

HEC MONTRÉAL

Stratégies Algorithmiques sur Indices de CDS avec
le Filtre de Kalman

Par

Amine El Kaouachi

Sciences de la Gestion
Option: Ingénierie Financière

*Mémoire présenté en vue de l'obtention du
grade de maîtrise ès sciences (M.Sc.)*

Décembre 2014
© Amine El Kaouachi, 2014

REMERCIEMENTS

Avant tout, je désire remercier ma mère pour son support inconditionnel. Aussi, je remercie ma directrice de mémoire Pascale Valéry pour sa contribution, son support et ses commentaires instructifs. Finalement, je souhaite remercier toute l'équipe d'analyse quantitative revenu fixe à la Caisse de Dépôt et Placement du Québec pour leurs précieux conseils et leur accueil chaleureux au sein de leur équipe.

TABLE DES MATIÈRES

TABLE DES MATIÈRES	5
1. INTRODUCTION	1
2. REVUE DE LITTÉRATURE	3
3. LE FILTRE DE KALMAN DISCRET	7
4. SPÉCIFICATION DU MODÈLE	9
4.1 Modèle de la Société Générale (2013)	9
4.2 Modèle à tendance stochastique	10
4.3. Estimation des paramètres	13
4.4 Implémentation de l'algorithme d'optimisation	15
5. GÉNÉRATION DE SIGNAUX	17
5.1 Indicateur de tendance	17
5.2 Indicateur de retour à la moyenne	19
5.3 Combinaison des deux signaux	20
6. DONNÉES	21
6.1 Indices de crédit	21
6.2 Rendements totaux de l'indice (<i>Total Return</i>)	21
6.3 Statistiques descriptives	22
7. ANALYSE DES RÉSULTATS	23
7.1 Analyse de la décomposition	23
7.2 Analyse de sensibilité – Impact du paramètre σ_2	24
7.3 Analyse de performance	26
Performance - CDX High Yield	27
Figure 2.A Positions sur l'indice CDX High Yield	27
Figure 2.B Positions sur l'indice CDX High Yield	27
Performance : CDX High Yield en calibrant la borne inférieure $\sigma_2^{inf} = 50\%$	31
Figure 3.A Performance de la stratégie appliquée au CDX High Yield - $\sigma_2^{inf} = 50\%$	31
Figure 3.B Positions sur l'indice CDX High Yield avec $\sigma_2^{inf} = 50\%$	31
8. CONCLUSION	33
9. ANNEXES	36
Annexe 1 : Filtre de Kalman Discret - Introduction	36
Annexe 2 : Filtre de Kalman Discret – Forme Générale	41
Annexe 3 : Série de rendements totaux – CDX High Yield	45
Annexe 4: Indices de crédit	46
A.4.1 : Description des indices de crédit	46
A.4.2 : Tableau des Statistiques Descriptives	47
Annexe 5: Indice de crédit et son logarithme	48
Annexe 6.A : Résultats de la décomposition par le modèle à tendance stochastique	50
A.6.1 : iTraxx Main	50
A.6.2 : iTraxx X-Over	51
A.6.3 : CDX Investment Grade	52
A.6.4 : CDX High Yield	53
Annexe 6: Impact de la variation de σ_2^{inf} - modèle à tendance stochastique - CDX High Yield	54
A.6.1: Décomposition avec le modèle à tendance stochastique en calibrant $\sigma_2^{inf} = 10^{-10}$	54
A.6.2: Décomposition avec le modèle à tendance stochastique en calibrant $\sigma_2^{inf} = 10\%$	55
A.6.3: Décomposition avec le modèle à tendance stochastique en calibrant $\sigma_2^{inf} = 50\%$	56
Annexe 7: Performance en- échantillon et hors-échantillon	57
A.7.1 : Performance – iTraxx Main	57
A.7.2 : Performance – iTraxx X-Over	59

Figure 15.A Positions sur l'indice CDX Investment Grade exposées sur sa série de rendements totaux	59
15.B Positions sur l'indice CDX High Yield.....	59
A.7.3: Performance – CDX Investment Grade	61
Figure 16.A Positions sur l'indice CDX Investment Grade exposées sur sa série de rendements totaux	61
Figure 16.B Positions sur l'indice CDX High Yield	61
Figure 16.C Statistiques de performance et mesures de risque de la stratégie pour le CDX IG62	
Figure 17.A Ratio d'Information pour la stratégie sur l'indice CDX High Yield	63
Figure 17.B Ratio d'Information pour la stratégie sur l'indice CDX High Yield en calibrant $\sigma_{2inf} = 50\%$	63
10. BIBLIOGRAPHIE	64

1. INTRODUCTION

L'innovation financière a donné naissance à de nouveaux instruments tels que les contrats de défaillance de crédit - CDS - qui sont devenus incontournables dans la gestion de portefeuilles obligataires et de risques de crédit. L'achat d'un contrat CDS permet de se protéger contre le risque de défaut d'une obligation corporative ou souveraine. Le défaut peut être sous la forme d'une faillite, d'un non-paiement, d'une restructuration, ou d'autres événements mentionnés dans les spécifications du contrat. Les CDS peuvent tout aussi bien être utilisés à des fins spéculatives puisqu'il est possible d'acheter ou vendre le CDS sans posséder le sous-jacent.

Un indice de CDS est simplement un portefeuille de CDS, servant ainsi d'instrument financier et de baromètre des conditions du marché de crédit. Les indices de CDS constituent un candidat parfait pour les stratégies statistiques de compression / décompression car ils sont parmi les instruments les plus liquides dans la sphère du crédit.

Nous présentons un modèle à tendance stochastique permettant de décomposer une série temporelle financière en la somme de deux composantes distinctes : un processus de marche aléatoire avec tendance stochastique (non-stationnaire) et un processus de retour à la moyenne (stationnaire).

L'idée provient initialement d'une publication de la Société Générale (Dando et Turc 2013). Après avoir présenté le modèle de la Société Générale (Dando et Turc 2013), nous proposons une nouvelle spécification avec l'introduction d'une tendance stochastique similaire à celle du modèle de Kim et Nelson (1998). Nous trouvons que la décomposition de l'indice de crédit change en fonction des valeurs initiales allouées en particulier au paramètre σ_2 , la volatilité de la tendance stochastique. Par ailleurs, cette propriété nous donne un contrôle sur la décomposition de l'indice de crédit en affectant le lissage de la composante tendancielle et l'amplitude du mouvement de retour vers la moyenne permettant améliorant ainsi la performance de la stratégie dans le cas du *CDX High Yield*.

Ce modèle n'impose pas l'absence d'opportunité d'arbitrage et se base uniquement sur la décomposition par le filtre de Kalman du log-spread d'un indice donné à partir de prix observés dans le marché. Étant donné que la méthode du filtre de Kalman nous donne une convergence locale, nous testons la stabilité des paramètres estimés en perturbant les valeurs initiales de notre système et retenons la solution optimale du problème d'optimisation. Dans un premier temps, on utilise cette décomposition pour générer des signaux d'achat ou de vente, puis on teste la stratégie sur quatre séries d'indices de crédit, soit l'*iTraxx Main*, l'*iTraxx X-Over*, le *CDX Investment Grade* et le *CDX High Yield*. On extrait alors des signaux d'achat et de vente dans le cadre d'une stratégie de construction de portefeuille dont nous mesurons ensuite la performance.

En utilisant l'estimation des paramètres obtenus par le processus d'optimisation du modèle à tendance stochastique, la stratégie donne des résultats globalement insatisfaisants en termes de performance, à l'exception du cas du *CDX High Yield*. Parallèlement, dans le cas de l'échantillon des quatre indices considérés dans le cadre de cette étude, nous trouvons que la stratégie ne semble pas dépendre du niveau de risque du produit transigé.

Pour l'indice *CDX High Yield*, nous parvenons à contrôler le lissage de la tendance en calibrant la borne inférieure de la volatilité de la tendance stochastique du modèle lors de l'algorithme d'optimisation. Ceci résulte également en un contrôle de l'amplitude allouée au processus de retour vers la moyenne, donnant des performances clairement améliorées avec une augmentation de 332% du ratio Sharpe.

2. REVUE DE LITTÉRATURE

La célèbre hypothèse d'efficience du marché financier d'Eugene Fama (1970) implique qu'un agent ne peut espérer battre le marché de manière consistante, soit enregistrer des rendements réalisés supérieurs au marché de façon consistante dans le temps. Toutefois, depuis le début des années 1990, de nombreux académiciens se basent sur des cas spécifiques pour remettre en perspective cette hypothèse. En effet, Rozeff et Kinney (1976) montrent que les espérances de rendements pour le mois de Janvier sont historiquement supérieures à celles des autres mois de l'année; phénomène connu sous le nom de « January effect ». French (1980) a documenté le « Monday effect » montrant une tendance à avoir des rendements négatifs les lundis, contrastant avec leur tendance à être positifs durant les autres jours de la semaine. D'autres anomalies notables incluent le 'P/E Ratio Effect' (Basu, 1977) et le 'Small firm effect' (Banz, 1981). De plus, Shleifer (1986) ainsi que Harris et Gurel (1986) notent une hausse surprenante du prix d'une action (jusqu'à 3%) après l'annonce de son inclusion dans l'indice du S&P 500, aussi connu sous le nom du 'S&P effect'.

Hong et Stein (1997) montrent que les agents ne sont pas totalement rationnels en exposant que les prix sous-réagissent à court-terme et sur-réagissent à long terme. Ce phénomène pourrait être expliqué par la théorie de la finance comportementale (Barberis et Thaler 2003). Il est aujourd'hui largement accepté que les prix suivent des tendances et affichent une propriété de retour à la moyenne. Cette idée est supportée par Cochrane (2001) qui montre que les primes de risque varient dans le temps et dépendent du cycle économique. Serait-il alors possible de décomposer une série temporelle financière en deux processus distincts; soit une tendance et un processus de retour à la moyenne?

La décomposition des séries temporelles a une longue histoire mathématique. Elle découle du théorème de représentation de Wold (1953) que toute série faiblement stationnaire (en covariance) peut s'écrire comme la somme de deux séries: une série déterministe et une série stochastique. Toutefois, il est rare de trouver des séries temporelles financières qui vérifient cette condition de stationnarité en covariance. Qu'en est-il concernant les séries non-stationnaires?

Bien qu'on ne retrouve pas de définition formelle du concept de '*tendance*' dans la littérature, on l'interprète souvent comme étant un mouvement directionnel persistant dans les données. En utilisant un théorème de Cartier et Perrin (1995), Fliess et Join (2009) montrent l'existence de tendances dans les séries temporelles financières.

Fliess et Join (2009) montrent aussi qu'une série temporelle financière donnée peut s'écrire comme la somme d'une tendance et d'une fonction fluctuant rapidement autour de zéro. Pour réaliser leurs estimations, ils utilisent des techniques relevant du domaine du traitement de signal. Dans ce papier, nous utiliserons la méthode du filtre de Kalman.

Les utilisations initiales du filtre de Kalman relèvent du domaine de l'ingénierie et plus particulièrement celui du traitement de signal. Quant à ses applications dans le domaine de l'économie et de la finance, celles-ci sont relativement récentes.

Le domaine de la macroéconomie compte des applications importantes du filtre de Kalman, en particulier pour la décomposition d'une série temporelle en une tendance et une composante cyclique. Kim et Nelson (1998) ont utilisé le filtre de Kalman dans un modèle contenant une composante non-observée du PIB réel en utilisant une marche aléatoire avec tendance stochastique.

Wada et Perron (2006) présentent une décomposition du PIB Américain en une tendance et une composante cyclique en utilisant le filtre d'Hodrick et Prescott (HP filter) et estiment la fonction du maximum de vraisemblance en utilisant une variante du filtre de Kalman.

Le filtre de Kalman a aussi été utilisé dans le domaine des titres à revenu fixe. En effet, Racicot et Théoret (2011) utilisent le filtre de Kalman pour estimer et prévoir la volatilité stochastique sur les taux d'intérêt Canadiens à court-terme. De plus, ils font une prévision du ratio P/E du S&P 500 et obtiennent des résultats proches de ceux obtenus via un GARCH(1,1).

Dal Bianco *et al.* (2012) utilisent le filtre de Kalman pour la prévision à court terme du taux de change EUR/USD en se basant sur un modèle économétrique avec des variables indépendantes (incluant des différentiels de taux d'intérêts, d'inflation et de croissance de la masse monétaire M1) de fréquences différentes. Les auteurs font référence à l'importante recherche de Meese et Rogoff (1983), « *beating the random walk* » par laquelle le mouvement de marche aléatoire est devenu le modèle de référence pour l'évaluation des taux d'intérêt en macroéconomie internationale. Ils estiment les paramètres dans une période en-échantillon et les backtestent dans une période hors-échantillon. Ils obtiennent des résultats encourageants vu que leur modèle a une valeur ajoutée par rapport à l'estimation d'une marche aléatoire.

Cassano et Sick (2012) présentent un modèle de retour à la moyenne à deux facteurs du prix des futures de cuivre sur le NYMEX. Ils utilisent le logarithme des prix spot des commodités pour garantir le signe positif de la commodité et estiment les paramètres inconnus à l'aide du filtre de Kalman selon la méthode du maximum de vraisemblance.

Ramaprasad Bhar (2010, chap.9) explique comment appliquer une approche espace-états et une version non-linéaire du filtre de Kalman ('unscented Kalman filter') pour estimer la volatilité implicite extraite des options sur les CDS selon le modèle d'Heston (1993).

Gilchrist et Egon (2010) ont construit un panier d'indices de crédit ayant un considérable pouvoir prédictif pour l'activité économique future. S'il est possible de trouver un lien économique entre les séries de PIB et les indices de CDS, on pourrait penser à utiliser les mêmes techniques de décomposition pour les indices de crédit que pour des séries de PIB. Notre papier utilise cette décomposition à des fins pratiques pour implémenter des stratégies de momentum.

Ces stratégies d'investissement se basent seulement sur les prix historiques (Chan *et al.* 1996). On distingue généralement deux types de stratégies momentum (Bruder *et al.* 2011) :

- Suivre la tendance (trend following) c'est-à-dire acheter (vendre) un actif lorsque la tendance estimée est positive (négative)

- Stratégie contrarienne (mean-reverting) qui consiste à aller à l'encontre de la tendance et donc à vendre (acheter) un actif lorsque la tendance estimée est positive (négative)

Dans ce papier, nous construisons une stratégie de momentum sur des indices de crédit. La spécification du modèle grâce au filtre de Kalman permet de prendre en compte le retour vers la moyenne lors de la génération des signaux de construction de portefeuille, constituant ainsi un point fort de la stratégie.

3. LE FILTRE DE KALMAN DISCRET

En 1960, Rudolf Kalman a publié un article intitulé '*A new Approach to Linear Filtering and Prediction Problems*' dans lequel il décrit l'algorithme qui sera connu comme le filtre de Kalman.

Le filtre de Kalman est un ensemble d'équations mathématiques qui permet d'estimer l'état d'un système à une date future, malgré l'imprécision des mesures et de la modélisation. C'est un algorithme récursif qui permet d'expliquer les états d'un système dynamique à partir d'une ou plusieurs mesures incomplètes ou bruitées.

La puissance du filtre de Kalman provient du fait qu'à chaque itération, il estime l'état du système, puis améliore ses résultats avec de nouvelles informations disponibles. Ainsi, le filtre de Kalman comporte deux phases: une phase de prédiction et une phase de mise à jour (aussi appelée de correction ou de révision) :

- 1- **Prédiction:** Le filtre de Kalman se sert des mesures actuelles et de l'état antérieur d'un système pour produire une estimation de son état courant.
- 2- **Mise à jour:** Les observations disponibles sont utilisées pour corriger l'état prédit dans le but d'obtenir une estimation plus précise.

Sorenson (1970) montre que le filtre de Kalman peut être considéré comme « une solution computationnelle efficace du problème des moindres carrés ». De plus, si les observations suivent une loi normale, le filtre de Kalman donne la solution optimale pour les problèmes de prédiction et de mise à jour.

Maybeck (1979) qualifie le filtre de Kalman d'« algorithme de traitement de données récursif optimal » (*optimal recursive data processing algorithm*) et souligne qu'un aspect de son optimalité est sa capacité à incorporer toute l'information qu'on lui fournit. De plus, le lissage et

la prévision se font dans la même étape dans l'algorithme du filtre de Kalman, minimisant ainsi les erreurs de lissage et permettant d'obtenir un meilleur résultat prévisionnel.

Le filtre de Kalman ne requiert pas que toute l'information soit stockée et réévaluée à chaque nouvelle mesure de l'état du système, ce qui est avantageux en termes de temps de calcul.

De manière récursive, on estime les paramètres optimaux à l'aide d'une fonction d'estimation telle que celle du maximum de vraisemblance.

Le filtre de Kalman linéaire a toutefois des limites, notamment :

1. Il ne s'applique pas aux modèles non-linéaires. Il existe cependant des variantes du filtre de Kalman qui permettent de traiter les cas où au moins l'une des équations de mesure et d'état est non-linéaire. Ces modèles peuvent être estimés en utilisant des filtres particuliers ou des méthodes de Monte Carlo séquentielles (Doucet *et al.* 2000). Ces méthodes sont plus robustes; en effet, le mécanisme de sélection séquentielle Monte-Carlo, permet aux particules d'évoluer de manière indépendante dans tout l'espace-état. Une revue des différentes méthodes de sélection est établie dans Gentil et Rémillard (2008).
2. La stabilité de la solution produite par le filtre de Kalman peut dépendre largement des valeurs assignées aux paramètres initiaux. Nous pallions à ce problème en perturbant les valeurs de départ des paramètres.
3. La convergence du filtre n'est pas assurée pour des modèles complexes.

Le filtre de Kalman linéaire existe sous une forme discrète et une forme continue. Étant donné la fréquence journalière de données, nous optons pour la version discrète du filtre de Kalman.

Dans l'*Annexe 1*, nous expliquons les étapes de l'algorithme du filtre de Kalman via un modèle discret univarié simple. Ensuite, en se basant sur l'intuition acquise, le lecteur peut se référer à l'*Annexe 2* pour une version générale du filtre de Kalman discret en utilisant la représentation espace-état.

4. SPÉCIFICATION DU MODÈLE

4.1 Modèle de la Société Générale (2013)

Cette section vise à expliquer le modèle de la Société Générale (Dando et Turc 2003), tel que décrit dans leur publication ‘*Trend-Following and mean-reverting strategies on credit indices*’ (2013). L’article expose une stratégie de trading algorithmique basée sur une décomposition d’indices de CDS en deux composantes : une tendance et un processus de retour à la moyenne. Les décompositions obtenues sont alors utilisées pour implémenter des stratégies de construction de portefeuille.

Soit S_t le logarithme d’un écart de crédit (spread) donné. On suppose que S_t peut s’écrire comme la somme d’une tendance et d’un processus de retour à la moyenne.

Nous avons donc

$$S_t = X_t + Y_t \quad (1)$$

où :

- X_t : Composante retour à la moyenne modélisée par un mouvement autorégressif (stationnaire) de premier ordre.
- Y_t : Composante lisse, modélisée par une marche aléatoire (non-stationnaire). Ainsi,

$$X_t = \alpha X_{t-1} + v_t \quad v_t \sim N(0, \sigma_v) \quad \alpha \in (0,1) \quad (2)$$

$$Y_t = Y_{t-1} + \varepsilon_t \quad \varepsilon_t \sim N(0, \sigma_\varepsilon) \quad (3)$$

- σ_v : la volatilité du processus autorégressif. σ_v contrôle l’amplitude du mouvement de la composante retour à la moyenne.

