



LETTRE DE RECHERCHE

JUILLET 2019

Intelligence Artificielle, Apprentissage profond et Réseaux Neuronaux Convolutifs appliqués aux marchés financiers

L'ESSENTIEL

Depuis près de 4 ans, nos *Lettres de Recherches* décrivent les fondements théoriques de nos processus de gestion quantitative, les progrès de nos recherches et les résultats mis en œuvre.

L'application aux marchés financiers de techniques d'Intelligence Artificielle est encore expérimentale et ne permet pas d'aboutir à des conclusions définitives et à une mise en œuvre généralisée. Néanmoins, les résultats intermédiaires que nous obtenons sont particulièrement prometteurs et justifient d'y consacrer une première *Lettre de Recherche* dédiée à ce thème.

Notre point de départ est l'analyse des résultats spectaculaires obtenus par l'Apprentissage Profond dans le domaine de la reconnaissance d'images ; nous avons souhaité mener nos propres expérimentations pour appliquer ces techniques aux marchés financiers en général et à notre processus de gestion quantitative sur actions en particulier.

Nous avons défini un protocole de mise en œuvre original, en deux temps principaux :


1. Représentation des actifs financiers sous forme d'images, non exploitables par l'œil humain, qui agrègent un grand nombre d'informations (prix, volumes, indicateurs d'analyse technique...)
2. Application d'une technique d'apprentissage profond bâtie sur des *Réseaux Neuronaux Convolutifs* (ou « *CNN* », *Convolutional Neural Networks*) dont l'objectif est de caractériser le comportement futur d'un titre (hausse ou baisse) en fonction des multiples informations agrégées dans les images.

Nous avons obtenu des résultats encourageants :

- Notre *CNN* prédit correctement le comportement futur d'un titre dans plus de 51% des cas en moyenne, ce qui est substantiel, au vu du nombre d'images testées ;
- Le taux de réussite de notre *CNN* est statistiquement significatif avec une *p-value* inférieure à 0,01%, ce qui signifie qu'un singe aurait moins de 0,01% de chance de faire un score égal ou meilleur ;
- L'intégration de ces premiers résultats à notre processus de gestion *Finaltis EfficientBeta™* en améliore significativement les résultats.

LA SUPREMATIE DE LA MACHINE SUR L'HOMME

New York, 11 Mai 1997 : lors d'une partie d'échecs, le champion du monde, Garry Kasparov, est surpris par un coup qu'il ne comprend pas. Quelques minutes plus tard, il quittera la table de jeu et laissera la victoire à son adversaire... *Deeper Blue*, développé par *IBM*, première machine parvenant à battre un champion du monde d'échecs. Cette victoire marque le début de la suprématie d'une série de programmes informatiques d'échecs sur les joueurs humains. L'avantage de la machine ne découle pas de sa « créativité », mais plutôt de son incroyable capacité de calcul et de mémorisation : ces logiciels s'appuient sur l'ensemble des connaissances accumulées par les Hommes depuis plus de 5 siècles au travers de concepts, de tactiques et de stratégies, sur une littérature très abondante, et sur des bases de données de millions de parties (dont celles de Garry Kasparov...)¹.



"Je pense qu'il est temps pour DeepBlue de jouer aux vrais échecs et je peux vous promettre à vous tous que, si DeepBlue joue à la régulière, je vous le garantis, je le réduis en pièces" Garry Kasparov commentant la victoire de DeeperBlue

Fin 2017, une équipe de développeurs de *GoogleDeepMind* et leur nouveau programme, *AlphaZero*, crée une petite révolution : il bat systématiquement, le meilleur « joueur » de l'époque, *StockFish8*. Outre le caractère spectaculaire de la performance, ce qui interpelle est qu'*AlphaZero* est d'une conception radicalement différente de la précédente génération d'intelligences artificielles : ses développeurs n'ont programmé que les règles du jeu. Aucun exemple de parties jouées par des humains n'a été nécessaire ; *AlphaZero* s'est contenté d'apprendre seul et librement, en jouant contre lui-même quelques millions de parties durant... 4 heures.

