

Les méthodes neuronales telles que les MLP, sont-elles plus performantes que les modèles ARIMA, pour prévoir des séries macroéconomiques mensuelles chaotées ?

Are neural network methods such as MLP, outperforms ARIMA models, for forecasting monthly chaotic macroeconomic series?

Melzi Zohir^{*1}

¹Maitre de conférences, ESC Koléa, Algérie, z_melzi@esc-alger.dz

Reçu le:20./11/2022

Accepté le:26./12/2022

Publié le : 31/12/2022

Résumé : Nous comparons deux techniques de modélisation endogènes, ARIMA et de réseaux de neurones MLP, pour la prévision à trois mois des importations mensuelles totales algériennes, exprimées en valeur.

Malgré de fortes perturbations affectant cet agrégat, les erreurs de prévisions sont minimales, avec une MAPE de l'ordre de 3 %, concernant les deux techniques.

Néanmoins, bien que les modèles MLP donnent de bons résultats, nous mettons des réserves quant à la stabilité de leurs estimations.

Mots clés : séries temporelles ; ARIMA ; réseaux de neurones ; prévision ; économétrie.

Jel Classification Codes : C32, C45, C53, C55.

Abstract: We compare two endogenous modeling techniques, ARIMA and MLP neural network, for the three-month forecast of total algerian monthly imports, expressed in value.

Despite strong disturbances affecting this aggregate, forecast errors are minimal, with a MAPE of around 3 %, for both techniques.

Nevertheless, although MLP models give good results, we have reservations about the stability of their estimates.

Keywords: time series; ARIMA; Neural network; Forecasting; Econometrics.

Jel Classification Codes: C32, C45, C53, C55.

* *Auteur correspondant*

1. Introduction

Toute la subtilité d'une bonne modélisation en économétrie, réside dans la capacité de l'économètre à pouvoir cerner les mécanismes régissant la variabilité des phénomènes qu'il souhaite étudier. Cependant, la théorie de l'échantillonnage, ainsi que la méthode d'estimation sur laquelle repose sa théorie, vont le contraindre à inférer statistiquement, de sorte à ce qu'il puisse viabiliser les résultats de ses estimations.

En analyse de séries temporelles, nous pouvons citer parmi les méthodes couramment utilisées, la méthodologie Box et Jenkins qui exploite la modélisation ARIMA. Une autre forme de formalisation de la relation d'une variable avec son passé, se retrouve de plus en plus utilisée dans les travaux de recherche parus récemment. Elle est axée sur l'apprentissage comme les réseaux de neurones, plus spécifiquement ceux récurrents (RNN), plus adaptés pour anticiper le comportement des séries à travers le temps.

Une littérature abondante traite récemment de ces nouvelles techniques de prévision, soit en complément ou en confrontation, avec des modèles classiques d'analyse de séries temporelles. En plus de l'avancée technologique et de la disponibilité des données statistiques, plusieurs variantes ont vu le jour, par perfectionnement, mais surtout par identification de la nécessité d'adapter les algorithmes, à la structure des données temporelles. On parle actuellement de réseaux de neurones récurrents, qui par leur apprentissage qui est à plusieurs reprises relancé dans l'optimisation des modèles, pourrait cerner les mécanismes comportementaux des différentes composantes des séries temporelles.

Cependant, deux interrogations nous viennent à l'esprit concernant la capacité de ces techniques modernes, à pouvoir prévoir les séries chronologiques d'une manière efficace. D'une part, bien que le caractère endogène des modèles classiques repose essentiellement sur l'extrapolation du comportement antérieur des séries vers le futur, celui-ci repose néanmoins sur des fondements théoriques qui exigent à ce que l'inférence statistique soit validée, afin de pouvoir viabiliser les estimations. D'un autre côté, ces modèles basés sur l'apprentissage, seraient-ils capables de proposer des estimations stables ?

Nous souhaitons confronter les modèles de réseaux de neurones classiques comme les MLP, et voir si effectivement ces derniers pourraient concurrencer des modèles classiques comme les ARIMA. En plus d'observer l'erreur de prévision et de voir si l'une ou l'autre des techniques proposées

pourrait être plus performante, nous allons discuter la méthode et sa stabilité, permettant de valider les estimations.

Nous présenterons dans une première section, la littérature qui aborde ce sujet de confronter, sinon pouvoir concilier les réseaux de neurones et les modèles de prévision conventionnels. Ceci va permettre d'asseoir notre méthode d'analyse sur un cadre conceptuel, dans la continuité de tout ce qui a été proposé récemment à ce sujet.

La deuxième section, aura pour objet de présenter les données sur lesquelles nous avons appliqué nos méthodes de calcul. Il s'agit des importations mensuelles algériennes, étalées sur une période relativement longue de 135 observations. En effet, chaque série temporelle caractérisant une variable donnée, qu'elle soit économique ou pas, aura ses propres caractéristiques et pourrait ne pas conduire à des conclusions similaires quant au choix des modèles retenus.

Après avoir présenté brièvement les deux modèles retenus dans notre étude, nous allons exposer tous les résultats de nos estimations, pour ensuite dans la section suivante, discuter les résultats obtenus.

Nous concluons sur la possibilité de choisir l'une ou l'autre de ces deux méthodes, afin de pouvoir prévoir d'une manière viable des agrégats macroéconomiques importants, comme les séries du commerce extérieur en Algérie.

2. Revue de la littérature et cadre conceptuel régissant la comparaison des méthodes ARIMA et réseaux de neurones, pour la prévision des séries temporelles à fréquence courte.