- σ_ε : la volatilité de la composante tendancielle. Elle contrôle la période de lissage. Plus σ_ε est grand, plus la composante tendancielle est proche de la variable observable S_t .
- $1-\alpha$: la vitesse de retour à la moyenne. Cette dernière peut être estimée grâce à la demi-vie, soit le temps moyen nécessaire pour que le processus atteigne la moitié de sa distance de la moyenne.

4.2 Modèle à tendance stochastique

Dando et Turc (2013) expliquent qu'ils n'ont pas réussi à estimer tous les paramètres par le maximum de vraisemblance et ont alors recours à la calibration. Cela nous a mené à repenser la spécification du modèle. Nous proposons donc une spécification similaire à celle de Kim et Nelson (1998) qui consiste à introduire une tendance stochastique au modèle. Cette section présente cette nouvelle spécification en détails.

Similairement à Dando et Turc (2013), nous considérons la série temporelle S_t , le logarithme du niveau d'un indice donné. L'usage du logarithme permet de capturer des mouvements exprimés en pourcentage et de s'assurer que nous gardons des prix d'indices strictement positifs.

On suppose que la série S_t peut s'écrire comme la somme d'une tendance et d'un processus de retour à la moyenne. Cette décomposition est justifiée par Fliess et Join (2009) dans le cadre des séries temporelles financières. D'où l'équation de mesure du modèle:

Équation de mesure:

$$S_t = X_t + Y_t \tag{4}$$

Les équations d'état vont comme suit :

Équations d'état:

$$X_t = \alpha X_{t-1} + e_{1t} \quad \alpha \in (0,1) \quad (5)$$

$$g_t = g_{t-1} + e_{2t} \quad (6)$$

$$Y_t = Y_{t-1} + g_{t-1} + e_{3t} \quad (7)$$

La série Y_t modélise la tendance du log-spread. C'est une marche aléatoire à tendance stochastique (non-stationnaire) similaire à Kim et Nelson (1998). X_t est le processus de retour à la moyenne, modélisé par un mouvement autorégressif stationnaire de premier ordre. En effet, la construction du processus force les racines du mouvement autorégressif à rester dans le cercle unitaire.

Les écarts types des terme d'erreurs e_{1t} , e_{2t} , e_{3t} sont respectivement σ_1 , σ_2 , σ_3 . Similairement à Kim et Nelson (1998), nous n'imposons aucune condition sur les écarts types des termes d'erreurs lors de l'optimisation additionnelle à leur signe strictement positif.

- σ_1 : l'écart type du processus autorégressif modélisant le mouvement de retour à la moyenne. σ_1 contrôle l'amplitude du mouvement de la composante retour à la moyenne.
- σ_2 : l'écart type de la dérive stochastique. Ce paramètre contrôle la volatilité de g_t , la tendance stochastique de notre modèle.
- σ_3 : l'écart type de la composante tendancielle. Ce paramètre contrôle la période de lissage. Plus σ_3 est grand, plus l'estimation de la composante tendancielle est proche de la variable observable.
- $1-\alpha$: la vitesse de retour à la moyenne. Cette dernière peut être estimée grâce à la demi-vie (half-life), soit le temps dont le processus a besoin (en moyenne) pour atteindre la moitié de sa distance de la moyenne. Intuitivement, plus α est grand, plus on se rapproche d'un processus racine unitaire.

Tout comme Kim et Nelson (1998), nous ne supposons aucune relation entre les trois paramètres $\sigma_1, \sigma_2, \sigma_3$. Le modèle peut s'écrire sous la représentation espace-états suivante:

Équation d'état :

$$\begin{bmatrix} X_t \\ g_t \\ Y_t \end{bmatrix} = \begin{bmatrix} \alpha & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} X_{t-1} \\ g_{t-1} \\ Y_{t-1} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \\ e_{3t} \end{bmatrix} \quad (8)$$

Équation de mesure :

$$S_t = [1 \ 0 \ 1] \cdot \begin{bmatrix} X_t \\ g_t \\ Y_t \end{bmatrix} \quad (9)$$

Nous suivons la forme générale d'Hamilton (1994) pour la représentation de systèmes dynamiques pour implémenter le filtre de Kalman, soit :

$$S_{t+1} = B + F S_t + v_{t+1} \quad (10)$$

$$y_t = A x_t + H S_t + w_t \quad (11)$$

$$E(v_t v_s) = \begin{cases} Q & t = s \\ 0 & \text{sinon} \end{cases} \quad E(w_t w_s) = \begin{cases} R & t = s \\ 0 & \text{sinon} \end{cases} \quad E(v_t w_s) = 0 \quad \forall t, s$$

Où Q et R sont les matrices de variances-covariances de v_t et w_t respectivement.

Par identification au modèle d'Hamilton, on a :

$$S_t = \begin{bmatrix} X_t \\ g_t \\ Y_t \end{bmatrix} \quad B = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad F = \begin{bmatrix} \alpha & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix} \quad v_{t+1} = \begin{bmatrix} e_{1t} \\ e_{2t} \\ e_{3t} \end{bmatrix} \quad A = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad H = \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix}$$

Nous pouvons maintenant utiliser cette représentation espace-états pour décomposer notre série S_t en la somme de deux séries distinctes Y_t (tendance) et X_t (retour à la moyenne).

4.3. Estimation des paramètres

Les deux modèles visent à décomposer le logarithme d'une série temporelle en une composante tendancielle et une composante de retour à la moyenne, dans le but d'implémenter des stratégies de construction de portefeuille profitables.

Dando et Turc (2013) ont tenté d'estimer les trois paramètres α , σ_v and σ_ε en utilisant la méthode du maximum de vraisemblance avec le Filtre de Kalman, mais concluent que cette approche n'a pas produit de bons résultats. Ils décident alors d'estimer uniquement le paramètre σ_v par la méthode du maximum de vraisemblance, et de calibrer les deux autres paramètres, σ_ε et α afin de maximiser le ratio Sharpe de la stratégie dans la période en-échantillon (« *in-sample* »).

La méthode utilisée est celle d'un pseudo-maximum de vraisemblance. Il est important de préciser que les séries temporelles d'indice de crédit et leur logarithme ne sont pas normaux mais nous travaillons quand même sous l'hypothèse de normalité. Cette hypothèse n'est pas restrictive dans notre cas puisque notre intérêt ne réside aucunement dans la prévision. Lors de l'estimation, nous n'imposons aucune restriction sur l'écart types des termes d'erreur, hormis leur signe strictement positif, et on restreint le paramètre de l'AR(1) à l'intervalle (0,0,99). Par conséquent, le mouvement de retour à la moyenne sera stationnaire. Notons qu'on se limite ici aux valeurs positives du cercle unitaire. En effet, supposer un paramètre α dans l'intervalle (-0,99,0) pourrait donner une composante autorégressive négative et ainsi un log-spread négatif – puisqu'il est égal à la somme du mouvement autorégressif et de la tendance stochastique – posant ainsi problème. Notons aussi que les bornes que nous avons choisies pour l'estimation du paramètre autorégressif sont consistantes avec Dando et Turc (2013).

Contrairement à la Société Générale, tous les paramètres sont optimisés de manière à maximiser la valeur objective, grâce à une optimisation avec les contraintes suivantes:

$$0 < \alpha < 0,99 \quad \text{et} \quad 0 < \sigma_i < \infty \quad i \in \{1,2,3\}$$

À priori, avec notre méthode du pseudo-maximum de vraisemblance, nous avons obtenu des difficultés notamment sur l'inversion de la matrice hessienne, ceci étant essentiel dans les conditions de recherche d'un optimum local. Les problèmes rencontrés dans notre algorithme pseudo-maximum de vraisemblance sont d'une part la singularité de la matrice hessienne et d'autre part, la matrice hessienne n'est pas nécessairement définie positive, ceci étant un enjeu considérable surtout pour l'estimation d'une matrice de variance-covariance afin de garder les propriétés de la variance. Ces problèmes liés à l'inversion de la matrice hessienne sont connus dans la littérature et des solutions pour y remédier ont été proposées. Nous allons utiliser 2 de ces méthodes pour dans un premier temps avoir une approximation robuste de l'inverse du hessien et dans un deuxième temps, nous désirons ajouter une correction sur l'autocorrélation et l'hétéroscédasticité.

Ainsi, pour se faire, nous utilisons la méthode d'inverse généralisée de Moore-Penrose (1956) qui permet d'obtenir une approximation robuste d'un inverse appelé « pseudo-inverse ». La méthode de Moore-Penrose stipule que par l'intermédiaire de la décomposition en valeurs singulières (l'utilisation de la distance minimale par moindres-carrés est utilisée également) que pour toute matrice $A \in \mathbb{R}_r^{m \times n}$, il existe une unique pseudo-inverse $A^+ \in \mathbb{R}_r^{n \times m}$ respectant les critères suivants :

En posant $G = A^+$, alors G existe si et seulement si

$$1. \quad A * G * A = A$$

$$2. \quad G * A * G = G$$

$$3. \quad (A * G)^T = AG$$

$$4. \quad (G * A)^T = GA$$

$$5. \quad A * G \text{ et } G * A \text{ sont hermitiennes}$$

Ainsi, l'avantage important de cette méthode est qu'elle permet l'obtention d'une inverse

adéquate qui est très utile dans l'estimation de matrice variance-covariance et que lorsqu'elle existe (satisfaisant les conditions Moore-Penrose), elle est unique.

Dans un deuxième temps, nous procédons à une correction sur l'estimation de la matrice variance-covariance pour l'autocorrélation et l'hétéroscédasticité en utilisant la méthode de Newey-West (1987) qui introduit un ajustement sur l'estimation de la matrice variance-covariance par l'intermédiaire d'une somme finie d'autocorrélations sur la variance des termes d'erreurs.

L'avantage majeur de notre modèle est qu'il utilise l'estimation statistique - et non le calibrage - lors de l'estimation des paramètres de notre modèle, soit α , σ_1 , σ_2 , σ_3 . Par ailleurs, nous montrons empiriquement dans la *Section 6.4* qu'il pourrait être préférable de calibrer la borne inférieure du paramètre σ_2 écart type de la tendance de la marche aléatoire stochastique. De plus, notre modèle ne fait aucune supposition d'ordre économique, par exemple concernant l'absence d'opportunité d'arbitrage puisque l'analyse se base uniquement sur la décomposition d'une série en deux processus distincts à partir de prix observés sur le marché.

4.4 Implémentation de l'algorithme d'optimisation

Nous utilisons la méthode de Quasi-Newton utilisant une approximation du Hessien par Broyden-Fletcher-Goldfarb-Shanno (BFGS) pour maximiser la fonction objectif. Notons que Dando et Turc (2013) n'ont pas précisé la nature exacte de leur algorithme d'optimisation.

Méthode de Quasi-Newton¹:

$$x^{k+1} = x^k - \lambda^k d^k \text{ où } d^k = \nabla f(x^k) * (H(x^k))^{-1} \quad (12)$$

où $(H(x^k))^{-1}$ est approximé par Algorithme BFGS

λ^k est le paramètre de recherche linéaire qui permet d'augmenter l'efficacité de l'algorithme d'optimisation en utilisant un critère d'arrêt sur le gradient pour chacune des itérations en

¹ ∇ et H sont respectivement le gradient et la matrice Hessienne de la fonction f . x^k est la solution itérative recherchée.

utilisant des directions descentes favorisant une minimisation des itérations selon le critère d'arrêt (ici, nous avons choisi le gradient). Pour se faire, nous avons fixé une tolérance sur le critère d'arrêt du gradient de facteur 10^{-10} . Cette méthode est traditionnellement efficace pour orienter l'algorithme dans les choix de directions de descentes itérations par itérations en plus de la méthode d'optimisation choisie (ici, la méthode Quasi-Newton).

Il peut toutefois s'avérer difficile de trouver un maximum global lors de l'estimation des paramètres par le filtre de Kalman puisque la fonction objective n'est pas nécessairement convexe. Pour pallier à ce problème, nous utilisons un procédé similaire à Boender-Rinnooy-Stougie-Timmer (1982). Notre méthode consiste à simuler des paramètres initiaux avec un générateur de variables uniformes pseudo-aléatoires sur l'intervalle de contraintes de chaque paramètre afin de considérer plusieurs scénarios de paramètres initiaux. Nous retenons finalement la solution ayant le plus grand maximum de vraisemblance. Cet algorithme permet de traiter le cas où les paramètres estimés par le filtre de Kalman convergent vers des optimums locaux.

Répéter cet algorithme une centaine de fois donne de très bons résultats dans notre cas puisque l'estimation des paramètres converge toujours vers les mêmes valeurs finales peu importe l'état initial du système.

5. GÉNÉRATION DE SIGNAUX

Une fois que nous avons estimé les paramètres α , σ_1 , σ_2 , σ_3 , l'objectif est maintenant d'utiliser la décomposition du logarithme de l'indice pour générer des signaux de construction de portefeuille.

5.1 Indicateur de tendance

Nous adoptons les mêmes règles pour trouver des indicateurs de tendance que celles utilisées par la Société Générale (Dando et Turc 2013). On suit les étapes suivantes pour identifier notre indicateur de tendance:

- Pour la série de log-spread et le processus autorégressif, on calcule les coefficients de régression b_{1m} , b'_{1m} , b_{3m} et b'_{3m} par rapport au temps pour des périodes d'un mois et trois mois. Ils représenteront respectivement les indicateurs de tendance 'court-terme' et 'moyen-terme'.

En gardant les mêmes notations, on a ainsi les régressions suivantes pour les indicateurs de tendance 'court-terme' (un mois):

$$S_t = a_{1m} + b_{1m}t + e_{1m}$$

$$X_t = a'_{1m} + b'_{1m}t + e'_{1m}$$

Et pour les indicateurs de tendance 'moyen-terme' (trois mois) :

$$S_t = a_{3m} + b_{3m}t + e_{3m}$$

$$X_t = a'_{3m} + b'_{3m}t + e'_{3m}$$

- On s'intéresse au signe de chacun des coefficients de régression b_{1m} , b'_{1m} , b_{3m} et b'_{3m} . Un coefficient positif se traduit par un signal d'achat (acheter la protection via l'indice). Un signal négatif se traduit par un signal baissier (vendre la protection via l'indice). On

calcule alors le ratio Sharpe réalisé pour chacun de ces indicateurs pendant le dernier mois. En posant $R_{t-1,t}$ et $\sigma_{t-1,t}$ respectivement le rendement et l'écart type annualisés de l'indice entre $t-1$ et t et $RF_{t-1,t}$ (pour le mois dernier pour l'indicateur 'court terme' ou pour les trois derniers mois pour l'indicateur 'moyen-terme'), le taux annualisé des bons du trésor Américains de maturité 5 ans (même maturité que tous les indices sous-jacents à la stratégie); le ratio Sharpe au temps t est calculé comme suit:

$$Sharpe_t = \frac{R_{t-1,t} - RF_{t-1,t}}{\sigma_{t-1,t}} \quad (13)$$

- On retient alors le coefficient de régression qui a le mieux performé au sens du ratio Sharpe durant la période précédente. On interprète une pente positive comme un signal haussier et une pente négative comme un signal baissier.

Nous obtenons ainsi des signaux d'achat ou de vente tirée de la composante tendancielle de la décomposition par le filtre de Kalman de l'indice de crédit avec le modèle à tendance stochastique.

5.2 Indicateur de retour à la moyenne

Comme Dando et Turc (2013), nous supposons une distribution normale autour de zéro pour le mouvement autorégressif; soit $X \sim N(\mu_x, \sigma_x)$ et donc $Z = \frac{X - \mu_x}{\sigma_x} \sim N(0,1)$

Nous choisissons un seul niveau de Z-score pour la composante de retour à la moyenne, soit de 1.6 (équivalent à une probabilité de 95%). Nous sommes ainsi en mesure d'identifier les niveaux extrêmes atteints par le processus de retour vers la moyenne.

Les signaux provenant du processus de retour à la moyenne proviennent de la règle suivante:

Signal d'achat	si $Z < -1,6$
Signal de vente	si $Z > 1,6$
Signal neutre	si $Z \in [-1,6, 1,6]$

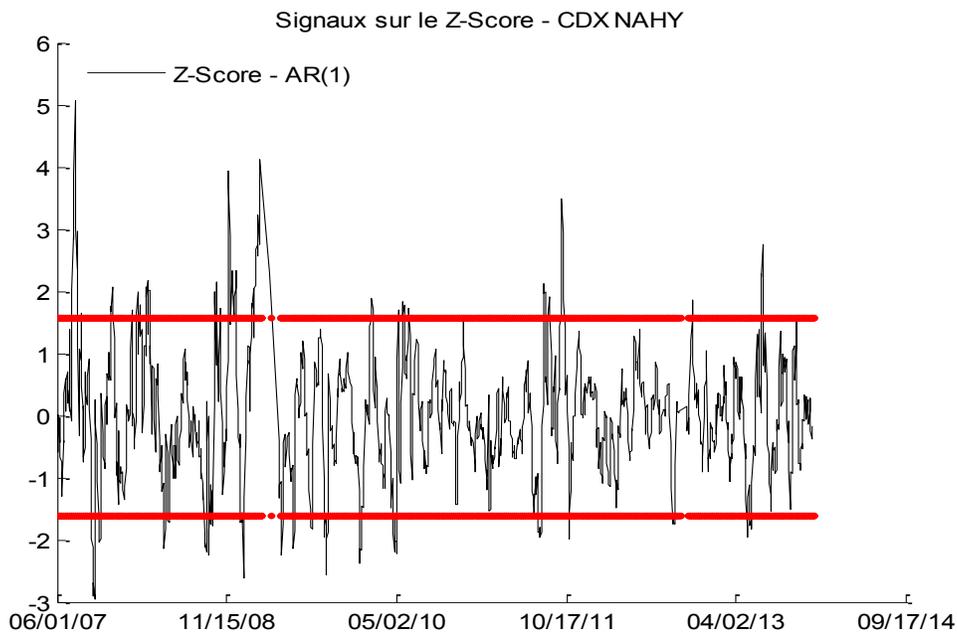


Figure 1 : Z-score du processus de retour vers la moyenne du CDX High Yield obtenu avec le modèle à tendance stochastique filtre de Kalman. Lorsque le Z-Score atteint +1,6 (-1,6), signal de vente (achat).

5.3 Combinaison des deux signaux

Il reste maintenant à combiner les signaux extraits de chacune des deux parties de la décomposition du logarithme de l'indice de crédit afin de prendre des positions sur le portefeuille.

Dando et Turc (2013) maximisent le ratio Sharpe des deux stratégies combinées (tendance et retour à la moyenne). Dans le modèle à tendance stochastique, nous prenons en compte les deux indicateurs pour générer le signal final. Nous supposons que les prix d'indices de CDS suivent la 'tendance' telles que définie dans la section 5.1. On combine alors les deux signaux, en favorisant le signal tendanciel sur le retour à la moyenne lorsque ce dernier est neutre. Le tableau ci-dessous résume cette combinaison:

Signal Tendance	Signal AR	Signal Final
-1	-1	-1
-1	0	-1
-1	1	0
0	-1	0
0	0	0
0	1	0
1	-1	0
1	0	1
1	1	1

**Tableau 1 : Ce tableau résume la combinaison des deux signaux (extrait de la tendance et du mouvement autorégressif) en un signal final. Ce dernier sera utilisé dans notre stratégie de construction de portefeuille.
1 : Achat -1 : Vente 0 : Neutre (ne rien faire)**

Une divergence des deux signaux se traduit par un signal global neutre et donc aucune position sur l'indice. De plus, lorsque le signal de retour vers la moyenne est neutre, on se base sur le signal de tendance.

