

Certitudes collectives et incertitudes individuelles, les données massives changent-elles la donne ?

par **Arthur Charpentier** (Université de Kyoto et Université du Québec à Montréal)

Depuis plus de deux siècles, les sciences sociales se heurtent à un paradoxe tenace : si les comportements individuels sont incertains, contingents et souvent imprévisibles, leur agrégation produit des régularités collectives d'une étonnante stabilité. De Quetelet à Durkheim, en passant par Weber, cette tension entre incertitude individuelle et certitude collective a nourri la constitution même d'une science sociale quantitative.

L'ère des données massives redonne une actualité brûlante à ce paradoxe. Jamais les sociétés humaines n'ont généré autant de traces numériques : achats, communications, déplacements, interactions en ligne, données physiologiques. Ces flux continus, enregistrés et analysés à grande échelle, alimentent l'espoir d'une prévisibilité quasi totale. Certains annoncent la fin de l'incertitude : les algorithmes sauraient anticiper nos choix de consommation, les crises sanitaires ou les évolutions politiques. Mais cette promesse soulève des questions épistémologiques et sociales profondes : que signifie appliquer une probabilité à un événement singulier ? Jusqu'où un score algorithmique peut-il être considéré comme fiable, juste ou légitime ?

L'objectif de ce texte est d'examiner, à nouveaux frais, le rapport entre incertitude individuelle et certitude collective à l'ère du big data. Pour ce faire, nous parcourrons plusieurs étapes : d'abord, revenir aux fondements historiques de la découverte des régularités collectives ; ensuite, montrer comment la rationalité limitée, loin de contredire la prévisibilité, contribue à l'émergence de modèles robustes ; puis analyser les débats contemporains sur l'interprétation des probabilités et la nécessité de calibrer les scores ; enfin, explorer la dimension temporelle de la prévision, du nowcasting instantané aux projections climatiques de long terme.

Notre thèse est que les données massives ne résolvent pas le paradoxe, mais en amplifient la portée et les enjeux. Elles déplacent le débat d'un plan strictement scientifique vers un plan éthique et politique : comment gouverner l'incertitude, dans un monde où elle est à la fois plus visible, plus mesurable, mais aussi plus contestable ?

De l'imprévisibilité individuelle à la régularité collective

Depuis ses origines, la statistique sociale s'est construite autour d'un paradoxe qui demeure au cœur de nos débats contemporains : l'action individuelle est incertaine, contingente, soumise à des influences multiples, mais les agrégats collectifs révèlent des régularités d'une étonnante stabilité.

L'individu demeure opaque, mais la collectivité devient lisible, par l'« *homme moyen* », par la loi des grands nombres, par les mécanismes micro-macro, par les réseaux, etc. Ce contraste, identifié dès le XIX^e siècle, constitue le socle de l'idée même de science sociale quantitative.

Découverte et théorisation des régularités

Adolphe Quetelet, astronome et statisticien belge, est l'un des premiers à mettre ce paradoxe en évidence dans *Sur l'homme et le développement de ses facultés* (1835). En analysant des séries de données sur les naissances, les mariages, les crimes ou les suicides, il découvre que les totaux annuels varient très peu d'une année sur l'autre. Cette invariance frappante, malgré l'imprévisibilité de chaque acte individuel, l'amène à formuler la notion d'« *homme moyen* », figure abstraite qui incarne les régularités sociales au-delà des particularités individuelles. Pour Quetelet, la statistique ne se limite pas à une description : elle révèle un ordre caché, une « physique sociale » capable de mettre au jour des lois semblables à celles de la nature.

Quelques décennies plus tard, Émile Durkheim reprend cette intuition et la systématise. Dans *Le Suicide* (1897), il montre que, si l'on ne peut jamais prédire qui se donnera la mort, les taux de suicide présentent une remarquable constance d'une population à l'autre. Cette structure récurrente n'est pas due au hasard mais à des déterminants sociaux : l'intégration communautaire, l'intensité des liens familiaux ou religieux, la régulation normative. Le suicide apparaît alors moins comme un acte individuel mystérieux que comme un fait social régulier, dont l'explication se trouve dans les structures collectives. Par ce geste théorique, Durkheim fonde la sociologie comme discipline autonome, distincte de la psychologie ou de la philosophie morale, et ancrée dans l'étude des régularités statistiques. Comme il l'écrivait déjà dans *Les règles de la méthode sociologique* (1895),

« *quand on est entré quelque peu en contact avec les phénomènes sociaux, on est surpris de l'étonnante régularité avec laquelle ils se reproduisent* » Durkheim (1895)

Autrement dit, même les pratiques apparemment les plus contingentes prennent, à l'échelle collective, une forme régulière qui fonde la possibilité d'une science sociale quantitative.

Max Weber, de son côté, insiste sur l'importance du sens et de la subjectivité dans l'action sociale. Pourtant, il reconnaît lui aussi que l'agrégation des actions individuelles produit des structures stables et prévisibles. Dans *Économie et société* (1922), il analyse par exemple comment les croyances religieuses influencent l'éthique économique, et comment, à travers la multitude des choix individuels, se dessinent des régularités collectives comme l'essor du capitalisme. Ainsi, même dans une perspective compréhensive centrée sur les motivations, les régularités émergent comme des effets d'agrégation. Weber souligne ainsi que,

« *de même que l'individu qui agit pratiquement, l'étude compréhensive les considère comme de simples 'data' [...] il est possible qu'à l'avenir la recherche découvre aussi des régularités incompréhensibles dans un comportement significativement différencié.* » Weber (1922)

Il admettait donc, même dans une perspective compréhensive, l'existence potentielle de régularités au sein de comportements hétérogènes.

Cette lecture des régularités comme des phénomènes « *naturels* », inscrits dans l'ordre social lui-même, a cependant été critiquée. Michel Foucault a montré que les statistiques ne se contentent pas

de révéler des lois objectives : elles participent aussi d'un régime de savoir-pouvoir. Dans *Sécurité, territoire, population* (1977-1978), il analyse comment, à partir du XVIII^e siècle, l'État commence à se fonder sur des régularités mesurées (natalité, mortalité, morbidité) pour orienter ses politiques. Ces agrégats deviennent ainsi des instruments de gouvernementalité : ils organisent et régulent les populations autant qu'ils les décrivent. Autrement dit, les certitudes collectives ne sont pas seulement des effets d'agrégation (comme chez Quetelet, Durkheim ou Weber) ; elles sont aussi construites et mobilisées comme outils de pouvoir.