Le cadre conceptuel de nos travaux, s'appuie sur les développements récents parus dans la littérature, qui s'intéresse à l'amélioration de l'analyse et des prévisions des séries temporelles. Nous avons retenu celles qui d'un côté, comparent les résultats des prévisions dans différents domaines, des modèles ARIMA et des réseaux de neurones. D'un autre côté, il y a celles qui concilient l'utilisation de ces deux modèles sous forme hybride, profitant des avantages de l'un et de l'autre, afin de pouvoir améliorer la qualité de la prévision.

Dans la confrontation des performances exprimées par l'évaluation des statistiques de minimisation de l'erreur de prévision, nous retrouvons plusieurs analyses dont celle de Sima S.-N. et al. (2018), qui présentent lors d'une conférence les résultats de prévisions de plusieurs séries économiques

et financières mensuelles, ainsi que Ghahreman A. et al. (2020), qui ont modélisé une série journalière du Tehran stock exchange, qui comparent les prévisions de deux méthodes : ARIMA et LSTM. Les auteurs constatent que si le modèle ARIMA s'ajuste mieux sur la tendance des séries étudiées, le modèle LSTM donne de meilleurs résultats sur le long terme. Hans W. et al. (2021) de leur côté, utilisent deux RNN, un MLP et un LSTM, pour prévoir les liquidités dans les entreprises, qu'ils comparent aux résultats de prévisions des modèles ARIMA et Prophet[†]. Ils introduisent une nouvelle statistique pour mesurer l'erreur de prévision et la performance des modèles : Interest Opportunity Cost (IOC). Cette statistique s'avère être meilleure pour les modèles RNN.

Diogo D. O. et al. (2021), effectuent une comparaison des résultats (RMSE et MAPE), uniquement de modèles RNN comme le MLP et le LSTM pour prévoir le trafic de véhicules dans des grandes avenues de New York. Ils considèrent différentes périodes de prévision comme le jour, la semaine et l'année et trouvent des résultats pratiquement similaires en exploitant ces deux méthodes.

La prévision de séries temporelles concerne plusieurs secteurs d'activité et plusieurs données qu'elles soient macroéconomiques, de la comptabilité nationale, financières, ou bien microéconomiques. Nous nous sommes penchés sur des travaux d'auteurs qui ont exploité différentes techniques afin de prévoir des séries de l'économie réelle comme les flux d'échanges internationaux. En effet, nous souhaitons dans notre étude, analyser et prévoir ce genre d'agrégats pour l'économie algérienne.

Qinglin Q. et al. (2019), estiment les exportations et importations mensuelles et trouvent qu'elles sont difficiles à prévoir et que le modèle LSTM a pu donner de bons résultats, comparativement à des méthodes de prévisions classiques comme le lissage exponentiel. Toujours dans le même registre, Mei-Li S. et al. (2021), effectuent des prévisions des flux d'importations et d'exportations de plusieurs pays avec des techniques de modélisation en séries temporelles comme les modèles ARIMA, MLP et LSTM et trouvent que les erreurs de prévision minimales se penchent plus du côté du modèle LSTM.

[†] Procédure automatique de prévision de séries temporelles, implémentée dans R et Python. <https://cran.r-project.org/web/packages/prophet/prophet.pdf#page.14>

Toujours dans la prévision de séries macroéconomiques, Luigi L. et al. (2022), effectuent une prévision de la croissance du PIB américain en exploitant un modèle LSTM : l'étude montre des résultats performants du modèle en prévision, notamment après la crise des sub-primes de 2007-2008 et l'après Covid-19.

En revanche, si toutes ces études donnent majoritairement des résultats plus performants en termes d'erreur de prévision pour les modèles RNN, Dariusz K. et al. (2022), trouvent que les modèles ARIMA sont plus performants que les modèles LSTM, pour prévoir quelques actions de sociétés représentées dans le NASDAQ, que ce soit en quotidien ou en mensuel.

En ce qui concerne les systèmes de modélisation conciliant et associant les modèles RNN et ARIMA, nous pouvons citer les travaux d'Emmanuel D. et al. (2021), qui utilisent un modèle hybride associant un modèle ARIMA pour capter la partie linéaire et le modèle en réseaux de neurones LSTM, pour capter l'aspect non linéaire des exportations indonésiennes. Le modèle retenu, a obtenu les plus petites valeurs des statistiques mesurant l'erreur de prévision, comparativement à des modélisation classiques non hybrides. Leur méthode consiste à d'abord décomposer la séries en trois composantes, tendance saisonnalité et résidus, pour ensuite utiliser l'ARIMA pour prévoir la tendance seule et un LSTM pour anticiper la non linéarité dans la saisonnalité et les résidus. Ils calculent en finalité, une prévision en associant celles issues du modèle hybride, qu'ils trouvent meilleures que s'ils avaient exploités les différents modèles seuls sans les associer.

