

# Vers une prédiction optimisée : réduction de dimension, mécanisme d'attention et sélection dynamique au service d'un jumeau numérique

Bruno PEREZ<sup>1</sup>, Imad MOURTAJI<sup>1</sup>, Imen ABIDI<sup>1</sup>

<sup>1</sup> Akkodis Research , AKR. Tour Coeur Défense, 92400 Courbevoie France.

bruno.perez@akkodis.com

## Résumé

Lors de nos premiers travaux, nous avons couplé un système multi-agents (SMA) à un apprentissage par renforcement (AR) pour optimiser la prédiction des événements indésirables associés aux soins (EIAS). Ce modèle s'appuie sur un jumeau numérique du bloc opératoire, synchronisé avec le jumeau physique, afin d'alerter en temps réel lors d'un EIAS. Dans ce papier, nous présentons l'évolution de notre approche, qui ne se limite plus à la génération d'alertes, mais anticipe désormais l'évolution globale de l'environnement. Pour ce faire, nous avons intégré des séries temporelles et un réseau de neurones LSTM pour mieux modéliser les dépendances temporelles. Cette solution permet d'alerter et de prédire le risque d'EIAS à court, moyen ou long terme, renforçant ainsi la sécurité des soins. Dans une perspective d'analyse des interactions, nous avons pu observer comment l'accumulation de signaux faibles et l'escalade de certains comportements collectifs entre agents préfigurent la survenue d'un EIAS. Ces observations ouvrent la voie à de nouvelles stratégies préventives, en adaptant les réponses du système aux dynamiques interactionnelles identifiées.

## Mots-clés

SMA, LSTM, ST, EIAS, Propagation d'incertitude

## Abstract

In our initial work, we coupled a multi-agent system (MAS) with reinforcement learning (RL) to optimize the prediction of adverse events associated with care (AEAC). This model relies on a digital twin of the operating room, synchronized with the physical twin, to alert in real time when an AEAC occurs. In this paper, we present the evolution of our approach, which is no longer limited to generating alerts, but now anticipates the global evolution of the environment. To achieve this, we have integrated time series and an LSTM neural network to better model temporal dependencies. This solution makes it possible to alert and predict the risk of AEAC in the short, medium or long term, thereby reinforcing the safety of care. From an interaction analysis perspective, we were able to observe how the accumulation of weak signals and the escalation of certain collective be-

haviors between agents foreshadow the occurrence of an AEAC. These observations pave the way for new preventive strategies, by adapting system responses to the interactional dynamics identified.

## Keywords

MAS, LSTM, TS, AEAC, Uncertainty Propagation

## 1 Introduction

Les opérations chirurgicales évoluent dans un environnement médical en constante innovation, offrant des procédures diversifiées mais augmentant la complexité des risques. La sécurité des patients dépend d'un cadre technique sophistiqué et de la collaboration entre disciplines. Les protocoles standardisés, tels que ceux de l'OMS, améliorent la gestion des risques, mais les événements indésirables graves restent préoccupants, avec 2385 cas signalés en 2022. Face à ce constat, nous avons dans des premiers travaux de recherche développé un jumeau numérique du bloc opératoire nommé PRIA (Prédiction des Risques à l'aide de l'Intelligence Artificielle) intégrant un système multi-agents (SMA) et un modèle d'apprentissage continu par renforcement (AR) [10]. L'objectif était de détecter des événements indésirables associés aux soins (EIAS) afin de générer des alertes en limitant au maximum les biais (faux négatifs, faux positifs) grâce au couplage SMA/AR. Dans ce papier, nous exposons l'intégration de la prédictivité à notre architecture. Il s'agit pour nous d'agrèger à notre architecture un paradigme capable de déterminer l'évolution de notre système dans notre contexte non déterministe. Nous avons orienté nos choix sur des séries temporelles enrichies par des algorithmes capables d'évoluer dans des contextes non forcément continus. Nous présentons dans la suite de cet exposé un état de l'art condensé mais représentatif des grandes tendances. Nous décrivons ensuite nos objectifs de recherche en terme de modélisation prédictive dans un contexte connecté de simulation. La présentation de nos premiers résultats suivie d'une discussion viennent clôturer ce papier.

## 2 Travaux antérieurs

La modélisation des risques en milieu de santé est largement répandue, car elle constitue une réponse essentielle aux enjeux de santé publique. Face à la complexité des environnements médicaux, notamment en bloc opératoire, plusieurs approches et paradigmes sont mis en œuvre afin d’anticiper la survenue d’évènements indésirables et d’améliorer la sécurité des patients. Ces modèles reposent sur des méthodologies variées, allant des analyses probabilistes aux systèmes d’intelligence artificielle, chacune présentant ses avantages et ses limites.