Pierre Bourdieu a prolongé cette réflexion en montrant que les catégories statistiques ne sont jamais neutres : elles participent à la construction de la réalité sociale qu'elles prétendent seulement décrire. Dans *La Distinction* (1979) et dans ses travaux sur l'État (*Sur l'État*, 1989-1992), il analyse comment les classifications (qu'elles portent sur l'origine sociale, le niveau scolaire ou les pratiques culturelles) produisent une vision légitime du monde social et contribuent à la reproduction des hiérarchies. Les régularités collectives ne sont donc pas seulement des régularités « *découvertes* », elles sont aussi le résultat d'opérations de catégorisation qui naturalisent des différences sociales et renforcent des rapports de domination. Foucault et Bourdieu rappellent que les statistiques sont aussi des instruments de pouvoir, qui orientent la manière dont la société se voit et se gouverne. Mais d'autres chercheurs, comme Francis Galton ou Émile Borel, ont privilégié une autre voie : celle d'une formalisation statistique et probabiliste des régularités, censée transcender les intentions sociales ou politiques.

Fondations probabilistes des régularités collectives

Dans une autre tradition, plus statistique, Francis Galton (1886) met en lumière le principe de la régression vers la moyenne. En étudiant la taille des enfants relativement à celle de leurs parents, il constate que les écarts individuels tendent à se compenser, de sorte que la moyenne demeure stable. Ce principe, d'abord formulé dans un cadre biométrique, a inspiré de nombreuses analyses en sciences sociales : il illustre la manière dont les fluctuations individuelles s'effacent dans l'agrégat, révélant une stabilité collective. Outre son analyse biométrique de la régression vers la moyenne, Francis Galton a également mis en évidence le pouvoir du consensus statistique dans *Vox Populi* (1907). En observant un concours agricole où l'on demandait aux participants d'estimer le poids d'un bœuf, il montra que la moyenne des estimations était étonnamment proche du poids réel. Cet épisode illustre que les erreurs individuelles, loin de s'additionner, tendent souvent à s'annuler dans l'agrégat, produisant une estimation collective robuste. L'« *homme moyen* » de Quetelet trouve ici une confirmation empirique : la moyenne n'est pas seulement une abstraction statistique, elle peut être un instrument de connaissance plus précis que l'expertise individuelle. Ces travaux, qui anticipent la notion contemporaine de *wisdom of crowds*, montrent que l'agrégation d'opinions imparfaites peut engendrer une régularité collective dotée d'une valeur prédictive forte.

Les constats empiriques de Quetelet et Galton ont trouvé, au tournant du XX^e siècle, une assise théorique avec les travaux mathématiques sur la probabilité. Émile Borel, dans *Le Hasard* (1914), insiste sur le rôle des lois des grands nombres : si l'individu reste imprévisible, les phénomènes collectifs, eux, obéissent à des régularités d'autant plus stables que le nombre d'observations est grand. Cette idée, reprise ensuite par Andreï Kolmogorov et Boris Gnedenko, fonde une lecture probabiliste des régularités sociales : l'ordre collectif n'est pas une illusion, mais une conséquence mathématique de l'agrégation des aléas individuels.

« *In fact, all epistemological value of the theory of probability is based on this: that large-scale random phenomena in their collective action create strict, nonrandom regularity* »
Gnedenko et Kolmogorov, 1954

Émile Borel soulignait ainsi que « *le hasard disparaît dans la masse* » : ce qui semble incertain et erratique au niveau micro devient prévisible et régulier au niveau macro. Les applications en assurance sont alors naturelles, dès le XVIII^e siècle : la *Society for Equitable Assurances* affirmait en 1764 que le calcul actuariel reposait sur

« *l'espérance de la continuité de la vie qui, bien que les vies des hommes prises séparément soient incertaines, est cependant réductible à une certitude dans un ensemble de vies* » (cité par Daston, 2021)

L'assurance-vie illustre ainsi l'une des premières applications institutionnelles de la loi des grands nombres.

Cette formalisation probabiliste complète la perspective sociologique : elle montre que la stabilité collective n'est pas seulement observée empiriquement, mais qu'elle découle de lois fondamentales du calcul des probabilités. Si Galton et Borel soulignent la robustesse mathématique des régularités collectives, d'autres, comme James Coleman, ont cherché à comprendre les mécanismes sociaux qui permettent leur émergence.

Passage du micro au macro, et mécanismes émergents

Au XX^e siècle, la question du lien entre micro et macro est reformulée par James Coleman. Dans *Individual Interests and Collective Action* (1986) et *Foundations of Social Theory* (1990), il propose un cadre théorique pour comprendre comment des comportements motivés par des intérêts individuels, souvent opportunistes et incertains, peuvent générer des structures collectives stables. Son fameux « *Coleman boat* » décrit la boucle par laquelle les structures sociales influencent les motivations individuelles, qui, une fois agrégées, transforment à leur tour les structures collectives. Coleman montre que l'ordre collectif n'est pas le produit d'une rationalité parfaite, mais d'un enchaînement d'actions limitées et encadrées par des institutions.

Des travaux ultérieurs prolongent et illustrent cette perspective. Thomas Schelling, dans *Micromotives and Macrobehavior* (1978), montre que des préférences individuelles apparemment anodines peuvent produire, par agrégation, des résultats collectifs massifs et stables. Son modèle de ségrégation résidentielle est resté célèbre : même une préférence faible pour vivre parmi des voisins similaires peut conduire à une ségrégation marquée à l'échelle d'une ville entière. La régularité collective n'est pas ici l'expression d'une intention, mais l'émergence d'un motif global à partir de microdécisions locales.

Dans les années 1990, les sciences des réseaux apportent une confirmation spectaculaire de ce mécanisme. Les travaux d'Albert-László Barabási et Réka Albert (1999) montrent que, dans des réseaux complexes, des interactions locales apparemment aléatoires produisent des structures globales très régulières, caractérisées par des lois de puissance et une hiérarchie de connectivité. Autrement dit, des dynamiques individuelles imprévisibles engendrent, par agrégation, une architecture collective robuste.