La technique à l'origine de cette révolution est apparue en 2012, lors d'un concours de reconnaissance d'images. Alors que ce domaine ne connaissait plus d'améliorations significatives - le taux d'erreur stagnant autour de 25% - une équipe utilisant une approche d'apprentissage profond (« Deep Learning ») a réalisé une percée spectaculaire, réduisant le taux d'erreur à 16%. Ces résultats ont conduit les chercheurs à appliquer cette technique à d'autres domaines ; de nouvelles applications n'ont cessé d'être trouvées. Outre les échecs, les équipes de *GoogleDeepMind* se sont intéressées au jeu de Go et ont développé *AlphaGo*, premier programme à battre des joueurs professionnels, dont le 9^{ème} dan coréen Lee Sedol en mars 2016, puis le champion du monde de la discipline, le chinois Ke Jie, en mai 2017. La forte médiatisation de ces victoires ne doit pas cacher des applications plus concrètes, comme dans l'imagerie médicale : l'apprentissage profond y permet de suggérer certains diagnostics bien en amont de l'apparition des premiers symptômes et bien avant que les radiologues en soient capables.

Ces dernières avancées de l'apprentissage profond nous ont incités à consacrer un projet de recherche à l'application de ces méthodes à la caractérisation des marchés financiers.

¹ La partie entre Garry Kasparov et *Deeper Blue* fait encore débat aujourd'hui : alors que certains pensent que les coups de *Deeper Blue* étaient en réalité déterminés par un ou plusieurs humains, d'autres évoquent un bug dans le programme d'*IBM*...

QU'EST-CE QUE L'APPRENTISSAGE PROFOND

Il n'existe pas encore de théorie fondamentale permettant d'expliquer pourquoi les systèmes d'Apprentissage Profond fonctionnent si bien dans certains domaines. Nous ne pouvons donc qu'en proposer une description succincte.

D'un point de vue théorique, les idées de base de l'apprentissage à partir de réseaux neuronaux ont été formulées il y a plusieurs décennies. A la mode à la fin du XX^{ème} siècle, il a surtout débouché sur des applications de scoring ou de détection de fraudes. Les tentatives d'application à la prise de décision en univers incertain se sont révélées plutôt décevantes jusque très récemment.

La persévérance des chercheurs, l'accès à une abondance de données, la baisse du coût de la puissance informatique et la profusion de bibliothèques logicielles en *open source* ont permis à cette technologie d'évoluer vers ce qui est appelé aujourd'hui l'Apprentissage Profond et d'être au cœur de nombreuses recherches académiques et privées.

L'apprentissage profond utilisé par Finaltis repose sur des *Réseaux Neuronaux Convolutifs* (nous utiliserons l'acronyme *CNN* pour *Convolutional Neural Networks*). Alors que l'extraction des caractéristiques qui permettent la classification est réalisée *manuellement* dans l'apprentissage classique, l'apprentissage profond met en œuvre plusieurs couches de réseaux convolutifs élémentaires, qui se forment à reconnaître des caractéristiques permettant la classification. Chaque couche affine la reconnaissance de l'image : les premières couches extraient des caractéristiques simples (contours), que les couches suivantes combinent pour former des concepts de plus en plus complexes. Ils apprennent ainsi le monde qui les entoure de façon naturellement hiérarchisée.



Les chats qui prennent l'avion compliquent la tâche des Réseaux Neuronaux Convolutifs chargés de différencier des images de chats et d'avions...

Exemple : La première couche d'un Réseau Neuronal Convolutif détecte les petites arêtes, les côtés sombres et les plus lumineux ; le niveau suivant prend en charge et détecte des éléments tels que les coins où deux arêtes se rejoignent. Le niveau suivant peut trouver des configurations plus compliquées, comme un groupe d'arêtes disposées en cercle. À un niveau encore plus profond, il pourrait détecter la juxtaposition récurrente d'angles en forme de truffe près d'un cercle en forme de tête, ou bien d'angles en forme d'ailes près d'un cylindre en forme de fuselage : le système est progressivement capable de différencier un chat d'un avion.

La mise en place d'un *Réseau Neuronal Convolutif* nécessite une phase d'apprentissage, pendant laquelle des dizaines de milliers d'images sont montrées aux systèmes afin d'extraire les caractéristiques principales. Chaque image est labellisée, permettant aux *CNN* d'associer les caractéristiques à un « label » (un chat ou un avion dans l'exemple précédent). Une fois cette phase terminée, il est alors possible de tester le système en comparant les labels obtenus sur des images avec leur vraie classification.