Nos précédents travaux portaient sur un générateur d’alertes, matérialisé par un SMA couplé à un AR, permettant ainsi de limiter les fausses alertes [10]. Notre état de l’art décrivait les systèmes multi-agents, l’apprentissage possible d’un SMA et, enfin, les jumeaux numériques dans le domaine de la santé. Dans cette section, nous abordons les travaux connexes à nos recherches actuelles, qui portent sur la prédictivité de la survenue d’un évènement indésirable.

### 2.1 Prédictivité de l’évolution d’un système complexe non déterministe

Au-delà de la génération optimisée d’une alerte dans un bloc opératoire, nous souhaitons prédire l’évolution de ces systèmes complexes. Les séries temporelles sont largement utilisées pour modéliser des systèmes dynamiques où les observations sont séquentielles et dépendent du temps [5, 7].

Les modèles ARIMA (AutoRegressive Integrated Moving Average) sont classiques pour les prévisions linéaires, mais ils montrent leurs limites face à des systèmes non linéaires et complexes [3]. Pour pallier ces insuffisances, les réseaux de neurones récurrents (RNN), et plus particulièrement les long short-term memory (LSTM), se sont imposés comme des alternatives efficaces. Ces derniers sont capables de capturer des dépendances temporelles longues et complexes, ce qui les rend particulièrement adaptés aux données séquentielles [6].

Cependant, les LSTM ne sont pas les seuls modèles à exploiter les données temporelles. Les réseaux de neurones convolutifs (CNN) peuvent également être utilisés pour extraire des caractéristiques temporelles lorsqu’ils sont appliqués à des séries temporelles. Bien qu’ils soient souvent utilisés en complément des LSTM pour améliorer la précision des prédictions, ils montrent des capacités intéressantes pour traiter des données structurées de manière spatiale [12, 1, 9]. Ici, une structure spatiale désigne l’organisation locale des données, où des points proches dans le temps sont considérés comme voisins, à la manière des pixels adjacents dans une image.

En outre, l’intégration de modèles statistiques traditionnels avec des techniques d’apprentissage profond a montré des résultats prometteurs. Par exemple, combiner ARIMA avec LSTM permet de tirer parti des forces des deux approches pour améliorer la précision des prévisions [11]. Cette approche hybride permet de mieux capturer à la fois les

tendances linéaires et les dynamiques non linéaires des systèmes complexes.

Malgré leurs avantages, ces modèles présentent plusieurs limites. La complexité computationnelle des modèles basés sur l’apprentissage profond, comme les LSTM, nécessite des ressources importantes et des temps d’entraînement longs. De plus, l’interprétabilité de ces modèles de type boîte noire reste un défi, ce qui peut être un obstacle dans des domaines sensibles comme la santé. Enfin, la performance des modèles dépend fortement de la qualité et de la quantité des données disponibles. Les données manquantes ou bruitées peuvent affecter négativement les prédictions, rendant ainsi crucial le prétraitement des données.

### 2.2 Plateformes et solutions de modélisation des risques au bloc opératoire

Plusieurs plateformes ont été développées pour améliorer la sécurité et gérer les risques au sein des blocs opératoires. Parmi celles-ci :

- SIM-PRO-BLOC [8] : Cette plateforme de simulation professionnelle est le fruit d’une collaboration entre différents professionnels de santé, visant à améliorer la qualité des soins et la prévention des risques au bloc opératoire.
- 3D Virtual Operating Room [4] : Il s’agit d’un serious game multilingue en 3D conçu pour former et entraîner les professionnels à la gestion des risques et à la prévention des évènements indésirables graves.
- Caresyntax [2] : Cette plateforme connecte la salle d’opération au système d’information hospitalier, permettant une gestion évolutive des vidéos et des données pour améliorer les performances et la sécurité au bloc opératoire.

Bien que ces solutions apportent des avancées significatives, elles présentent certaines limites. Par exemple, les plateformes de simulation, bien qu’efficaces pour la formation, peuvent ne pas refléter toutes les complexités des situations réelles. De plus, l’intégration de systèmes comme Caresyntax dans les infrastructures hospitalières existantes peut s’avérer coûteuse et techniquement complexe. Enfin, la dépendance à des bases de données et à des systèmes informatiques soulève des questions concernant la confidentialité des données et la cybersécurité.

### 2.3 Nos contributions en réponse aux verrous et limites identifiés

Pour surmonter les limites et verrous précédemment identifiés, notre approche se distingue par l’utilisation de séries temporelles modélisées à l’aide d’un LSTM, et enrichies par des techniques innovantes de traitement des données. Nous proposons d’explorer l’utilisation de méthodes de réduction de dimensionnalité, telles que l’analyse en composantes principales (ACP), pour prétraiter les données et ré-

duire leur complexité avant de les introduire dans le modèle LSTM.

De plus, nous proposons de mettre en œuvre un mécanisme de sélection dynamique, où le système compare en temps réel les erreurs absolues moyennes (EAM) de chaque modèle pour chaque variable et choisit automatiquement celui qui minimise l'erreur. En complément, nous envisageons d'incorporer des mécanismes d'attention afin de permettre au modèle de se concentrer sur les parties les plus pertinentes des séries temporelles, améliorant ainsi la précision des prévisions.