Confirmation contemporaine par la science des données

À l'ère des données massives, ce constat prend une dimension nouvelle. Les données de mobilité urbaine, issues des GPS, des cartes de transport ou des applications de navigation, montrent que les trajets quotidiens d'un individu sont soumis à des variations nombreuses, mais que les flux agrégés révèlent des régularités frappantes : heures de pointe, embouteillages récurrents, schémas d'occupation de l'espace. De la même manière, les données de téléphonie mobile analysées par Eagle, Pentland et Lazer (2009) montrent que, bien que chaque appel ou message soit contingent, les réseaux d'interaction qu'ils forment suivent des motifs stables, prédictibles et reproductibles. À une échelle plus large, les réseaux sociaux en ligne mettent en évidence des régularités collectives dans la diffusion de l'information ou l'adoption des innovations, qui échappent à la volonté consciente des acteurs individuels.

Ce paradoxe (l'imprévisibilité individuelle et la régularité collective) n'est pas une curiosité historique, mais une constante des sciences sociales. Il fonde la possibilité même de la prévision statistique et de la gouvernance par les nombres. L'essor des données massives n'a pas aboli cette tension : il la rend plus visible et plus exploitable. Nous disposons aujourd'hui d'une confirmation empirique spectaculaire de ce que Quetelet ou Durkheim avaient entrevu. Mais cette confirmation pose de nouvelles questions : si les régularités collectives sont mieux mesurées, comment éviter de les confondre avec des certitudes individuelles ? Et jusqu'où peut-on utiliser ces régularités pour orienter les comportements, sans basculer dans une forme de déterminisme social ?

Ainsi, de Quetelet à l'analyse contemporaine des big data, se déploie un même fil rouge : l'individu demeure opaque, mais la collectivité devient lisible. Les données massives ne changent pas la nature du paradoxe, mais elles en démultiplient la portée. Elles offrent aux chercheurs, aux assureurs, aux décideurs publics une capacité inédite d'objectiver ces régularités, de les modéliser et de les exploiter. Mais elles rappellent aussi la nécessité de maintenir une vigilance critique sur ce que ces chiffres signifient réellement : des certitudes collectives, jamais des certitudes individuelles

Rationalité limitée et émergence de modèles prévisibles

Si la stabilité des agrégats sociaux peut sembler paradoxale au regard de l'imprévisibilité des individus, une partie de l'explication réside dans les limites mêmes de la rationalité humaine. Loin d'abolir toute régularité, ces contraintes cognitives, institutionnelles et collectives deviennent au contraire le moteur de formes prévisibles de comportement.

Heuristiques et biais cognitifs : de Simon à Kahneman et Gigerenzer

L'une des révolutions conceptuelles majeures dans l'étude du comportement humain provient des travaux d'Herbert Simon, qui introduit la notion de « *rationalité limitée* » (*bounded rationality*). Contrairement au modèle néoclassique de l'« *homo economicus* », doté d'une information parfaite et de capacités de calcul illimitées, Simon (1947 ; 1955 ; 1976) montre que les individus prennent leurs décisions sous contraintes cognitives, avec des informations incomplètes et dans des horizons temporels réduits. Plutôt que de maximiser leurs gains, ils se contentent de solutions « *satisfaisantes* » (*satisficing*). Cette vision ouvre la voie à une compréhension plus réaliste des comportements : loin d'être parfaitement rationnels, les individus adoptent des règles pratiques qui structurent néanmoins leurs choix.

Les travaux fondateurs de Daniel Kahneman et Amos Tversky (1974) prolongent cette intuition en montrant que les individus recourent systématiquement à des heuristiques cognitives (comme la représentativité, la disponibilité ou l'ancrage) qui permettent de simplifier la décision mais engendrent des biais prévisibles. Ainsi, les individus tendent à surestimer les petits risques (loteries, accidents rares) et à extrapoler de manière excessive à partir d'événements récents. Ces biais, loin d'être de simples erreurs aléatoires, introduisent une structure régulière dans le jugement humain. En d'autres termes, les limites cognitives ne produisent pas seulement du bruit : elles génèrent des motifs stables et reproductibles qui peuvent être modélisés statistiquement.

Dans une perspective complémentaire, Gerd Gigerenzer et ses collaborateurs (1999) défendent l'idée que ces heuristiques sont souvent écologiquement rationnelles. Autrement dit, elles ne sont pas de simples approximations défectueuses, mais des règles adaptées à des environnements spécifiques. Par exemple, la règle « *take the best* » (choisir la première option jugée plausible) permet de prendre des décisions rapides et efficaces dans des contextes incertains, tout en produisant des comportements cohérents à l'échelle collective. Ainsi, la rationalité limitée ne conduit pas à un chaos décisionnel, mais à des régularités prédictibles, confirmant le paradoxe fondateur : l'imprévisibilité des choix individuels s'accompagne de certitudes collectives observables.

Routines organisationnelles et dynamiques collectives

Dans les organisations, la rationalité limitée des individus est compensée par des routines collectives qui stabilisent les comportements. Comme l'ont montré Simon et March (1958), ces routines ne sont pas de simples habitudes : elles sont des mécanismes de coordination qui réduisent l'incertitude en canalisant les choix individuels. Les procédures standardisées, les hiérarchies ou les règles implicites agissent comme des filtres qui orientent l'action, assurant une certaine prévisibilité. Ces dynamiques ne concernent pas seulement les entreprises : elles valent aussi pour les administrations, les universités ou les hôpitaux, où des routines institutionnelles garantissent la continuité des décisions. Loin d'entraver la flexibilité, ces dispositifs rendent possibles des ajustements collectifs en fournissant un socle de régularité. Autrement dit, les routines constituent un cadre de stabilité qui transforme l'imprévisibilité individuelle en certitudes collectives, illustrant à nouveau le paradoxe fondateur des sciences sociales

Dans une perspective plus macroscopique, Thomas Schelling (*Micromotives and Macrobehavior*, 1978) illustre comment des préférences individuelles apparemment anodines peuvent produire des résultats collectifs massifs et stables. Son modèle de la ségrégation résidentielle est devenu emblématique : même une préférence faible pour vivre parmi des voisins similaires peut conduire, par agrégation, à une ségrégation marquée à l'échelle d'une ville entière. La régularité collective n'est pas ici le produit d'une intention partagée, mais l'émergence spontanée d'un motif global à partir de micro-décisions locales.

