبؤ باستخدامه ببيانات الاقتصاد الكلي.
- 2- تم تخفيف عدم التأكد الإحصائي ومعالجة مشكلة Over Parameterization في بيانات الاقتصاد السوري من خلال فرض معلومات مسبقة أسهمت في إضافة مصفوفة معلومات على البيانات، وفرض بنية هيكلية من نوع Minnesota.
- 3- أشارت نتائج التنبؤ داخل العينة إلى أن نموذج VAR الهيكلي البيزي الهرمي يعمل بشكل جيد من حيث الدقة التنبؤية وتوضيح خصائص البيانات المستخدمة في التحليل. كما أظهرت نتائج تقييم التنبؤات خارج العينة تقارباً بين القيم الفعلية والقيم المقدرة لبيانات الاقتصاد الكلي باستخدام النموذج مع سلوكها نفس الاتجاه.
- 4- أسهم النموذج المقترح في تخفيف حالة عدم التأكد من جانبين: جانب إحصائي من خلال نجاح النموذج بالتنبؤ خارج العينة بوجود عدد كبير من المتغيرات مع التوافر الزمني المحدود لها، وجانب اقتصادي من خلال توفير تنبؤات أنبية حول متغيرات الاقتصاد الكلي مع تضمين مجالات الثقة والخطأ في التنبؤ إلى هذه التقديرات.
- 5- يوفر النموذج المقترح من خلال تحليل السيناريو أداة هامة لتخطيط السياسات الاقتصادية من خلال إدراج معلومات جديدة حول المسار المستقبلي لمتغير واحد أو عدة متغيرات، أو من الممكن تضمين مدى استهدافه بمعدل معين على باقي المتغيرات.

6-2 التوصيات:

- 1- بسبب التطبيق الواسع لنماذج VAR في تقييم السياسات الاقتصادية، كان من الضروري إضافة بنية هيكلية على النموذج تسمح بمعالجة أهم المشاكل في بيانات الاقتصاد السوري وهي التوافر الزمني المحدود، وبالتالي الحصول على تنبؤات أفضل في البيئة التي تتطور بشكل عشوائي، مما يجعل هذا النموذج أداة هامة لواضعي السياسات الاقتصادية والقائمين على تقدير البيانات في المكتب المركزي للإحصاء ومصرف سورية المركزي خاصة مع التأخر في النشر الرسمي لهذه البيانات.
- 2- من الممكن في دراسات لاحقة زيادة دقة هذا النموذج في التنبؤ خارج العينة من خلال تطويره رياضياً لإمكانية الاستفادة من بيانات الترددات العالية (أسعار الصرف - معدلات الفائدة - أسعار الأسهم) والتي تصدر في الوقت الآني.

7- المراجع:

1. العكاري، خضر. (2022). قياس عدم التأكد في السياسة الاقتصادية في سورية باستخدام نموذج النقل العشوائي البيزي. مجلة السياسات والتنمية الاقتصادية - المعهد العربي للتخطيط. 24(3). 63-93.
2. علي، عبد العظيم وعمر، فوزية. (2013). استخدام الشبكات العصبية الاصطناعية للتنبؤ من أنموذج الاقتصاد الكلي متعدد الأبعاد في العراق للمدة 1996-2007. مجلة الاقتصاد الخليجي، 24،
3. خليل، فادي و خليل، هادي. (2020). دراسة قياسية لأثر صدمات مكونات العرض النقدي في متغيرات الاقتصاد الكلي الرئيسية في سورية. مجلة البحوث الاقتصادية والمالية لجامعة أم البواقي الجزائرية. 7 (2). 298-323.
4. المكتب المركزي للإحصاء (2022). المجموعة الإحصائية السورية 2021. سورية: دمشق. <http://www.cbssyr.sy>
5. Al-Akkari, K., & ali, bushra. (2022). *Using Bayesian Inference for Stochastic Volatility Model (Empirical Evidence from Damascus Securities Exchange)*. Tishreen University Journal- Economic and Legal Sciences Series, V. 44, N. 3, PP: 11-32.
6. Alakkari, Khder, Yadav, Shikha, Mishra, Pradeep, *Measuring Economic Uncertainty in Syria: An Approach to the Stochastic Volatility Model*, Indian Journal of Economics and Development, 2022, V. 18, N. 2, PP: 281-291.
7. Banbura, M., Giannone, D., and Reichlin, L. (2010). *Large Bayesian vector auto regressions*. Journal of Applied Econometrics, V. 25, N. 1. PP:71-92.
8. Doan T, Litterman R, Sims C (1984). *Forecasting and Conditional Projection Using Realistic Prior Distributions*. Econometric Reviews, V. 3, N. 1, PP: 1-100.
9. De Mol C, Giannone D, Reichlin L (2008). *Forecasting Using a Large Number of Predictors: Is Bayesian Shrinkage a Valid Alternative to Principal Components*. Journal of Econometrics, V. 146, N. 2, PP: 318-328.
10. Silver, Nate. (2012). *The Signal and the Noise: Why Most Predictions Fail – but Some Don't*. United States: Penguin Group.
11. Forero, Fernando. (2021). *Forecasting Peruvian Macroeconomic Variables with Bayesian Vector Auto regressions with Time-Varying in the mean*. Working paper. Banco Central de Reserva del Perú. 1-30.
12. Fama, B. (1995). *The behavior of stock market prices*. Journal of Business, V. 38, N. 1, PP: 34-105.
13. Geweke, John. (1992). *Evaluating the Accuracy of Sampling-Based Approaches to the Calculations of Posterior Moments*. Bayesian Statistics, V. 4, PP: 641-649.
14. Gelman A, Carlin JB, Stern HS, Dunson DB, Vehtari A, Rubin DB (2013). *Bayesian Data Analysis*. Chapman & Hall/CRC. ISBN 978-1439840955.
15. Higham NJ. (1999). *Analysis of the Cholesky Decomposition of a Semi-Definite Matrix*. Technical report, Manchester Institute for Mathematical Sciences. MIMS EPrint 2008.56.
16. Sims, CA. (1980). *Macroeconomics and Reality*. Econometrica, PP. 1-48.
17. Sims, Christopher. (1993). *A Nine-Variable Probabilistic Macroeconomic Forecasting Model*. In Business Cycles, Indicators and Forecasting, PP. 179-212. University of Chicago Press.

18. Sims Christopher, Zha, Tao. (1998). *Bayesian Methods for Dynamic Multivariate Models*. International Economic Review, PP. 949–968.
19. Simon, Du; Jason, Lee. (2018). *On the power of over-parametrization in neural networks with quadratic activation*. In Proceedings of the 35th International Conference on Machine Learning, PP: 1329–1338.
20. Koop, G. M. (2013). *Forecasting with medium and large Bayesian VARs*. Journal of Applied Econometrics, V. 8, N. 2, PP:177–203.
21. Koop, Gary and Korobilis, Dimitris. (2010). *Bayesian Multivariate Time Series Methods for Empirical Macroeconomics*. Foundations and Trends in Econometrics, V. 3, N. 4, PP: 267–358.
22. Kilian L, Lütkepohl H (2017). *Structural Vector Autoregressive Analysis*. Cambridge University Press.
23. Kastner, Gregor and Schantter, Sylvia and Lopes, Hedibert. (2017). *Efficient Bayesian Inference for Multivariate Factor Stochastic Volatility Models*. Department of finance Accounting and statistics. Vienna University of Economics and Business.
24. Kastner, G. and Huber, F. (2020). *Sparse Bayesian vector auto regressions in huge dimensions*. Journal of Forecasting, V. 39, N. 7, PP:1142-1165.
25. Litterman, RB. (1980). *A Bayesian Procedure for Forecasting with Vector Autoregressions*. MIT Working Paper.
26. Mandelbort, B. (1963). *The variation of certain speculative prices*. Journal of Business, V. 36, PP:394–419.
27. Giannone, D., Lenza, M., and Primiceri, G. E. (2015). *Prior selection for vector autoregressions*. The Review of Economics and Statistics, V. 97, N. 2, PP: 436–4.
28. Crump, R. and Eusepi, S and Giannone, D and Qian, E and Sbordone, A. (2021). *A Large Bayesian VAR of the United States Economy*. Federal Reserve Bank of New York Staff Reports, N. 976. USA.
29. Perron, Pierre and Timothy, Vogelsang. (1992). *Testing for a Unit Root in a Time Series with a Changing Mean: Corrections and Extensions*, Journal of Business & Economic Statistics, V. 10, PP: 467–470.
30. Perron, Pierre (2006). *Dealing with Structural Breaks*, in Palgrave Handbook of Econometrics, V. 1: Econometric Theory, K. Patterson and T. C. Mills (eds.), Palgrave Macmillan, 278- 352.
31. Villani, M (2009). *Steady-State Priors for Vector Autoregressions*. Journal of Applied Econometrics, V. 24, P. 4, PP: 630–650.
32. Uhling, Harald. (2005). *What are the effects of monetary policy on output? Results from an agnostic identification procedure*. Journal of Monetary Economics. V. 52, N. 2. PP: 381-419.