En parallèle, nous mettrons en œuvre une stratégie de propagation d'incertitude qui permettra de quantifier et de diffuser l'incertitude inhérente aux données et aux prédictions à travers l'ensemble du modèle. Cette approche innovante vise à :

- Mesurer la fiabilité des prédictions en intégrant explicitement l'incertitude à chaque étape du traitement.
- Identifier les sources d'erreur potentielles, facilitant ainsi l'analyse de la robustesse du modèle dans des environnements complexes.
- Améliorer l'interprétabilité des résultats en fournissant des indicateurs quantitatifs de confiance, essentiels pour la prise de décision dans des contextes opérationnels critiques.

Cette double contribution, combinant une modélisation avancée avec LSTM et mécanismes d'attention, à une approche de propagation d'incertitude, offre une solution complète pour optimiser la prédictivité et la transparence des prévisions dans des environnements synchronisés.

### 3 Notre architecture

Dans nos premiers travaux, le couplage SMA/RL, combinant les Systèmes Multi-Agents et l'apprentissage par renforcement (AR ou plus communément RL) est une contribution novatrice à la création de jumeaux numériques, une capacité avancée pour simuler de manière approfondie la complexité des environnements réels. L'intérêt substantiel de cette approche se situe à la fois sur le plan théorique, grâce à la formalisation des interactions entre agents autonomes, et sur le plan pratique, en permettant la simulation avancée de scénarios complexes dans divers secteurs. Les premiers résultats ont permis de vérifier l'efficacité de cette architecture dans la mise en œuvre de notre générateur d'alertes, en limitant les fausses alertes (faux positifs et faux négatifs).

Nos travaux de recherche actuels sont axés sur la prédictivité de l'évolution de notre système, en se concentrant sur l'estimation de la variation probable du SMA entre deux synchronisations du bloc opératoire avec le SMA. Dans cette optique, nous avons enrichi notre architecture en y intégrant un modèle ARIMA pour l'analyse des séries temporelles, un réseau LSTM pour l'exploitation de ces mêmes séries, ainsi qu'une méthode de propagation d'incertitude.

#### 3.1 Modèle ARIMA

Le modèle ARIMA (AutoRegressive Integrated Moving Average) est une méthode classique de modélisation des séries temporelles qui combine trois composantes essentielles : la partie autorégressive (AR), la différenciation (I) pour rendre la série stationnaire et la partie de moyenne mobile (MA). Formellement, un modèle ARIMA( $p, d, q$ ) s'exprime par :

$$\phi(L)(1 - L)^d x_t = \theta(L)\epsilon_t,$$

où : -  $x_t$  désigne la valeur de la série à l'instant  $t$ , -  $L$  est l'opérateur de retard, défini par  $Lx_t = x_{t-1}$ , -  $\epsilon_t$  représente un bruit blanc.

Les polynômes  $\phi(L)$  et  $\theta(L)$  sont donnés par :

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p,$$

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q.$$

La composante intégrée, notée  $(1 - L)^d$ , permet de différencier la série  $d$  fois afin d'éliminer toute tendance non stationnaire. En combinant ces trois éléments, le modèle ARIMA est capable de capturer à la fois les dépendances temporelles et les effets des chocs aléatoires, ce qui en fait un outil puissant pour la prévision des séries temporelles.

#### 3.2 LSTM, mécanismes d'attention et réduction de dimension

Afin de tirer profit des capacités de mémorisation du LSTM pour extraire des caractéristiques pertinentes tout en réduisant la dimensionnalité du problème, nous proposons d'appliquer ce modèle aux données du SMA. Soit une variable d'état  $x(t) \in \mathbb{R}^n$  représentant les mesures du SMA à différents instants  $t$ . Notre objectif est d'estimer la variation  $\Delta SMA$  entre deux instants de synchronisation, que nous formulons comme une fonction  $f$  :

$$\Delta SMA = f(x(t), x(t-1), \dots, x(t-T))$$

où  $T$  représente la taille de la fenêtre temporelle considérée. Pour améliorer la capacité prédictive et réduire la complexité des données, nous appliquons une réduction de dimensionnalité via l'analyse en composantes principales. Soit  $X \in \mathbb{R}^{T \times n}$  la matrice des observations sur la fenêtre  $T$ , nous cherchons une transformation linéaire définie par :

$$Y = XW$$

avec  $W \in \mathbb{R}^{n \times m}$  (où  $m < n$ ) constitué des vecteurs propres associés aux  $m$  plus grandes valeurs propres de la covariance de  $X$ . Cette étape permet de prétraiter les données et de réduire leur dimensionnalité tout en préservant l'essentiel de la variance.

