

Human Frontier — L'IA ne sera jamais tenue responsable. Vous,
oui.

Olivier Laurent

Chapitre 1 — Le risque certain

Tout le monde a peur que l'IA se trompe. Ce n'est pas le bon problème.

Voici le bon. Un jeudi soir, tard. Une recommandation est ouverte à l'écran : quatre pages, des titres propres, une synthèse que vous approuvez, un chiffre qui correspond à ce que vous attendiez. Vous l'avez rédigée avec un système d'IA, ou quelqu'un de votre équipe l'a fait. Vous l'avez lue une fois. Rien n'a accroché. Votre nom va en bas, et dans une dizaine de secondes vous allez appuyer sur Envoyer. Posez-vous maintenant une question qu'on ne vous a jamais posée : qu'avez-vous vérifié, exactement ?

Pas lu. Vérifié. Quel chiffre avez-vous remonté jusqu'à sa source ? Quelle hypothèse avez-vous formulée à voix haute et mise à l'épreuve ? Quel paragraphe vous a fait tiquer, même brièvement, avant que vous le laissiez passer ? Si la réponse honnête est « aucun, mais ça avait l'air juste », vous venez de rencontrer le risque dont parle ce livre. Ce n'est pas que l'IA s'est trompée. Elle ne s'est peut-être pas trompée. C'est que vous avez signé quelque chose que vous n'avez pas examiné, et si cela se révèle faux, l'IA ne sera jamais tenue responsable. Vous, oui.

Je vais donner un nom à ce risque, parce qu'il n'en a pas dans le débat public : le biais d'automatisation avec une signature humaine.

Ça ne ressemble pas à un risque. Ça ressemble à un mardi.

Le mémo d'hier : trois paragraphes résumant une négociation avec un fournisseur, rédigés à partir des notes de l'appel, envoyés à votre directrice. Il disait que le fournisseur avait « donné son accord de principe » sur les conditions révisées. Personne, parmi ceux qui étaient à l'appel, ne se souvient qu'il ait accepté quoi que ce soit ; les notes disaient qu'il allait « examiner ». Le mémo se lisait mieux que les notes, donc le mémo a gagné.

La prévision du dernier comité de direction : une courbe de croissance construite par un modèle à partir des trois dernières années, avec une note de bas de page que personne n'a dépliée. La note supposait que le plus gros client se renouvelle aux mêmes conditions. Le responsable de ce client, qu'on n'a pas interrogé, aurait pu dire en une phrase que non.

La clause que personne n'a relue parce qu'elle se lisait bien : un plafond de responsabilité, réécrit pour plus de clarté, qui s'applique désormais à une autre partie que celle qu'il visait avant. C'est grammatical. C'est clair. C'est faux, et c'est paraphé.

Aucune de ces trois histoires n'est une histoire d'IA qui se trompe. Dans deux des trois, l'IA n'a rien fait de mal ; elle a produit une lecture plausible d'une matière mince. Chacune est l'histoire

d'une personne qui a lu, approuvé, signé, et dont le nom sera le seul dont on se souviendra quand la question reviendra. Personne n'a décidé de céder son jugement. Il est parti un paragraphe à la fois.

Un vieux biais sous un déguisement neuf

Le biais d'automatisation n'est pas une découverte de l'ère de l'IA. C'est la tendance d'une personne qui travaille avec un système automatisé à accorder à ce que produit le système plus de poids que les preuves ne le justifient, et à cesser de produire ses propres contrôles une fois que le système a parlé. Les chercheurs l'ont décrit dans les cockpits d'avion dès les années 1980, bien avant que quiconque ait entendu parler d'un modèle de langage. Bainbridge, en 1983, dans un article sur les « ironies de l'automatisation », a établi quelque chose qui sonne encore à l'envers : plus un système automatisé devient fiable, moins son opérateur humain s'exerce, et plus il est mauvais au rare moment où son intervention est réellement nécessaire. La fiabilité ne rend pas l'humain plus sûr. Elle le rend moins bon. Parasuraman et Manzey, passant en revue des décennies de ces travaux en 2010, ont retrouvé le même schéma du poste de pilotage au diagnostic médical : les aides automatisées qui ont généralement raison rendent leurs superviseurs humains moins capables d'attraper les fois où elles ont tort.