Ces exemples montrent que la rationalité limitée, qu'elle soit cognitive ou institutionnelle, n'abolit pas les régularités collectives : elle en constitue au contraire le terreau. Les comportements bornés et myopes, lorsqu'ils sont répétés et agrégés, donnent lieu à des structures sociales robustes et prédictibles.

Rationalité limitée à l'ère des big data : cycles et modélisations numériques

Un exemple paradigmatique de cette logique est fourni par les marchés financiers. Dans le fameux « *El Farol Problem* » proposé par W. Brian Arthur (1994), chaque individu décide d'aller ou non dans un bar en fonction de ce qu'il anticipe des choix des autres. Les décisions individuelles sont incertaines et variables, mais le système agrégé produit une régularité autour d'un équilibre. Cette dynamique explique aussi les cycles de bulles et de krachs : chaque investisseur, limité cognitivement, imite les comportements observés ou suit des règles heuristiques simples (« *acheter quand ça monte* »). L'irrationalité apparente des marchés prend ainsi la forme de cycles collectifs prévisibles.

À l'ère des données massives, ces intuitions trouvent une confirmation empirique nouvelle. Alex Pentland (2014), avec sa notion de « *physique sociale* », montre que la diffusion d'idées et d'innovations est largement déterminée par des biais d'imitation et d'attention limitée. Les flux d'information dans les réseaux sociaux obéissent à des régularités quantifiables, indépendantes des intentions individuelles. De même, Dirk Helbing (2012) a utilisé des modèles multi-agents pour montrer que des règles comportementales très simples, inspirées des heuristiques humaines, suffisent à générer des structures collectives robustes et prévisibles, qu'il s'agisse de trafic routier, de foules en mouvement ou de dynamiques d'opinion.

Ces approches contemporaines rappellent que les big data n'abolissent pas la rationalité limitée : ils en exploitent les régularités structurelles pour améliorer la prévision. L'individu reste imprévisible, mais ses biais, ses routines et ses heuristiques produisent des motifs répétitifs qui, une fois agrégés, deviennent des certitudes collectives. En d'autres termes, les big data ne suppriment pas l'incertitude individuelle : ils amplifient la capacité à gouverner l'incertitude collective, en rendant visibles et mesurables des structures déjà pressenties par Simon, Schelling ou Arthur.

Ces mécanismes comportementaux expliquent pourquoi des régularités collectives émergent malgré des choix individuels bornés. Mais comprendre leur existence ne suffit pas : encore faut-il savoir comment les mesurer et les interpréter. C'est ici que la théorie des probabilités intervient, en proposant des cadres épistémologiques distincts pour penser le lien entre incertitude individuelle et certitude collective. Passons donc de la description des comportements à l'interrogation sur la signification même des probabilités.

Fréquentisme vs. probabilités uniques : épistémologie des données massives

Après avoir vu comment les comportements bornés des individus produisent néanmoins des régularités collectives, il faut se tourner vers la question plus fondamentale de leur interprétation. Car derrière chaque pourcentage ou chaque score prédictif se cache une controverse ancienne : la probabilité doit-elle être comprise comme une fréquence observée ou comme un degré de croyance ? Explorer cette dualité (entre fréquence et croyance, entre collectif et individuel) est indispensable pour comprendre comment les données massives réactivent un débat ancien et pourquoi la gouvernance de l'incertitude passe aujourd'hui par une articulation des deux approches.

Deux traditions de la probabilité : fréquence ou croyance

Le paradoxe entre incertitude individuelle et certitude collective se retrouve au cœur même de la théorie des probabilités. Depuis ses origines, ce concept oscille entre deux traditions distinctes. La première est le fréquentisme, pour lequel la probabilité est la limite d'une fréquence relative observée dans une série d'expériences répétées. Dire qu'un dé a une chance sur six de donner un quatre signifie que, dans un grand nombre de lancers, la proportion de quatre tendra vers un sixième. Cette conception, défendue par Richard von Mises (1928) et formalisée par Jerzy Neyman (1937) ou Ronald Fisher (1956), a dominé la statistique du XX^e siècle, notamment dans les protocoles d'inférence et de tests d'hypothèses. Sa force réside dans sa robustesse empirique : elle relie directement la probabilité à l'observation répétée et à l'agrégation de données. Mais elle atteint ses limites dès lors que l'on s'intéresse à des événements uniques et non répétables : une élection, une opération chirurgicale, une décision judiciaire.

C'est précisément ce problème qu'affronte la seconde tradition, celle du bayésianisme. Pour Bruno de Finetti (1937/1974) ou Leonard Savage (1954), la probabilité n'est pas une propriété du monde, mais un degré de croyance rationnelle attribué à un événement, même unique. Affirmer qu'il y a 70 % de chances de pluie demain signifie non pas qu'il pleuvra dans 70 % des cas, mais que l'agent est prêt à parier dans cette proportion. La probabilité devient ici un outil subjectif de décision, cohérent avec un cadre logique et normatif. Cette approche permet d'appliquer le langage probabiliste à des situations singulières, mais elle introduit une dimension interprétative qui inquiète ceux qui cherchent une notion « objective » de probabilité. Dans son *Theory of Probability (An Inquiry into the Logical and Mathematical Foundations of the Calculus of Probability)*, 1971), Hans Reichenbach propose une articulation entre ces deux visions

« La probabilité est utilisée comme un substitut de la vérité tant que la vérité est inconnue [...] Si la probabilité a quelque chose à voir avec la fiabilité des prédictions, l'énoncé de la probabilité doit être vérifiable en termes d'occurrence de l'événement prédit. [...] Si l'on nous demande de trouver la probabilité d'un événement futur particulier, nous devons d'abord intégrer ce cas dans une classe de référence appropriée. » Hans Reichenbach (1971)

Autrement dit, toute probabilité appliquée à un cas singulier suppose de le rapporter à une classe collective, ce qui réactive le lien entre fréquentisme et bayésianisme. Ces deux visions ne sont pas seulement théoriques : elles traduisent deux manières de penser le rapport entre individus et collectifs. Le fréquentisme met en avant la régularité des masses, tandis que le bayésianisme accorde une place centrale à l'incertitude vécue par l'agent singulier.

Un débat réactivé par les données massives

À l'ère du big data, cette tension classique ne disparaît pas, elle se renforce. D'un côté, l'accumulation massive de données semble donner raison aux fréquentistes : plus l'échantillon est grand, plus la fréquence observée paraît stable. Les réseaux sociaux, la mobilité urbaine ou les transactions financières montrent en effet des régularités frappantes dès lors que l'on agrège des millions de comportements individuels. De ce point de vue, le big data incarne une forme de triomphe de la probabilité fréquentiste, permettant de mettre en évidence des régularités collectives invisibles à petite échelle.