DES IMAGES INNOVANTES DE MARCHES

Nos travaux se concentrent sur l'étude du comportement des actions de l'indice *Euro Stoxx*, avec pour objectif de définir un ensemble de titres qui présentent une probabilité significativement supérieure à 50% d'avoir à court / moyen terme un meilleur ratio rendement / risque que celui d'un indice équilibré des constituants de l'*Euro Stoxx*.

QUELLES INFORMATIONS UTILISER ?

La mise en œuvre de *Réseaux Neuronaux Convolutifs* dans ce cadre nous conduit à définir des images de titres contenant des informations prédictives de leur comportement futur. Si la première intuition peut conduire à envisager des images construites uniquement à partir de l'évolution des performances relatives du titre par rapport à l'indice susmentionné, cette démarche ne semble pas optimale pour profiter de toutes les capacités d'apprentissage de notre *CNN*. Ainsi, pour chaque constituant de l'indice, nous enrichissons les images d'un ensemble d'indicateurs issus de l'analyse technique :

- les performances de chaque titre relatives à la performance d'un indice équilibré des constituants de l'*Euro Stoxx* ;
- des RSI (*Relative Strength index*) sur plusieurs horizons de temps de ces performances relatives, mais également des volumes et des carrés des variations relatives ;
- des croisements de moyennes mobiles de l'évolution des performances relatives, définis par le rapport de deux moyennes mobiles (avec plusieurs horizons de temps) ;
- des informations sur les dynamiques des variances et des volatilités, définies par (avec plusieurs valeurs de k_1 et k_2) :

$$\text{Int} \left[F \left(\frac{\text{Variance estimée}(j - k_1, j)}{\text{Variance estimée}(j - k_2, j - k_1)} \right) \right]$$

avec F la fonction de répartition d'une loi de Fischer Snédecor ($k_1, k_2 - k_1$)

L'utilisation d'un grand nombre d'indicateurs doit permettre à l'apprentissage profond de combiner les informations pour obtenir des signaux originaux et d'écarter les informations non pertinentes.

Remarque : Les Réseaux Neuronaux Convolutifs nécessitent un grand nombre d'images pour assurer un apprentissage de qualité. Or, les données financières, contrairement aux photographies de chats sur internet, sont, par nature, en nombre limité. Le nombre restreint de données fondamentales explique leur absence, à ce jour, dans notre étude.

CONSTRUCTIONS DES IMAGES

Pour chaque titre, à une date donnée t , nous couplons ces informations sur une seule image de la manière suivante :

- Chaque indicateur est associé à une couleur ;
- Le temps est représenté horizontalement (abscisse), la colonne de pixels la plus à droite représentant la veille du jour de calcul ;
- Chaque image représente l'évolution des indicateurs sur les 65 jours ouvrés précédant la veille du jour de calcul, (soit l'intervalle $[t-65 ; t-1]$) ;

- Les ordonnées permettent de connaître la valeur de l'indicateur à la date t , normalisée entre 0 et 255 ;
- Le label (« le résultat ») peut prendre 10 valeurs différentes (entre 0 et 9) et est obtenu par la formule ci-dessous. Il représente le ratio rendement / risque futur, calculé sur l'intervalle $[t + 1 ; t + 65]$ de chaque titre :

$$Int \left[F \left(\frac{\text{Moyenne rdt}(j + 1, j + 65)}{\text{volatilité estimée}(j + 1, j + 65) / \sqrt{65}} \right) \right]$$

avec F la fonction de répartition d'une loi de Student à 64 degrés de liberté

Ainsi défini, nous obtenons à chaque t et pour chaque action, une image de 65 pixels de long et de 255 pixels de haut.