Rien de ces recherches ne portait sur l'IA générative. Ce n'était pas nécessaire. Le mécanisme est une relation entre une personne et un système dont la production a l'air digne de confiance, pas une propriété d'une technologie particulière. Ce que l'IA générative ajoute n'est pas un biais nouveau. C'est une intensité nouvelle et un déguisement nouveau.

L'intensité : un pilote automatique tombe rarement en panne et le signale quand cela arrive. Un système d'IA produit une réponse chaque fois que vous le sollicitez, instantanément, dans le registre d'un expert sûr de lui, que le raisonnement sous-jacent tienne ou non. Il n'y a aucun signal de défaillance dans l'interface. L'output faux ressemble exactement à l'output juste.

Le déguisement est la partie sur laquelle je vous demande de vous arrêter. Une calculatrice vous donne un nombre. Un GPS vous donne un itinéraire. Aucun des deux ne produit quelque chose qui se lit comme votre propre pensée. Un output d'IA, si. Il arrive en phrases complètes, dans un registre que vous reconnaissez, dans une structure que vous auriez choisie vous-même : la recommandation, le raisonnement, les réserves. Quand vous le lisez, l'expérience n'est pas « une machine m'a dit ceci ». Elle est plus proche de « c'est ce que j'aurais conclu, dit mieux et plus vite que je n'aurais su le dire ». C'est le voile. Pas un mensonge. Une surface de cohérence si lisse que vous ne pouvez pas savoir, de l'intérieur, si vous êtes d'accord avec l'output ou si vous avez simplement cessé de produire le désaccord que vous auriez eu autrement.

Pourquoi votre prudence ne vous protège pas

Vous vous dites peut-être que cela arrive à d'autres. Des gens négligents. Des gens qui ne prennent pas leur travail au sérieux. Deux affaires disent le contraire.

Dans l'affaire *Mata v. Avianca*, des avocats ont déposé devant un tribunal fédéral américain un mémoire contenant des références à des décisions de justice qui n'existaient pas. Les références avaient été générées par un système d'IA et jamais confrontées à une source primaire. C'étaient des avocats en exercice, dans la seule profession dont tout le métier consiste à citer une autorité vérifiée. En 2025, Deloitte Australie a remboursé la dernière tranche d'un contrat de 440 000 AUD passé avec le gouvernement australien, après la découverte de références fabriquées par une IA dans le

rapport livré. C'étaient des consultants, produisant le genre de document dont toute la valeur tient à la rigueur.

Si le biais d'automatisation avec une signature humaine n'attrapait que les négligents, il ne vaudrait pas un livre. Il attrape des gens consciencieux, qui font un travail normal sous une pression normale, et il les attrape précisément parce que leur conscience professionnelle vise, à juste titre dans tout autre contexte, le contenu de ce qu'ils lisent plutôt que la sensation de l'avoir compris.

C'est cette sensation qui a cassé, et il est utile de savoir pourquoi. Les psychologues étudient depuis longtemps la fluidité de traitement : la facilité avec laquelle un texte traverse votre esprit est utilisée, sans votre permission, comme un substitut de sa vérité et de la compétence de son auteur. Un texte qui se lit sans effort, dans des rythmes familiers, avec un registre assuré, est jugé plus crédible que le même contenu présenté maladroitement. Pendant l'essentiel de l'histoire humaine, ce raccourci était raisonnable, parce que produire un argument cohérent, assuré et bien construit exigeait de l'avoir pensé. La fluidité était une preuve de pensée. Cette corrélation n'existe plus. Un modèle produit une fluidité maximale sur un sujet qu'il n'a, au sens qui compte, jamais raisonné, et avec la même fluidité que l'affirmation soit fondée ou fausse. Votre heuristique ne peut pas faire la différence, parce que le signal qu'elle lit, la facilité, est désormais présent dans les deux cas. Personne n'a envoyé de circulaire. Être prudent ne règle rien, parce que la prudence tourne sur la même heuristique.

À quoi servait une signature

Toutes les histoires de biais d'automatisation se terminent de la même façon : un être humain a signé. Pas une machine agissant seule. Une personne avec un nom, une fonction et une obligation professionnelle, qui a approuvé, expédié, déposé ou recommandé. Cette signature est censée attester d'un événement précis : un humain a appliqué un jugement indépendant à ceci et en répond. C'est toute la raison d'avoir un humain dans le processus. Pas parce que les humains sont plus intelligents que les systèmes d'IA sur des tâches étroites ; souvent ils ne le sont pas. Parce qu'un humain peut être tenu responsable d'une façon qu'un système ne peut pas l'être, et que la responsabilité n'est réelle que si le jugement derrière elle a vraiment eu lieu.

