



Bayésien : le mot qui achète de la crédibilité réglementaire sans (toujours) la mériter.

10 mars 2026

Le mot qui rassure...

Parcourez les pitches des start-ups d'IA en santé. Lisez les dossiers de marquage CE. Assistez aux conférences medtech. Un mot revient avec une régularité troublante : bayésien. « Notre modèle est bayésien » : rigoureux, transparent, quantifiant l'incertitude, approuvé par les régulateurs. Sous-entendu : nous ne sommes pas une boîte noire. Nous sommes de la statistique sérieuse.

Avant de se demander si c'est vraiment du bayésien... rencontrons d'abord Monsieur Bayes.

En quoi consiste le bayésianisme ?

Thomas Bayes, pasteur anglican du XVIII^e siècle, a introduit un résultat mathématique simple et puissant : une règle permettant de mettre à jour une probabilité lorsque de nouvelles observations apparaissent.

Dans l'interprétation développée ensuite par Laplace et la tradition bayésienne, la probabilité n'est pas seulement la fréquence d'un événement dans des répétitions d'expérience. Elle peut aussi représenter un état de connaissance : une mesure

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

rationnelle de notre incertitude sur le monde, plutôt qu'une propriété intrinsèque de celui-ci.

Formellement : $P(A|B)$ lire la probabilité de A sachant B.

Si vous observez B, dans quelle mesure devez-vous réviser votre croyance sur A ?

Le théorème de Bayes répond à cette question avec élégance :

$$P(A|B) = P(B|A) \times P(A) / P(B)$$

Trois termes. Trois concepts :

- $P(A)$ est le prior. Ce que vous croyiez avant d'observer quoi que ce soit.
- $P(B|A)$ est la vraisemblance. C'est la probabilité d'observer B si A est vrai.
- $P(A|B)$ est le posterior. Ce que vous devriez croire maintenant que vous avez vu l'occurrence de B.

C'est un moteur de mise à jour de la connaissance. Vous partez d'une croyance initiale. Vous observez des données. Vous révisez. Vous observez encore. Vous révisez encore. À chaque étape, votre incertitude est explicite, quantifiée, propagée.

En médecine, cette approche est similaire à une démarche diagnostic. Un clinicien qui examine un patient fait du bayésianisme intuitif : il part d'une probabilité pré-test, le prior (épidémiologie, présentation clinique), observe un résultat de test (la vraisemblance), et révisé son diagnostic (le posterior). Le rapport de vraisemblance positif ou négatif n'est rien d'autre que le facteur bayésien habillé en langage médical.

La promesse de l'IA bayésienne en santé est donc précise : encoder ce raisonnement formellement, propager l'incertitude à chaque étape, produire non pas un score mais une distribution. Non pas « probabilité 87% » mais « probabilité 87%, avec une incertitude de $\pm 12\%$ selon la qualité des données disponibles sur ce patient ». C'est une promesse sérieuse. Elle mérite d'être prise au sérieux... précisément parce qu'elle est rarement tenue.

Des vertus réelles

En IA médicale, cette approche a des applications légitimes et documentées.

Les données rares d'abord. En oncologie rare, en maladies orphelines ou en pédiatrie, les cohortes disponibles sont souvent limitées. Dans ces contextes, entraîner des modèles complexes (en particulier des réseaux de neurones profonds) peut conduire

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

rapidement à un surapprentissage lorsque le nombre de variables dépasse largement le nombre de patients.

Les méthodes bayésiennes offrent ici un avantage important. Elles permettent d'incorporer explicitement de l'information externe sous forme de **priors** : résultats d'essais antérieurs, connaissances physiopathologiques ou expertise clinique. Cette information agit comme une régularisation structurée qui stabilise l'inférence lorsque les données empiriques sont rares.

De nombreuses données biomédicales se trouvent ainsi dans des situations **HDLSS (High Dimensionality, Low Sample Size)**, où le nombre de variables mesurées excède largement la taille de la cohorte disponible. Ce régime statistique est fréquent dans certaines situations cliniques, notamment dans les maladies rares, les données omiques ou les cohortes spécialisées.