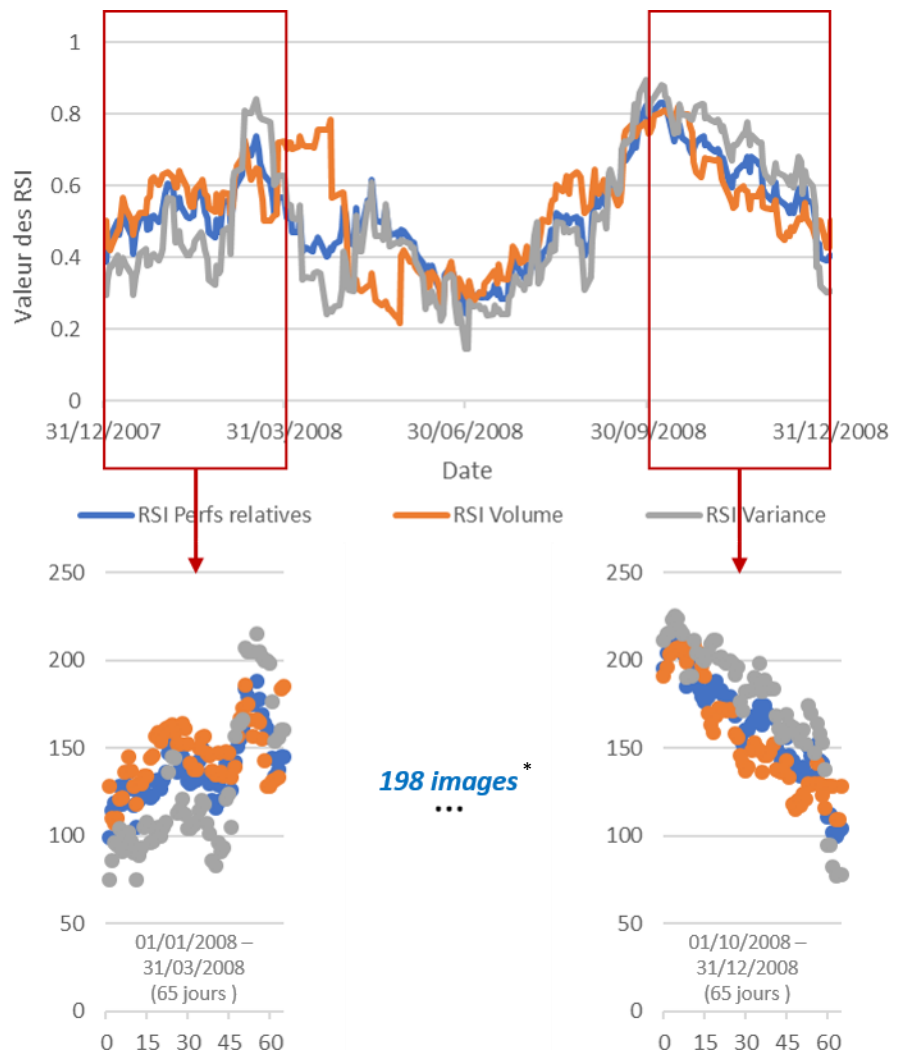
Nous illustrons la construction des images par l'exemple ci-contre, qui se limite à 3 indicateurs :

- RSI 25 jours sur la performance relative ;
- RSI (conditionnel au signe des variations relatives) 25 jours sur le volume ;
- RSI (conditionnel au signe des variations relatives) 25 jours du carré des variations

Le premier graphique illustre le comportement de ces 3 indicateurs sur l'année 2008.

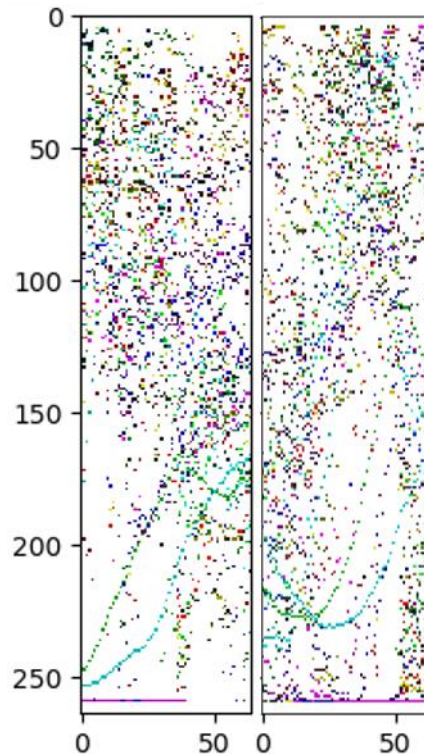
Nous construisons maintenant, pour chaque période de 65 jours (les deux cadres rouges illustrent la première et la dernière période de 65 jours de l'année 2008) : nous obtenons donc, pour cet exemple, 198 images de marché par constituant de l'indice.