Après une description détaillée de la nature des données utilisées dans le cadre de ce problème, nous comparons la performance de la stratégie sur le CDX High Yield avec deux décompositions présentées dans la *Section 5.4*, soit pour des valeurs de $\sigma_2^{\text{inf}} = 10^{-10}$ et $\sigma_2^{\text{inf}} = 50\%$.

6. DONNÉES

6.1 Indices de crédit

Acheter un indice de crédit consiste à vendre la protection sur les contrats de CDS de l'indice, dans les mêmes proportions et investir le notionnel résiduel dans le marché monétaire. La position reflète donc une exposition longue au crédit. Un levier constant de 1 est supposé lors de la construction de l'indice.

Dans le cas d'un défaut ou autre événement de crédit, la protection est payée et Markit® remplace l'indice par un nouvel indice ne contenant pas le titre ayant fait défaut.

Il est important de noter que les indices de crédit sont rebalancés tous les six mois, induisant un changement de maturité et de composition dans l'indice. Nous utilisons donc l'indice du CDS générique (disponible sur Bloomberg ®) qui prend déjà soin de ces ajustements.

Tous les indices ont une maturité de 5 ans, soit la maturité la plus liquide pour ce type de contrats. On s'intéresse aux indices de crédit suivants: *iTraxx Main* (Europe) l'*iTraxx X-Over* (Europe), *CDX Investment Grade* (Amérique du Nord) et *CDX High Yield* (Amérique du Nord). Le lecteur pourra se référer à l'*Annexe 4* pour une description des spécificités de chacun de ces indices.

Toutes les données présentées dans cette recherche proviennent de Bloomberg® et Markit® et sont d'excellente qualité.

6.2 Rendements totaux de l'indice (*Total Return*)

La série de rendements totaux prend en compte les défauts, les rebalancements de l'indice et les mouvements des CDS composant l'indice. Nous utilisons cette série pour créer l'indicateur de tendance et calculer la performance de la stratégie.

On utilise des séries journalières qui sont les prix de fermeture d'indices de CDS à partir du 21 mars 2007, qui correspond à la base de 100 fixée pour la série de rendements totaux. On suppose que la valeur de l'indice pour une journée donnée est égale au prix de fermeture de l'indice et que les transactions pour un jour donné ont lieu à ce prix.

Le choix de la fréquence des données joue un rôle important dans les résultats obtenus. Des observations de haute fréquence (horaires ou journalières) contiendront naturellement plus de bruit que des observations de basse fréquence (mensuelles ou trimestrielles). Étant donné que le filtre de Kalman est un algorithme de filtrage adaptatif, nous choisissons de travailler avec des données journalières.

6.3 Statistiques descriptives

L'*Annexe 5* compare graphiquement l'indice de CDS à son logarithme pour chacun des indices de crédit étudiés, soit l'*iTraxx Main*, l'*iTraxx X-Over*, le *CDX Investment Grade* et le *CDX High Yield*.

On constate que les indices de crédit montrent tous une volatilité importante et sont fortement influencés par les événements subséquents à la faillite de Lehman Brothers, le 15 Septembre 2008. Les indices européens (l'*iTraxx Main*, l'*iTraxx X-Over*) ont montré une plus grande réaction à la crise de la dette dans la zone euro atteignant même des niveaux comparables à ceux de 2008 pour l'*iTraxx Main* (*Annexe 4.1*).

Graphiquement, les séries de CDS et leur logarithme n'apparaissent pas stationnaires. Nous confirmons cela avec le test de Kwiatkowski–Phillips–Schmidt–Shin (KPSS). De plus, les séries d'indice ainsi que leur logarithme ne suivent pas une loi normale comme le confirme le test de Jarque-Bera. On présente les statistiques descriptives dans l'*Annexe 4.2*.

7. ANALYSE DES RÉSULTATS

7.1 Analyse de la décomposition

Nous présentons les résultats de la décomposition du logarithme de chacun des indices de crédit dans l'*Annexe 6*.

Dans le cas décomposition du log de l'indice *iTraxx X-Over* (*Annexe 6.2*), l'estimation du paramètre autorégressif α du processus de retour vers la moyenne est égale à la valeur de la borne supérieure 0,99. Théoriquement, cela ne pose pas de problème, puisqu'on le force par construction à rester à l'intérieur du cercle unitaire assurant ainsi la stationnarité du processus de retour vers la moyenne. Néanmoins, en comparant avec les autres valeurs du paramètre α pour les trois autres modèles, nous retrouvons des valeurs similaires (0,869, 0,977 et 0,927 respectivement pour l'*iTraxx Main*, le *CDX Investment Grade* et le *CDX High Yield*) sans toutefois toucher la borne.

Le paramètre autorégressif α est le plus élevé parmi les quatre modèles présentés pour l'indice *iTraxx X-Over*. Intuitivement, dans le cas d'un choc sur le processus d'auto-régression où le retour à la moyenne se fait plus lentement, l'écart présent entre la série réalisée et la décomposition de sa tendance par le filtre de Kalman à tendance stochastique prend plus de temps à s'estomper. Cette observation peut être validée en observant aussi le graphique de la décomposition de l'*iTraxx Main* (α le plus faible) dont la composante de retour à la moyenne contribue plus significativement à la décomposition comparativement aux autres indices.

En comparant les estimations des paramètres sur les quatre décompositions de log-indices, on constate tout d'abord que l'écart type (σ_1) des processus autorégressifs des séries sur les indices *Investment Grade* sont nettement plus élevées que celle des indices de type *High Yield*, autant en Europe et qu'en Amérique du Nord. Tel que mentionné dans la *Section 4.2*, le paramètre σ_1 détermine l'amplitude des mouvements autour de la moyenne et nous observons alors sur le graphique de composante de retour à la moyenne des variations plus importantes que pour les séries *High Yield*. Ceci est en concordance avec les observations du marché puisque le marché du High Yield est un marché de nature illiquide, composé de titres avec une note de crédit

inférieure à BBB- (S&P) ou Baa3 (Moody's). Notamment, ce marché est très affecté lorsque les écarts de crédit augmentent lors d'une augmentation de la volatilité en période d'incertitude et/ou de crise. Les graphiques montrent bien ceci de par un écartement des spreads prononcé durant la crise des subprimes de 2008 (*Annexe 4*). Cet écart se traduit également dans les mouvements de retour à la moyenne, puisque les quatre séries d'intérêt dévient de plus de trois écarts-types de la moyenne (niveau 0).

En ce qui concerne le paramètre σ_3 , il est le plus élevé pour la série du *CDX Investment Grade* (*Annexe 6.3*) qui sera donc la série où la composante tendancielle sera la plus proche de la variable observée. Ainsi, graphiquement, on peut vérifier que la composante tendancielle est très proche de la valeur observée, laissant ainsi présager que les signaux provenant de cette composante seront relativement plus précis que pour les trois autres séries.

On remarque des résultats semblables aussi pour σ_2 qui est nettement supérieur pour les deux séries de crédit de type *Investment Grade*. Encore une fois, ce paramètre affecte la modélisation de la dérive stochastique, c'est-à-dire la variance du processus g_t . Une analyse plus approfondie de l'impact de ce paramètre dans la modélisation est faite dans la section suivante.

7.2 Analyse de sensibilité – Impact du paramètre σ_2

Rappelons que σ_2 est la volatilité de la tendance stochastique du modèle présenté à la *Section 4.2*. Ce paramètre contrôle la volatilité de la tendance stochastique du modèle. Soit σ_2^{inf} la borne inférieure du paramètre σ_2 fixée lors de l'optimisation par contraintes. En variant les valeurs de σ_2^{inf} nous pouvons observer l'impact de ce paramètre sur l'état de la décomposition.

Nous présentons les résultats obtenus pour la décomposition du log de l'indice *CDX High Yield* pour des valeurs de σ_2^{inf} égales à 10^{-10} , 10% et 50% dans l'*Annexe 6*.

Notons que le cas $\sigma_2^{\text{inf}} = 10^{-10}$ correspond à la décomposition de l'indice sans calibration de σ_2^{inf} . Calibrer la valeur de la borne inférieure σ_2^{inf} vers une valeur élevée ne garantit pas toujours une convergence vers des résultats cohérents. Une valeur de $\sigma_2^{\text{inf}} = 50\%$ s'est avérée être un bon

compromis entre la convergence du modèle tout en imposant une borne inférieure d'ordre suffisamment important pour illustrer l'impact d'une valeur extrême du paramètre.

L'impact de la calibration de σ_2^{inf} est donc un outil permettant de contrôler la paramétrisation de la composante de retour à la moyenne ainsi que celle de la tendance. Les différentes valeurs de la calibration sur la série du *CDX High Yield* permettent d'identifier l'impact de ces perturbations et d'observer l'ajustement des autres paramètres. On observe qu'imposer une plus grande valeur de σ_2 affecte le lissage de la composante tendancielle et donc limitera l'impact des bruits sur les signaux. En effet, il y a aura moins de positions prises mais on constatera une amélioration dans la qualité des signaux et ainsi une amélioration dans la performance de l'algorithme (*Annexe 7.5*).

Notons aussi en augmentant σ_2 , le paramètre autorégressif s'approche de la borne de 0.99 (celui-ci converge rapidement alors que $\alpha = 0,99$ lorsque $\sigma_2=10\%$), de plus σ_1 augmente légèrement ce qui augmente donc l'amplitude du mouvement autour de la moyenne. Ces dernières remarques sont aisément observables sur les graphiques alors que la tendance est moins saccadée et que le processus de retour vers la moyenne est de plus grande amplitude. En effet, les valeurs passent de l'intervalle (-0,2 ; 0,4) à (-0,3 ; 0,5). Finalement, on observe un changement majeur dans le paramètre σ_3 alors qu'il passe de 0,003 à 0,004 et puis à 0,032. Ce qui rejoint l'idée mentionnée dans la section précédente; puisque plus σ_2 est grand, plus l'estimation de la composante tendancielle est proche de la variable observable.

Aussi, nous présentons les résultats pour l'indice du *CDX High Yield* en faisant varier la borne inférieure du paramètre σ_2 lors du processus d'optimisation, σ_2^{inf} . En augmentant la valeur de la contrainte σ_2^{inf} , on obtient une tendance plus lisse, et, par conséquent, un processus de retour vers la moyenne de plus grande amplitude. Intuitivement, augmenter la valeur de σ_2 revient à restreindre la variabilité du processus autorégressif, augmentant les amplitudes et causant ainsi un ralentissement de sa vitesse de retour à la moyenne.

De cette manière, on peut contrôler le lissage de la tendance dépendamment de l'objectif de la décomposition. Cela peut possiblement dépendre de notre horizon de placement ou encore du poids qu'on veut accorder aux mouvements de retour à la moyenne ou de tendance dans notre

décision d'investissement. Nous étudierons l'impact sur la courbe d'équité pour l'indice du *CDX High Yield*.

La décomposition capte bien le renversement de tendance après la crise de crédit de 2008 pour les trois valeurs de bornes inférieures de σ_2 . En effet, on voit bien que graphiquement, le processus de tendance décroît préalablement à la série elle-même laissant mettre ainsi plus de poids sur le processus autorégressif.

7.3 Analyse de performance

Nous avons testé la performance dans plusieurs cas de figure. Dans un premier temps, nous avons procédé à la décomposition des indices de crédit par le filtre de Kalman avec le modèle à tendance stochastique dans la période *en-échantillon* (21 Mars 2007 au 31 Décembre 2011) et nous nous sommes fondé sur ces estimations pour calculer la performance dans la période *hors-échantillon* (1^{er} Janvier 2012 au 5 Novembre 2013). Dans un deuxième temps, nous avons considéré une stratégie plus réaliste consistant à évaluer la performance de la stratégie en se basant sur l'estimation d'une nouvelle décomposition chaque semaine. Nous trouvons des performances similaires pour les deux approches.

La stratégie donne des résultats insatisfaisants en termes de performance hormis dans le cas du *CDX High Yield* (voir *Figures 2.A et 2.B ci-dessous*). Les performances des stratégies pour les indices *iTraxx Main*, *iTraxx X-Over*, *CDX Investment Grade* sont présentées dans l'*Annexe 7*.

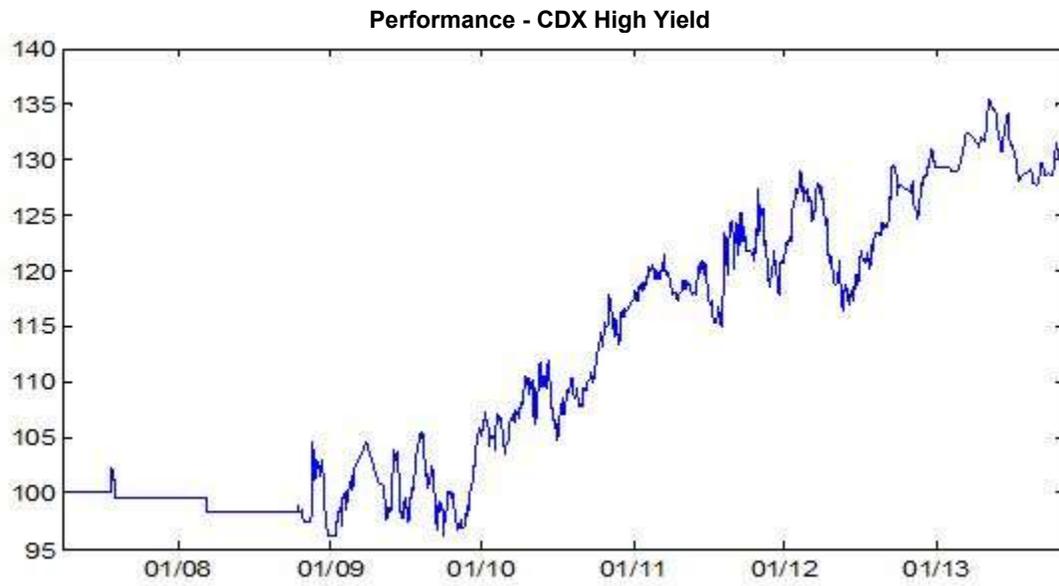


Figure 2.A Positions sur l'indice CDX High Yield exposées sur sa série de rendements totaux

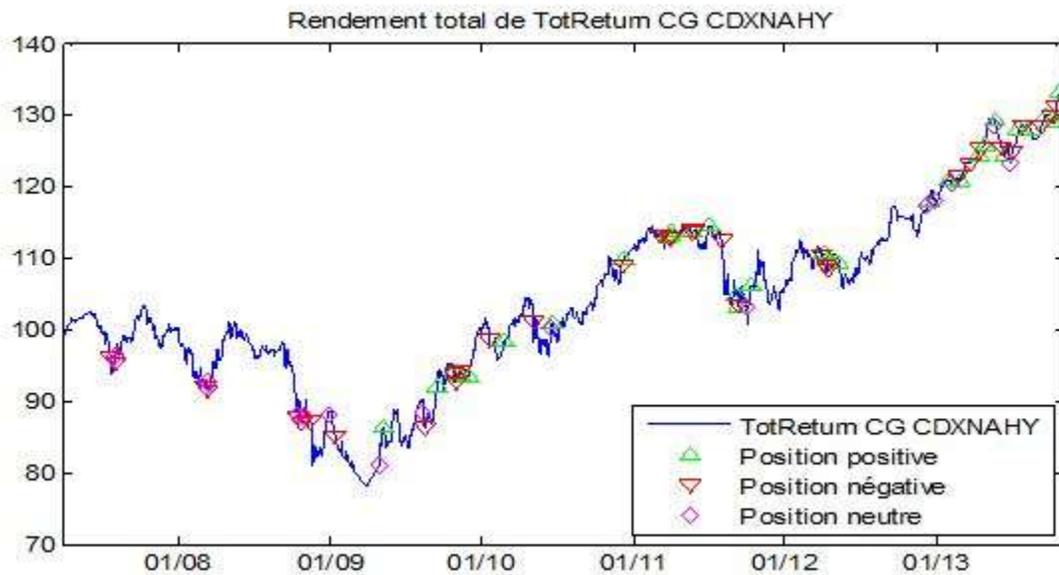


Figure 2.B Positions sur l'indice CDX High Yield exposées sur sa série de rendements totaux

Dates	29-Mar-2007 to 05-Nov-2013
Richesse initiale	100,00 \$
Richesse finale	128,56 \$
Retour sur investissement annualisé	3,87%
Volatilité annualisée	8,91%
Max Drawdown	10,24%
Ratio Sharpe	0,43

Mesures de Risque

VaR [%]	1 jour	5 jours	10 jours
1%	-1,3%	-2,8%	-4,0%
5%	-0,9%	-2,0%	-2,8%

Mesures de Performance

	Toutes positions confondues	Positions courtes	Positions longues
Profit Net	28,56 \$	(6,13 \$)	34,69 \$
Profit Brut	69,14 \$	18,88 \$	50,26 \$
Perte Brute	(40,58 \$)	(25,01 \$)	(15,56 \$)
Facteur de bénéfice	1,70	0,75	3,23
Nombre total de transactions	65	34	31
Transactions profitables (%)	46%	35%	58%
Positions gagnantes	30	12	18
Positions perdantes	35	22	13
Profit net moyen	0,44 \$	(0,18 \$)	1,12 \$
Position gagnante moyenne	2,30 \$	1,57 \$	2,79 \$
Position perdante moyenne	(1,16 \$)	(1,14 \$)	(1,20 \$)
Ration gain moyen:perte moyenne	1,99	1,38	2,33
Plus grande position gagnante	8,84 \$	7,93 \$	8,84 \$
Plus grande position perdante	(6,48 \$)	(6,48 \$)	(3,82 \$)
Ratio: + grand gagnant : profit brut	13%	42%	18%
Ratio: + grand perdant: perte brute (%)	16%	26%	25%
Retour sur investissement	29%	-6%	35%
Taux de rendement annuel	4%	-1%	5%
Période totale (en jours)	2413	2413	2413
Temps dans le marché (en %)	69%	19%	50%
Temps dans le marché (en jours)	1668	456	1212

Figure 2.C Statistiques de performance et mesures de risque de la stratégie pour l'indice CDX High Yield en calibrant $\sigma_2^{\text{inf}} = 50\%$ - 28 Avril 2009 au 5 Novembre 2013

Tout d'abord, on constate que le rendement le plus élevé à partir du modèle algorithmique est sur l'indice *CDX Investment Grade* avec un rendement annualisé de 3,87% en plus d'avoir obtenu le plus haut pourcentage de transactions rentables. Par contre, il est important de constater que cette stratégie sur cet indice spécifique est risquée avec une volatilité annualisée à 8,91%. Ainsi, pour comparer les stratégies entre elles, nous utilisons le Ratio Sharpe. Il est important de mentionner que cette méthode suppose une linéarité entre le risque et le rendement. Ainsi, l'indice affichant la meilleure rentabilité par rapport au niveau de risque fut l'indice *iTraxx Main* alors que la stratégie de décomposition obtient un rendement annuel de 1,75% pour un risque de 2,82%.