Le biais d'automatisation avec une signature humaine est la défaillance dans laquelle la forme de la responsabilité survit et la substance disparaît. La personne signe encore. La forme est inchangée. Mais le jugement n'a jamais été exercé, parce que l'output est arrivé en ayant déjà l'air d'un jugement, et qu'il n'y avait aucune couture visible par où la pensée de la personne était censée entrer. Sous pression de temps, c'est-à-dire la plupart du temps dans la plupart des métiers, la voie de moindre résistance est de laisser la couture se refermer. Vous lisez un output fluide, bien argumenté, il correspond d'assez près à votre idée préalable de la situation, et vous signez. Pas par paresse. Par réaction rationnelle à un système qui a rendu le désaccord coûteux et l'accord gratuit.

Multipliez maintenant. Une recommandation rédigée avec l'aide de l'IA est approuvée par un chef de service qui fait confiance à la fluidité, remontée à une directrice qui applique le même raccourci, et arrive devant un conseil d'administration avec trois signatures derrière elle, dont aucune n'est un contrôle indépendant : trois occurrences de la même confiance non examinée, empilées, et prises pour trois actes de vigilance. Demandez à l'un des trois s'il a relu le document, et chacun répondra oui, sincèrement.

Les régulateurs ont commencé à nommer cela. L'article 14(4)(b) de l'AI Act européen oblige les fournisseurs de systèmes d'IA à haut risque à les concevoir de sorte que les personnes chargées de les superviser soient en mesure de rester conscientes du biais d'automatisation. C'est une obligation

de conception qui pèse sur le fournisseur, pour les systèmes à haut risque, sur un calendrier encore mouvant, et je ne suis pas juriste ; la troisième partie dit ce que cela veut dire et ce que cela ne veut pas dire. Pour l'instant, retenez seulement ceci : un texte de loi a dû écrire « rester conscient du biais d'automatisation » parce que ses rédacteurs avaient vu le même schéma et l'avaient jugé assez fréquent pour exiger une défense.

Pourquoi « certain », et non « spéculatif »

Il y a une version de la conversation sur l'IA que je n'ai pas. Elle dit : dans un certain nombre d'années, des systèmes plus intelligents que nous poursuivront des objectifs que nous n'avions pas voulus, et l'issue sera très mauvaise. Je ne vais pas discuter cette prophétie, ni pour ni contre. Elle dépend de choses qui ne sont pas arrivées et n'arriveront peut-être pas : une trajectoire de capacités, une défaillance des contrôles, un calendrier que personne ne prétend sérieusement connaître. Des gens raisonnables et informés en débattent vivement, et ce livre ne tranchera pas ce débat.

Le biais d'automatisation avec une signature humaine ne dépend de rien de tout cela. Il exige trois choses qui sont déjà vraies, partout où l'IA sert à éclairer une décision : l'IA produit un texte fluide, les humains lisent la fluidité comme un signal de qualité, et les décisions se prennent sous pression de temps. Les trois tiennent aujourd'hui, dans votre organisation, un mardi ordinaire. Ce n'est pas un risque qui pourrait se matérialiser si le développement de l'IA prend telle direction. Il se matérialise chaque fois que quelqu'un lit un paragraphe qui sonne compétent et s'arrête là.

Remarquez aussi ce que cela fait à la question que tout le monde pose en premier : l'IA est-elle déjà assez bonne ? Pour ce risque-ci, la question est à côté du sujet. Un meilleur modèle produit un texte plus fluide, ce qui referme la couture plus vite, pas moins vite. Chaque progrès de fiabilité du système est, par l'ironie de Bainbridge, une petite réduction de l'entraînement que son humain reçoit à le rattraper. La question n'est jamais de savoir si l'IA est assez bonne. C'est de savoir si vous êtes encore dans la boucle, ou seulement dans la signature.

C'est aussi pourquoi on en parle si peu par rapport à sa taille. Il n'a pas d'histoire. Personne n'écrit un titre sur « un chef de service approuve une recommandation rédigée par IA qui reposait sur une hypothèse non formulée ». La défaillance est silencieuse, répartie sur des millions de petites approbations, et invisible même pour la personne qui l'a commise, parce qu'une réponse fautive et fluide ne s'annonce pas. Elle reste là, signée, jusqu'à ce que quelque chose casse en aval et que quelqu'un doive expliquer ce qui s'est passé. À ce moment-là, l'explication « l'IA l'a dit » vaut exactement zéro, et tout le monde dans la pièce le sait.