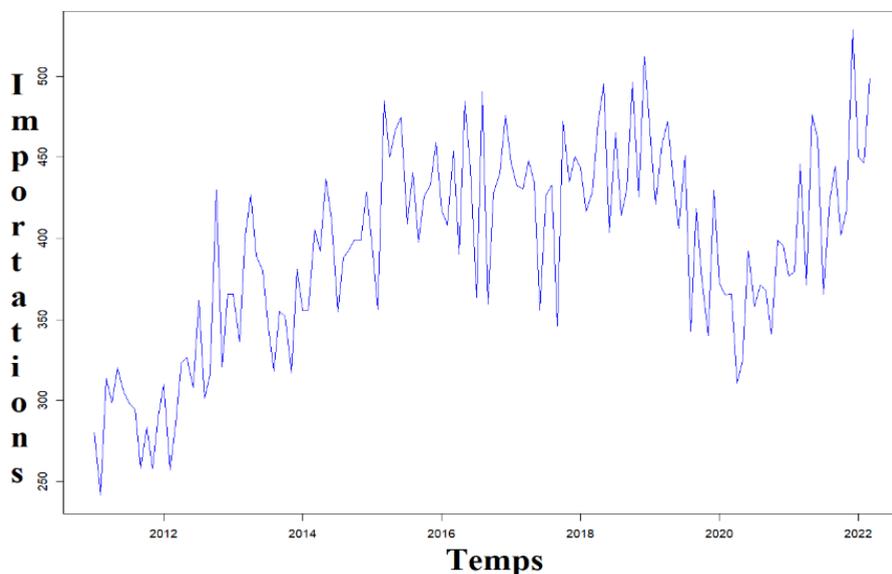
D'autres travaux comme ceux d'Arash N. K. et al.(2012), proposent l'utilisation de modèles hybrides de réseaux de neurones (MLP et RBF), afin de modéliser et réduire l'erreur induite par une modélisation ARIMA, du taux de change de EUR/USD journalier (3440 points), du 1 avril 2001 au 31 juillet 2010. Ils constatent également, que les résultats sont meilleurs en associant les trois méthodes, plutôt que de les exploiter chacune séparément. Atila A. et al. (2007), associent également plusieurs modèles, ARIMA, Linear ANN, Multi-Layer perceptron (MLP), et Radial Basis Function Network (RBFN), pour prévoir les entrées de touristes en Turquie de Janvier 1984 à Décembre 2003. Ils aboutissent aux mêmes résultats, avec de meilleures performances quand la composante non-linéaire est prise en considération par ces techniques NN, associées aux modèles ARIMA.

3. Les données

Nous souhaitons prévoir une série temporelle, importante dans l'économie algérienne. Il s'agit des importations totales, exprimées en milliards de dinars. La série est proposée par l'Office National des Statistiques, sur une période allant de janvier 2011 à mars 2022.

Le graphique 1 de la série, montre des fluctuations qui évoluent autour d'une tendance difficile à observer. Plusieurs valeurs atypiques observables, perturbent la série au point que nous avons du mal à déceler un éventuel mouvement saisonnier notoire. À noter que la visualisation graphique est insuffisante, nous effectuerons les tests et estimations à travers une procédure puissante, qui va permettre de détecter et traiter ces valeurs avec plus de précision.

Figure N° 1. Importations algériennes totales mensuelles en valeur, en milliards de dinars.



Source : Office National des statistiques.

4. Méthode d'analyse

Un choix optimal d'un modèle ARIMA, se base sur des étapes proposées sous forme d'un algorithme prédéfini dans la méthodologie de Box et Jenkins (1970). D'un autre côté, les réseaux de neurones, notamment ceux adaptés pour prévoir des séries chronologiques, sont assez complexes et exigent plus de temps de calcul en phase d'apprentissage. Mais vu qu'ils prennent en

considération la dépendance à long terme des séries temporelles, ils arrivent à fournir des résultats plus performants. Ce résultat, n'est pas vérifiable dans tous les cas de figure. En effet la structure des données préalablement sélectionnées, influence fortement les résultats escomptés.

La littérature, propose une multitude d'analyses basées sur ce genre de modélisation, ainsi que d'autres formes de réseaux de neurones plus classiques comme les MLP. Elles sont soit utilisées indépendamment pour les comparer à d'autres méthodes de prévisions classiques comme les modèles ARIMA[‡], sinon, combinées sous formes de modèles hybrides, afin de pouvoir améliorer et donc diminuer l'erreur de prévision.

Nous souhaitons exploiter ces différentes méthodes à savoir ARIMA, MLP[§] et LSTM^{**}, pour prévoir un agrégat macroéconomique algérien à fréquence courte, à savoir les importations mensuelles totales en valeur. Les fluctuations ainsi que l'évolution de cette série temporelle paraissent difficiles à anticiper.

Les modèles LSTM, récemment implémentés dans des logiciels de renom tels que Python et encore moins dans R, ne permettent pas actuellement d'avoir quelque recul sur leur paramétrage d'une manière précise. Les procédures de test sur des sous-échantillons sont certes proposées mais celles destinées à prévoir des valeurs futures sont moins évidentes.

Nous allons dans un premier temps, appliquer l'algorithme de Box et Jenkins, afin de traiter et identifier le modèle ARIMA optimal, en vue de la prévision de courte période de la série mensuelle des importations algériennes. Nous exploiterons ensuite, la procédure *mlp()* dans R, en exploitant ses possibilités de paramétrage, afin d'identifier le réseau de neurones MLP optimal pour

[‡] Box and Jenkins (1970).

[§] Pour plus de détails sur ces techniques, se référer à l'ouvrage proposé par Taweh Beysolow II (2017) *Introduction to deep learning using R*, Apress.

^{**} Après plusieurs essais, nous n'avons pas pu aboutir à des résultats concluants. Nous nous sommes abstenus de retenir cette technique, à cause de sa récente implémentation dans R, sans pouvoir disposer d'une procédure de prévision définitive.

prévoir trois mois de notre série. Nous comparerons en finalité, les résultats de prévision de ces deux techniques de modélisation.

5. Résultats :

Nous présentons dans cette section, d'abord les résultats obtenus à travers la méthodologie Box et Jenkins, pour ensuite présenter ceux obtenus par le modèle MLP.

5.1 Méthodologie Box-Jenkins appliquée, pour la prévision de l'évolution mensuelle des importations mensuelles algériennes

Nous appliquons un algorithme selon la méthodologie Box et Jenkins (1971), afin de prévoir la série mensuelle des importations algériennes. Nous allons présenter les différentes étapes, qui permettent de formaliser un modèle de prévision de courte période.