De l'autre, la quête de personnalisation extrême réactive l'approche bayésienne. La médecine individualisée, la justice prédictive ou la tarification d'assurance cherchent à estimer le risque de tel patient, de tel justiciable, de tel conducteur. Ces contextes exigent d'attribuer une probabilité à un événement unique, irréductible à une fréquence répétée. C'est le rôle du calcul bayésien : donner un sens à l'incertitude singulière, en l'exprimant comme un degré de confiance conditionné par les données disponibles.

Ce double mouvement révèle une ambivalence profonde. La probabilité est tantôt un outil de stabilisation collective (prévoir les taux de chômage, les flux de trafic, la mortalité), tantôt un instrument de gestion individualisée (attribuer un score de récidive ou de risque médical). Les données massives ne tranchent pas entre les deux traditions : elles rendent nécessaire leur articulation, car les mêmes chiffres peuvent être lus comme fréquences collectives ou comme croyances individuelles.

Vers une épistémologie hybride : probabilité et gouvernance de l'incertitude

L'historien Ian Hacking (1975) a montré que cette ambivalence traverse toute l'histoire moderne des sciences : la probabilité est née dans les jeux de hasard, où la répétition permettait de définir des lois stables, mais elle a ensuite été appliquée à des événements historiques uniques, comme les guerres ou les épidémies. Cette extension a toujours posé un problème conceptuel majeur : peut-on vraiment dire qu'un accusé a « 25 % de chances de récidiver » ou qu'une opération chirurgicale a « 15 % de risques d'échouer » ? Dans un cadre strictement fréquentiste, ces énoncés n'ont pas de sens. Dans un cadre bayésien, ils deviennent interprétables, mais au prix d'un glissement : la probabilité cesse d'être une propriété du monde pour devenir une mesure de nos croyances et de nos décisions. Cette difficulté se manifeste de façon aiguë en droit. Comme l'ont résumé Fenton et Neil (2018)

« Écoutez, soit le type l'a fait, soit il ne l'a pas fait. S'il l'a fait, il est coupable à 100 %, et s'il ne l'a pas fait, il est coupable à 0 %. Par conséquent, donner une probabilité de culpabilité intermédiaire n'a aucun sens et n'a pas sa place en droit. » Fenton & Neil (2018)

Cette difficulté à admettre une logique probabiliste dans un système juridique fondé sur le binaire (« *coupable* » ou « *non coupable* ») illustre bien les tensions que soulève la justice prédictive. Parler d'une « *probabilité de culpabilité* » est en effet problématique, tant sur le plan légal qu'éthique. En revanche, il devient plus acceptable de raisonner en termes de prévention et de gestion des risques. C'est précisément ce que font les logiciels comme COMPAS, qui attribuent à chaque individu un score de « *risque de récidive* » exprimé en pourcentage. Mais un tel chiffre ne dit rien du futur personnel de l'accusé : il reflète uniquement la moyenne observée dans un groupe d'individus jugés comparables. La même ambiguïté se retrouve en médecine, lorsqu'un oncologue annonce qu'un patient a « 40 % de chances de rechute » : cette probabilité décrit une régularité collective, mais n'a pas de valeur prédictive pour le destin singulier du patient. Dans les deux cas, qu'il s'agisse de justice ou de santé, la tension entre certitudes statistiques collectives et incertitude vécue individuellement devient une question cruciale de justice et de légitimité sociale.

Ces enjeux ne sont pas seulement techniques : ils engagent une réflexion éthique et politique sur la gouvernance algorithmique. Qui décide des seuils de risque acceptables ? Comment garantir que l'acceptabilité sociale d'un score prédictif soit débattue démocratiquement, plutôt que laissée aux seuls experts techniques ? Comme le soulignent les débats sur la régulation de l'intelligence artificielle, l'enjeu n'est pas seulement d'améliorer les modèles, mais de décider collectivement des usages légitimes de ces prédictions. La légitimité sociale des données massives dépend donc autant

de leur performance technique que de leur inscription dans un cadre de délibération publique. Cynthia Dwork et ses collègues (2012) ont montré que les scores probabilistes peuvent renforcer des discriminations si leur calibration et leur interprétation ne sont pas soigneusement contrôlées. Barocas, Hardt et Narayanan (2019) insistent sur la nécessité de penser la fairness dans le machine learning : un même score peut avoir des significations différentes selon les groupes sociaux, produisant des injustices systémiques si l'on le traite comme une vérité absolue.

Ainsi, l'épistémologie contemporaine des probabilités est nécessairement hybride. Les big data obligent à articuler la robustesse empirique du fréquentisme avec la souplesse interprétative du bayésianisme. La probabilité devient à la fois mesure collective et outil décisionnel individuel, statistique et croyance, calcul et politique. Mais cette hybridité appelle un outil pratique permettant de juger si les probabilités énoncées correspondent bien à la réalité observée. C'est précisément le rôle de la calibration, qui constitue le prolongement nécessaire de ce débat théorique.

Calibration et interprétation des scores

Comprendre la probabilité, c'est une chose ; savoir si elle un score renvoyé par un modèle complexe est interprétable comme la probabilité en est une autre. La calibration désigne précisément ce passage : vérifier que les scores prédictifs produits par un modèle correspondent effectivement aux fréquences observées.

De la probabilité abstraite au score opérationnel

Si la probabilité est un concept pluriel, elle doit, pour être utile, prendre la forme d'un score exploitable dans la décision. Mais un chiffre comme « *70 % de probabilité* » ne dit pas grand-chose en lui-même : il doit être confronté à la réalité observée. C'est précisément l'objet de la calibration, qui consiste à vérifier que les prédictions correspondent effectivement aux fréquences empiriques. Si un modèle affirme que 30 % des patients d'un certain profil rechuteront, on attend qu'en moyenne, sur cent patients similaires, une trentaine connaisse effectivement une rechute. La calibration établit ainsi le lien entre l'abstraction probabiliste et l'expérience vécue, entre la théorie et l'usage.