La dernière étape consiste alors à définir les labels de ces images, en calculant les ratios rendement / risque sur les 65 jours suivant la date de calcul de l'image (entre le 02/04/2008 et le 01/07/2008 pour la première image de l'exemple).



Evolution des RSI de la performance relative, du volume et des carrés des variations sur l'année 2008 pour un titre donné - (*) : 198 images = 262 jours ouvrés en 2008 - 65 + 1

Avec cette méthode, et l'intégration de tous les indicateurs techniques sur les différents horizons de temps, nous obtenons les images ci-dessous, incompréhensibles pour l'œil humain. L'ordinateur, qui est capable de différencier précisément la valeur de deux pixels, est à même de tirer les informations nécessaires à la lecture de ces images.

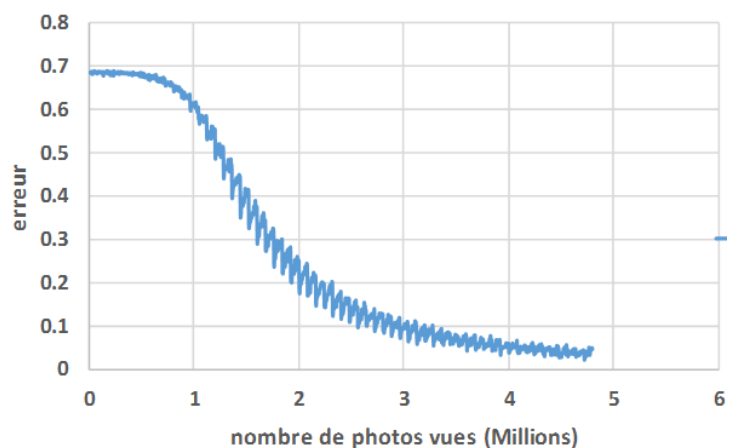


Deux images obtenues par notre méthode.
Celle de gauche indique un titre qui va surperformer l'indice équilibré des constituants de l'Euro Stoxx ;
celle de droite, un titre qui va sous-performer.

L'APPRENTISSAGE

Nous réalisons des apprentissages à partir d'images définies avec la méthode précédente sur des périodes de 3 ans. Nous conservons seulement celles dont les labels correspondent aux variations relatives extrêmes (label 0 – baisse - et 9 – hausse).

Ainsi composé, l'ensemble d'apprentissage comprend plus de 40 000 images. Afin d'améliorer l'apprentissage, nous présentons au **CNN** un grand nombre de fois (plus de 50 fois) les mêmes images.



Evolution de la performance de notre modèle de classification

NOTRE CNN A-T-IL APPRIS ?

Afin de tester la qualité de l'apprentissage, nous présentons à nouveau toutes les photos utilisées pour l'apprentissage et vérifions les résultats. En moyenne, sur chaque période de 3 ans utilisée pour l'apprentissage, notre CNN présente un taux de réussite de 99% sur les 20.000 images décrivant une baisse future ; pour les 20.000 images décrivant une hausse future, notre CNN présente un taux de réussite de 98%. Notre CNN interprète donc de façon très précise les images qu'il a apprises.

Notre Réseau Neuronal Convolutif se comporte comme un étudiant qui aurait appris sa leçon par cœur et qui serait capable de la réciter quasiment sans erreur.

NOTRE CNN A-T-IL COMPRIS CE QU'IL A APPRIS ?

Les excellents résultats précédents ne présagent pas de la capacité prédictive de notre système. Pour cela, nous lui présentons de nouvelles images issues de l'année suivante de la période utilisée pour l'apprentissage, et comparons les labels obtenus (hausse ou baisse) avec les résultats réels.

En moyenne, pour chaque période d'apprentissage $[N-3 ; N-1]$, le CNN donne le bon label des images de l'année N dans plus de 51% des cas ce qui correspond à une p -value inférieure à 0,01%, ce qui signifie qu'un singe aurait moins de 0,01% de chance de faire un score au moins aussi bon. Si le taux de réussite de notre CNN semble faible, il est statistiquement significatif.