Les données ainsi prétraitées sont ensuite introduites dans un modèle LSTM, dont le fonctionnement interne se résume par les équations suivantes :

$$\begin{aligned}
i_t &= \sigma(W_{xi} y_t + W_{hi} h_{t-1} + b_i), \\
f_t &= \sigma(W_{xf} y_t + W_{hf} h_{t-1} + b_f), \\
o_t &= \sigma(W_{xo} y_t + W_{ho} h_{t-1} + b_o), \\
\tilde{c}_t &= \tanh(W_{xc} y_t + W_{hc} h_{t-1} + b_c), \\
c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \\
h_t &= o_t \odot \tanh(c_t),
\end{aligned}$$

où  $i_t$ ,  $f_t$  et  $o_t$  représentent respectivement les portes d'entrée, d'oubli et de sortie,  $c_t$  est l'état de la cellule,  $h_t$  la sortie et  $\odot$  désigne la multiplication élément par élément.

Afin de renforcer la précision des prévisions, nous envisageons également l'intégration d'un mécanisme d'attention. Ce mécanisme permet au modèle de pondérer différemment les contributions de chaque instant de la séquence en définissant des poids  $\alpha_{t,i}$  calculés par :

$$\alpha_{t,i} = \frac{\exp(e_{t,i})}{\sum_{j=1}^T \exp(e_{t,j})}, \text{ avec } e_{t,i} = \phi(h_t, y_i),$$

où  $\phi$  est une fonction de score (par exemple, une fonction linéaire ou basée sur le produit scalaire). Le vecteur de contexte  $c_t$  est ensuite obtenu par :

$$c_t = \sum_{i=1}^T \alpha_{t,i} y_i,$$

et sert à affiner la prédiction finale, qui s'exprime par :

$$\Delta SMA = g(h_t, c_t),$$

où  $g$  est une fonction de combinaison, par exemple une couche entièrement connectée.

Ainsi, notre contribution réside dans la combinaison de techniques de réduction de dimensionnalité (ACP), de modélisation temporelle par LSTM et d'un mécanisme d'attention, visant à optimiser l'estimation de la variation du SMA dans des environnements synchronisés. Cette approche intégrée permet de réduire la complexité des données tout en capturant efficacement les dynamiques temporelles et en focalisant l'apprentissage sur les informations les plus pertinentes pour la prédiction. Nous abordons à présent la stratégie appliquées à la propagation d'incertitudes.

### 3.3 Propagation d'incertitudes

Dans notre approche, la propagation d'incertitude repose sur une méthode d'approximation linéaire fondée sur le développement de Taylor. Soit une fonction

$$y = f(x_1, x_2, \dots, x_n)$$

où chaque variable  $x_i$  est mesurée avec une incertitude associée  $\sigma_{x_i}$ . En supposant l'indépendance des variables, l'incertitude totale sur  $y$  est alors évaluée par la formule classique de propagation d'erreur :

$$\sigma_y^2 = \sum_{i=1}^n \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_{x_i}^2.$$

Cette approche consiste à linéariser  $f$  autour des valeurs moyennes des variables d'entrée, de sorte que le coefficient de sensibilité  $\frac{\partial f}{\partial x_i}$  quantifie l'impact de l'incertitude sur  $x_i$  sur la sortie  $y$ . Pour des systèmes non linéaires ou comportant des interactions complexes, cette méthode peut être complétée par des techniques de simulation Monte Carlo, offrant ainsi une estimation plus robuste de la distribution des incertitudes. Ce cadre formel permet de mesurer précisément la fiabilité des prédictions et d'identifier les sources dominantes d'erreur, contribuant ainsi à une meilleure compréhension et interprétation des résultats obtenus.

La Figure 1 décrit notre architecture dans sa globalité. Le jumeau physique se synchronise avec le jumeau numérique sachant que les échanges entre le SMA et le jumeau numérique se fait via une base pivot qui communique avec la couche interaction (côté SMA). L'apprentissage par renforcement est quant à lui connecté à la couche d'apprentissage du SMA. Grâce à cet apprentissage, les agents du système peuvent apprendre en continu à partir de l'évolution du système lui-même, ce qui permet de prédire son évolution future et d'optimiser les décisions en temps réel. Cette approche est particulièrement utile dans notre contexte, où les systèmes en question sont en constante évolution et nécessitent une adaptation continue pour fonctionner de manière optimale. La brique prédictivité est le module qui correspond à nos travaux actuels que nous présentons dans ce papier. Il s'agit de prédire l'évolution de l'état du système entre deux synchronisations. Le choix des séries temporelles couplés à un LSTM auquel s'agrège la propagation d'incertitude vient enrichir notre outil destiné à l'anticipation de la survenue d'un EIAS. Comme illustré dans la figure 2, cette approche combine plusieurs étapes clés : réduction de dimensionnalité pour simplifier les données d'entrée, modélisation dynamique à l'aide de LSTM et mécanismes d'attention pour se concentrer sur les parties les plus pertinentes des séries temporelles. En parallèle, la propagation d'incertitude permet de quantifier et diffuser l'incertitude à travers le modèle, améliorant ainsi la fiabilité et l'interprétabilité des prédictions.