C'est dans ce contexte que nous avons développé chez Qualees un système de génération de données synthétiques non pour remplacer les observations réelles, mais pour stabiliser l'apprentissage dans ces situations de données HDLSS.

La quantification de l'incertitude ensuite. Un modèle bayésien ne produit pas un score ponctuel mais il produit une distribution. Il dit non pas « 87% de probabilité de sepsis » mais « entre 74% et 96%, selon la qualité des données disponibles sur ce patient ».

Cette distinction est fondamentale : il existe deux types d'incertitude que la plupart des modèles confondent :

- L'incertitude aléatoire liée au bruit intrinsèque des données, irréductible,
- L'incertitude épistémique liée à l'ignorance du modèle, réductible avec plus de données ou un meilleur modèle.

Un cadre bayésien rigoureux les distingue et propage explicitement la seconde vers les prédictions. C'est cette distribution qui est directement actionnable pour le clinicien : elle lui dit quand faire confiance au modèle et quand demander un avis supplémentaire.

L'intégration de connaissances causales enfin. Un réseau bayésien peut encoder explicitement des relations physiopathologiques connues (la fièvre influence la CRP, qui influence le score de sepsis) sous forme de graphe orienté. Le modèle ne découvre pas ces relations à partir des données : il les intègre comme contraintes structurelles. Dans des domaines où la causalité est bien établie, c'est un avantage décisif sur un réseau de neurones qui apprend des corrélations sans distinguer cause et effet. La FDA et l'EMA l'ont compris. Leurs guidances sur les méthodes bayésiennes dans les essais

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

cliniques (respectivement 2010 et 2018) reconnaissent explicitement la valeur de cette approche pour les petites populations, les maladies rares et les dispositifs médicaux à données limitées.

Le bayésianisme en santé a donc une légitimité réelle. Ce n'est pas un archaïsme. Ce n'est pas une mode. C'est ce qui rend la suite d'autant plus inconfortable.

Le DAG, le graphe causal ... et la confusion fatale

Un réseau bayésien est construit autour d'un DAG (graphe orienté sans boucle) dans lequel chaque flèche dit : « cette variable influence celle-là ». Chaque nœud est une variable. Chaque arc est une dépendance probabiliste. La structure entière encode une distribution de probabilité jointe sur l'ensemble des variables ce qui permet de calculer efficacement des probabilités conditionnelles :

$P(\text{sepsis} \mid \text{fièvre, CRP élevée, hypotension})$.

C'est élégant. C'est puissant. Et c'est là que commence la confusion. Un arc dans un réseau bayésien ne dit pas : « A cause B ». Il dit : « si j'observe A, je dois réviser ma croyance sur B ». C'est une relation statistique une dépendance dans les données. Pas une affirmation sur le monde (confère les "World models").

La distinction est l'œuvre de Judea Pearl (prix Turing 2011) qui a formalisé ce que les épidémiologistes savaient intuitivement sans pouvoir le dire précisément. Pearl distingue trois niveaux de raisonnement :

- Observer : $P(B|A)$. Si je vois A, que puis-je dire sur B ? C'est le niveau de la corrélation. De la statistique classique.
- Intervenir : $P(B|\text{do}(A))$. Si j'agis sur A (si je le fixe par une intervention externe) que se passe-t-il sur B ? C'est le niveau de l'essai contrôlé randomisé. De la causalité.
- Imaginer : Si A avait été différent, B aurait-il changé ? C'est le niveau du contrefactuel. De la responsabilité médicale. De la médecine personnalisée.

Un réseau bayésien opère au premier niveau (sauf si le DAG est causal et non pas statistique). Un graphe causal opère aux trois. La différence n'est pas technique. Elle est épistémologique.