L'étalonnage d'un modèle de prévision s'effectue sur un petit sous-échantillon d'une série temporelle en fin de période. De ce fait, nous retirons à la série les trois derniers mois, que nous allons comparer aux prévisions effectuées par le modèle retenu, découlant de l'algorithme de Box et Jenkins. La première étape, consiste à « nettoyer » la série, d'éventuelles valeurs aberrantes, pouvant fortement chahuter le comportement « conventionnel » des composantes de la série temporelle.

La procédure *seasplot()* sous logiciel R, teste la présence d'une tendance pour ensuite tester également la présence d'un mouvement saisonnier. La présence de ces deux composantes sont confirmées par ce test.

```
> seasplot(impvalmp)
Results of statistical testing
Evidence of trend: TRUE (pval: 0.005)
Evidence of seasonality: TRUE (pval: 0)
```

Nous testons dans une seconde étape, la stationnarité de notre série temporelle. Nous exploitons trois tests, les plus utilisés, afin de comparer les résultats. Le principe général, consiste à tester la présence d'une racine unitaire, selon trois modèles différents : avec constante et trend, sans trend avec constante et sans constance ni trend. Nous éliminons les situations pour

mieux représenter la série, jusqu'à conclure sur quel modèle retenir, afin de tester la racine unitaire (la non stationnarité).

On teste selon le modèle spécifique sous l'hypothèse H_0 , la présence d'une racine unitaire, contre l'alternative H_1 , de stationnarité et nous concluons selon le modèle caractérisant la série temporelle. Le tests de Dickey-Fuller augmenté, présente des p-value toutes significatives, confirmant la présence d'une racine unitaire. Celui de Phillips-Perron décèle la non-stationnarité, uniquement pour le modèle sans constante ni trend, confirmant un processus DS. Celui de KPSS^{††} en revanche, a plus de mal à confirmer la non stationnarité pour le premier modèle, probablement à cause du chahut présent dans les fluctuations de la série^{‡‡}.

Table N° 1. tests de stationnarité de la série des importations, en niveau.

Augmented Dickey-Fuller Test alternative: stationary								
Type 1: no drift no trend			Type 2: with drift no trend			Type 3: with drift and trend		
Lag	stat	p.value	lag	stat	p.value	lag	stat	p.value
4	0.638	0.826	4	-1.87	0.3805	4	-2.13	0.5172
Phillips-Perron Unit Root Test alternative: stationary								
4	0.38	0.774	4	-43.7	0.01	4	-72	0.01
KPSS Unit Root Test alternative: nonstationary								
2	0.526	0.1	2	1.36	0.01	2	0.525	0.01

Source : résultats de tests sous logiciel R, par l'auteur.

^{††} Le test d'hypothèses H_0 et H_1 pour KPSS, est inversé : le contraire des tests ADF et P-P.

^{‡‡} Nous éviterons de détailler les tests. Tout intéressé, pourra se référer aux ouvrages de référence.

En effectuant les mêmes tests sur la série différenciée, elle devient stationnaire : les p-value deviennent inférieures à 5 %, l'erreur de première espèce (supérieure pour KPSS).

Table N° 2. Tests de stationnarité des importations, en différence première.

Augmented Dickey-Fuller Test alternative: stationary								
Type 1: no drift no trend			Type 2: with drift no trend			Type 3: with drift and trend		
Lag stat p.value			lag stat p.value			lag stat p.value		
4	-7.47	0.01	4	-7.55	0.01	4	-7.54	0.01
Phillips-Perron Unit Root Test alternative: stationary								
4	-175	0.01	4	-175	0.01	4	-175	0.01
KPSS Unit Root Test alternative: nonstationary								
2	0.56	0.1	2	0.0989	0.1	2	0.0561	0.1

Source : résultats de tests sous logiciel R, par l’auteur.

La série étant stationnarisée en différence, nous lui appliquons également une différenciation en t-12, afin de lui retirer la composante saisonnière. Nous pouvons ainsi, estimer les coefficients d'autocorrélations simples et partiels, afin d'identifier le modèle adéquat pouvant au mieux représenter la série mensuelle de flux.

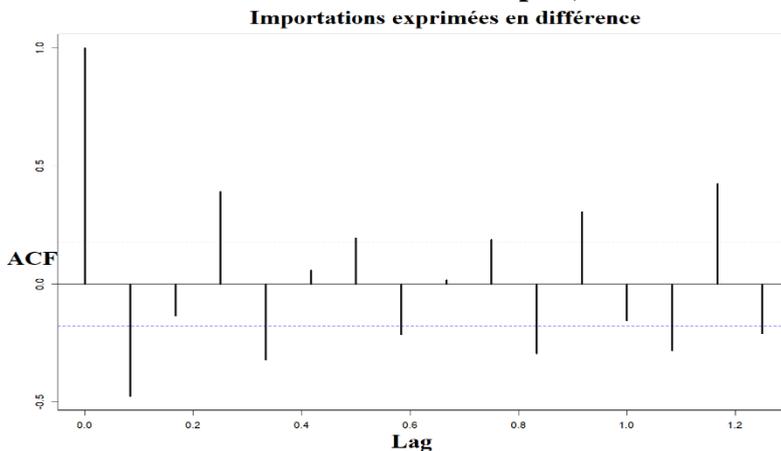
Notons qu'une procédure sous R, *auto.arima()*, estime sous critères de minimisation (AIC, etc.), automatiquement le modèle optimal. Néanmoins, au vu de l'aspect de la série trop chahuté par des valeurs aberrantes, le modèle estimé qui a été retenu est sous la forme : ARIMA(2,1,0)(1,0,0). Ceci est une indication, mais nous allons performer d'autres options, afin d'affiner les caractéristiques du modèle optimal à retenir, par « avis d'expert ».

Le graphique des autocorrélations simples (Figure 2), calculé sous procédure *acf()* dans R, donne un premier coefficient d'autocorrélation significatif, avec des perturbations induisant des autocorrélations d'ordre supérieur. Celui des autocorrélations partielles (Figure 3) calculé sous *pacf()*, donne deux

coefficients partiels significatifs, les suivants étant significativement proches de zéro.