Nos premières expérimentations et résultats sont présentés dans la section qui suit.

## 4 Expérimentations, résultats et discussion

Le protocole expérimental consiste à comparer trois approches de prévision sur des séries temporelles réelles issues d'un fichier CSV contenant les variables *FC* (fréquence cardiaque), *Temp* (température), *Cholesterol* et *Glycemie*. Le millier de données généré par le jumeau physique virtuel (voir nos premiers travaux [10]) est d'abord chargé, puis ensuite réparti en deux ensembles : 80 % pour l'entraînement et 20 % pour le test. Sur la base de l'ensemble d'entraînement, trois modèles sont ajustés :

- Un modèle ARIMA classique, adapté aux tendances linéaires,

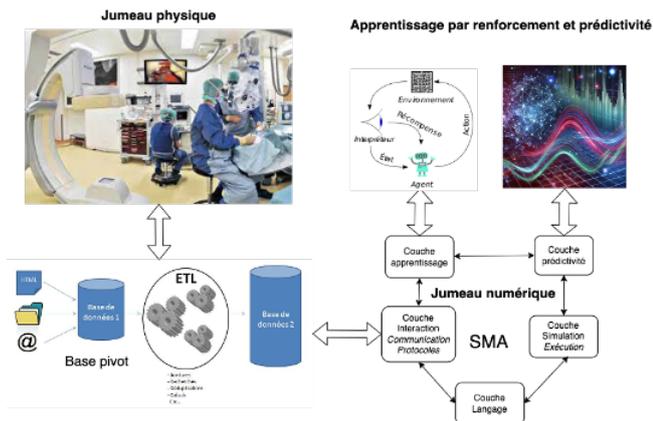


FIGURE 1 – Architecture globale

- Un modèle LSTM, capable de capturer des non-linéarités,
- Un modèle hybride qui corrige la prévision ARIMA à l'aide d'un LSTM appliqué sur les résidus.

Pour chacun de ces modèles, la performance est évaluée sur l'ensemble test à l'aide de l'erreur absolue moyenne. Par ailleurs, une propagation d'incertitude est réalisée pour le modèle hybride en utilisant l'écart-type des résidus. Enfin, un mécanisme de sélection dynamique compare les EAM et choisit le modèle ayant la meilleure performance pour produire la prévision finale.

#### 4.1 Premiers résultats

Les premiers résultats montrent que pour la plupart des variables, ARIMA et le modèle hybride obtiennent des erreurs quasi nulles, tandis que le LSTM présente des erreurs plus élevées. Toutefois, pour la variable *FC*, le LSTM affiche une EAM légèrement inférieure à celle d'ARIMA et du modèle hybride, bien que l'incertitude associée soit élevée.

Nous pouvons résumer ces premiers résultats dans le tableau 1 :

Variable	FC	Temp	Cholesterol	Glycémie
ARIMA_EAM	17.48	0.03	0.03	0.03
LSTM_EAM	15.97	14.06	7.94	4.71
Hybrid_EAM	19.51	0.03	0.03	0.03
Incertitude_EAM	16.23	0.00	0.00	0.00

Tableau 1 – Comparaison des EAM des modèles

Pour *Temp*, *Cholesterol* et *Glycémie*, ARIMA et le modèle hybride obtiennent des performances quasi parfaites (EAM  $\approx 0.03$ ), suggérant que ces séries suivent des tendances linéaires bien capturées par des modèles statistiques classiques.

En revanche, pour *FC*, le LSTM présente une performance légèrement meilleure (EAM  $\approx 15.97$ ) que ARIMA et le modèle hybride, ce qui indique une possible présence de non-linéarités dans cette variable.

La propagation d'incertitude (nous le rappelons) consiste à combiner les incertitudes de chaque variable pour obtenir