Exemple concret. Le tabagisme cause le cancer du poumon. Le tabagisme jaunit aussi les doigts. Dans les données cliniques, doigts jaunes et cancer du poumon sont donc corrélés, non pas parce que l'un cause l'autre, mais parce qu'ils partagent une cause commune. Schématiquement : (A)Tabagisme \rightarrow (B)Cancer du poumon et (A)Tabagisme \rightarrow

Jérôme Vetillard

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

(C)Doigts jaunes. Un réseau bayésien appris sur ces données va détecter la corrélation entre doigts jaunes et cancer et inclure un arc entre les deux. C'est statistiquement justifié. C'est causalement faux. Intervenir sur les doigts jaunes en les décolorant par exemple n'aura aucun effet sur le risque de cancer. Le réseau bayésien, interrogé sur cette intervention, se trompera en l'absence de DAG causal. Le graphe causal, qui encode la structure en fourche avec le tabagisme comme cause commune, répond correctement : l'arc entre doigts jaunes et cancer est une illusion de corrélation, pas une relation d'influence. C'est précisément la distinction entre observer et intervenir, le premier et le second niveau de Pearl.

Un réseau bayésien opère au premier (sauf si DAG causal). Il ne peut pas répondre aux questions du second. La plupart des start-ups vendent la causalité. Elles livrent la corrélation. Dans un formalisme qui ressemble suffisamment à l'un pour que personne ne réclame l'autre.

Il faut ici ajouter une précision qui aggrave le diagnostic. Un DAG peut être construit de deux manières :

- Spécifié à la main par un expert clinique, qui encode ses hypothèses sur les relations entre variables parce qu'on a une connaissance fine du phénomène physiopathologique,
- Ou appris automatiquement à partir des dépendances statistiques observées dans les données.

Dans le premier cas, les arcs peuvent refléter une causalité réelle si l'expert la connaît. Dans le second cas, un DAG appris uniquement sur les données n'implique aucune interprétation causale valide, il encode des corrélations, rien de plus.

L'exemple des doigts jaunes s'applique dans les deux situations : par ignorance dans le premier cas, par construction dans le second.

Est-ce vraiment du bayésien ?

Revenons donc à la question posée en ouverture. Dans la majorité des implémentations que l'on rencontre dans les start-ups de santé, la réponse honnête est : non.

Pas entièrement. Pas au sens où Bayes, Laplace ou Pearl l'entendraient.

Voici ce qui se passe réellement. La structure du graphe (le DAG, les nœuds, les arcs) est "dessinée à la main" par un expert clinique ou un biostatisticien. C'est déjà une hypothèse forte : on suppose connaître a priori quelles variables influencent quelles

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

autres. Dans des pathologies bien comprises, c'est défendable. Dans des pathologies complexes, multifactorielles, mal élucidées, c'est une fiction structurée.

Les probabilités dans les nœuds sont ensuite estimées par maximum de vraisemblance sur les données d'entraînement. C'est-à-dire : par une méthode fréquentiste classique. On cherche les paramètres qui maximisent la probabilité d'observer les données et ce sans prior, sans distribution a posteriori, sans propagation de l'incertitude.

Le résultat ressemble à du bayésien. Il se nomme bayésien. Il ne l'est pas. C'est du fréquentisme en costume bayésien, du "Canada Dry statistique". La différence n'est pas cosmétique. Elle est opérationnelle. Un vrai modèle bayésien propage l'incertitude à travers le graphe. Si je suis incertain sur la valeur d'un paramètre (parce que mes données d'entraînement sont rares, ou parce que le patient devant moi ressemble peu à la population d'entraînement) cette incertitude se répercute sur la sortie. Le clinicien reçoit une distribution, pas un score.

Un modèle fréquentiste déguisé ne propage rien. Il produit « probabilité 87% de sepsis » avec la même confiance sur dix mille patients que sur dix. L'incertitude épistémique est invisible. Elle est masquée derrière un chiffre qui a l'air précis.

C'est précisément ce que les guidances FDA et EMA sur les méthodes bayésiennes cherchent à garantir : la propagation rigoureuse de l'incertitude dans les contextes de données limitées.

Ce que la plupart des implémentations commerciales ne fournissent pas. Elles bénéficient de l'aura réglementaire du bayésianisme sans en satisfaire les exigences. C'est un transfert de légitimité non mérité.