PROCESSUS FINALTIS EFFICIENTBETA™ & APPRENTISSAGE PROFOND

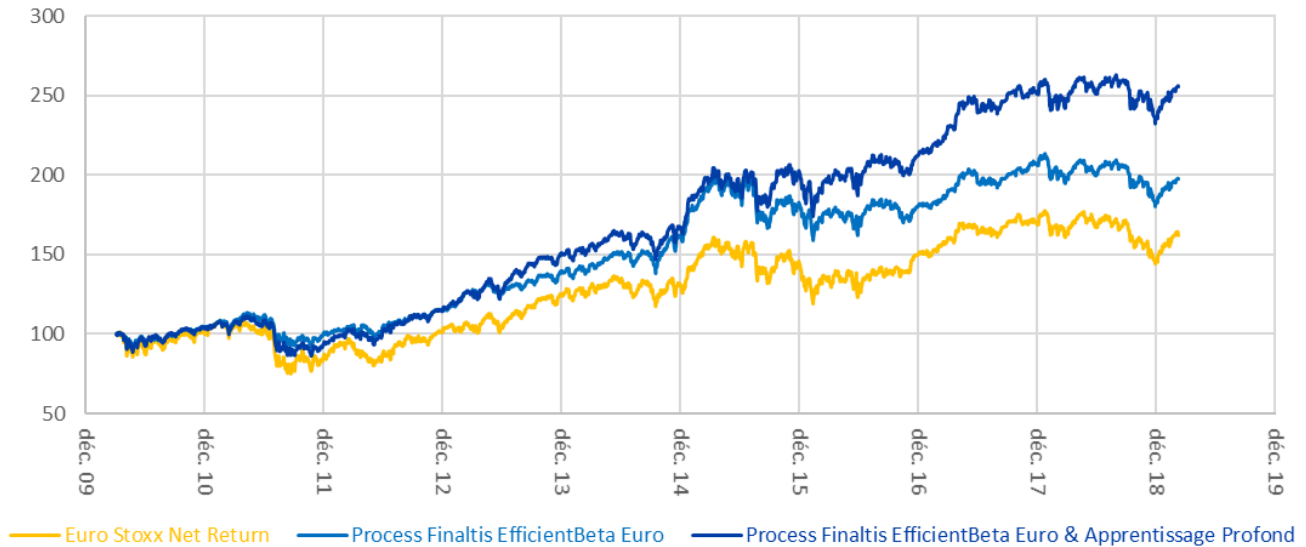
La partie ci-dessous présente les premiers résultats d'un prototype de portefeuille obtenu à partir des méthodes présentées. Si leur mise en production est encore éloignée, le portefeuille présentant notamment des caractéristiques de diversification non satisfaisantes, elle permet d'avoir une première idée des capacités offertes par ces approches.

Nous couplons les résultats de notre apprentissage précédent, qui permet de différencier l'espérance de rendement des titres, au processus de gestion *Finaltis EfficientBeta™*, qui construit un portefeuille de minimum variance. Alors qu'aucune autre méthode ne nous avait permis jusque là d'apporter une information utilisable sur le rendement futur, les prévisions (labels Hausse/Baisse) obtenues par apprentissage profond nous permettent d'envisager une Maximisation du ratio Rendement / Risque, une amélioration significative par rapport à une Minimisation de la Variance. Ainsi, sur la période [2010,2019], à chaque rebalancement de fin de trimestre :

1. nous supposons d'abord que tous les titres ont la même espérance de rendement futur ;
2. nous augmentons l'espérance de rendement futur des titres dont le CNN prédit une hausse ;
3. nous diminuons l'espérance de rendement futur des titres dont le CNN prédit une baisse.

Nous construisons ensuite le portefeuille optimal avec notre méthodologie bayésienne propriétaire en tenant compte (i) du filtre ESG introduit en septembre 2018 ainsi que (ii) des frictions de toutes natures pour chaque marché.

Nous comparons les résultats obtenus par ce nouveau prototype de portefeuilles couplant le processus de gestion *Finaltis EfficientBeta™* et les résultats obtenus grâce à l'apprentissage profond, d'une part à l'*Euro Stoxx*, et d'autre part à un portefeuille de variance minimale issu du processus de gestion *Finaltis EfficientBeta™ Euro*.