Il est intéressant de remarquer aussi un fort déséquilibre en faveur du crédit de plus haute qualité (de type *Investment Grade*) pour ce qui est du risque entrepris par la stratégie de décomposition. Effectivement, on observe que les stratégies sur l'*iTraxx Main* et le *CDX Investment Grade* ont obtenu une volatilité annualisée de 8,87% et 8,91% respectivement, pratiquement quatre fois plus que les stratégies sur le crédit de type High Yield. D'ailleurs, la même conclusion peut être tirée à partir des valeurs de VaR historique. Il s'agit là d'une observation importante alors que vraisemblablement le crédit de type *High Yield* est plus risqué et donc la stratégie ne semble pas dépendre du niveau de risque du produit transigé.

On observe aussi que les stratégies de position longue ont porté fruit significativement plus souvent que les positions de courtes et ce, pour tous les indices. Effectivement, pour les positions longues, nous obtenons un taux de rendement position à 45%, 49%, 58% et 55% pour les indices *iTraxx Main*, *iTraxx X-Over*, *CDX Investment Grade* et *CDX High Yield* tandis que pour les positions courtes, il ne s'agissait que de 26%, 37%, 35% et 26%. Les différences sont considérables et laissent donc présager la possibilité d'améliorer largement les résultats en se concentrant sur les positions longues. Pourtant, s'il est important de prendre des positions courtes, il serait utile de sortir une liste des positions courtes et séparer les divers cas de figure. Ainsi, il serait possible d'ajouter des critères plus restrictifs (arrêt de perte par exemple) aux positions courtes qui semblent être la cause principale de certaines performances médiocres.

Finalement, nous constatons que les stratégies sur les indices *iTraxx*, que ce soit *Investment Grade* ou *High Yield*, sont beaucoup plus actives dans le marché malgré le fait qu'elles ne

performent pas nécessairement beaucoup mieux. Les signaux d'achat ou de vente ont été déclenchés plus souvent, particulièrement pour l'indice *iTraxx Main* qui a effectué 264 transactions qui ne semblent pas avoir été justifiées puisque la performance était de -1,6% annualisé et pour un niveau de risque de 8,87%. Ainsi, il semblerait que la stratégie algorithmique proposée ne soit pas très bien adaptée à ce type d'indice et nécessite l'ajout de signaux additionnels pour espérer être profitable dans cet environnement de crédit Européen.

Les derniers résultats de la stratégie sont très encourageants lorsqu'on force le paramètre de variance de la dérive stochastique à 0,5 à la place de l'estimé par maximum de vraisemblance (*voir figures 3. A et 3.B ci-dessous*). Effectivement, lorsqu'on force dans le cas du σ_2 *CDX High Yield*, les performances sont clairement améliorées alors que le Ratio Sharpe s'améliore de 332% (passant de 0,34 à 1,13). On note par contre que le niveau de risque a augmenté puisque la variance annualisée est dorénavant de 10,07% comparativement à 2,29%. Ainsi, avoir augmenté σ_2 à 0,5 affecte le lissage de la composante tendancielle et donc réduit le nombre de signaux. D'ailleurs, on constate que le nombre de transaction a diminué de 65 à 40 et que les positions sont gardées plus longtemps puisque le temps passé dans le marché est de 93% comparativement à seulement 69% avant. Ainsi, la performance supérieure s'explique par une amélioration de la qualité des signaux et particulièrement l'amélioration de la performance des positions courtes. Avec $\sigma_2 = 0.5$, les positions courtes sont 50% du temps rentables alors qu'elles ne l'étaient qu'à 26% du temps lorsque le paramètre σ_2 était libre.

Performance : CDX High Yield en calibrant la borne inférieure $\sigma_2^{inf} = 50\%$

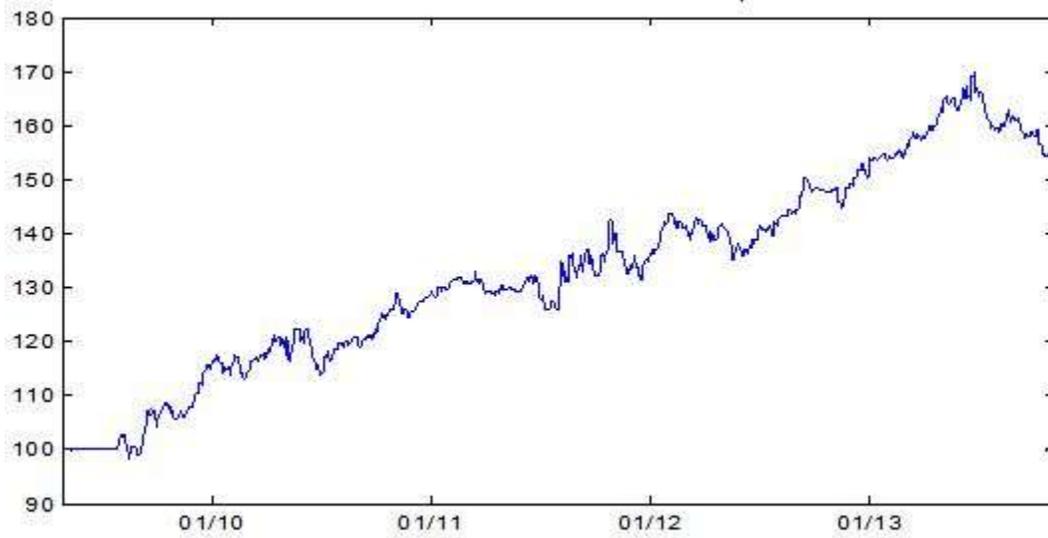


Figure 3.A Performance de la stratégie appliquée au CDX High Yield - $\sigma_2^{inf} = 50\%$

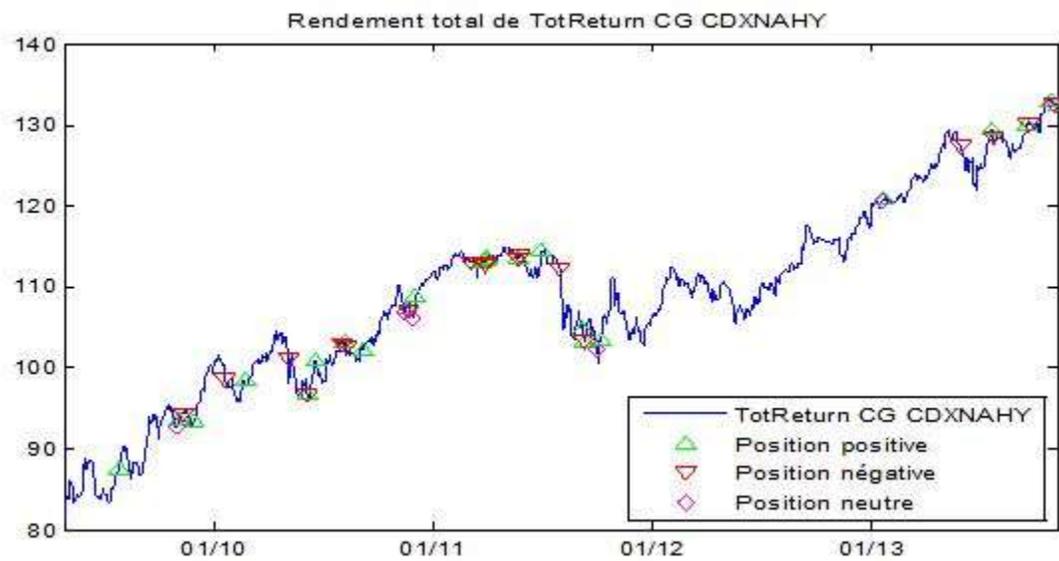


Figure 3.B Positions sur l'indice CDX High Yield avec $\sigma_2^{inf} = 50\%$ exposées sur sa série de rendements totaux

Dates	28-Apr-2009 au 05-Nov-2013
Richesse initiale	100,00\$
Richesse finale	154,37
Retour sur investissement annualisé	10,07%
Volatilité annualisée	8,95%
Max Drawdown	9,72%
Ratio Sharpe	1,13

Mesures de Risque

VaR [%]	1 jour	5 jours	10 jours
1%	-1,3%	-2,7%	-3,8%
5%	-0,9%	-1,9%	-2,6%

Mesures de Performance

	Toutes positions confondues	Positions courtes	Positions longues
Profit Net	54,37 \$	1,93 \$	52,45 \$
Profit Brut	77,58 \$	17,27 \$	60,32 \$
Perte Brute	(23,21 \$)	(15,34 \$)	(7,87 \$)
Facteur de bénéfice	3,34	1,13	7,66
Nombre total de transactions	40	18	22
Transactions profitables (%)	55%	50%	59%
Positions gagnantes	22	9	13
Positions perdantes	18	9	9
Profit net moyen	1,36 \$	0,11 \$	2,38 \$
Position gagnante moyenne	3,53 \$	1,92 \$	4,64 \$
Position perdante moyenne	(1,29 \$)	(1,70 \$)	(0,87 \$)
Ration gain moyen: perte moyenne	2,74	1,13	5,31
Plus grande position gagnante	22,01 \$	8,69 \$	22,01 \$
Plus grande position perdante	(5,15 \$)	(5,15 \$)	(2,38 \$)
Ratio: + grand gagnant : profit brut	28%	50%	36%
Ratio: + grand perdant: perte brute (%)	22%	34%	30%
Retour sur investissement	54%	2%	52%
Taux de rendement annuel	10%	0%	10%
Période totale (en jours)	1652	1652	1652
Temps dans le marché (en %)	93%	23%	70%
Temps dans le marché (en jours)	1542	382	1160

Tableau 3.C: Statistiques de performance et mesures de risque de la stratégie pour l'indice CDX High Yield en calibrant $\sigma_2^{\text{inf}} = 50\%$ - 28 Avril 2009 au 5 Novembre 2013

8. CONCLUSION

Nous avons exploré la décomposition des indices *iTraxx Main*, *iTraxx X-Over*, *CDX Investment Grade* et *CDX High Yield* en deux processus distincts : une tendance et mouvement de retour vers la moyenne. Nous proposons une nouvelle spécification du modèle de la Société Générale (2013) avec l'introduction d'une tendance stochastique permettant d'obtenir la convergence de tous les paramètres vers une solution réelle en maximisant la fonction de pseudo-maximum de vraisemblance.

Ensuite, nous avons implémenté une stratégie de construction de portefeuille basée sur les deux processus découlant de la décomposition, en favorisant le processus de tendance. Dans un premier temps, nous mesurons la performance de la stratégie entre le 21 Mars et le 5 Novembre 2013.

La décomposition de l'indice de crédit change en fonction des valeurs initiales allouées en particulier au paramètre σ_2 , représentant la volatilité de la tendance stochastique introduite au modèle. Cette propriété nous donne un contrôle sur la décomposition de l'indice de crédit en affectant à la fois le lissage de la composante tendancielle et l'amplitude du mouvement de retour vers la moyenne. Le praticien a ainsi l'option de calibrer la valeur de ce paramètre en fonction de facteurs spécifiques à l'investisseurs, soit l'horizon de placement ou encore le poids qu'il préfère allouer à une vue tendancielle relativement à une stratégie de retour vers la moyenne.

Il est important de se rappeler que le filtre de Kalman est une méthode d'estimation qui ne garantit pas une convergence dans tous les cas de figures étant donné que la précision du modèle dépend en grande partie du choix des valeurs de l'état initial du système, que l'on choisit de manière plus ou moins empirique. Comme nous avons montré, nous pallions à ce problème en perturbant les valeurs initiales des paramètres et en retenant le résultat ayant le plus grand pseudo-maximum de vraisemblance.

Nous considérons que cette stratégie est de type 'rendements absolus' de par ses rendements faiblement corrélés avec d'autres classes d'actifs. Pour cette raison, et comme Dando et Turc

(2013), nous comparons la performance de la stratégie par rapport au taux sans risque – Schneeweis et Spurgin (1999). Par conséquent, le Ratio d'Information dans ce cas n'est alors autre que le Ratio Sharpe. Cependant, d'autres modèles auraient pu être considérés tels que le modèle ARMA(1,1). En prenant pour référence la stratégie passive consistant simplement à acheter l'indice (vendre la protection), on obtient un Ratio d'Information de -0.38 (*Figure 17.A*) et de 1.96 (*Figure 17.B*) en calibrant σ_2^{inf} à 50%. Notons que notre stratégie sur le *CDX High Yield* surperforme la stratégie passive en calibrant σ_2^{inf} à 50%.

Une première limite est liée à la généralisation du modèle à d'autres classes d'actifs. En effet, certains modèles non-linéaires peuvent être trop complexes et non adaptés à la méthode du filtre de Kalman. Dans ce cas, ces modèles peuvent être estimés en utilisant des filtres particuliers ou des méthodes de Monte Carlo séquentielles (Doucet *et al.* 2000). Ces méthodes sont plus robustes par rapport à leur mécanisme de sélection auquel les particules, par la sélection séquentielle Monte-Carlo, permet d'évoluer de manière indépendante dans tout l'espace-état. Une revue des différentes méthodes de sélection est faite dans Gentil et Rémillard (2008).

Notre modèle ne converge pas si l'on ignore la partie autorégressive. Cela nous empêche de comparer l'importance de la partie autorégressive dans ce modèle en comparant le pseudo-maximum de vraisemblance du modèle complet à celui du modèle contraint sans le processus autorégressif.

On constate que les signaux dépendent de la calibration du paramètre σ_2 du modèle. La calibration de ce paramètre peut se faire en fonction de l'horizon d'investissement.

On peut noter des améliorations pratiques à notre algorithme. En effet, plus de temps pourrait être consacré à la génération de signaux et à l'introduction de conditions (ex : ordre d'arrêt de perte, ratio rendement perte...) visant à maximiser la performance de la stratégie. Ceci dit, on pourrait explorer des signaux mensuels. D'un point de vue pratique, on pourrait aussi explorer l'implémentation d'un tableau de bord et joindre les résultats de cette stratégie avec une vue fondamentale de marché.

De plus, l'un des critères de sélection utilisé est le ratio de Sharpe, qui limite notre horizon décisionnel à un risque de second ordre, c'est-à-dire la matrice de variance-covariance. Cet algorithme ne permet donc pas de capter des mouvements de sauts importants par exemple et se limite aux trajectoires linéaires de la série temporelle.

L'importance du paramètre σ_2 dans le cadre de cette recherche mérite un ouvrage supplémentaire consistant à optimiser pour la calibration optimale permettant de maximiser sur différents intervalles une mesure d'intérêt, par exemple le ratio Sharpe ou minimisant le risque de 'drawdown' en maximisant plutôt le ratio de Sortino.

9. ANNEXES

Annexe 1 : Filtre de Kalman Discret - Introduction

Le filtre de Kalman est formé de deux équations distinctes qui illustrent les étapes de prévision et de mise à jour propres à l'algorithme; une équation d'état et une équation de mesure. L'équation de mesure lie la variable non-observée X_t à la variable observée Y_t tandis que l'équation d'état (aussi appelée « équation de transition ») décrit la dynamique à la variable X_t (non observée) de varier en fonction du temps.

Décrivons le détail des étapes du filtre de Kalman à partir de la première itération. Pour cela, nous nous inspirons de la méthodologie décrite dans Arnold *et al.* (2008) et nous conservons les mêmes notations. On n'impose pas de distribution spécifique aux termes d'erreur. Rappelons que la variable Y_t est observable tandis que X_t ne l'est pas.

Équation de mesure :

$$Y_t = m_t X_t + b_t + \varepsilon_t \quad (14)$$

Soit $b_t = 0$ et $m_t = m$:

$$Y_t = m X_t + \varepsilon_t \quad (15)$$

Équation d'état (transition) :

$$X_{t+1} = a_t X_t + g_t + \theta_t \quad (16)$$

Soit $g_t = 0$ et $a_t = a$:

$$X_{t+1} = a X_t + \theta_t \quad (17)$$

Supposons que les variables ε_t , θ_t et X_0 ne sont ni corrélés, ni auto-corrélés.

Étapes:

On commence par insérer une valeur initiale de $X_0 \sim (\mu_0, \sigma_0)$ dans l'équation d'état (2) pour obtenir X_{1P} , la prévision de la variable X_1 au temps $t = 0$

$$X_{1P} = a X_0 + \theta_0 \quad (18)$$

On insère X_{1P} dans l'équation de mesure (1) pour obtenir une prévision de Y_1 , que nous notons Y_{1P} . On obtient donc :

$$Y_{1P} = m X_{1P} + \varepsilon_1 = m (a X_0 + \theta_0) + \varepsilon_1 \quad (19)$$

Au moment de la réalisation de Y_1 , on calcule l'erreur Y_{1E} :

$$Y_{1E} = Y_1 - Y_{1P} \quad (20)$$

On utilise alors cette erreur (Y_{1E}) pour ajuster notre prévision de X_1

Valeur prédite ajustée:

$$X_{1P-ADJ} = X_{1P} + k_1 Y_{1E} \quad (21)$$

$$\begin{aligned} &= X_{1P} + k_1 [Y_1 - Y_{1P}] \\ &= X_{1P} + k_1 [Y_1 - m (a X_0 + \theta_0) - \varepsilon_1] \\ &= X_{1P} (1 - m k_1) + k_1 Y_1 - k_1 \varepsilon_1 \end{aligned} \quad (22)$$

La variable k_1 est le gain de Kalman. Elle est choisie de manière à minimiser la variance de X_{1P-ADJ} . En effet, on peut aisément montrer que le gain de Kalman est équivalent au coefficient d'une régression linéaire de X_{1P} sur Y_{1P} soit avec Y_{1P} la variable indépendante et X_{1P} la variable dépendante :

$$\text{Var} (X_{1P-ADJ}) = p_1 * (1 - m k_1)^2 + k_1^2 * r_1 \quad (23)$$

où p_1 est la variance de X_{1P} .

$$\begin{aligned} \text{FOC: } \quad \partial \text{Var} (X_{1P-ADJ}) / \partial k_1 &= -2m p_1 [1 - m k_1] + 2 k_1 r_1 = 0 \\ k_1 &= \frac{p_1 * m}{(p_1 * m^2 + r_1)} = \frac{\text{Cov} (X_{1P}, Y_{1P})}{\text{Var} (Y_{1P})} \end{aligned} \quad (24)$$

En se rappelant que p_1 est la variance de X_{1P} , on a :

$$\text{Var} (X_{1P-ADJ}) = p_1 * (1 - m k_1)^2 + k_1^2 * r_1 \quad (25)$$

On insère maintenant X_{1P-ADJ} dans l'équation de transition de X_t et on recommence le processus pour $t=2\dots$

Pout tout t , nous avons :

$$E[Y_{tP}] = E[m * (X_{tP-ADJ}) + \varepsilon_t] = m * E[X_{tP-ADJ}] \quad (*) \quad (26)$$

$$\text{Var}[Y_{tP}] = \text{Var}[X_{tP-ADJ}] * m^2 + r_t \quad (**) \quad (27)$$

Les étapes du filtre de Kalman peuvent se résumer selon le schéma suivant :

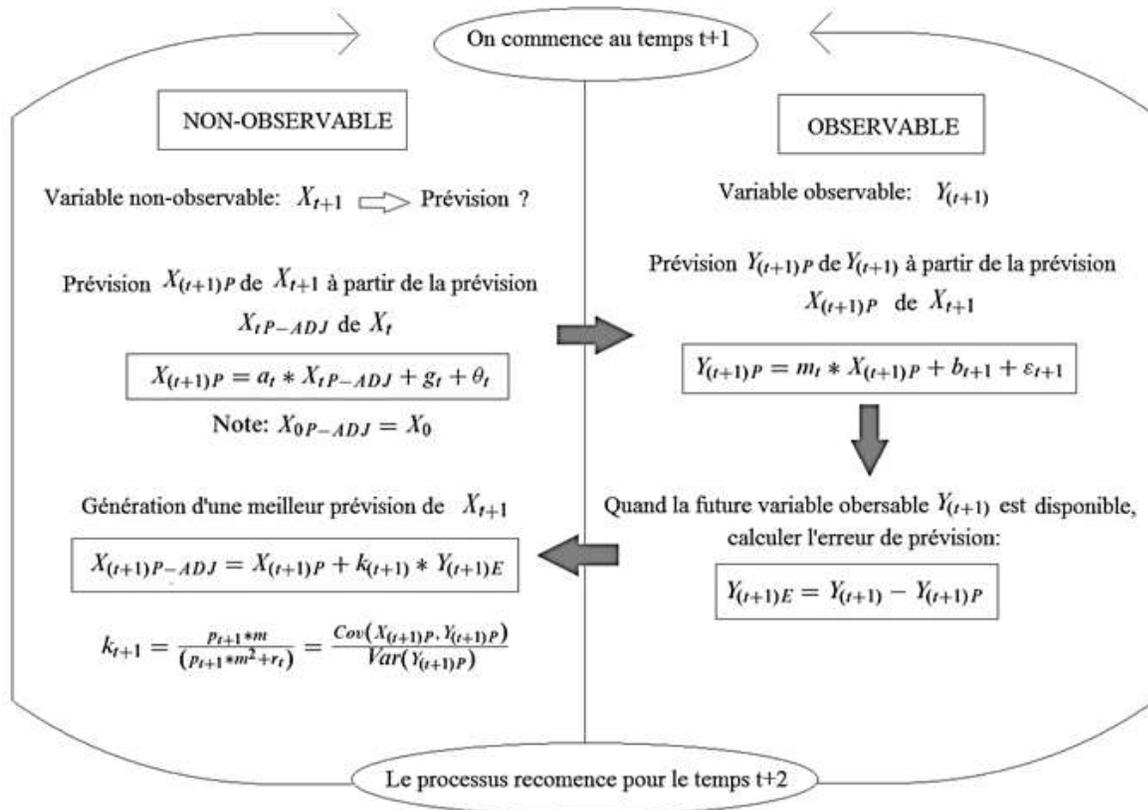


Schéma 1 : Processus du Filtre de Kalman

Il est important de noter qu'il n'est pas dans la capacité du filtre de Kalman d'estimer les paramètres inconnus dans l'équation de transition, soit a et θ_t dans cet exemple. Par conséquent, il est nécessaire d'obtenir une estimation de ces paramètres en question pour permettre au filtre de Kalman de générer la série temporelle pour la variable non-observée.