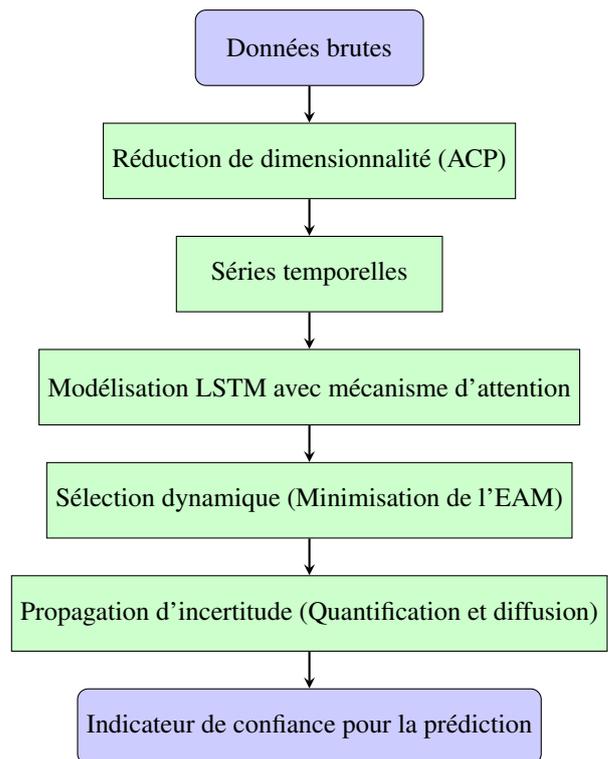


FIGURE 2 – Architecture globale du processus de prédiction

une estimation globale de la fiabilité des prédictions. Cependant, dans notre cas, l'incertitude, exprimée via l'écart-type et les intervalles, est significative uniquement pour la variable *FC*, tandis qu'elle est quasi nulle pour les autres variables. Cette disparité crée un déséquilibre dans la quantification de l'incertitude globale : la contribution de *FC* domine entièrement le calcul, ce qui fausse la représentation de la fiabilité du modèle dans son ensemble.

En d'autres termes, la propagation d'incertitude n'est pas exploitable dans notre contexte car l'incertitude élevée sur *FC* ne permet pas d'obtenir une mesure homogène et robuste de l'incertitude globale. Le faible niveau d'incertitude pour les autres variables ne compense pas ce déséquilibre, rendant l'indicateur final peu pertinent pour guider les décisions ou affiner le modèle. Ainsi, la méthode de propagation d'incertitude, dans ces conditions, n'apporte pas d'information utile par rapport aux résultats obtenus.

Afin d'optimiser le choix du modèle en temps réel, le code a été modifié pour intégrer un mécanisme d'attention et de sélection dynamique.

#### 4.2 Résultats avec réduction de dimension, sélection dynamique et mécanismes d'attention

Dans cette nouvelle approche, nous appliquons la réduction de dimension pour le modèle LSTM. Nous comparons ensuite les EAM obtenues par les trois approches pour chaque variable et choisissons automatiquement le modèle qui minimise l'erreur. De plus, nous intégrons un mécanisme d'at-

tention afin de permettre au modèle de se concentrer sur les parties les plus pertinentes des séries temporelles, améliorant ainsi la précision des prévisions. Cette amélioration permet une adaptation automatique du système aux caractéristiques spécifiques de chaque série, en exploitant la capacité d'ARIMA à modéliser des tendances linéaires et la force du LSTM dans le traitement de non-linéarités, tout en optimisant l'apprentissage grâce à l'attention.

Le tableau 2 résume les performances obtenues :

Variable	FC	Temp	Cholesterol	Glycémie
ARIMA_EAM	17.48	0.0318	0.0318	0.0318
LSTM_EAM	16.32	6.6095	5.5443	4.3904
Hybrid_EAM	17.82	0.0316	0.0316	0.0316
Incertitude_EAM	16.23	0.00	0.00	0.00
<b>Best Model</b>	LSTM	Hybrid	Hybrid	Hybrid

Tableau 2 – Comparaison des performances des modèles

- Pour *FC*, le mécanisme de sélection dynamique opte pour le modèle LSTM, ce qui est cohérent avec une performance légèrement meilleure pour cette variable.
- Pour *Temp*, *Cholesterol* et *Glycémie*, le modèle hybride est sélectionné, offrant des erreurs comparables à celles d'ARIMA ( $EAM \approx 0.0316-0.0318$ ), confirmant que ces séries sont bien prédites par des modèles linéaires ou hybrides.
- Les intervalles d'incertitude sont identiques à nos premiers résultats et confirment la non-pertinence quant à l'utilisation de la propagation d'incertitude.

Le premier graphique (figure 3) présente les EAM obtenues pour chaque modèle sur les quatre variables (*FC*, *Temp*, *Cholesterol* et *Glycémie*) avant l'intégration des mécanismes d'attention, de sélection dynamique et de réduction de dimension. On constate que, pour *Temp*, *Cholesterol* et *Glycémie*, les modèles ARIMA et Hybrid obtiennent des EAM quasi nulles (0,03), alors que pour *FC* le LSTM affiche une erreur légèrement inférieure (15,97) comparée à ARIMA (17,48) et Hybrid (19,51).

