

Votre montre sait quand votre cœur va défaillir avant vous

Internet des Objets (IoT), séries temporelles et détection d'anomalies pour la santé connectée

Pinel Baudelaire T. DAHOUI

Data Scientist & IA | Ingénieur en Travaux Statistiques
Master Statistiques Appliquées aux Sciences du Vivant
tpineldahoui@gmail.com | github.com/Baudelaire12

CIPMA-CHAIRE UNESCO | Bénin

Jeudi 6 Mars 2025

Série LinkedIn STEM au Quotidien — Jour 4/40

Plan de la présentation

- 1 Mise en contexte
- 2 Concepts clés
- 3 Développement mathématique
- 4 Cas pratique
- 5 Conclusion
- 6 Références

Des capteurs qui veillent sur nous 24h/24

Chiffre clé

En 2022, **505 millions** d'appareils portables de santé étaient actifs dans le monde. Ce chiffre devrait atteindre **1,1 milliard** d'ici 2027 (Statista, 2023).

- L'Apple Watch a détecté des cas de **fibrillation auriculaire** avec une sensibilité de 84% et une spécificité de 99% (Perez et al., 2019 — Apple Heart Study, Stanford).
- Les montres connectées collectent des données à **50 Hz** : soit 180 000 mesures d'accélération par heure.
- Un Holter cardiaque connecté génère jusqu'à **250 000 battements** analysés en 24h.

Question centrale

Comment extraire un signal cliniquement utile d'un flux massif de données physiologiques brutes générées en continu ?

Les capteurs IoT en santé : que mesurent-ils ?

Capteur	Grandeur mesurée	Fréquence	Application
Photopléthysmographe	Fréquence cardiaque (FC)	25–50 Hz	Arythmies
Accéléromètre 3D	Mouvement, chutes	50–200 Hz	Personnes âgées
Électrode ECG	Signal électrique cardiaque	250–1000 Hz	FA, infarctus
Oxymètre SpO	Saturation en oxygène	1 Hz	Apnée du sommeil
Capteur galvanique	Conductance cutanée	4 Hz	Stress, anxiété
Thermomètre IR	Température corporelle	0.016 Hz	Fièvre, ovulation

Modèle IoT santé

Capteur → Collecte → Transmission → Stockage Cloud → Analyse IA → Alerte clinique

Séries temporelles : définition et propriétés

Définition

Une **série temporelle** est une suite d'observations $\{x_t\}_{t=1}^T$ indexées par le temps, captée à intervalles réguliers Δt .

Décomposition classique (modèle additif) :

$$x_t = T_t + S_t + C_t + \varepsilon_t$$

- T_t : tendance (trend) — évolution à long terme
- S_t : saisonnalité — patterns répétitifs (rythme circadien)
- C_t : composante cyclique
- ε_t : bruit aléatoire (innovations)

Stationnarité : Une série est stationnaire si $\mathbb{E}[x_t]$ et $\text{Cov}(x_t, x_{t+k})$ ne dépendent pas de t .

Modélisation ARIMA pour les signaux physiologiques

Modèle ARIMA(p, d, q) — AutoRegressive Integrated Moving Average :

$$\Phi(B)(1 - B)^d x_t = \Theta(B)\varepsilon_t$$

où :

- B : opérateur retard ($Bx_t = x_{t-1}$)
- $\Phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$: polynôme AR
- $\Theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q$: polynôme MA
- d : ordre de différenciation pour stationnariser la série

Détection d'anomalie par seuil statistique :

$$\text{Anomalie si } |x_t - \hat{x}_t| > \mu_\varepsilon + k \cdot \sigma_\varepsilon, \quad k \in \{2, 3\}$$

Un point est flagué comme anormal si son résidu dépasse k écarts-types de la distribution des résidus.

LSTM pour la prédiction de séries physiologiques

Long Short-Term Memory (LSTM) — architecture RNN adaptée aux longues dépendances temporelles :

$$\left\{ \begin{array}{ll} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) & \text{(porte d'oubli)} \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) & \text{(porte d'entrée)} \\ \tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) & \text{(cellule candidate)} \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t & \text{(état de cellule)} \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) & \text{(porte de sortie)} \\ h_t = o_t \odot \tanh(C_t) & \text{(état caché)} \end{array} \right.$$

Application cardiaque

Un LSTM entraîné sur des séries ECG de 24h peut anticiper un épisode de fibrillation auriculaire **30 minutes à l'avance** avec une AUC de 0.87 (Tison et al., 2018).

Apple Heart Study : détection de FA à grande échelle

L'étude

La **Apple Heart Study** (Stanford, 2019) est la plus grande étude de cardiologie à distance jamais menée : **419 093 participants** aux États-Unis, recrutés uniquement via l'application iPhone.

Résultats clés (Perez et al., 2019) :

Indicateur	Valeur
Participants notifiés d'irrégularité	0.52% (2 161 personnes)
Concordance avec patch ECG (PPV)	84%
Spécificité de la notification	99.3%
Participants en FA au moment notifié	34%
Participants suivis par cardiologue	57% des notifiés

Enjeu africain : Des solutions IoT à bas coût (**ECG mobile Alivecor**) sont testées pour le dépistage cardiaque en zones rurales d'Afrique subsaharienne [Source à vérifier — programme/11]

Conclusion et perspectives

Synthèse

Les objets connectés de santé génèrent un flux continu de données physiologiques dont l'analyse par des modèles de séries temporelles et de deep learning permet la détection précoce d'anomalies cardiaques, respiratoires ou métaboliques — souvent avant l'apparition de symptômes cliniques.

Perspectives :

- Modèles de fondation (Foundation Models) pour l'ECG — entraînés sur des millions de signaux
- Federated Learning pour analyser les données sans les centraliser (protection de la vie privée)
- Développement de wearables abordables pour les pays à revenus faibles et intermédiaires
- Intégration des données IoT dans les dossiers médicaux électroniques (DME) africains

« *Le meilleur capteur pour votre santé, c'est celui que vous portez déjà au poignet.* »

— Inspiration : Eric Topol, *The Patient Will See You Now*, 2015

Références bibliographiques

-  Perez, M. V., et al. (2019). Large-scale assessment of a smartwatch to identify atrial fibrillation. *New England Journal of Medicine*, 381(20), 1909–1917.
-  Tison, G. H., et al. (2018). Passive detection of atrial fibrillation using a commercially available smartwatch. *JAMA Cardiology*, 3(5), 409–416.
-  Statista. (2023). *Number of connected wearable devices worldwide 2016–2027*. Statista Research Department.
-  Topol, E. J. (2015). *The Patient Will See You Now : The Future of Medicine Is in Your Hands*. Basic Books.
-  Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis : Forecasting and Control* (5e éd.). Wiley.
-  Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.

Merci pour votre attention

Pinel Baudelaire T. DAHOUI

Data Scientist & IA | CIPMA-CHAIRE UNESCO, Bénin

`tpineldahoui@gmail.com`

`github.com/Baudelaire12`

LinkedIn : @Pinel Baudelaire DAHOUI

Série STEM au Quotidien — 40 jours pour comprendre le monde par les données