Supposons que $Y_{t+1|t}$ ne sont pas auto-corrélés et suivent une distribution normale de moyenne et variance définies dans les équations (*) et (**), nous avons la distribution de jointe de vraisemblance conditionnelle suivante :

$$L = \prod_{t=1}^{t=T} \left\{ \left[\frac{1}{\sqrt{2\pi * Var(Y_{(t|t-1)})}} \right] * e^{-\frac{\sum_{t=1}^T (Y_t - E[Y_t|t-1])^2}{2 * Var(Y_{(t|t-1)})}} \right\} \quad (28)$$

La fonction de log-vraisemblance à maximiser pour ce modèle est alors :

$$\ln(L) = -\frac{1}{2} \left[T \ln(2\pi) + \sum_{t=1}^T \ln[\text{var}(Y_{t|t-1})] + \sum_{t=1}^T \frac{(Y_t - E[Y_{t|t-1}])^2}{\text{var}(Y_{t|t-1})} \right] \quad (29)$$

Annexe 2 : Filtre de Kalman Discret – Forme Générale

Maintenant que nous avons développé l'intuition du filtre de Kalman à travers un modèle simple, considérons le cas plus général utilisant des représentations espace-état.

On utilise le filtre sur un modèle espace-état décrivant une équation de mesure et une équation d'état. Ce choix provient de la facilité d'implémentation dans des programmes de calcul matriciel tel que MATLAB®. On s'inspire du document de Guo (2009) pour la suite, en se basant sur la notation d'Hamilton (1994) et en changeant A' par A and H' par H pour alléger la notation.

Notons que la variable y_t est observable tandis qu' S_t ne l'est pas. Les équations d'état et de mesure sont respectivement :

$$S_{t+1} = B + F S_t + v_{t+1} \quad (30)$$

$$y_t = A x_t + H S_t + w_t \quad (31)$$

$$E(v_t v_s) = \begin{cases} Q & t = s \\ 0 & \text{sinon} \end{cases} \quad E(w_t w_s) = \begin{cases} R & t = s \\ 0 & \text{sinon} \end{cases} \quad E(v_t w_s) = 0 \quad \forall t, s$$

Ce système possède n variables de mesure, k variables d'état et m variables exogènes.

Les dimensions de chaque variable sont les suivantes :

Variable	S_t	y_t	x_t	A	H	F
Dimension	k x 1	n x 1	m x 1	n x m	n x k	k x k

Tableau 2 : Dimensions des variables utilisées pour l'implémentation du filtre de Kalman:

Le but est de trouver un estimé de $\{S_t\}_{t=1}^T$ sachant $\{y_t\}_{t=1}^T$. Pour cela, nous devons estimer tous les paramètres. Dans le modèle standard, on fait l'hypothèse que v_t et w_t sont distribués selon une loi normale :

$$\begin{cases} v_t \sim N(0, Q) \\ w_t \sim N(0, R) \end{cases}$$

Distribution non-conditionnelle des variables d'état

L'équation d'état est un modèle VAR(1). Sa distribution non-conditionnelle peut être déduite si elle est stationnaire.

Dans le cas univarié, si f est inférieur à 1 en valeur absolue, alors S_t est faiblement stationnaire :

$$\begin{cases} E(S_t) = \frac{b}{1-f} \\ Var(S_t) = \frac{q}{1-f^2} \end{cases}$$

Si la racine de $1-f=1$ se situe sur le cercle unitaire, alors S_t est un processus de racine unitaire. Cela implique la non-existence de sa distribution non-conditionnelle.

Filtre

Les étapes principale du filtre sont les même que celle du cas simple.

Posons :

$S_{t|t-1}$: Préviation conditionnelle optimale de S_t sachant l'information I_{t-1} au temps $t-1$.

$P_{t|t-1}$: Préviation conditionnelle de la variance

$$P_{t|t-1} = E \left[(S_t - S_{t|t-1})(S_t - S_{t|t-1})' \mid I_{t-1} \right] \quad (32)$$

Se référer au document de Guo (2009) pour plus de détails.

1. Début de la récurrence:

À $t=0$, faire hypothèse sur l'état initial du système.

(a) En utilisant la distribution non-conditionnelle (si elle existe) (puisque'il n'y a pas informations au temps zéro):

$$\hat{S}_{0|0} = E(S_1) = (I - F)^{-1} B \quad (33)$$

$$\hat{P}_{0|0} = E[(S_1 - E(S_1))(S_1 - E(S_1))'] = h(\theta) \quad (34)$$

(b) En supposant que $S_0 \sim N(a_0, P_0)$

$$E(S_0) = a_0 \quad (35)$$

$$Var(S_0) = P_0 \quad (36)$$

avec a_0, P_0 des paramètres additionnels.

(c) En supposant une valeur arbitraire pour S_0 (par exemple $S_0 = 0$) et avec P_0 très grand pour indiquer que l'estimation initiale est très incertaine, par exemple $P_0 = 100$ (voir Kim et Nelson (1998)).

2. Prévisions ex ante pour la prochaine période $S_{t|t-1}$ ($t > 0$)

$$\hat{S}_{t|t-1} = B + F\hat{S}_{t-1|t-1} \quad (37)$$

$$\hat{P}_{t|t-1} = \Omega + F\hat{P}_{t-1|t-1}F' \quad (38)$$

3. Prévision de y_t ($t > 0$)

Sachant $\hat{S}_{t|t-1}$, on utilise l'équation de mesure pour estimer y_t :

$$\hat{y}_{t|t-1} = Ax_t + H\hat{S}_{t|t-1} \quad (39)$$

On calcule l'erreur :

$$\hat{w}_t = y_t - \hat{y}_{t|t-1} = H(S_t - \hat{S}_{t|t-1}) + v_t \quad (40)$$

4. Correction ex post de la prévision de $S_{t|t-1}$

$$\hat{S}_{t|t} = \hat{S}_{t|t-1} + K_t \hat{w}_t \quad (41)$$

$$\hat{P}_{t|t} = (I - K_t H) \hat{P}_{t|t-1} \quad (42)$$

avec K_t le gain de Kalman:

$$K_t = \hat{P}_{t|t-1} H' (H \hat{P}_{t|t-1} H' + R)^{-1} \quad (43)$$

5. Répéter le processus

Une fois les itérations terminées, on obtient les séries $\{\hat{y}_{t|t-1}\}$, $\{\hat{y}_{t|t}\}$, $\{\hat{P}_{t|t-1}\}$, $\{\hat{P}_{t|t}\}$

Annexe 3 : Série de rendements totaux – CDX High Yield

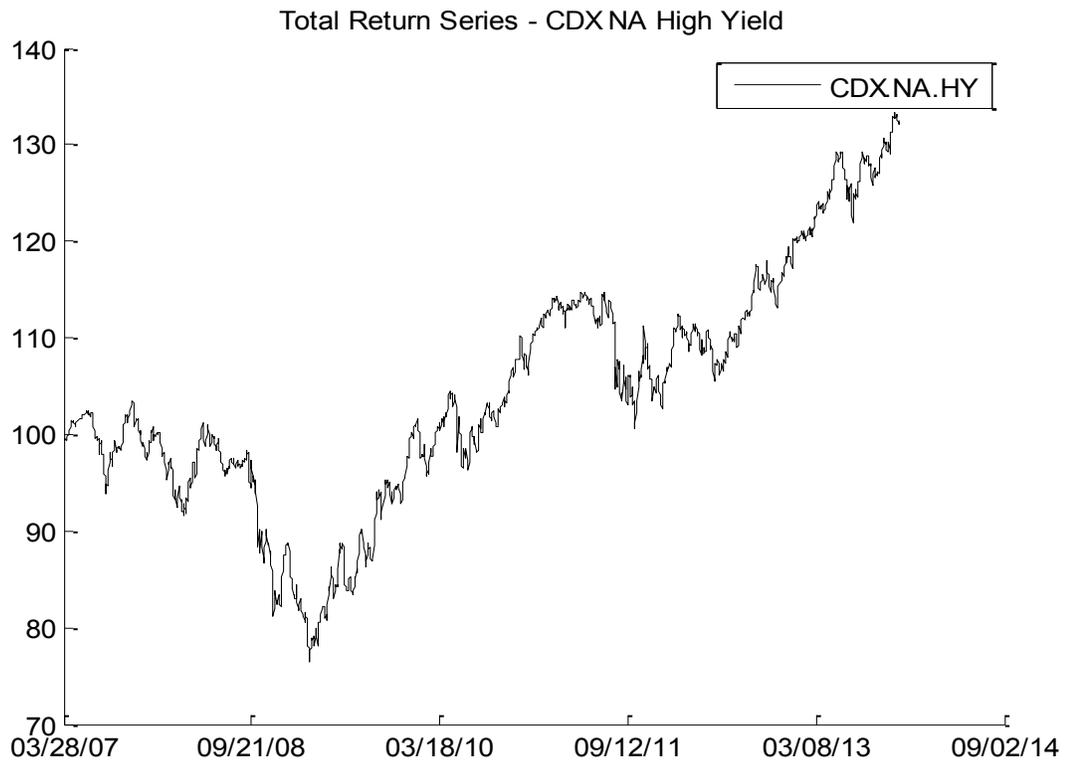


Figure 4: Graphique de la série de 'Total Return' pour l'indice de crédit CDX High Yield
28 Mars 2007 – 2 Septembre 2014

Annexe 4: Indices de crédit

A.4.1 : Description des indices de crédit

Nous expliquons brièvement certaines propriétés de ces indices en se basant sur la publication de l'équipe de recherche en crédit de JP Morgan (Septembre 2013), *Global CDS Indices*.

- **iTraxx Main (Europe)**

L'*iTraxx Main* (Europe) est formé des 125 contrats de CDS les plus liquides diversifiés sur 5 secteurs. La note de crédit la plus faible selon Moody's S&P et Fitch doit être supérieure à Baa3/BBB- Negative Watch/Outlook. (Note : Si une entité est notée par plus de deux agences, on retient la note la plus faible). Les compagnies sans note de crédit sont exclues de l'indice *iTraxx Main*

- **iTraxx X-Over (Europe)**

L'*iTraxx X-Over* est composé de CDS Européens à haut rendement avec les CDS les plus liquides. À cela s'ajoutent des CDS Européens à haut rendement qui ne sont pas négociés activement avec des CDS mais qui ont émis suffisamment de dette au cours des 12 derniers mois précédant la date de rebalancement.

- **CDX Investment Grade (Amérique du Nord)**

L'indice *CDX Investment Grade*, coté en points de base par an, est composé de 125 titres sous-jacents. Il est négocié avec un coupon fixe de 100 points de base.

- **CDX High Yield (Amérique du Nord)**

L'indice *CDX High Yield*, cotée en termes de prix, est composé de 100 titres sous-jacents. Il se négocie avec un 'upfront' (qui est égal à $(100 \$ - \$ \text{prix}) / 100$) et un coupon fixe de 500 points de base.

A.4.2 : Tableau des Statistiques Descriptives

	mean	median	max	min	range	std	Skewness	Kurtosis	kpsstest	jbtest
ITRAXX EUR	0,8634	0,8850	2,1531	0,2013	1,9519	0,4890	0,4347	2,1884	VRAI	VRAI
Log ITRAXX EUR	-0,3342	-0,1222	0,7669	-1,6032	2,3701	0,6427	-0,2768	1,7462	VRAI	VRAI
ITRAXX EUR XOVER	4,4383	4,0682	11,5300	1,4900	10,0400	1,9854	1,1185	4,0806	VRAI	VRAI
Log ITRAXX EUR XOVER	1,3986	1,4032	2,4450	0,3988	2,0462	0,4244	0,2005	2,3706	VRAI	VRAI
CDXNAIG	0,8809	0,8549	2,8550	0,2940	2,5610	0,4303	1,2181	5,0505	VRAI	VRAI
Log CDXNAIG	-0,2391	-0,1567	1,0491	-1,2242	2,2733	0,4760	0,0113	2,3540	VRAI	VRAI
CDXNAHY	5,0513	4,3723	15,7147	2,0885	13,6262	2,2479	2,1023	8,6676	VRAI	VRAI
Log CDXNAHY	1,5437	1,4753	2,7546	0,7364	2,0182	0,3720	0,7379	3,6385	VRAI	VRAI

Tableau 3: Ce tableau présent les statistiques descriptives pour les indices de crédit étudiés ainsi que leur logarithme pour la période allant du 1^{er} Janvier 2004 au 1er Décembre 2013.

Test de KPSS : L'hypothèse nulle suppose la stationnarité de la série.

Test de Jarque-Bera : L'hypothèse nulle suppose que la série provient d'une distribution normale avec moyenne et variance inconnues

VRAI : signifie que le test l'hypothèse a été rejeté avec un niveau de confiance de 95%.

Les séries ne sont donc ni stationnaires (KPSS), et ne proviennent pas de données normalement distribuées (Jarque-Bera).

Annexe 5: Indice de crédit et son logarithme

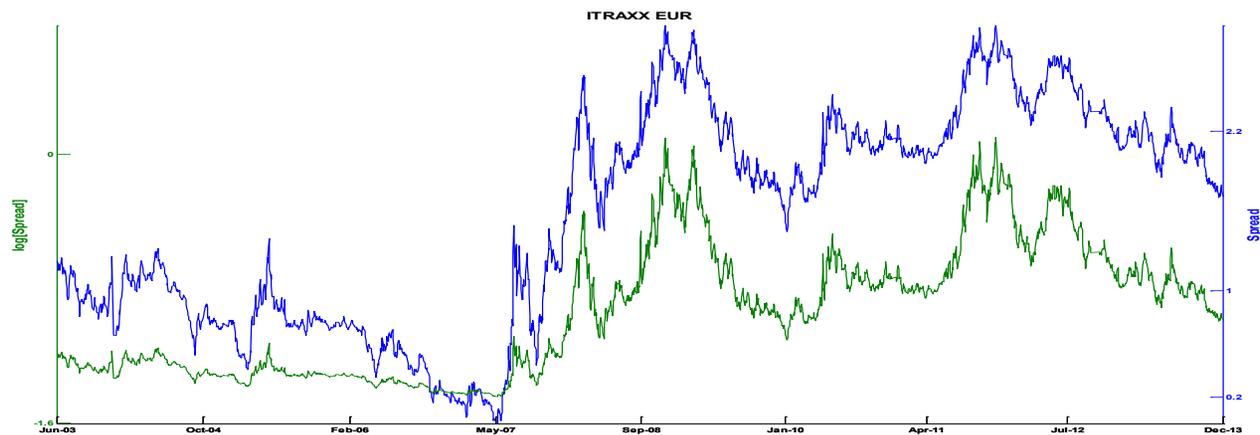


Figure 5.A : Graphique du niveau de l'indice iTraxx EUR Main et son logarithme

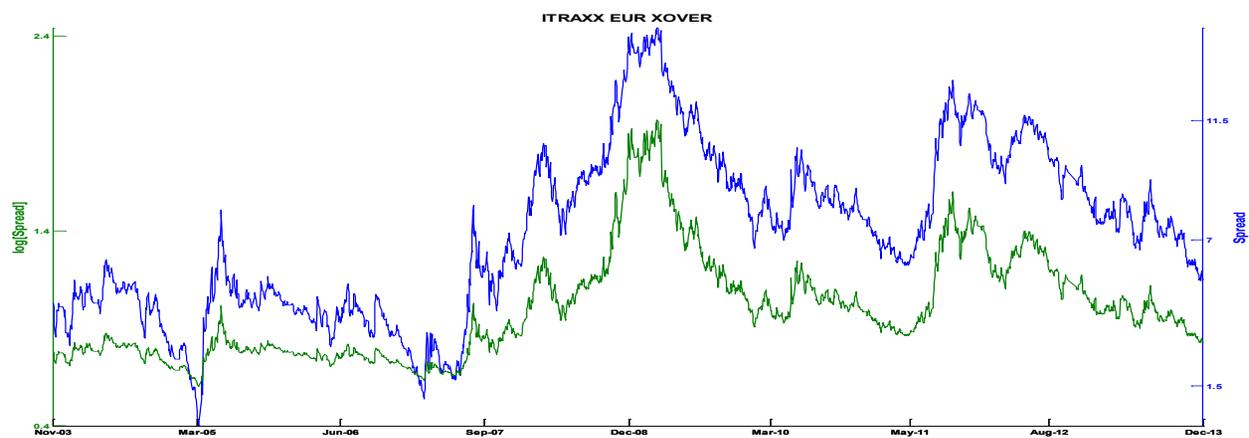


Figure 5.B : Graphique du niveau de l'indice iTraxx EUR X-Over et son logarithme

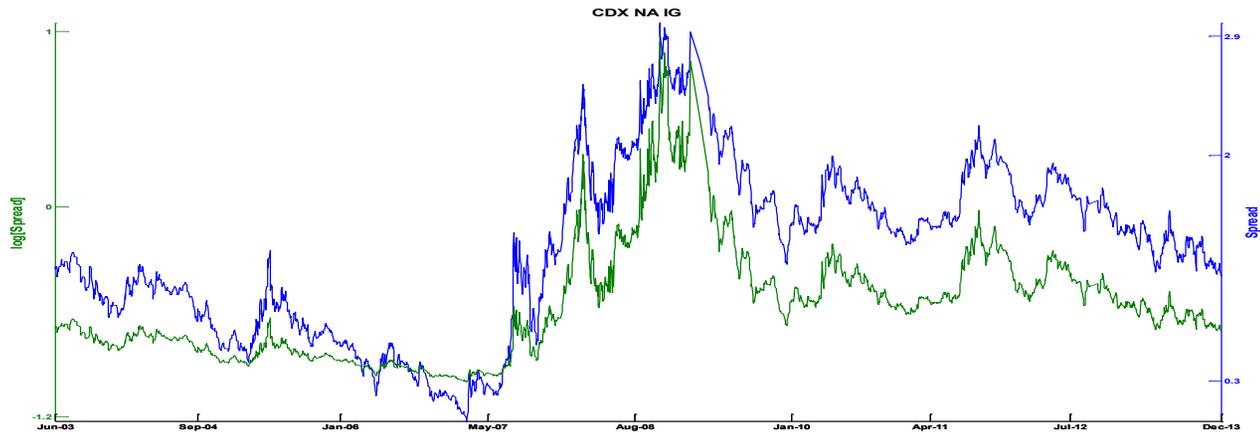


Figure 5.C : Graphique du niveau de l'indice du CDX Investment Grade et son logarithme