Evolution de la performance de l'indice et des simulations du processus de gestion « Finaltis EfficientBeta™ Euro » et du processus de gestion « Finaltis EfficientBeta™ Euro couplé aux résultats de l'apprentissage profond »

Nous obtenons les résultats suivants :

Avril 2010 – Mars 2019	<i>Euro Stoxx Net Return</i>	Processus de gestion <i>Finaltis EfficientBeta™</i>	Prototype <i>Finaltis EfficientBeta™ & Apprentissage Profond</i>
Rendements	7,14%	8,45%	11,45%
Volatilité	18,79%	12,93%	14,07%
Ratio	0,38	0,65	0,81

Avertissement : les statistiques de la colonne de droite sont issues d'une stratégie à l'état de prototype, nécessitant validations et approfondissements. Par exemple, il convient d'étudier l'impact des frictions sur ce prototype, même si, le portefeuille étant rebalancé trimestriellement, il est raisonnable d'estimer que l'effet du CNN sur les frictions, et réciproquement, sera très faible.

Conformément à nos attentes, notre prototype de portefeuille réduit moins la volatilité que le processus de gestion *Finaltis EfficientBeta™*, dont l'objectif est de construire le portefeuille de variance minimale. Cependant, en maximisant le ratio rendement / risque, il offre une amélioration significative du ratio de Sharpe.

CONCLUSIONS

Les résultats obtenus grâce à l'utilisation de l'Intelligence Artificielle nous conduisent à mener nos propres expérimentations sur son application à la finance de marché. S'il est encore trop tôt pour proposer un processus de gestion complet, les premiers résultats sont encourageants, et notre approche de définition d'images de marché est prometteuse.

De nombreuses pistes sont à explorer ; certaines permettront des améliorations incrémentales et d'autres conduiront peut-être à des évolutions majeures du processus de gestion.

AUTEURS



REMY CROISILLE

Responsable de la Recherche

Rémy est Normalien (ENS Ulm), agrégé de mathématiques et détient plusieurs DEA en mathématiques et statistiques financières.

Membre de Finaltis depuis 2005



CHRISTOPHE OLIVIER

Directeur des Investissements

Christophe est ingénieur diplômé (1990) de l'Ecole Centrale de Paris, et lauréat (1991) de l'Institut d'Etudes Politiques de Paris.

Membre de Finaltis depuis 2002



NICOLAS RENAUD

Contrôleur des risques

Nicolas est ingénieur diplômé (2009) de l'INSA de Lyon et major (2010) du mastère spécialisé de Techniques Financières de l'ESSEC.

Membre de Finaltis depuis 2010

CONTACTS



63 AVENUE DES CHAMPS ELYSEES 75008 PARIS • www.finaltis.com

Thierry RIGOLET • +33 (0)1 55 27 27 07 • trigoulet@finaltis.com

Denis BEAUDOIN • +33 (0)1 55 27 27 01 • dbeaudoin@finaltis.com

AVERTISSEMENT

Ce document ne constitue pas une proposition d'investissement. Il a été réalisé dans un but d'information uniquement. Il ne présente donc aucune valeur contractuelle. Aucune des informations apparaissant dans le présent document ne saurait être considérée comme une offre de services ou de produits émanant de FINALTIS, ni comme une offre ou la sollicitation d'une offre d'achat ou de vente de valeurs mobilières ou de tout autre produit d'investissement. FINALTIS décline en conséquence toute responsabilité quant à l'utilisation qui pourrait être faite par quiconque du contenu des présentes pages. L'accès au produit décrit dans cette présentation, Finaltis EfficientBeta™ Euro fait l'objet de restrictions à l'égard de certaines personnes et/ou dans certains pays.

Ce produit peut être amené à intervenir sur les marchés de gré à gré, à traiter des instruments volatils et, ce faisant, risqués. Le risque de défaut de contrepartie ne peut être écarté. Il n'offre par voie de conséquence ni garantie de restitution de capital, ni garantie de performance minimale, ni, plus généralement, aucune assurance que les objectifs ou caractéristiques indiqués seront atteints.

Le niveau de détail présenté ci-après et la terminologie employée requièrent des connaissances et une expérience des marchés financiers correspondant à celles des investisseurs professionnels au sens de la Directive MIF. En conséquence, la présente présentation est réservée aux investisseurs professionnels.