8- الملاحق:

ملحق (1): الأكواد المستخدمة في لغة البرمجة الإحصائية R لتقدير نموذج BVARs والتنبؤ باستخدامه.

BVAR package	الحزمة المستخدمة
R> data<- ts(EU, start = c(1, 1980)) R> data<- diff(log(data)) R> plot(data)	حساب معدلات النمو من متغيرات الاقتصاد الكلي ورسم تطورها خلال الفترة الزمنية المدروسة
R> mn <- bv_minnesota(lambda = bv_lambda(mode = 0.2, sd = 0.4, min = 0.0001, max = 5), alpha = bv_alpha(mode = 2, sd = 0.25, min = 1, max = 3), var = 1e07) R> soc <- bv_soc(mode = 1, sd = 1, min = 1e-04, max = 50) R> sur <- bv_sur(mode = 1, sd = 1, min = 1e-04, max = 50) R> priors <- bv_priors(hyper = "auto", mn = mn, soc = soc, sur = sur) R> mh <- bv_metropolis(scale_hess = c(0.05, 0.0001, 0.0001), adjust_acc = TRUE, acc_lower = 0.25, acc_upper = 0.45)	إدراج المعلومات الأولية وفق النمذجة الهرمية
R> run <- bvar(data, lags = 2, n_draw = 50000, n_burn = 25000, n_thin = 1, priors = priors, mh = mh, verbose = TRUE)	تقدير النموذج بعد ادخال المعلومات المناسبة
R> print(run) R> plot(run, type = "dens", vars_response = "GDP", vars_impulse = "GDP-lag1")	الرسم البياني لمعاملات التوزيع الأولي والملاحق (prior and posterior)
R> run_mcmc <- as.mcmc(run) R> geweke.diag(run_mcmc) R> plot(residuals(run, type = "mean"), vars = c("GDP", "INV", "IPR", "EMP", "CPS", "INF"))	الاختبارات التشخيصية للنموذج
R> opt_irf <- bv_irf(horizon = 6, identification = TRUE) R> irf(run) <- irf(run, opt_irf, conf_bands = c(0.05, 0.16)) R> plot(irf(run), area = TRUE, vars_impulse = c("IPR", "CPS"), vars_response = c(1, 6))	استجابة متغيرات الاقتصاد الكلي في سورية للصدات
R> predict(run) <- predict(run, horizon = 4, conf_bands = c(0.05, 0.16)) R> plot(predict(run), area = TRUE, t_back = 10, vars = c("EMP", "IPR", "INF", "GDP", "CPS", "INV")) R> X<- print(predict(run)).. summary(X)	التنبؤ غير المشروط ببيانات الاقتصاد الكلي في سورية
R> path <- c(0.1343, 1.1423, 0.2002, 1) R> predict(run) <- predict(run, horizon = 4, cond_path = path, cond_var = "INF") R> plot(predict(run), t_back = 6, vars = c("GDP", "INF"))	تحليل السيناريو والتنبؤ المشروط بالنمو الاقتصادي في سورية