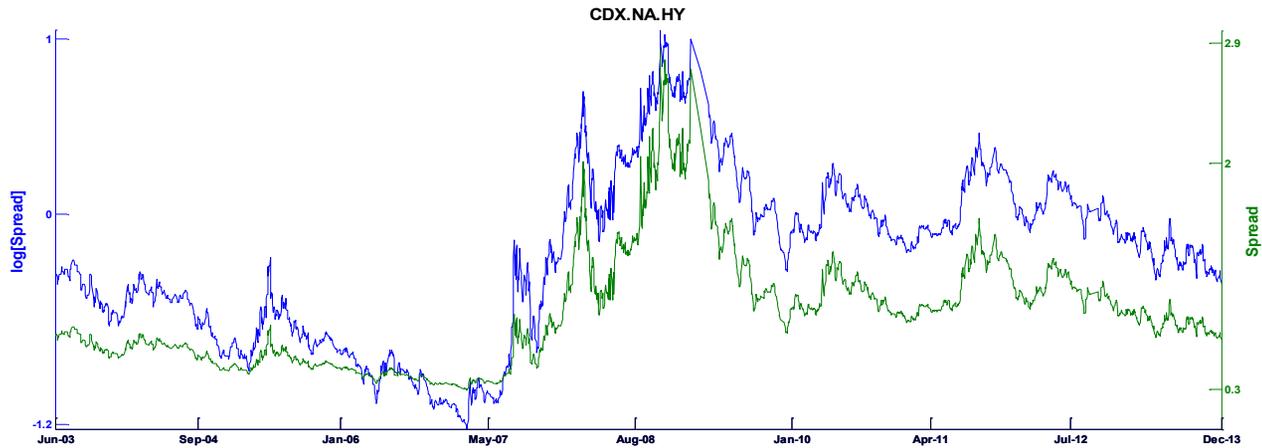


Figure 5.D : Graphique du niveau de l'indice du CDX High Yield et son logarithme

Annexe 6.A : Résultats de la décomposition par le modèle à tendance stochastique

A.6.1 : iTraxx Main

Paramètre	Estimation	Écart type	t-stat	p-value
α	0,869	1,61E-02	5,40E+01	1,18E-02
σ_1	0,112	9,78E-03	1,15E+01	5,54E-02
σ_2	0,037	4,23E-04	8,75E+01	7,28E-03
σ_3	0,006	2,44E-04	2,46E+01	2,59E-02

Tableau 4 – Estimation et variance de chaque paramètre obtenu par la décomposition du log ITRAXX EUR avec le modèle à tendance stochastique. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.

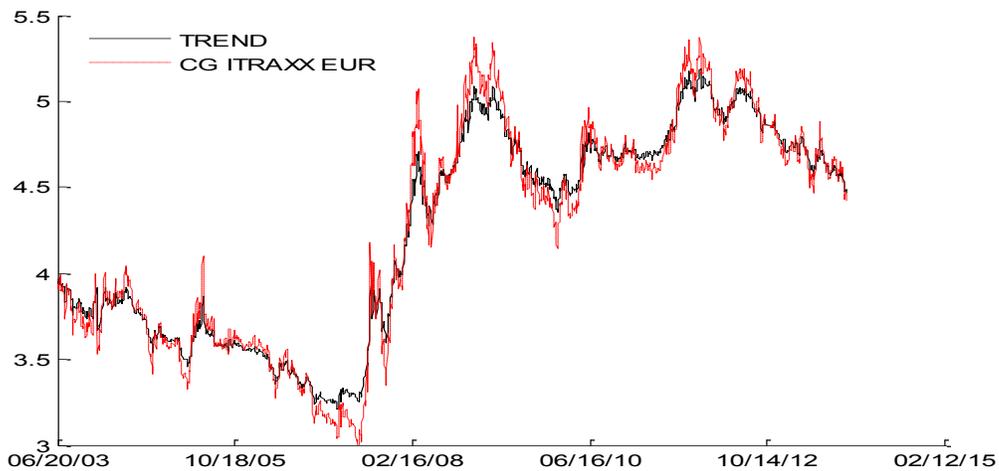


Figure 6.A - Composante tendancielle (en noir) de la décomposition du log iTraxx Main EUR (en rouge)

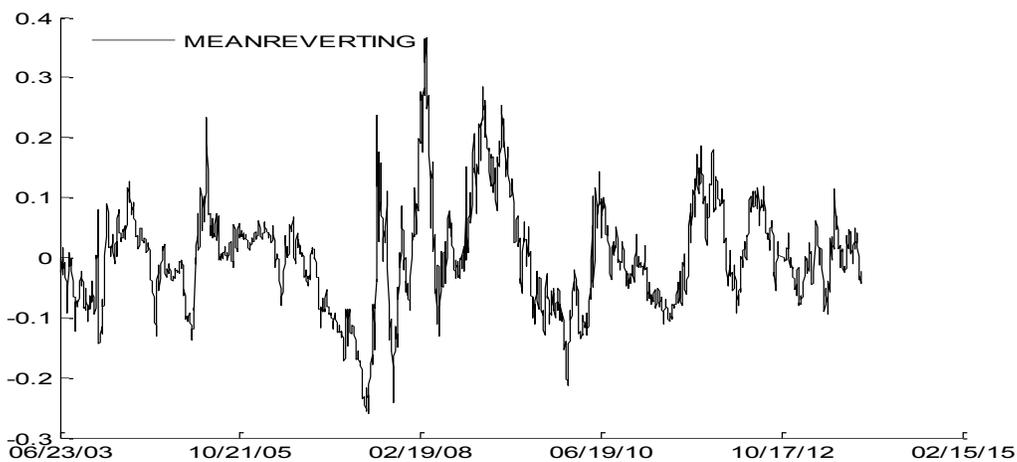


Figure 6.B - Composante de retour à la moyenne de la décomposition du log iTraxx Main

A.6.2 : iTraxx X-Over

Paramètre	Estimation	Écart type	t-stat	p-value
α	0,99	3,80E-02	2,61E+01	2,44E-02
σ_1	0,018	1,07E-03	1,68E+01	3,78E-02
σ_2	0,005	9,06E-04	5,52E+00	1,14E-01
σ_3	0,002	2,13E-04	9,39E+00	6,75E-02

Tableau 5 – Estimation et variance de chaque paramètre obtenu par la décomposition du log iTraxx X-Over avec le modèle à tendance stochastique. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.



Figure 7.A - Composante tendancielle (en noir) de la décomposition du log iTraxx X-Over (en rouge)

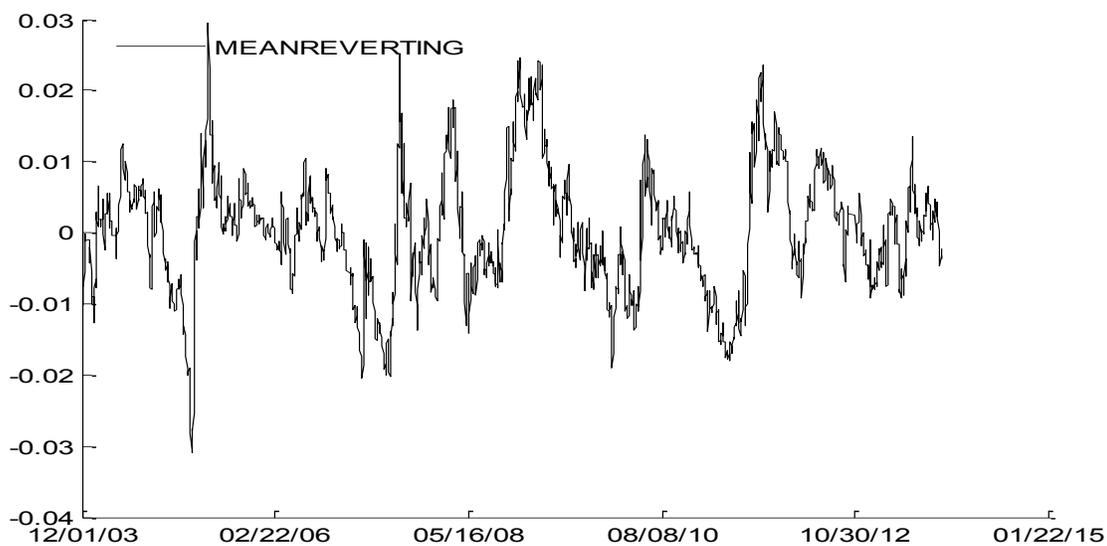


Figure 7.B - Composante de retour à la moyenne de la décomposition du log iTraxx X-Over

A.6.3 : CDX Investment Grade

Paramètre	Estimation	Écart type	t-stat	p-value
α	0,977	3,91E-02	2,50E+01	2,55E-02
σ_1	0,116	1,07E-04	1,08E+03	5,87E-04
σ_2	0,082	8,49E-05	9,66E+02	6,59E-04
σ_3	0,015	2,13E-04	7,04E+01	9,04E-03

Tableau 6 – Estimation et variance de chaque paramètre obtenus par la décomposition du log CDX Investment Grade avec le modèle à tendance stochastique. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.



Figure 8.A - Composante tendancielle (en noir) de la décomposition du log CDX Investment Grade (en rouge)

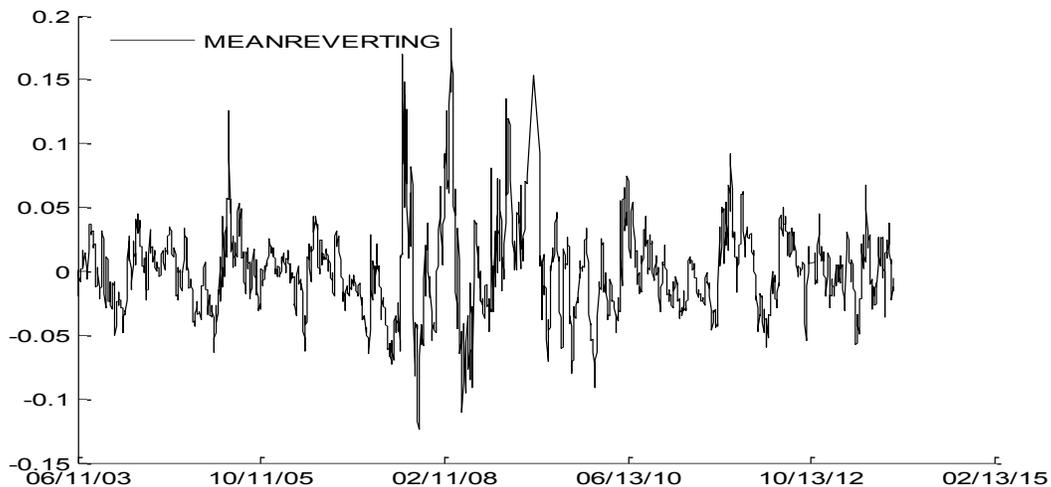


Figure 9.B - Composante de retour à la moyenne de la décomposition du log CDX Investment Grade

A.6.4 : CDX High Yield

Paramètre	Estimation	Écart type	t-stat	p-value
α	0,927	3,43E-2	2,70E+01	2,35E-02
σ_1	0,034	3,40E-4	1,00E+02	6,37E-03
σ_2	0,010	1,43E-3	6,99E+00	9,04E-02
σ_3	0,003	1,22E-3	2,46E+00	2,46E-01

Tableau 7 – Estimation et variance de chaque paramètre obtenus par la décomposition du log CDX High Yield avec le modèle à tendance stochastique. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.

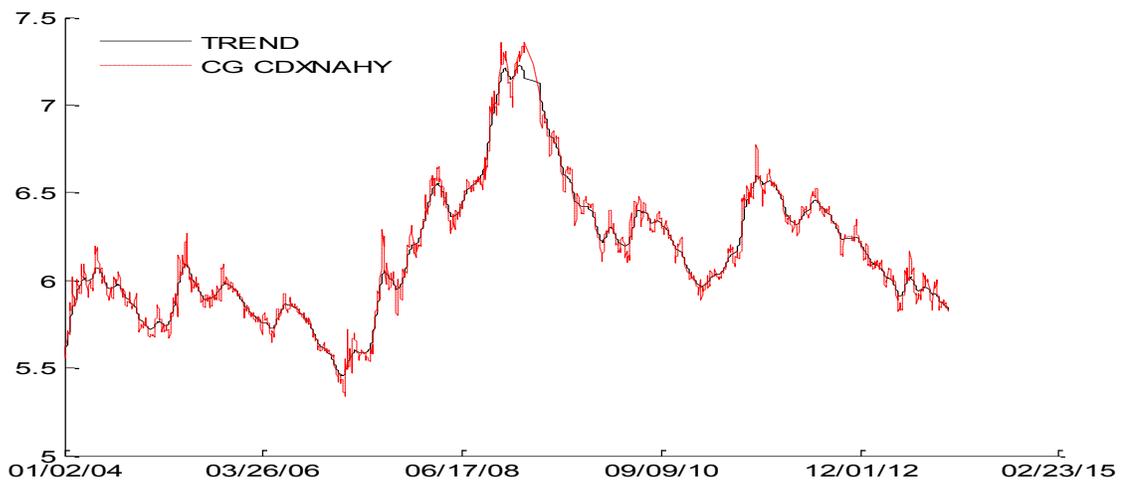


Figure 10.A - Composante tendancielle (en noir) de la décomposition du log CDX High Yield (en rouge)

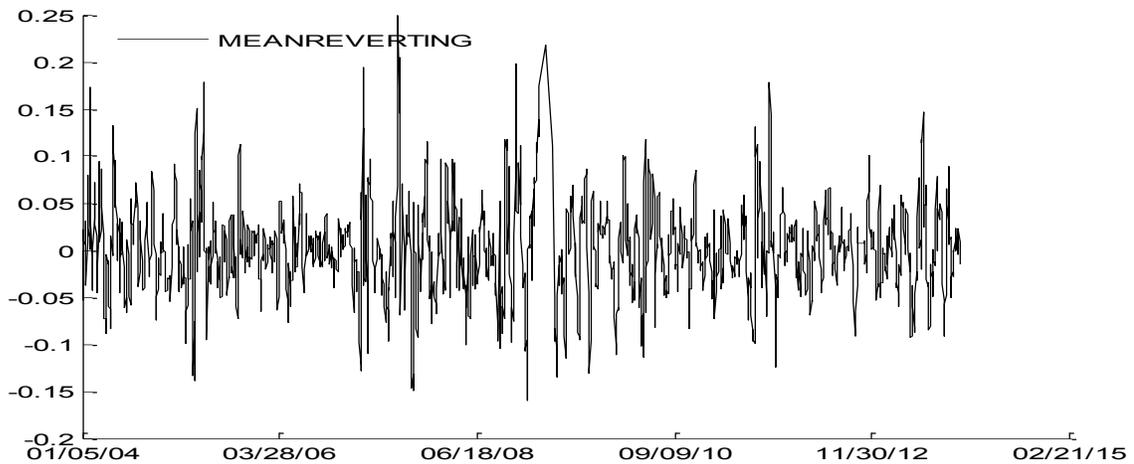


Figure 10.B - Composante de retour à la moyenne de la décomposition du CDX High Yield avec $\sigma_2^{\text{inf}} = 10^{-10}$

Annexe 6: Impact de la variation de σ_2^{inf} - modèle à tendance stochastique - CDX High Yield

A.6.1: Décomposition avec le modèle à tendance stochastique en calibrant $\sigma_2^{inf} = 10^{-10}$

Paramètre	Estimation	Écart-type	t-stat	p-value
A	0,918	3,43E-6	2,68E+05	2,38E-06
σ_1	0,045	3,40E-4	1,32E+02	4,81E-03
σ_2	0,010	1,43E-5	6,99E+02	9,10E-04
σ_3	0,003	1,22E-8	2,46E+05	2,59E-06

Tableau 8 – Estimation et variance de chaque paramètre obtenus par la décomposition du log CDX High Yield avec le modèle à tendance stochastique en calibrant la borne inférieure $\sigma_2^{inf} = 10^{-10}$. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.

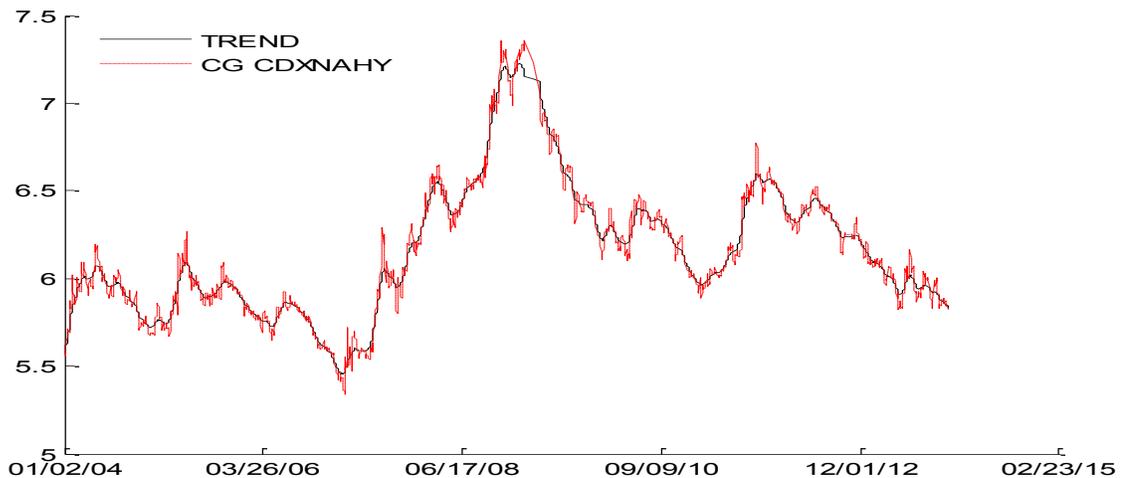


Figure 11.A - Composante tendancielle (en noir) de la décomposition du log CDX High Yield (en rouge) avec $\sigma_2^{inf} = 10^{-10}$

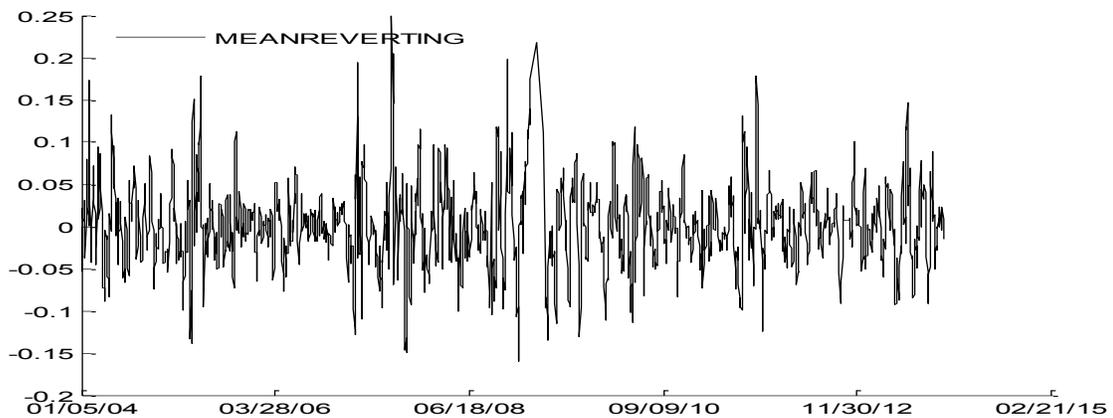


Figure 11.B - Composante de retour à la moyenne de la décomposition du log CDX High Yield avec $\sigma_2^{inf} = 10^{-10}$

A.6.2: Décomposition avec le modèle à tendance stochastique en calibrant $\sigma_2^{inf} = 10\%$

Paramètre	Estimation	Écart-type	t-stat	p-value
α	0,990	4.51E-7	2,20E+06	2,90E-07
σ_1	0,034	3,40E-4	1,00E+02	6,37E-03
σ_2	0,100	6,72E-4	1,49E+02	4,28E-03
σ_3	0,004	1,81E-8	2,21E+05	2,88E-06

Tableau 9 – Estimation et variance de chaque paramètre par filtre de Kalman dans le cas du CDX High Yield en calibrant la borne inférieure $\sigma_2^{inf} = 10\%$. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.