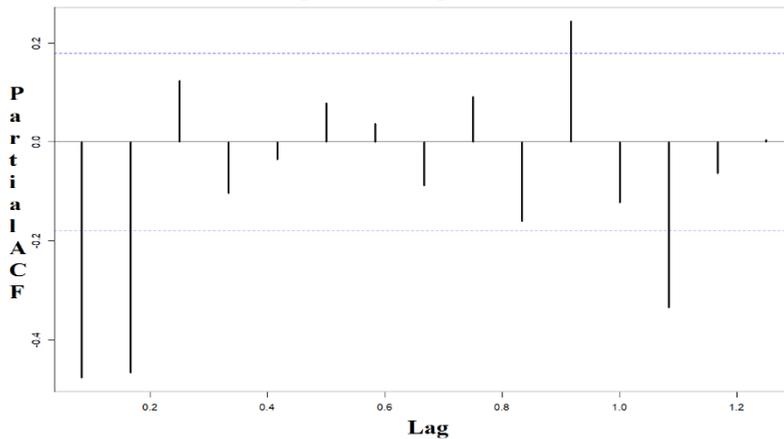
Nous retenons ainsi de premier abord, un modèle ARIMA (2,1,1) pour modéliser et prévoir la série. La composante saisonnière sera incorporée et nous testerons chaque cas, selon les critères de minimisation et selon la présence d'une racine unitaire saisonnière ou pas. Afin de conclure sur un modèle final optimal, nous le testerons sous la forme SARIMA(2,1,1)(1,0,0) ou bien SARIMA(2,1,1)(1,1,0) pour la partie saisonnière côté SAR, sinon, SARIMA(2,1,1)(0,0,1) ou bien SARIMA(2,1,1)(0,1,1), pour la partie saisonnière côté SMA. En sachant qu'il y aura une différenciation d'ordre 12, à tester selon la présence ou non d'une racine unitaire saisonnière. Notons enfin, que nous testerons les cas où l'on va exprimer (ou non) la série en logarithme.

Figure N° 2. Fonction d'autocorrélations simples, de la série différenciée.



Source : procédure sous logiciel R.

Figure N° 3. Fonction d'autocorrélations partielles, de la série différenciée.
Importations exprimées en différence



Source : procédure sous logiciel R.

La puissante procédure *seas()* sous R, estime un modèle SARIMA avec de nombreuses possibilités de configuration. Elle se base sur le choix entre les deux méthodes de désaisonnalisation, les plus utilisées dans les organismes mondiaux de référence, à savoir X13-ARIMA du Bureau of Census américain, et Tramo-Seats de l'université de Madrid. La mise à jour de la procédure, aboutit actuellement à la méthode combinée X13-TS^{§§}.

Nous pouvons soit laisser la procédure calculer le modèle optimal, ce qui est fortement déconseillé, sinon, spécifier quelques paramètres élémentaires, comme l'ordre AR, MA, SAR et SMA, ainsi que l'intégration de la série à modéliser. La procédure dispose également d'un bloc de "nettoyage" de la série des valeurs aberrantes, prenant en considération différents cas de ces dernières.

Nous avons souhaité afin d'étalonner le modèle, garder hors modélisation les 3 derniers mois de la série, de janvier à mars 2022. Nous effectuons ainsi, la prévision que nous allons comparer aux valeurs effectives de la série durant cette même période.

^{§§} <https://cran.r-project.org/vignettes/seas>

Le seuil critique d'identification des valeurs aberrantes étant par défaut 5, a été baissé à 3 pour plus de contrainte d'identification de la procédure, à cause d'un fort chahut dans les fluctuations de notre série temporelle. Les résultats d'estimation, sont présentés dans le tableau 3.

Comme observé sur le graphique de la série, la procédure a détecté pas moins de 9 valeurs atypiques. Elles sont identifiées selon différentes natures, qu'elles soient en variation forte instantanément, ou bien d'autres phénomènes comme un changement de niveau dans la série. En général, on préconise de ne garder que les plus importantes et éviter de retenir trop de valeurs atypiques, au risque de perturber les autres composantes de la série. Néanmoins, nous avons souhaité garder ces 9 points car les résultats d'estimation et de prévision (nous le verrons), s'avèrent meilleurs. D'autant plus que la taille de l'échantillon importante de plus de 130 points, nous permet de les garder toutes.

Les coefficients AR(1) et AR(2) sont significatifs. Le MA(1) est à peine significatif et nous souhaitons au vu des résultats d'estimation, le garder dans le modèle. La présence d'une saisonnalité notoire est confirmée, avec un coefficient SAR(1) estimé significatif. Notons enfin, qu'en plus de la différenciation d'ordre 1 pour la stationnarisation, la procédure donne de meilleurs résultats, en la différenciant à l'ordre 12, à cause d'une probable présence d'une racine unitaire saisonnière.

Table N° 3. Résultats d'estimation : modèle ARIMA(2 1 1)(1 1 0).