Historiquement, cette exigence est ancienne : les astronomes et météorologues du XIX^e siècle comparaient déjà leurs prévisions aux observations pour valider leurs modèles. Mais à l'ère des données massives, où les probabilités envahissent la médecine, la justice et l'assurance, la calibration devient une étape incontournable non seulement pour la crédibilité scientifique, mais aussi pour la légitimité sociale des prédictions.

Domaines d'application : médecine, justice, assurance

La médecine illustre de manière exemplaire les ambiguïtés de la calibration. Lorsqu'un oncologue annonce qu'un patient a « *40 % de chances de rechute* », ce chiffre ne correspond pas à une vérité individuelle (le patient rechutera ou non) mais à une régularité observée au sein d'un collectif de patients comparables. Le problème vient souvent de l'interprétation : médecins comme patients tendent à confondre un score de groupe avec une prédiction individuelle. Un modèle peut être bien calibré collectivement tout en induisant une compréhension erronée au niveau singulier.

L'affaire COMPAS a cristallisé ces débats, en révélant que les scores de récidive pouvaient non seulement manquer de calibration, mais aussi amplifier des discriminations structurelles. L'enquête

de ProPublica (Angwin et al., 2016) a montré que, pour des prévenus noirs, le logiciel surestimait systématiquement le risque de récidive, tandis qu'il était trop optimiste pour les prévenus blancs. Ce constat a alimenté une controverse plus large sur la place des algorithmes dans la justice : loin d'être neutres, ils reflètent et parfois renforcent les inégalités sociales préexistantes. La justice prédictive illustre ainsi les tensions entre l'ambition d'objectiver les décisions judiciaires et le risque de figer des biais historiques dans des modèles opaques. Ici, le problème n'était pas seulement technique : il touchait à l'équité même de la justice. La calibration se révèle alors indissociable de la question des droits fondamentaux.

Dans le domaine assurantiel, la logique probabiliste est assumée comme telle. Comme le note Frederick Schauer (2006),

« être actuariaire, c'est être un spécialiste de la généralisation [...] Les actuaires guident les compagnies d'assurance dans la prise de décisions concernant de grandes catégories [...], mais qui peuvent ne pas être possédées par un membre particulier de la catégorie. » Schauer (2006)

Cette logique de généralisation probabiliste s'est imposée historiquement de façon contrastée. Ainsi, Horace Binney, avocat de Philadelphie, critiquait dès 1852 l'absence de tables de mortalité chez les assureurs incendie, jugeant leurs pratiques « *non scientifiques* ». Comme l'a montré Tebeau (2003), cette critique marqua un tournant : dans les décennies suivantes, les compagnies d'assurance-incendie se mirent à développer des outils statistiques et cartographiques, transformant radicalement leur rapport au risque. L'actuariat consiste donc à appliquer des régularités statistiques à des collectifs, tout en acceptant qu'elles ne valent pas pour chaque individu. En assurance, la « *calibration* » constitue quasiment une obligation légale. Un assureur qui affirme qu'un profil de conducteur a 5 % de risques d'accident doit démontrer que, sur un large portefeuille comparable, environ cinq sur cent ont effectivement eu un accident. Cette exigence est inscrite dans les réglementations prudentielles comme Solvabilité II en Europe. La calibration n'est donc pas une option méthodologique : elle conditionne la validité actuarielle et la conformité réglementaire, rejoignant les débats contemporains sur la transparence algorithmique. Le Règlement général sur la protection des données (RGPD) en Europe a introduit ce que certains ont appelé un « *droit à l'explication* » des décisions automatisées : les individus devraient pouvoir comprendre, au moins dans leurs grandes lignes, la logique des algorithmes qui les concernent. Même si ce droit reste juridiquement limité et interprété de manière diverse, il illustre une exigence croissante de rendre les modèles prédictifs non seulement performants, mais également intelligibles et contestables. La transparence devient ainsi un enjeu démocratique autant que technique, conditionnant la légitimité de l'usage des scores dans la santé, la justice ou l'assurance.

Au-delà des considérations techniques, la question de la légitimité sociale des prédictions algorithmiques renvoie à un débat plus large sur la transparence et l'explicabilité. Le Règlement général sur la protection des données (RGPD) a introduit ce que certains ont interprété comme un « *droit à l'explication* » des décisions automatisées. Comme l'ont montré Edwards et Veale (2017), ce droit est en réalité limité et ambigu : il ne garantit pas un accès complet au fonctionnement interne des modèles, mais impose aux organisations de fournir aux individus une compréhension intelligible et contestable de la logique générale qui sous-tend les décisions. Cette tension entre transparence technique (souvent illusoire dans le cas des modèles complexes comme les réseaux neuronaux) et transparence sociale (la possibilité pour les citoyens de débattre, contester et réguler ces outils) illustre bien l'enjeu démocratique. La gouvernance algorithmique ne se joue donc pas seulement dans

l'amélioration des performances statistiques, mais dans la capacité à instaurer des mécanismes institutionnels et juridiques permettant de rendre les algorithmes responsables devant la société.

Défis contemporains : illusion d'objectivité et gouvernance démocratique

Dans le domaine du machine learning, la calibration est devenue un champ de recherche en soi. Des techniques comme le Platt scaling (1999), l'isotonic regression (Zadrozny & Elkan, 2002) ou le temperature scaling (Guo et al., 2017) visent à corriger la tendance des algorithmes modernes à produire des probabilités mal calibrées. Mais ces ajustements rappellent que la calibration n'est jamais automatique : elle doit être activement recherchée, vérifiée et communiquée.

Les données massives accentuent à la fois les potentialités et les risques. D'un côté, elles permettent de tester la calibration sur des millions de cas, renforçant la rigueur empirique. De l'autre, elles créent une illusion d'objectivité : un score issu d'une immense base de données peut paraître indiscutable, alors qu'il dépend toujours de choix méthodologiques (sélection des variables, qualité des données, architecture du modèle). Cette opacité accroît le risque que les utilisateurs interprètent les probabilités comme des certitudes individuelles, au lieu d'y voir des tendances collectives conditionnelles.

Les régulateurs ont pris la mesure de cet enjeu. L'AI Act européen (2024) impose aux assureurs une transparence accrue : il faut non seulement démontrer la performance des modèles, mais aussi leur calibration et leur équité. La Food and Drug Administration aux États-Unis exige des preuves similaires pour les outils de diagnostic médical. Au-delà de la technique, la calibration devient ainsi une question de confiance démocratique : elle détermine la manière dont les citoyens acceptent que des probabilités orientent leurs vies quotidiennes, qu'il s'agisse de soins, de justice ou de finance.