Pourquoi personne ne le dit ? Parce que le régulateur vérifie rarement l'implémentation au niveau de l'inférence. Parce que le clinicien n'a pas les outils pour le détecter. Et parce que l'équipe de développement, nous y venons, n'a parfois pas elle-même les compétences pour faire autrement.

Le déficit RH que personne ne nomme

Posons la question directement. Pourquoi autant de start-ups de santé arrivent-elles à la même conclusion architecturale ? La réponse officielle : le bayésien est explicable, rigoureux, réglementairement accepté. Nous l'avons vu, c'est partiellement vrai.

La réponse réelle ? c'est ce qu'elles peuvent recruter. Un data scientist senior maîtrisant les architectures transformer, le fine-tuning de modèles de langage médicaux, la calibration d'incertitude par conformal prediction, le federated learning sur données FHIR coûte entre 80 000 et 140 000 euros en France. Ils/elles partent à Londres, Zurich

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

ou San Francisco dès qu'une offre sérieuse se présente ce qui restreint l'offre disponible sur le marché national (problème de quantité d'output et de spoliation par migration géographique).

Un biostatisticien formé à la régression logistique, aux modèles de survie, aux réseaux bayésiens, ça existe de façon plus massive, formés en masters de biostatistique, écoles de pharmacie, des CROs. Ça coûte 45 000 à 60 000 euros. Ils/elles connaissent le vocabulaire réglementaire, savent parler aux médecins.

Le choix architectural (du fréquentisme déguisé en approche bayésienne) devient alors un choix RH déguisé en choix technique. Ce n'est pas une accusation de mauvaise foi. C'est une contrainte de marché. Les start-ups font avec ce qu'elles trouvent et ce qu'elles trouvent, ce sont des profils biostat solides, honnêtes, compétents dans leur domaine.

Le problème n'est pas leur compétence. Le problème est le glissement. Car le biostatisticien fréquentiste compétent sait construire des modèles bien calibrés, interpréter des intervalles de confiance, gérer les données manquantes. Ces compétences sont réelles et précieuses. Mais les transposer dans un formalisme bayésien sans maîtriser l'inférence bayésienne rigoureuse, sans savoir spécifier un prior informatif, sans comprendre la sensibilité du posterior au choix du prior, sans maîtriser les méthodes qui permettent de calculer concrètement le posterior (ce que ni Stan, ni PyMC, ni aucun tableur ne font automatiquement) produit exactement ce que nous avons décrit : Du fréquentisme habillé, vendu comme du bayésien.

Ce glissement a un nom dans d'autres industries : dette technique cachée. On livre quelque chose qui fonctionne dans les conditions du développement. On ne livre pas quelque chose qui fonctionnera dans les conditions du déploiement réel (population différente, données évolutives, cas hors-distribution). La dette est invisible à la livraison. Elle se révèle dans le temps. Un prior figé est un biais qui dort. Une structure causale imposée en 2021 sur une population de CHU parisien sera silencieusement fautive en 2026 sur une population de médecine de ville en zone rurale. Personne dans la start-up n'a les compétences (ni souvent le mandat) pour faire évoluer le modèle. La maintenance bayésienne rigoureuse est un métier "rare". Il n'est pas dans l'organigramme.

Ce qui a été vendu comme une architecture pérenne parce que transparente est en réalité une architecture figée parce que sous-staffée.

Ce que ça coûte...et à qui ?

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

Revenons à ce qui compte. Un modèle fréquentiste déguisé en bayésien, spécifié à la main par un biostatisticien compétent mais non formé à l'inférence bayésienne rigoureuse, déployé sur une population différente de la population d'entraînement, sans procédure de détection de dérive, sans maintenance architecturale prévue : Ce modèle va se tromper. Silencieusement. Progressivement. Sans alarme. Il ne dira pas « je suis en dehors de mon domaine de validité ». Il produira « probabilité 84% de réhospitalisation » sur un patient pour lequel il n'a aucune légitimité statistique. Avec la même confiance apparente que sur les dix mille patients de la cohorte d'entraînement. Et le clinicien, informé que le modèle est « bayésien (donc supposé rigoureux, et "explicable") fera confiance. Ce n'est pas un scénario hypothétique. C'est le mécanisme exact par lequel des algorithmes médicaux correctement certifiés à un instant T deviennent dangereux à T+18 mois.