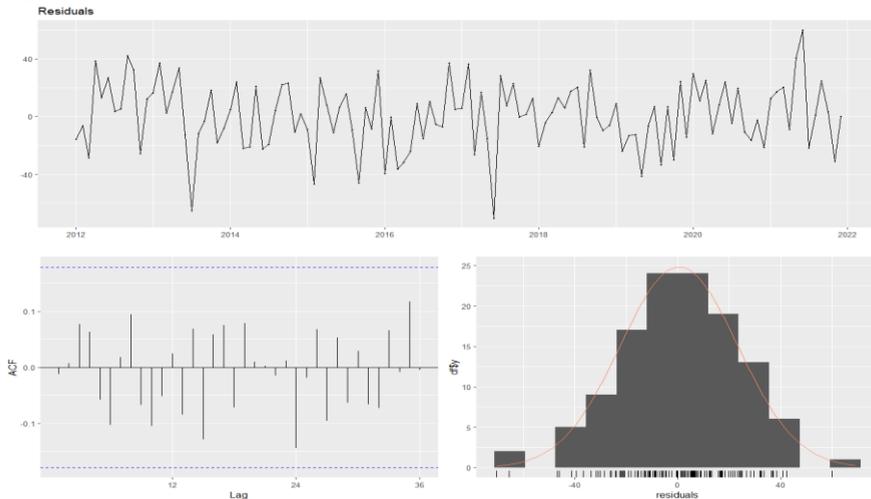
Call: seas(x = impvalmp, arima.model = "(2 1 1)(1 1 0)", outlier.critical = 3)				
Coefficients:	Estimate	Std. Error	z value	Pr(> z)
AO2012.Oct	67.41342	15.85210	4.253	2.11e-05
LS2013.May	-48.11786	14.62708	-3.290	0.001003
AO2016.Aug	58.79372	15.24062	3.858	0.000114
AO2016.Dec	54.32956	15.32951	3.544	0.000394
AO2017.May	-74.74038	15.80053	-4.730	2.24e-06

LS2019.Oct	-50.41888	14.61252	-3.450	0.000560
LS2020.Mar	-76.91262	15.34858	-5.011	5.41e-07
LS2020.Jun	72.91482	15.01787	4.855	1.20e-06
AO2021.Dec	83.73299	23.29536	3.594	0.000325
AR-Nonseasonal-01	-0.91577	0.11557	-7.924	2.31e-15
AR-Nonseasonal-02	-0.65018	0.07470	-8.704	< 2e-16
AR-Seasonal-12	0.29606	0.09089	-3.257	0.001124
MA-Nonseasonal-01	-0.28580	0.15156	-1.886	0.059328
SEATS adj. ARIMA: (2 1 1)(1 1 0) Obs.: 132 Transform: non				
AICc: 1136, BIC: 1185 QS (no seasonality in final): 0				
Box-Ljung (no autocorr.): 16.85 Shapiro (normality): 0.9906				

Source : Procédure *seas()*, sous logiciel R.

Les résidus (dernière ligne du tableau 3 et figure 4) du modèle présentent de bonnes propriétés d'un bruit blanc, avec une absence d'autocorrélation (test de Ljung-Box), suivant une loi normale (test de Shapiro-Wilk). Le graphique des autocorrélations (ACF), ne montre pas de coefficient significatif, ni de possible valeur aberrante apparente (qui sort de l'intervalle de confiance).

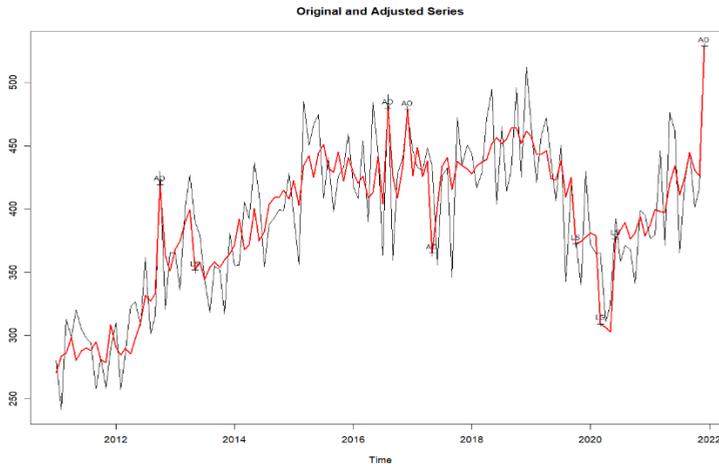
Figure N° 4. Analyse des résidu du modèle SARIMA(2,1,1)(1,1,0).



Source : procédure sous logiciel R.

Le graphique 5, montre l'ajustement du modèle estimé à la série des flux des importations, avec l'identification de plusieurs valeurs aberrantes, essentiellement des « additive outlier » et quelques valeurs en « level shift ».

Figure N° 5. Ajustement de l'estimation du modèle, à la série brute.



Source : effectué sous logiciel R.

À partir du moment où le modèle retenu présente de bonnes propriétés, nous avons effectué une prévision des 3 premiers mois de 2022. La prévision est comparée aux mêmes mois de la série originelle utilisés comme cible, afin de vérifier la pertinence et la robustesse du modèle.

Nous avons calculé les écarts absolus, entre le mois effectif et sa prévision (tableau 4). Le meilleur point prévu, est celui de janvier à 1,27 % d'erreur. Vient ensuite celui de mars, à 3,5 %. Le mois de février, dépasse les 7 %.

La moyenne de ces erreurs absolues (MAPE), est de 3,98 %. Cette erreur de prévision moyenne est assez faible, et demeure très pertinente au vu des caractéristiques très chahutées de la série étudiée.

Table N° 4. Prédiction à 3 mois, des importations mensuelles algériennes.

	Janvier 2022	Février 2022	Mars 2022
Valeurs effectives	450.0	446.6	498.6
Prédiction	444.2541	414.4986	481.2345
Écart absolu (%)	1.276857	7.187954	3.482857
MAPE (%)	3.982556		

Source : calculés, sous logiciel R.

5.2 Prédiction des importations algériennes, par le réseau de neurones MLP

Les MLP, sont des réseaux de neurones assez complexes et difficiles à paramétrer. Bien qu'ils soient de plus en plus utilisés dans la prédiction des séries temporelles, la difficulté réside dans le fait d'identifier le nombre de couches ainsi que le nombre de paramètres à introduire, pour une bonne minimisation de l'erreur, compte tenu des pondérations introduites.