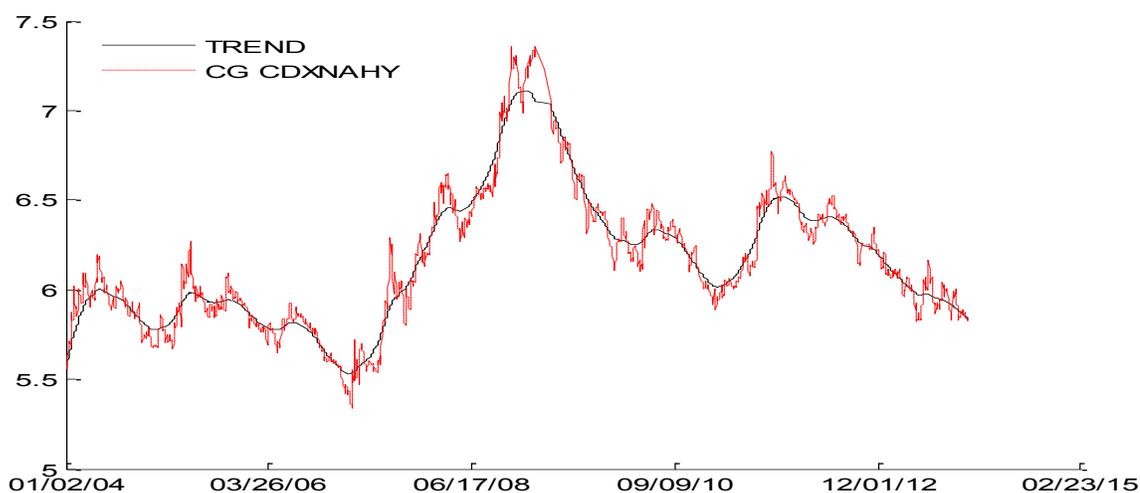


Figure 12.A - Composante tendancielle (en noir) de la décomposition du log CDX High Yield (en rouge) avec $\sigma_2^{inf} = 10\%$

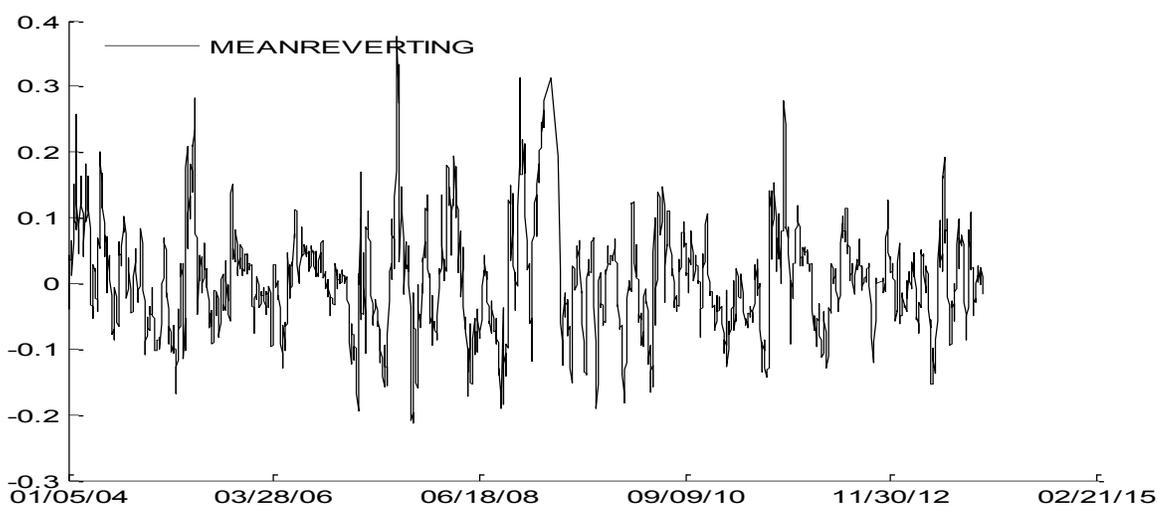


Figure 12.B - Composante de retour à la moyenne de la décomposition du log CDX High Yield avec $\sigma_2^{inf} = 10\%$

A.6.3: Décomposition avec le modèle à tendance stochastique en calibrant $\sigma_2^{\text{inf}} = 50\%$

Paramètre	Estimation	Écart-type	t-stat	p-value
A	0,990	5,22E-2	1,90E+01	3,35E-02
σ_1	0,037	3,40E-4	1,09E+02	5,85E-03
σ_2	0,500	1,86E-4	2,69E+03	2,37E-04
σ_3	0,032	9,50E-7	3,37E+04	1,89E-05

Tableau 10 – Estimation et variance de chaque paramètre par filtre de Kalman dans le cas du log CDX High Yield en calibrant la borne inférieure $\sigma_2^{\text{inf}} = 50\%$. Les tests statistiques ont été menés avec un test bilatéral avec un seuil de signification de 5%.

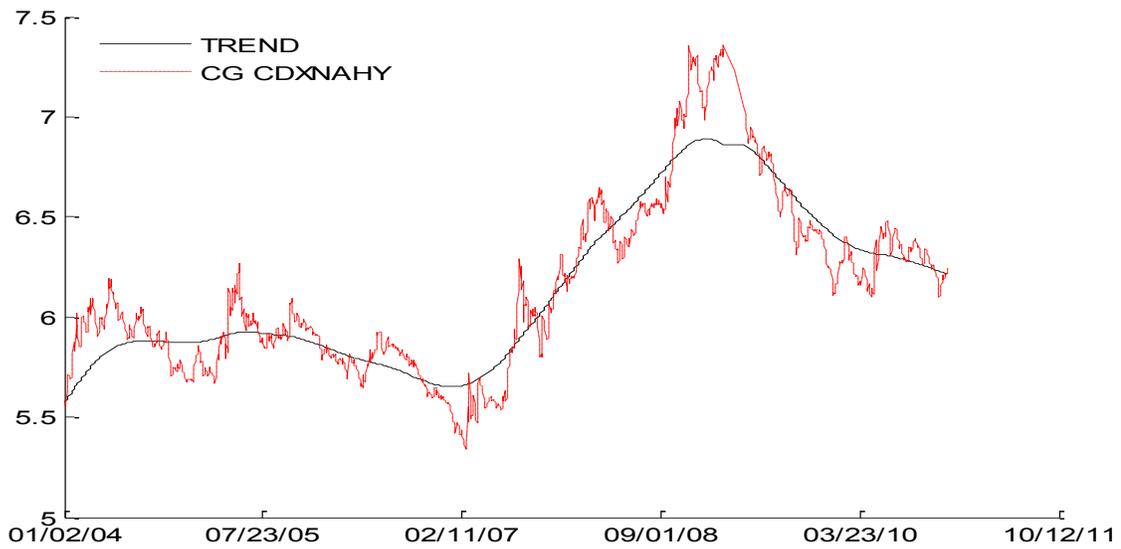


Figure 13.A - Composante tendancielle (en noir) de la décomposition du log CDX High Yield (en rouge) avec $\sigma_2^{\text{inf}} = 50\%$



Figure 13.B - Composante de retour à la moyenne de la décomposition du log CDX High Yield avec $\sigma_2^{\text{inf}} = 50\%$

Annexe 7: Performance en- échantillon et hors-échantillon

A.7.1 : Performance – iTraxx Main

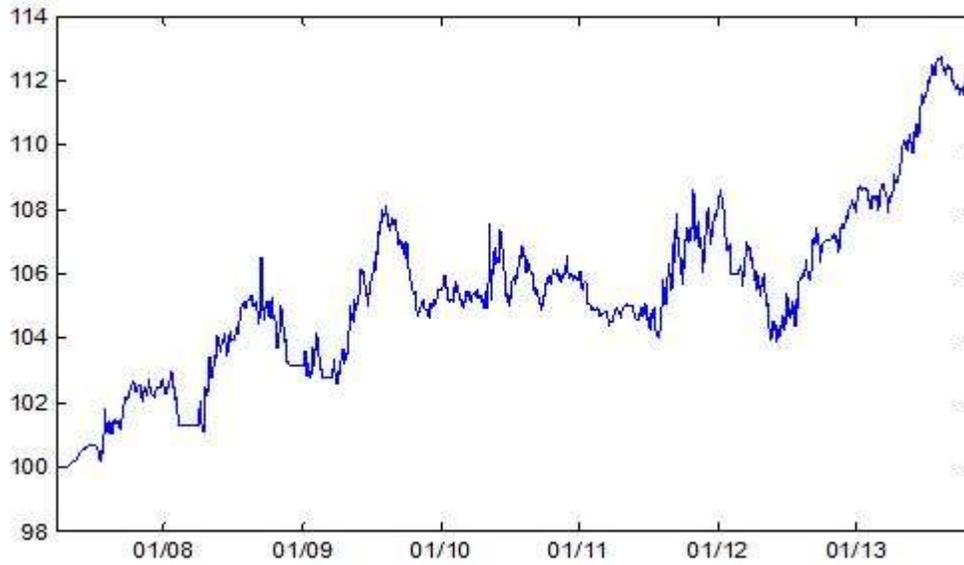


Figure 14.A Performance de la stratégie sur l'indice iTraxx Main

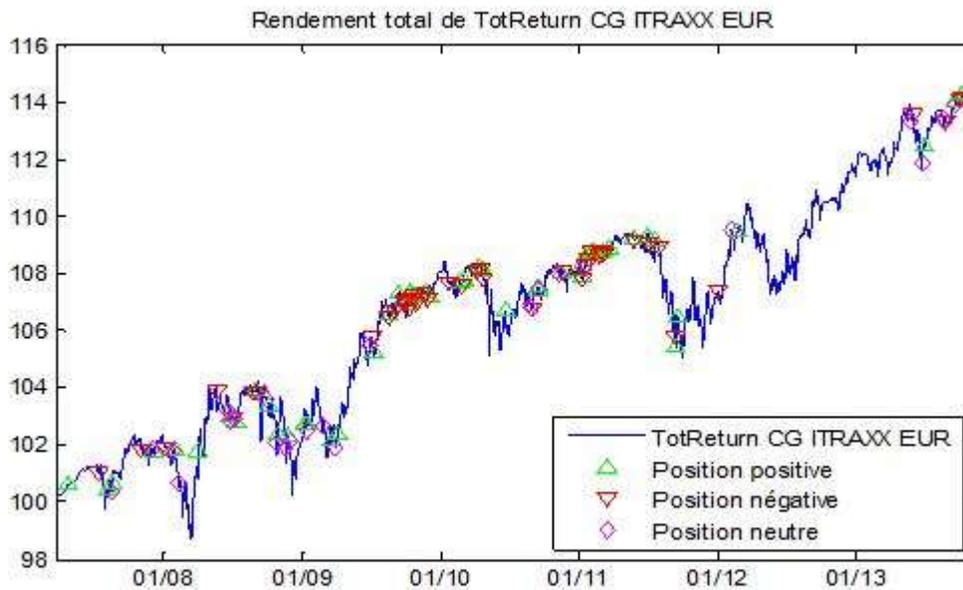


Figure 14.B Positions sur l'indice iTraxx Main exposées sur sa série de rendements totaux

Dates	22-Mar-2007 to 05-Nov-2013
Richesse initiale	100,00 \$
Richesse finale	112,22 \$
Retour sur investissement annualisé	1,75%
Volatilité annualisée	2,92%
Max Drawdown	4,44%
Ratio Sharpe	0,60

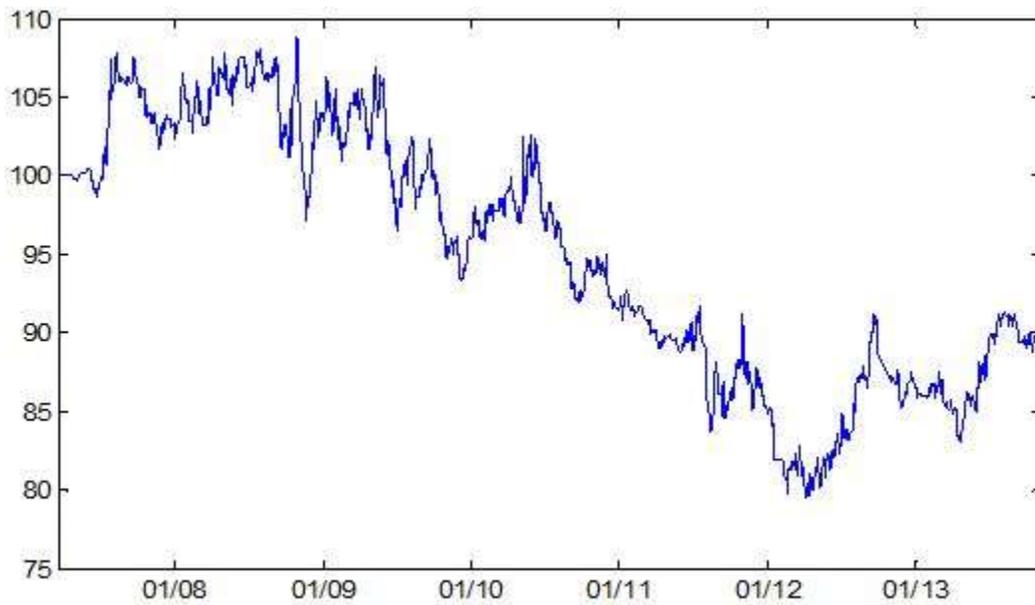
Mesures de Risque

VaR [%]	1 jour	5 jours	10 jours
1%	-0,4%	-0,9%	-1,3%
5%	-0,3%	-0,6%	-0,9%

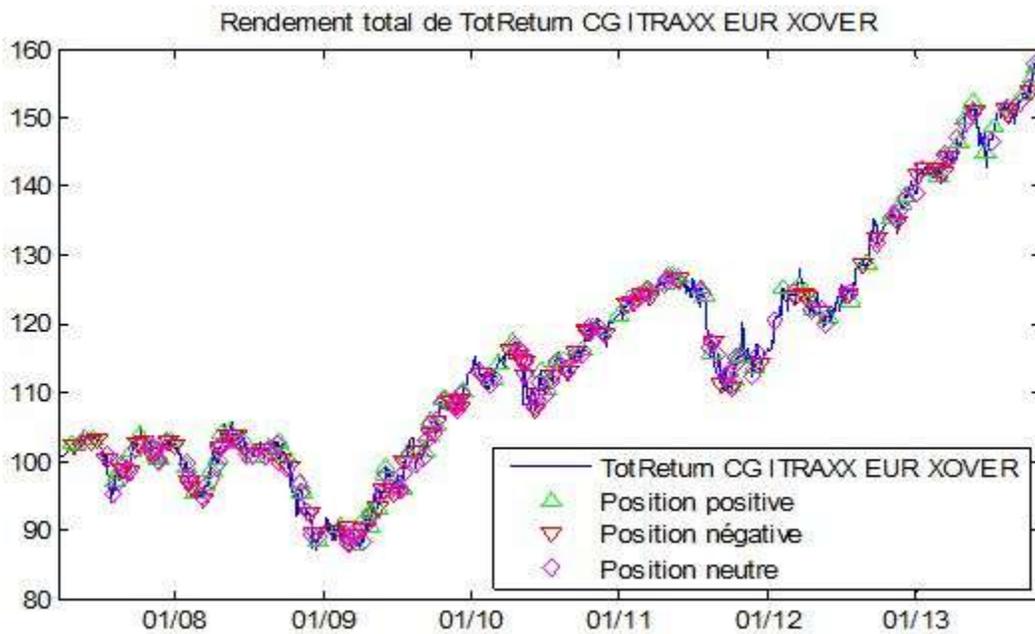
Mesures de Performance

	Toutes positions confondues	Positions courtes	Positions longues
Profit Net	12,22 \$	0,65 \$	11,57 \$
Profit Brut	26,96 \$	8,39 \$	18,57 \$
Perte Brute	(14,73 \$)	(7,74 \$)	(6,99 \$)
Facteur de bénéfice	1,83	1,08	2,66
Nombre total de transactions	95	42	53
Transactions profitables (%)	37%	26%	45%
Positions gagnantes	35	11	24
Positions perdantes	60	31	29
Profit net moyen	0,13 \$	0,02 \$	0,22 \$
Position gagnante moyenne	0,77 \$	0,76 \$	0,77 \$
Position perdante moyenne	(0,25 \$)	(0,25 \$)	(0,24 \$)
Ration gain moyen: perte moyenne	3,14	3,06	3,21
Plus grande position gagnante	3,75 \$	3,44 \$	3,75 \$
Plus grande position perdante	(2,11 \$)	(2,11 \$)	(1,33 \$)
Ratio: + grand gagnant : profit brut	14%	41%	20%
Ratio: + grand perdant: perte brute (%)	14%	27%	19%
Retour sur investissement	12%	1%	12%
Taux de rendement annuel	2%	0%	2%
Période totale (en jours)	2420	2420	2420
Temps dans le marché (en %)	91%	24%	66%
Temps dans le marché (en jours)	2196	592	1604

A.7.2 : Performance – iTraxx X-Over



**Figure 15.A Positions sur l'indice CDX Investment
Grade exposées sur sa série de rendements totaux**



**15.B Positions sur l'indice CDX High Yield
exposées sur sa série de rendements totaux**

Dates	22-Mar-2007 to 05-Nov-2013
Richesse initiale	100,00 \$
Richesse finale	89,87 \$
Retour sur investissement annualisé	-1,60%
Volatilité annualisée	8,87%
Max Drawdown	29,86%
Ratio Sharpe	-0.18