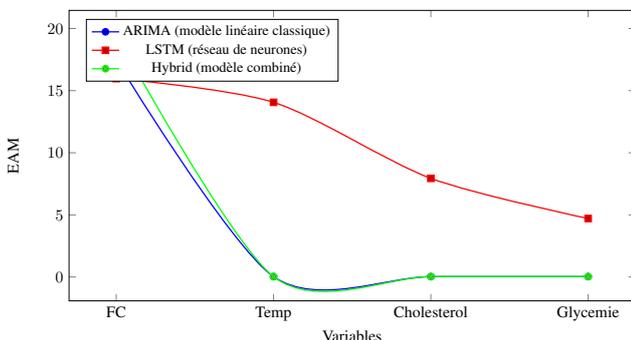


FIGURE 3 – Résultats sans intégration des principes d'attention de sélection dynamique et de réduction de dimension

Le second graphique (figure 4) regroupe les résultats obtenus après intégration des mécanismes d'attention, de sélection dynamique et de réduction de dimension. Pour chaque

variable, le modèle final est choisi en fonction de l'EAM la plus faible. Ainsi, pour *FC* le LSTM est retenu ( $EAM \approx 16,32$ ) tandis que pour *Temp*, *Cholesterol* et *Glycémie*, le modèle Hybrid est sélectionné (avec des EAM très faibles, autour de 0,0316 à 0,0318). Cette approche dynamique permet d'adapter la méthode à la nature spécifique de chaque série en tirant parti des mécanismes d'attention, qui mettent en évidence les informations les plus pertinentes et renforcent la capacité du modèle à capturer des structures complexes.

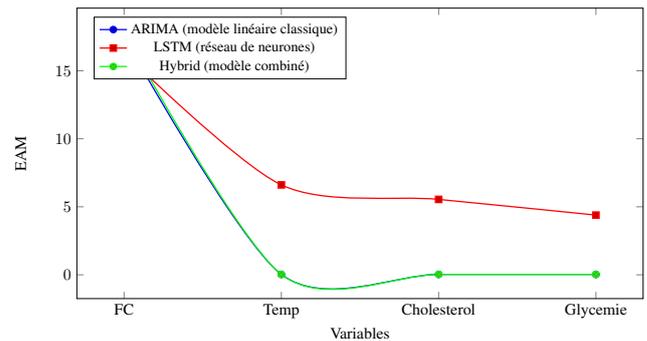


FIGURE 4 – Résultats avec intégration des principes d'attention de sélection dynamique et de réduction de dimension

Les premiers résultats montrent que pour trois variables (*Temp*, *Cholesterol* et *Glycémie*), les modèles ARIMA et Hybrid obtiennent des EAM extrêmement faibles, indiquant une dynamique linéaire bien capturée par ces approches. En revanche, pour la variable *FC*, le LSTM présente une légère supériorité avec une EAM inférieure (15,97 vs 17,48 pour ARIMA et 19,51 pour Hybrid), suggérant des non-linéarités dans cette série.

Après l'implémentation du mécanisme de sélection dynamique, le système choisit automatiquement le LSTM pour *FC* et le modèle Hybrid pour les autres variables, garantissant ainsi la meilleure performance possible en fonction de la nature des données. De plus, l'intégration d'un mécanisme d'attention a permis d'améliorer la prise en compte des dépendances temporelles, en mettant en avant les séquences les plus pertinentes pour la prédiction. Parallèlement, une réduction de dimension a été appliquée afin d'éliminer les redondances dans les variables explicatives, réduisant ainsi la complexité des modèles et améliorant leur généralisation. Ces ajustements permettent d'optimiser la prévision en temps réel en adaptant à la fois le choix du modèle et la pertinence des informations utilisées.

En conclusion, l'intégration d'un mécanisme de sélection dynamique des modèles, couplé à l'attention et à la réduction de dimension, a permis d'adapter en temps réel la méthode de prévision à la nature des données tout en améliorant la robustesse des prédictions. Pour des variables présentant des dynamiques linéaires (*Temp*, *Cholesterol*, *Glycémie*), ARIMA et le modèle hybride se montrent très performants, tandis que pour la variable *FC*, qui semble contenir des non-linéarités, le LSTM offre de meilleurs résultats.

tats grâce à sa capacité à capturer des relations complexes. L'attention renforce encore cette différenciation en pondérant intelligemment les séquences influentes, tandis que la réduction de dimension améliore l'efficacité computationnelle et la stabilité des modèles. Cette approche modulaire et adaptative constitue une avancée prometteuse pour la prévision en temps réel, tout en ouvrant la voie à des améliorations ultérieures, notamment en matière d'estimation de l'incertitude et d'optimisation des architectures neuronales.

## 5 Conclusion

Dans le cadre de nos travaux de recherche, inscrits dans la continuité de PRIA (jumeau numérique du bloc opératoire), nous avons intégré la brique de prédictivité à notre architecture. L'objectif n'est plus seulement de générer des alertes en temps réel, mais également de prédire la survenue d'un EIAS entre deux synchronisations du jumeau numérique avec le bloc opératoire. Pour ce faire, nous avons exploité des données extraites du jumeau physique afin d'éprouver nos modèles de prévision ; à savoir ARIMA, LSTM et un modèle hybride combinant ARIMA et LSTM, auquel est associée une composante de propagation d'incertitude. Cette approche vise à adapter le choix du modèle à la dynamique spécifique de chaque variable.