Ce que ce livre fait à la place

On ne répare pas une heuristique de fluidité cassée en s'efforçant de remarquer quand elle se trompe. Remarquer est la fonction qui a été désactivée. Ce que vous pouvez faire, c'est cesser de vous fier à l'heuristique, pour la classe de décisions où se tromper coûte quelque chose, et la remplacer par une séquence de contrôles externe, répétable, qui se moque de la confiance que l'output vous inspire.

Revenez au jeudi soir. Les dix secondes avant d'appuyer sur Envoyer ne sont pas, en réalité, trop courtes pour contenir un contrôle. Elles sont trop courtes pour contenir une relecture, ce que la plupart des gens tentent puis abandonnent. Un contrôle est un acte différent, et petit. Nommez le seul chiffre ou la seule affirmation sur lesquels toute la recommandation repose, celui qui, s'il est faux, rend le reste sans objet. Dites, en une phrase, ce qui doit être vrai pour que cette affirmation tienne, et remarquez si le document le dit ou le suppose. Puis nommez la personne qui pourrait

le confirmer par un message de deux lignes, et décidez si vous envoyez ce message avant ou après votre signature. C'est le contrôle entier, à sa plus petite taille, et il prend à peu près le temps de lire ce paragraphe. Il ne vous dit pas si l'output est juste. Il vous dit si vous le savez, et si la réponse honnête est non, il vous dit qui le sait. La plupart des signatures n'obtiennent même pas cela, non parce que dix secondes sont trop peu, mais parce que personne n'a dit au signataire quoi en faire.

Cette séquence, mise à l'échelle de l'enjeu, est le reste de ce livre. Pas une défense contre les erreurs de l'IA ; l'IA se trompera parfois quoi que vous fassiez, et ce n'est pas le problème que je résous. Une défense contre la signature qui devient un tampon. Une signature avec un registre derrière elle, une liste écrite d'hypothèses avec une personne nommée pour vérifier chacune, une courte liste de questions ouvertes avec un propriétaire, n'est plus un tampon, quelle que soit la fluidité de l'output qui l'a produite. Le registre retransforme « je l'ai lu et ça semblait bon » en « j'ai regardé ceci précisément, voici ce que j'ai trouvé, et voici ce qu'il me reste à savoir ». Tout ce qui suit à partir du chapitre 5 est la mécanique de ce registre, sans transformer chaque décision en projet de recherche.

Je ne suis pas arrivé à cela depuis une théorie du risque de l'IA. J'y suis arrivé depuis un bureau commercial dans l'industrie pharmaceutique, contrats, pricing, appels d'offres, stratégie hospitalière, en regardant des analyses rédigées par IA avancer plus vite que la capacité de quiconque à les contrôler, et en constatant que le contrôle n'échouait pas parce que les gens étaient négligents. Il échouait parce que personne n'avait de méthode, et qu'en inventer une à partir de rien, sous délai, à chaque fois, n'est pas une méthode. C'est de la chance. Alors j'en ai construit une, et je l'ai construite avant d'écrire ce livre. Tout ce qui a été généré pendant sa construction y est passé. Ce qui a survécu est ici.

Avant de fermer ce chapitre

Les trois chapitres suivants vous donnent la frontière : deux lignes que toutes les organisations confondent, la différence entre relire et vérifier, et quatre profils de la personne qui signe. L'un des quatre est vous, et le chapitre 4 se termine par douze questions qui vous permettent de compter à quel point vous avez déjà franchi la ligne. Avant d'y aller, passez trois questions sur l'output que vous avez signé le plus récemment.

1. Qu'est-ce qui vous a fait arrêter de vérifier à l'endroit où vous vous êtes arrêté ?
2. Si quelqu'un dont le métier est de trouver la faille vous demandait de défendre cette décision sans jamais dire « l'IA l'a dit », combien de temps la défense tiendrait-elle ?
3. Y a-t-il en ce moment sur votre bureau quelque chose qui se lit déjà comme « globalement juste », et si oui, quelle est la seule chose dedans que vous n'avez pas réellement vérifiée ?

Le livre complet

Ce chapitre est le premier des douze. Le livre complet, en EPUB et PDF : humanfrontier.ai/livre — 9,99 €.