En définitive, la calibration montre que les probabilités n'ont de valeur que si elles sont confrontées au réel et interprétées correctement. Elle rappelle que les scores ne sont jamais des vérités individuelles, mais des approximations collectives, toujours fragiles et situées. Mais même un modèle parfaitement calibré pose une question essentielle : combien de temps cette validité tient-elle ? La calibration établit un lien entre prédictions et observations passées ; elle ne garantit pas que cette correspondance se maintiendra demain. Pour juger de la pertinence d'une probabilité, il faut donc intégrer la dimension temporelle : une prévision n'est jamais valable sans préciser son horizon. C'est à cette question que nous devons maintenant nous tourner.

Temporalité de la prévision : horizon et justesse

La qualité d'une prévision ne se mesure pas seulement à sa précision statistique, mais aussi à l'horizon de temps auquel elle s'applique. Une anticipation peut être très exacte à court terme et perdre toute pertinence au-delà de quelques jours ; inversement, elle peut être robuste sur plusieurs décennies tout en étant muette sur les événements singuliers. Les données massives, en multipliant les sources et les fréquences d'observation, accentuent ce contraste : elles renforcent la prévisibilité à très court terme mais ne résolvent pas les incertitudes structurelles des horizons longs.

Prévoir l'immédiat : granularité, réactivité et nowcasting

À court terme, la multiplication des capteurs et la puissance des algorithmes permettent d'atteindre des performances prédictives impressionnantes. En météorologie, l'assimilation en temps réel des

données satellites et radars, couplée aux équations de Navier–Stokes, offre des prévisions fiables à 24 ou 48 heures (Lorenz, 1963 ; Kalnay, 2003). En médecine, les données issues de capteurs connectés (rythme cardiaque, sommeil, mobilité, etc.) permettent de détecter des crises imminentes, par exemple en cardiologie ou en psychiatrie. Les marchés financiers offrent aussi un exemple intéressant d’articulation entre imprévisibilité individuelle et régularité globale. Rama Cont (2001) a montré que, malgré la volatilité extrême des comportements d’investisseurs, certaines « *propriétés stylisées* » se retrouvent systématiquement : distributions de rendements à queues épaisses, volatilité persistante, corrélations en grappes. Ces régularités statistiques émergent du chaos des décisions individuelles, confirmant que l’incertitude microéconomique ne contredit pas, mais alimente l’existence de motifs macro-structurels exploitables par la modélisation.

Cette logique de prévision immédiate est aujourd’hui désignée sous le terme de « *nowcasting* ». Dans la météorologie, il s’agit d’anticiper les conditions atmosphériques des prochaines heures grâce à l’assimilation rapide de données radar et satellites. En économie, le nowcasting exploite des flux massifs et continus (recherches Google, données de cartes bancaires, informations de mobilité, etc.) pour estimer en temps quasi réel la croissance du PIB ou l’évolution du chômage, avant même la publication officielle des statistiques. En épidémiologie, il permet d’évaluer immédiatement le nombre de cas lors d’une épidémie à partir de données numériques, comme cela a été le cas pour la grippe ou la Covid-19.

Les modèles de nowcasting transforment l’action en permettant des interventions rapides et ciblées. Des études récentes montrent, par exemple, que l’analyse des recherches Google associées à la détresse peut suivre l’évolution hebdomadaire des suicides d’enfants au Japon (Matsubayashi et al., 2022), tandis que les données de smartphones peuvent prédire une tentative de suicide à une semaine avec une AUC de 0,84 (Yoshino et al., 2021). La granularité extrême des big data est ici un atout décisif : elle permet de saisir des signaux faibles immédiatement exploitables. Mais cette précision se paie d’une forte dépendance au contexte : la validité des modèles décroît rapidement dès que l’on s’éloigne de l’instant observé.

Le moyen terme : la temporalité de l’assurance

Un deuxième niveau de prévision, crucial pour de nombreux secteurs, concerne le moyen terme, sur quelques mois à quelques années. Dans l’assurance, l’horizon d’un an est déterminé par la durée contractuelle : l’assureur doit estimer la sinistralité à venir pour fixer la prime et satisfaire aux exigences prudentielles (Charpentier, 2020). Qui plus est, cet horizon d’un an est aussi imposé par les réglementations prudentielles, comme Solvabilité II en Europe. Cette directive oblige les assureurs à démontrer, chaque année, leur capacité à couvrir les sinistres prévisibles sur douze mois. Autrement dit, la temporalité de la prévision est institutionnalisée : la science actuarielle ne cherche pas seulement à anticiper l’avenir, elle doit prouver sa robustesse dans un cadre de gouvernance réglementaire qui fixe l’horizon de validité des modèles.

Ici, les modèles s’appuient moins sur des flux en temps réel que sur des variables dites « *lentes* » : historique de sinistres, état de santé, caractéristiques socio-démographiques, exposition géographique (Benjamin & Pollard, 1980). Cette temporalité médiane contraste avec celle des géants du numérique, spécialisés dans l’ultra-court terme. Alors que Google ou Meta détectent des changements d’humeur en temps réel grâce aux traces numériques, les actuaires cherchent des prédicteurs structurels capables de tenir sur douze mois. Ainsi, dans le cas du suicide, les recherches en ligne permettent d’anticiper une tentative imminente, mais la prévision annuelle repose sur des facteurs stables : chômage, isolement social, précarité financière, troubles psychiatriques chroniques

(Qin et al., 2003 ; WHO, 2014). Les deux approches ne s'opposent pas, elles se complètent : l'assurance gère un risque structurel, tandis que les plateformes numériques détectent un danger imminent.

Les horizons longs : tendances structurelles et incertitude irréductible

À long terme, la prévision s'éloigne de l'événement singulier pour se concentrer sur des tendances structurelles. Le climat en fournit un exemple paradigmatique : les modèles du GIEC (IPCC) projettent, sur plusieurs décennies, l'évolution des températures globales ou de la fréquence des événements extrêmes (IPCC, 2021). Ces prévisions ne disent rien de la météo d'un jour donné, mais elles sont indispensables pour guider les politiques publiques et les instruments financiers tels que les assurances climatiques (Surminski & Oramas-Dorta, 2014). La démographie fonctionne sur une logique similaire : la natalité et la mortalité sont relativement stables à grande échelle, ce qui permet des projections à vingt ou cinquante ans (Lee & Tuljapurkar, 1994).