Les premiers résultats expérimentaux, obtenus sans mécanismes d'attention, de sélection dynamique et de réduction de dimension, montrent que le choix du modèle optimal dépend fortement du comportement des variables. Pour trois variables (*Temp*, *Cholesterol*, *Glycémie*), dont la dynamique s'avère quasi linéaire, ARIMA et le modèle hybride affichent d'excellentes performances ( $EAM \approx 0,03$ ). En revanche, pour la variable *FC*, dont le comportement semble plus complexe et non linéaire, le LSTM présente une EAM légèrement inférieure (15,97) comparé à ARIMA (17,48) et au modèle hybride (19,51).

Ces résultats indiquent que, pour les variables présentant une dynamique linéaire, les approches classiques (ARIMA) ou leur hybridation avec un LSTM offrent des prédictions très précises, alors que pour *FC*, la capacité du LSTM à capturer des non-linéarités lui confère un léger avantage.

Suite à l'intégration d'un mécanisme de sélection dynamique, le système compare en temps réel les EAM de chaque modèle pour chaque variable et choisit automatiquement celui qui minimise l'erreur. En outre, l'ajout de mécanismes d'attention et de réduction de dimension permet au modèle de se concentrer sur les informations les plus pertinentes des séries temporelles, renforçant ainsi la précision des prévisions. On constate que, grâce à cette approche dynamique, le système opte pour le LSTM pour *FC* (confirmant la présence de non-linéarités) et pour le modèle hybride pour les autres variables linéaires. L'automatisation de la sélection, couplée à l'attention, permet ainsi d'optimiser les prévisions en fonction de la nature de chaque série.

Du point de vue de la visualisation, nous avons représenté ces résultats sous forme de courbes dans deux graphiques

distincts. Le premier graphique illustre les premiers résultats obtenus sans sélection dynamique, tandis que le second met en évidence les performances après implémentation du mécanisme adaptatif. Ces courbes démontrent clairement l'intérêt de l'hybridation dynamique, qui permet de réduire l'erreur globale en sélectionnant le modèle le plus adapté à chaque variable.

En conclusion, l'intégration de la réduction de dimension, d'un mécanisme d'attention et la sélection dynamique constitue une avancée encourageante dans notre démarche de prédictivité. En adaptant le choix du modèle aux caractéristiques spécifiques de chaque variable, nous parvenons à optimiser les performances de prévision. Néanmoins, la composante de propagation d'incertitude nécessite encore des ajustements, car les résultats actuels ne sont pas suffisamment probants pour une exploitation opérationnelle. En termes de perspectives, nous envisageons un déploiement en conditions réelles, ainsi qu'un approfondissement de l'ajustement de la propagation d'incertitude, afin d'intégrer de manière fiable les marges d'erreur dans notre système prédictif. Cette démarche représente une étape cruciale pour améliorer la synchronisation entre le jumeau numérique et le bloc opératoire, garantissant ainsi une meilleure anticipation des événements indésirables.

## Références

- [1] Shaojie Bai, J. Zico Kolter, and Vladlen Koltun. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv :1803.01271*, 2018.
- [2] L Bourgeois, J Delode, S Kirche, A Massei, V Moreno, X Payet-Burin, et al. Bloc opératoire : état de l'art des technologies biomédicales. *IRBM News*, 40(4) :117–156, 2019.
- [3] George EP Box, Gwilym M Jenkins, Gregory C Reinsel, and Greta M Ljung. *Time series analysis : forecasting and control*. John Wiley & Sons, 2015.
- [4] Gilles Devreux. *Le rôle des comportements informationnels dans la prise de conscience de la situation : usage dans le serious game 3D Virtual Operating Room*. PhD thesis, Université Toulouse le Mirail-Toulouse II, 2015.
- [5] James D. Hamilton. *Time Series Analysis*. Princeton University Press, Princeton, NJ, 1994.
- [6] S Hochreiter. Long short-term memory. *Neural Computation MIT-Press*, 1997.
- [7] Bryan Lim and Stefan Zohren. Time-series forecasting with deep learning : a survey. *Philosophical Transactions of the Royal Society A*, 379(2194) :20200209, 2021.
- [8] Didier Maocec. Sim-pro-bloc : Se former autrement. *Manipulateur d'imagerie médicale et de radiothérapie (342, septembre)*, pages 20–25, 2024.
- [9] Boris N Oreshkin, Dmitri Carpo, Nicolas Chapados, and Yoshua Bengio. N-beats : Neural basis expansion analysis for interpretable time series forecasting.

In *International Conference on Learning Representations (ICLR)*, 2020.

- [10] B Perez. Amélioration de la sécurité chirurgicale avec un jumeau numérique prédictif : le rôle des systèmes multi-agents et de l'apprentissage par renforcement. 2024.
- [11] G Peter Zhang. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, 50 :159–175, 2003.
- [12] Guoqiang Zhang, B Eddy Patuwo, and Michael Y Hu. Forecasting with artificial neural networks : : The state of the art. *International journal of forecasting*, 14(1) :35–62, 1998.