Un point aggrave le diagnostic. La performance globale d'un modèle peut rester acceptable alors que sa calibration s'est dégradée (la calibration étant la correspondance entre la probabilité prédite et la fréquence réelle de l'événement). Un modèle mal calibré affiche un chiffre précis. Il ne dit pas que ce chiffre est faux dans le sous-groupe du patient devant vous. C'est précisément ce que le clinicien ne peut pas détecter sans outillage spécifique. La dérive (dataset shift dans la littérature méthodologique) est documentée. La sous-détection de cette dérive dans les systèmes déployés l'est aussi. Trois vecteurs l'alimentent silencieusement :

- L'évolution des populations de patients,
- Le changement des pratiques médicales,
- La transformation des systèmes d'information cliniques.

Aucun n'est exceptionnel. Tous sont inévitables.

Le coût n'est pas supporté par la start-up. Elle a livré ce qui était dans le cahier des charges. Le marquage CE a été obtenu. L'investisseur est satisfait.

Le coût est supporté :

- Par le patient qui reçoit une recommandation erronée,
- Par le clinicien qui a fait confiance à un chiffre qui avait l'air rigoureux,
- Par le système de santé qui a acheté une solution présentée comme pérenne et qui devra la remplacer,

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

- Et par le prochain porteur de projet "vigilant et honnête" qui arrive avec un modèle de deep learning mieux calibré, mieux validé, mieux surveillé et à qui on oppose : « mais est-il explicable ? »

La boucle est bouclée.

Ce qu'il faut exiger...

Le bayésien a des vertus réelles dans des contextes précis (données rares, connaissances causales établies, populations bien définies) . Ces vertus méritent d'être utilisées à bon escient.

Pas nécessairement du fréquentisme. Les méthodes classiques ont leur place (à condition de ne pas les vendre pour ce qu'elles ne sont pas).

Ce qu'il faut exiger c'est la même chose que pour n'importe quel dispositif médical :

- Une validation clinique indépendante sur la population cible et non pas sur la cohorte de développement,
- Une caractérisation honnête de l'incertitude et non pas un score ponctuel présenté comme une distribution,
- Une procédure de surveillance de dérive et non pas une certification figée à la date de déploiement,
- Une équipe capable de maintenir le modèle dans le temps et non pas seulement de le livrer,
- Et une réponse honnête à la question posée en ouverture : est-ce vraiment du bayésien ? Ou est-ce du fréquentisme en costume (utile, parfois, peut-être, mais pas ce qui est sur l'étiquette) ?

L'IA en santé n'a pas besoin de faux bayésianisme pour être légitime. Elle a besoin de rigueur. De transparence sur ce qu'elle est réellement. Et de professionnels assez honnêtes pour dire à leurs clients (et à leurs investisseurs) ce qu'ils livrent vraiment.

Chaque semaine, je lis des présentations de start-ups qui se revendiquent « bayésiennes », « IA explicable* » (https://www.linkedin.com/posts/jeromev_ia-santaez-xai-activity-7436733820088819712-5UfC?utm_source=share&utm_medium=member_desktop&rcm=ACoAAACHnekBGRF-CabUoQQTa69kbB9dT2pMuMI) et qui livrent du maximum de vraisemblance dans un graphe probabiliste. L'étiquette est là. La promesse ne l'est pas.

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com

Ce n'est pas une critique de l'ambition. C'est une exigence de précision. Dans une médecine qui se voudrait dite "de précision"... la précision n'est pas une option

[Jérôme Vetillard](#)

CTO | VP R&D | Chief Product Officer | AI-Powered Healthcare & Life Sciences Products | Compliance by Design | PhD
AgroParisTech | CPO MIT Sloan | Exec MBA IE Business School & Brown University

Twingital-institute / Twingital-ventures : twingital-ventures.com