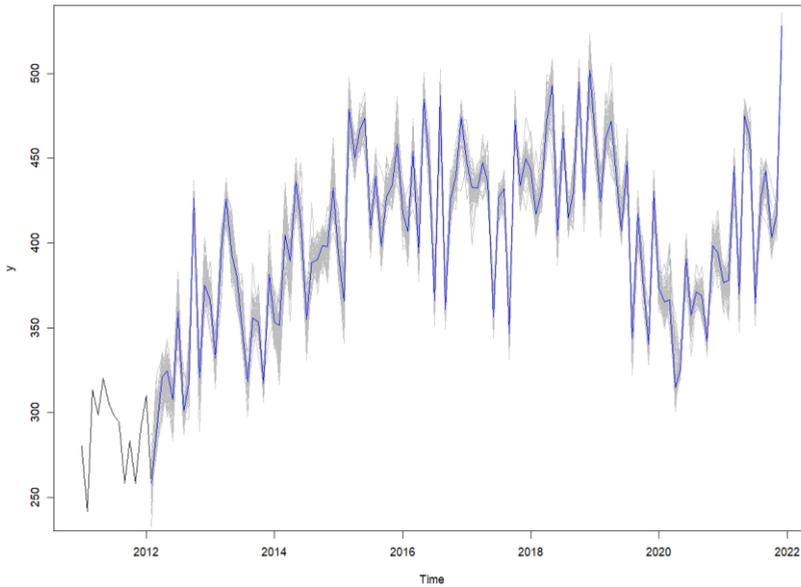
La procédure *mlp()* dans R, permet cependant de bien spécifier les paramètres à introduire dans le modèle. Nous avons d'abord naïvement lancé la procédure automatiquement, en laissant le logiciel optimiser ce paramétrage, pour ensuite imposer certaines contraintes comme le nombre de retards, la périodicité de la série, ainsi que l'éventuelle introduction de variables muettes, caractérisant le mouvement saisonnier mensuel de notre série économique.

Après plusieurs tentatives, nous avons retenu le modèle suivant, implémenté dans la procédure :

```
x=mlp(impvalmp, reps=100, retrain=T, difforder=NULL, outplot=T, allow.det.season =T)
```

Le graphique 6, donne un aperçu de l'ajustement du modèle sur la série originelle des importations. Autour de cet ajustement, on observe des fluctuations grisées, qui montre le nombre de tentatives afin d'atteindre un optimum d'ajustement.

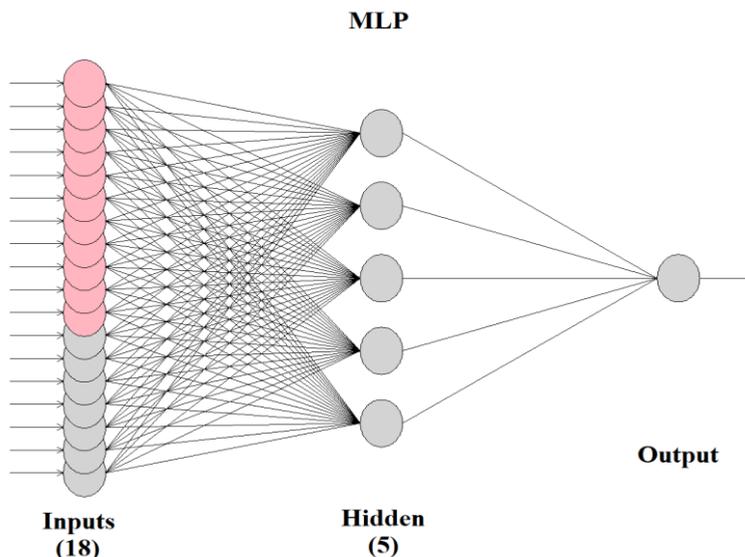
Figure N° 6. Ajustement du modèle MLP sur les importations mensuelles algériennes.



Source : effectué sous logiciel R.

La procédure a retenu 18 entrées - ou paramètres - (figure 7), compte tenu de la saisonnalité et du bruit contenu dans la série. En notant que la non-linéarité présente dans la composante saisonnière et le résidu, est bien prise en compte par cette technique de modélisation. 5 couches cachées sont également retenues pour le modèle final optimal.

Figure N° 7. Modèle MLP compilé, appliqué aux importations algériennes.



Le tableau 5, représente les prévisions sur les trois derniers mois de la série, comparées avec ses valeurs effectives. Le meilleur mois prévu étant le mois de février, avec une erreur de moins de 2 %, comparativement aux deux autres mois avec des écarts un peu plus élevés. La statistique d'erreur moyenne absolue sur les trois mois est de l'ordre de 3,33 %, plus faible mais assez proche que celle calculée dans la modélisation ARIMA.

Retenons cependant, que la recompilation de la même procédure, avec le même paramétrage, peut conduire à des prévisions - légèrement - différentes.

Table N° 5. Prédiction à 3 mois, des importations mensuelles algériennes.

	Janvier 2022	Février 2022	Mars 2022
Valeurs effectives	450.0	446.6	498.6
Prédiction	429.7318	439.0996	517.6640
Écart absolu (%)	4.504040	1.679438	3.823497
MAPE (%)	3.335658		

Source : calculés, sous logiciel R.

5. Discussion

Les résultats obtenus par les deux méthodes ARIMA et MLP, sont satisfaisantes voire même excellentes, vu l'aspect chahuté de la série des importations mensuelles algériennes. Prévoir trois mois de cette série avec une erreur moyenne absolue de près de 3 %, conforte l'idée de pouvoir exploiter de ces deux techniques en vue de la prévision à court terme.