Mesures de Risque

VaR [%]	1 jour	5 jours	10 jours
1%	-1,3%	-2,9%	-4,2%
5%	-0,9%	-2,1%	-3,0%

Mesures de Performance

	Toutes positions confondues	Positions courtes	Positions longues
Profit Net	(10,13 \$)	(10,81 \$)	0,68 \$
Profit Brut	90,35 \$	38,77 \$	51,57 \$
Perte Brute	(100,47 \$)	(49,58 \$)	(50,89 \$)
Facteur de bénéfice	0,90	0,78	1,01
Nombre total de transactions	264	111	153
Transactions profitables (%)	184	81	103
Positions gagnantes	43%	37%	49%
Positions perdantes	80	30	50
Profit net moyen	104	51	53
Position gagnante moyenne	(0,06 \$)	(0,13 \$)	0,01 \$
Position perdante moyenne	1,13 \$	1,29 \$	1,03 \$
Ration gain moyen:perte moyenne	(0,97 \$)	(0,97 \$)	(0,96 \$)
Plus grande position gagnante	1,17	1,33	1,07
Plus grande position perdante	5,10 \$	5,10 \$	3,42 \$
Ratio: + grand gagnant : profit brut	(5,53 \$)	(4,65 \$)	(5,53 \$)
Ratio: + grand perdant: perte brute (%)	6%	13%	7%
Retour sur investissement	6%	9%	11%
Taux de rendement annuel	-10%	-11%	1%
Période totale (en jours)	2420	2420	2420
Temps dans le marché (en %)	82%	35%	47%
Temps dans le marché (en jours)	1983	851	1132

Figure 15.C Statistiques de performance et mesures de risque de la stratégie pour l'indice CDX IG

A.7.3: Performance – CDX Investment Grade

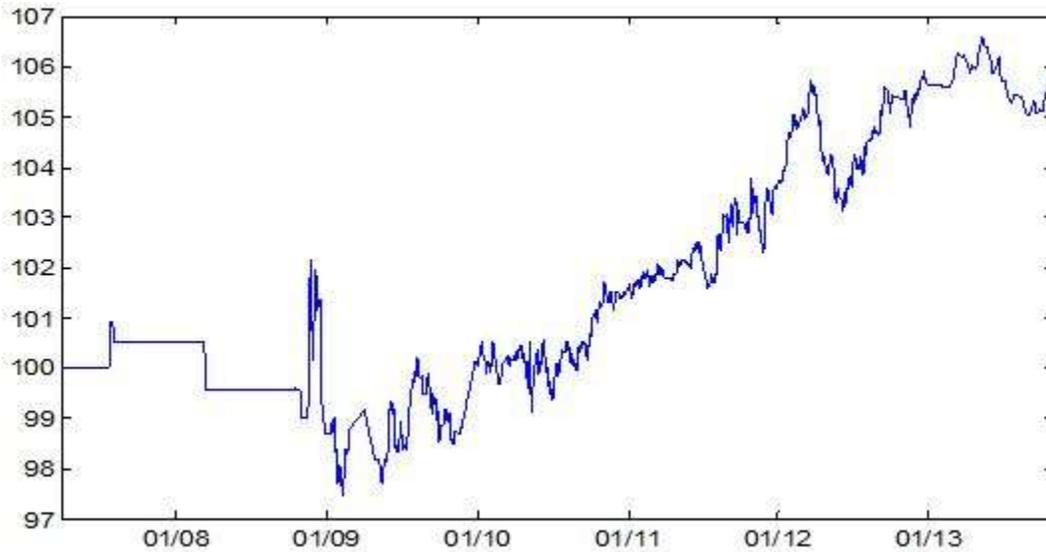


Figure 16.A Positions sur l'indice CDX Investment Grade exposées sur sa série de rendements totaux

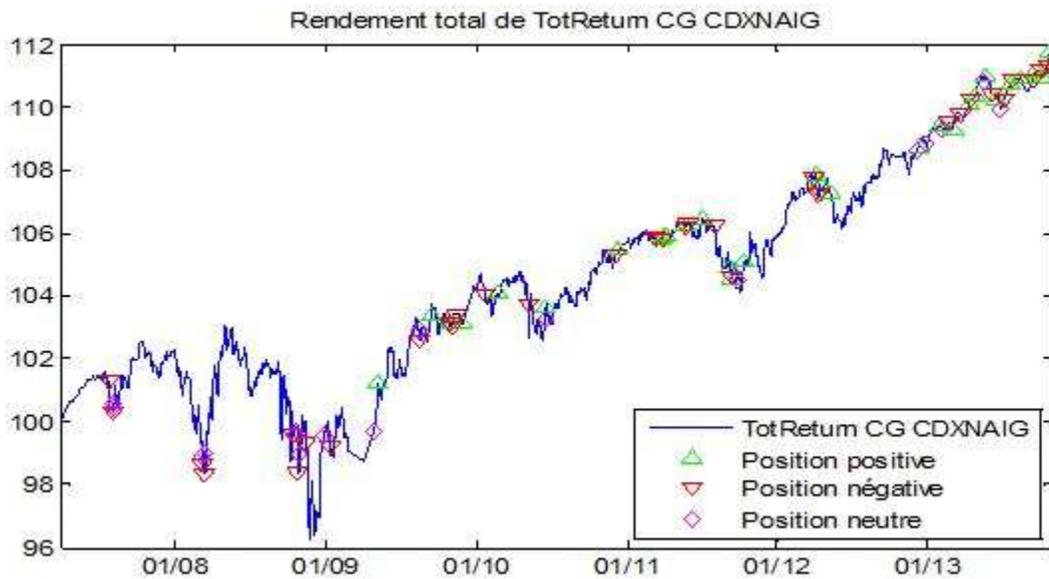


Figure 16.B Positions sur l'indice CDX High Yield exposées sur sa série de rendements totaux

Dates	29-Mar-2007 au 29-Oct-2013
Richesse initiale	100,00
Richesse finale	105,28
Retour sur investissement annualisé	0,78%
Volatilité annualisée	2,29%
Max Drawdown	4,69%
Ratio Sharpe	0,34

Mesures de Risque

VaR [%]	1 jour	5 jours	10 jours
1%	-0,3%	-0,7%	-1,0%
5%	-0,2%	-0,5%	-0,7%

Mesures de Performance

	Toutes positions confondues	Positions courtes	Positions longues
Profit Net	5,28 \$	(2,39 \$)	7,67 \$
Profit Brut	14,30 \$	3,48 \$	10,82 \$
Perte Brute	(9,02 \$)	(5,87 \$)	(3,15 \$)
Facteur de bénéfice	1,58	0,59	3,43
Nombre total de transactions	65	34	31
Transactions profitables (%)	40%	26%	55%
Positions gagnantes	26	9	17
Positions perdantes	39	25	14
Profit net moyen	0,08 \$	(0,07 \$)	0,25 \$
Position gagnante moyenne	0,55 \$	0,39 \$	0,64 \$
Position perdante moyenne	(0,23 \$)	(0,23 \$)	(0,23 \$)
Ration gain moyen:perte moyenne	2,38	1,65	2,83
Plus grande position gagnante	2,60 \$	1,30 \$	2,60 \$
Plus grande position perdante	(0,72 \$)	(0,72 \$)	(0,59 \$)
Ratio: + grand gagnant : profit brut	18%	38%	24%
Ratio: + grand perdant: perte brute (%)	8%	12%	19%
Retour sur investissement	5%	-2%	8%
Taux de rendement annuel	1%	0%	1%
Période totale (en jours)	2406	2406	2406
Temps dans le marché (en %)	69%	19%	50%
Temps dans le marché (en jours)	1661	456	1205

Figure 16.C Statistiques de performance et mesures de risque de la stratégie pour le CDX IG

Rendements annualisés			
Stratégie active	Stratégie passive	Tracking error	Ratio d'Information
3.87%	4.24%	0.97%	-0.3808

Figure 17.A Ratio d'Information pour la stratégie sur l'indice CDX High Yield

R_a : Rendement annualisé sur la stratégie active

R_i : Rendement annualisé sur la stratégie passive

S : Tracking error – écart type de la différence entre les rendements de la stratégie active et les rendements de la stratégie passive

$$\text{Ratio d'Information} = \frac{R_a - R_i}{S}$$

Rendements annualisés			
Stratégie active	Stratégie passive	Tracking error	Ratio d'Information
10,07%	4,24%	2,97%	1,9630

Figure 17.B Ratio d'Information pour la stratégie sur l'indice CDX High Yield en calibrant $\sigma_2^{\text{inf}} = 50\%$

Le Ratio d'Information est calculé de la même manière que ci-dessus

10. BIBLIOGRAPHIE

Arnold, Tom, Mark J. Bertus et Jonathan Godbey (2008). « A Simplified Approach to Understanding the Kalman Filter Technique », *The Engineering Economist*, vol. 53, no. 2, p. 140-155.

Basu, Sanjay (1977). « Investment Performance of Common Stocks in Relation to their Price-Earnings Ratios: A Test of the Efficient Market Hypothesis », *The Journal of Finance*, vol. 33, no. 3, p. 663-682.

Banz, Rolf (1981). « The Relationship between Return and Market Value of Common Stocks », *Journal of Financial Economics*, vol. 9, no. 1, p. 3-18.

Barberis, Nicholas et Robert Thaler (2003). « A Survey of Behavioral Finance », *Handbook of the Economics of Finance*, vol. 1, p. 1053-1128.

Beveridge, Stephen et Charles Nelson (1981). « A new approach to decomposition of economic time series into permanent and transitory components with particular attention to measurement of the 'business cycle' », *Journal of Monetary Economics*, vol. 7, no 2, p. 151–174.

Bhar, Ramaprasad (2010). *Stochastic Filtering with Applications in Finance*, Singapore, World Scientific Publishing Co., 337 p.

Blöchliger, Lea (2008). *Power Prices: A Regime-Switching Spot Forward Price Model with Kim Filter Estimation*, thèse de doctorat, Goldingen, University of St Gallen, 255 p.

Boender, Guus, Alexander Rinnoy Kan et Gerrit Timmer (1982). « A Stochastic Method for Global Optimization », *Mathematical Programming*, vol. 22, p. 125–140.

Boissard, Johan (2012). *Applications and Uses of Digital Filters in Finance*, mémoire de maitrise, Zurich, Swiss Federal Institute of Technology Zurich, 100 p.

Bruder, Benjamin, Tung-Lam Dao, Jean-Charles Richard et Thierry Roncalli (2011). *Trend Filtering Methods for Momentum Strategies*, Paris, Lyxor Asset Management, 64 p.

Burdz, Krzysztof (2009). *The Search for Certainty: On the Clash of Science and Philosophy of Probability*, Washington, World Scientific Publishing Company, 272 p.

Buus, Ida et Charlotte Renneberg J. Nielsen (2009). *The Relationship between Equity Prices and Credit Default Swap Spreads: An Empirical Analysis*, mémoire de maitrise, Copenhagen, Copenhagen Business School, 589 p.

Cartier Pierre et Yvette Perrin (1995). « Integration over Finite Sets », dans Diener, Francine et Marc Diener (dir.), *Nonstandard Analysis in Practice*, Springer, p. 185-204.

Casasola Enzo, Clanzig Kellya et Deville Thibault (2010). *Étude de Cas: Filtre de Kalman* [document inédit], récupéré le 20 septembre 2013 de http://rose.eu.org/2010/wp-content/uploads/2010/03/Kalman_article.pdf.

Cassano, Mark et Gordon Sick (2012). « Forward Copper Price Models: A Kalman Filter Analysis », *Alberta Finance Institute Conference 2012*, London June 2012.

Chan, Kenneth, Narasimhan Jegadeesh et Josef Lakonishok (1996). « Momentum Strategies », *The Journal of Finance*, vol. 51, no 5, p. 1681-1713.

Cochrane, John (2001). « Long-Term Debt and Optimal Policy in the Fiscal Theory of the Price Level », *Econometrica*, vol. 69, no. 1, p. 69-116.

Dal Bianco, Marcos, Maximo Carmacho et Gabriel Perez-Quiros (2012). « Short-Run Forecasting of the Euro-Dollar Exchange Rate with Economic Fundamentals », *Journal of International Money and Finance*, Elsevier, vol. 31, no 2, p. 377-396.

Dando, Raphael et Julien Turc (2013). « Trend-Following and Mean-Reverting Strategies on Credit Indices », *Société Générale*.

Doucet, Arnaud, Simon Godsill et Christophe Andrieu (2000). « On Sequential Monte Carlo Sampling Methods for Bayesian Filtering », *Statistics and Computing*, vol. 10, p. 197-208.

Estrella, Arturo et Frederic S. Mishkin (1998). « Predicting U.S. Recessions: Financial Variables as Leading Indicators », *The Review of Economics and Statistics*, vol. 80, no. 1, p. 45-61.

Fama, Eugene F. (1970). « Efficient Capital Markets: A Review of Theory and Empirical Work », *The Journal of Finance*, vol. 25, no. 2, p. 383-417.

Fliess, Michel et Cédric Join (2009). « A Mathematical Proof of the Existence of Trends in Financial Time Series », *Systems Theory: Modelling, Analysis and Control*, p. 43-62.

French, Kenneth (1980). « Stock Returns and the Weekend Effect », *Journal of Financial Economics*, vol. 8, p. 59-69.

Gilchrist, Simon et Egon Zakrajšek (2011). « Credit Spreads and Business Cycle Fluctuations », *American Economic Review*, vol. 102, no. 4, p. 1692-1720.

Gentil, Ivan et Bruno Rémillard (2008). « Using Systematic Sampling Selection for Monte Carlo Solutions of Feynman-Kac Equations », *Advances in Applied Probability*, vol. 40, no. 2, p. 454-472.

Giovanni, Calice, Christos Ioannidis et Rong Hui Miao (2010). *A Markov Switching Unobserved Component Analysis of the CDX Index Term Premium* [document inédit], Bath, University of Bath, 53 p.

- Guo, Steve (2009). Estimating Time Series Model Using Kalman Filter in Matlab.
- Hamilton, James Douglas (1994). *Time Series Analysis*, Princeton, Princeton University Press, 816 p.
- Harris, Lawrence et Eitan Gurel (1986). « Price and Volume Effects Associated with Changes in the S&P 500 List: New Evidence for the Existence of Price Pressures », *The Journal of Finance*, vol. 41, no. 4, p. 815-829.
- Harris, Richard et Robert Sollis (2003). *Applied Time Series Modelling and Forecasting*, New York, Wiley, 316 p.
- Harvey, Andrew et Thomas Trimbur (2008). « Trend Estimation and the Hodrick-Prescott Filter », *Journal of Japan Statistics*, vol. 38, no. 1, p. 41-49.
- Harvey, Andrew (1990). *Forecasting Structural Time-Series Models and the Kalman Filter*, Cambridge, Cambridge University Press, 572 p.
- Harvey, Andrew et Neil Shephard (1993). « Structural Time Series Models », dans Maddala *et al.* (dir.), *Handbook of Statistics, Volume 11*, Elsevier Science Publisher, p. 261-302.
- Harvey, Andrew (1985). « Trends and Cycles in Macroeconomic Time Series », *Journal of Business & Economic Statistics*, vol. 3, no. 3, p. 216-227.
- Harvey, Andrew (1987). « Applications of the Kalman Filter in Econometrics », *Advances in Econometrics*, vol. 1, p. 285-312.
- Heston, Steven (1993). « A Closed-Form Solution for Options with Stochastic Volatility with Applications to Bond and Currency Options », *The Review of Financial Studies*, vol. 6, no. 2, p. 327-343.
- Hong, Harrison et Jeremy C. Stein (1998). « A Unified Theory of Underreaction, Momentum Trading and Overreaction in Asset Markets », *The Journal of Finance*, vol. 54, no. 6, p. 2143-2184.
- JP Morgan (2013). « Global CDS Indices », *JP Morgan Europe Credit Research*.
- Kalman, Rudolf (1960). « A New Approach to Linear Filtering and Prediction Problems », *Transaction of the ASME: Journal of Basic Engineering*, vol. 82, p. 35-45.
- Kim, Chang-Jin et Charles R. Nelson (1998). *State-Space Models with Regime-Switching: Classical and Gibbs-Sampling Approaches with Applications*, Cambridge, The MIT Press, 311 p.
- Markit (2011). *Markit CDX/LCDX Total Return Index Guide*. Récupéré le 5 octobre 2013 de <http://www.markit.com/assets/en/docs/products/data/indices/credit-index-annexes/Markit%20CDX%20and%20LCDX%20Total%20Return%20Index%20Guide.pdf>

Maybeck, Peter (1979). *Stochastic Models, Estimation and Control: Volume 1*, London UK, Academic Press, 444 p.

Meese, Richard et Kenneth Rogoff (1983). « Empirical Exchange Rate Models of the Seventies: Do They Fit Out of the Sample? », *Journal of International Economics*, vol. 14, p. 3-24.

Moore, Eliakim Hastings (1920). « On the Reciprocal of the General Algebraic Matrix », *Bulletin of the American Mathematical Society*, vol. 26, p. 394-395.

Newey, Whitney et Kenneth West (1987). « A Simple, Positive Semidefinite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix », *Econometrica*, vol. 55, p. 347-370.

Penrose, Roger (1955). « A Generalized Inverse for Matrices ». *Proceedings of the Cambridge Philosophical Society*, vol. 51, p. 406-413.

Racicot, Francois-Eric et Raymond Théoret (2011). « Forecasting Stochastic Volatility using the Kalman Filter: An Application to Canadian Interest Rates and Price-Earnings Ratio », *Aestimatio – The IEB International Journal of Finance*, vol. 1, p. 28-47.

Robinson Abraham (1996). *Non-Standard Analysis*, Princeton, Princeton University Press, édition révisée, 308 p.

Rozeff, Michael et William Kinney (1976). « Capital Markets Seasonality: The Case of Stock Returns », *Journal of Financial Economics*, vol. 3, p. 379-402.

Shleifer, Andrei (1986). « Do Demand Curves for Stocks Slope Down? », *The Journal of Finance*, vol. 41, no. 3, p. 579-590.

Sorenson, Harold (1970). « Least-Squares estimation: from Gauss to Kalman », *Spectrum IEEE*, vol. 7, no. 7, p. 63-68.

Skalli, Mohamed Reda (2010). *Pertinence économique de la restriction d'absence d'arbitrage sur le modèle Nelson-Siegel*, mémoire de maîtrise, Montréal, HEC Montréal.

Terasvirta, Timo, Dag Tjostheim et Clive W.J. Granger (2010). *Modelling Non-Linear Economic Time Series*, Oxford, Oxford University Press, 592 p.

Tommaso, Proietti et Alessandra Luati (2012). « Maximum Likelihood Estimation of Time Series Models : The Kalman Filter and Beyond », *Handbook of Research Methods and Applications in Empirical Macroeconomics*, p. 334-362.

Wada, Tatsuma et Pierre Perron (2006). *An Alternative Trend-Cycle Decomposition using a State Space Model with a Mixture of Normals: Specifications and Applications to International Data* [document inédit], Boston, Boston University, 42 p.

White, Halbert (1984). *Asymptotic Theory for Econometricians*, New York, Academic Press, 264 p.

Wold, Herman (1954). *A Study in the Analysis of Stationary Time Series*, Stockholm, Almqvist & Wiksell, 236 p.

Schneeweis, Thomas et Richard B. Spurgin (1999). « Alpha, Alpha...Who's Got the Alpha? », *The Journal of Alternative Investments*, vol. 2, no. 3, p.83-87.