Cependant, si les résultats sont équivalents, ceci ne nous empêche pas de mettre des réserves sur les modèles MLP, moins basés sur des fondements ou algorithmes plus stricts et contraignants que ceux imposés à la validation des modèles ARIMA, comme la méthodologie Box et Jenkins.

Ajoutons à cela, l'instabilité des résultats, quand la procédure MLP est relancée à plusieurs reprises, qui ne donnera pas les mêmes résultats. Ces derniers seront certes relativement proches dans un intervalle de confiance raisonnable, mais qui pourraient être remis en cause sur des prévisions de plus longue périodes, sur plusieurs mois.

6. Conclusion

Si le modèle MLP a pu réaliser des erreurs de prévision minimales, comme pour le modèle ARIMA, deux problèmes peuvent néanmoins être soulevés :

- Le paramétrage de cette technique de modélisation,
- et la stabilité de ses estimations.

Il est possible de nos jours, de proposer des procédures automatisées, faciles à paramétrer sous un logiciel de statistiques. Cependant, il persiste un danger de pouvoir les utiliser sans pour autant maîtriser parfaitement leur mécanisme. Les modèles de réseaux de neurones en général, ressemblent aux modèles économétriques, sur le principe de minimisation d'écarts entre une (ou plusieurs) variable(s) d'intérêt et son (ou leur) ajustement(s). en revanche, les algorithmes complexes qui sont utilisés pour passer d'une phase de test à une phase de validation, peuvent demeurer opaques pour certains utilisateurs.

Dans un autre volet, bien que la mathématique propose des méthodes assez puissantes pour justement optimiser les calculs, nous pensons qu'elles ne

devraient pas être utilisées sans critique, au vu de la complexité des valeurs réelles qui représentent un phénomène donné.

Le deuxième point, accompagne les critiques déjà citées concernant le premier. Comment savoir si effectivement, les paramètres ont bien été choisis, pour les introduire dans la procédure ? nous ne pouvons pas outrepasser les fondements théoriques de la statistique mathématique, notamment en inférence statistique, ni la théorie économique qui doit trouver un sens viable sur le choix du paramétrage.

Nous pensons qu'il serait utile d'exploiter ces méthodes puissantes, mais pas en « boîte fermée ». Il faudra soit d'un côté traiter préalablement les séries avant de les modéliser, soit d'un autre côté, analyser compte tenu de leur structure, les paramètres pouvant les influencer réellement.

La littérature propose à ce sujet, des méthodes hybrides qui devraient attirer l'attention de l'analyste, car ceci pourrait conduire à obtenir des résultats meilleurs et stables, à condition d'être prudent sur l'appui des fondements théoriques, pour le bon paramétrage des procédures de calcul.

Bibliographie

- Abdoli, G., Mehrara, M., Ardalani, M., E., (2020) COMPARING THE PREDICTION ACCURACY OF LSTM AND ARIMA MODELS FOR TIME-SERIES WITH PERMANENT FLUCTUATION, *Periódico do Núcleo de Estudos e Pesquisas sobre Gênero e Direito Centro de Ciências Jurídicas - Universidade Federal da Paraíba* V. 9 - N° 02.
- Aslanargun, A., Mammadov, M., Yazici, B., Yolacan, S. (2007, January) Comparison of ARIMA, neural networks and hybrid models in time series: Tourist arrival forecasting, *Journal of Statistical Computation and Simulation*. DOI: 10.1080/10629360600564874.
- Box, G. and Jenkins, G. (1970) Time Series Analysis: Forecasting and Control. *Holden-Day, San Francisco*.
- Dave, E., Leonardo, A., Jeanice, M., Hanafiah, N. (2021) Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM, *Procedia Computer Science*, 179, 480–487.
- *Kia, A., N., Fathian, M., Gholamian, M., R. (2012, July) Using MLP and RBF Neural Networks to Improve the Prediction of Exchange Rate Time

Series with ARIMA, *International Journal of Information and Electronics Engineering*, Vol. 2, No. 4.

- Kobiela, D., Krefta, D., Król, W., Weichbroth, P. (2022) ARIMA vs LSTM on NASDAQ stock exchange data, *Procedia Computer Science*, 207, 3830–3839.
- Longo, L., Riccaboni, M., Rungi, A. (2022) A neural network ensemble approach for GDP forecasting, *Journal of Economic Dynamics & Control*, 134, 104278.
- Oliveira, D., D., Rampinelli, M., Tozatto, G., T., Varejaõ Andreaõ, R., Müller. S., M., T. (2021) Forecasting vehicular traffic flow using MLP and LSTM, *Neural Computing and Applications*, 33:17245–17256. <https://doi.org/10.1007/s00521-021-06315-w>
- Qu, Q., Z., Tang, J., Wu, S., Wang, R. (2019) A Trend Forecast of Import and Export Trade Total Volume based on LSTM *IOP Conf. Series: Materials Science and Engineering* 646, 012002. doi:10.1088/1757-899X/646/1/012002
- Siami-Namini, S., Tavakoli, N., Siami Namin, A. (2018, December) A Comparison of ARIMA and LSTM in Forecasting Time Series *Conference Paper*. DOI: 10.1109/ICMLA.2018.00227
- Shen, M., L., Lee, C., F., Liu, H., H., Chang, P., Y., Yang, C., H. (2021) Effective multinational trade forecasting using LSTM recurrent neural network, *Expert Systems With Applications*, 182, 115199.
- Taweh Beysolow II (2017) *Introduction to deep learning using R*, Apress.
- Weytjens, H., Lohmann, E., Kleinstauber, M. (2021) Cash flow prediction: MLP and LSTM compared to ARIMA and Prophet, *Electronic Commerce Research*, 21:371–391. <https://doi.org/10.1007/s10660-019-09362-7>