Ces prévisions de long terme reposent sur des données longitudinales et des tendances inertielles. Les données massives apportent ici une valeur ajoutée en affinant les paramètres et en améliorant la granularité, mais elles ne suppriment pas l'incertitude. Le futur reste soumis à des ruptures imprévisibles : crises sanitaires, bouleversements politiques, innovations technologiques. Autrement dit, plus l'horizon s'éloigne, plus la prévision doit être interprétée comme une fourchette de scénarios plutôt qu'une projection déterministe.

Enfin, à long terme, il faut distinguer deux registres de prévision. Le premier est scientifique : le climat ou la démographie reposent sur des régularités structurelles qui autorisent des projections robustes à plusieurs décennies. Le second est politique et économique : anticiper l'évolution des marchés financiers, de la stabilité géopolitique ou des innovations technologiques relève d'un horizon incertain, traversé par des ruptures non linéaires. Là où le GIEC peut produire des scénarios probabilisés pour 2100, les institutions économiques ou les gouvernements doivent souvent se contenter de scénarios conditionnels plus fragiles. Cette distinction rappelle que toutes les prévisions de long terme n'ont pas la même valeur : certaines s'appuient sur des invariants physiques, d'autres sur des comportements humains profondément contingents

Temporalités multiples et gouvernance de l'incertitude

Ces trois horizons (court, moyen et long terme) ne sont pas interchangeables. Ils mobilisent des données différentes, répondent à des objectifs distincts et sont encadrés par des régulations spécifiques. L'assurance en offre une illustration claire : le contrat annuel impose une prévision d'un an, quelle que soit la qualité des données de court terme. Les régulateurs imposent en outre des modèles explicables et auditables (GLM, arbres de décision), là où les plateformes numériques peuvent recourir à des modèles opaques pour la publicité ciblée (OECD, 2017).

Cette diversité des temporalités invite à une gouvernance plus nuancée de l'incertitude. Les big data permettent de rapprocher ces horizons : utiliser le temps réel pour déclencher des interventions rapides, sans renoncer aux modèles structurels qui assurent la stabilité collective à moyen et long terme. L'articulation des temporalités devient alors la véritable innovation : savoir quand privilégier la granularité immédiate et quand se reposer sur la robustesse des tendances.

En définitive, la temporalité de la prévision rappelle que l'incertitude ne disparaît jamais, mais change de visage selon l'horizon choisi. À court terme, elle se réduit fortement grâce à la densité des

données, mais cette prévisibilité est éphémère. À long terme, elle reste irréductible, même si les tendances collectives offrent une certaine stabilité. Les données massives ne bouleversent pas cette structure : elles permettent surtout d'articuler les échelles temporelles, rapprochant le court et le long terme et rendant l'incertitude plus gouvernable.

Conclusion

Les données massives n'abolissent pas le paradoxe fondateur des sciences sociales : l'imprévisibilité individuelle coexiste avec la stabilité collective. Au contraire, elles lui donnent une visibilité et une portée inédites. De Quetelet à Durkheim, puis des modèles multi-agents aux réseaux sociaux contemporains, on retrouve la même logique : l'agrégation de comportements incertains engendre des régularités robustes.

L'apport des big data est d'abord empirique : ils confirment et affinent ces régularités, que ce soit dans la mobilité, la finance ou la diffusion d'idées. Mais il est aussi conceptuel : en réactivant la tension entre fréquentisme et bayésianisme, en rendant décisive la question de la calibration, et en plaçant au premier plan la temporalité des prévisions. À court terme, le nowcasting illustre la puissance d'une granularité extrême ; à moyen terme, l'assurance rappelle que la prévision est aussi une institution réglementée ; à long terme, le climat et la démographie rappellent les limites irréductibles de l'anticipation.

Ces avancées ne sont pas neutres. Elles engagent des enjeux éthiques et politiques : justice prédictive et biais algorithmiques (Angwin et al., 2016), transparence et « droit à l'explication » (RGPD), fairness et légitimité sociale des décisions. La gouvernance de l'incertitude repose désormais autant sur la qualité technique des modèles que sur la capacité démocratique à débattre de leurs usages.

En définitive, les données massives « changent la donne » dans un sens précis : elles amplifient nos certitudes collectives, sans jamais supprimer les incertitudes individuelles. Elles ouvrent la possibilité d'une gouvernance plus fine de l'incertitude, mais cette possibilité n'est féconde que si elle s'accompagne d'une vigilance critique, articulant robustesse statistique, respect des trajectoires singulières et exigence démocratique de transparence.

Références

- Angwin, J., Larson, J., Mattu, S., & Kirchner, L. (2016). Machine bias. *ProPublica*.
- Arthur, W. B. (1994). Bounded rationality and inductive behavior in the El Farol problem. *American Economic Review*, 84(2), 406–411.
- Baecke, P., & Bocca, L. (2017). The value of vehicle telematics data in insurance risk selection. *Decision Support Systems*, 98, 69–79.
- Barabási, A.-L., & Albert, R. (1999). Emergence of scaling in random networks. *Science*, 286(5439), 509–512.
- Barocas, S., Hardt, M., & Narayanan, A. (2019). *Fairness and machine learning*. MIT Press.
- Benjamin, B., & Pollard, J. H. (1980). *The analysis of mortality and other actuarial statistics*. Heinemann.
- Bourdieu, P. (1979). *La distinction. Critique sociale du jugement*. Paris : Éditions de Minuit.
- Bourdieu, P. (2012). *Sur l'État. Cours au Collège de France (1989-1992)*. Paris : Seuil.
- Charpentier, A. (2020). *Assurance et Big Data*. ENSAE-CREST.
- Coleman, J. S. (1986). *Individual interests and collective action*. Cambridge University Press.
- Coleman, J. S. (1990). *Foundations of social theory*. Harvard University Press.
- Cont, R. (2001). Empirical properties of asset returns: Stylized facts and statistical issues. *Quantitative Finance*, 1(2), 223–236.
- Daston, L. (2021). *Rules: A Short History of What We Live By*. Princeton University Press.
- de Finetti, B. (1974). *Theory of probability* (Vol. 1). Wiley. (Original work published 1937).
- Durkheim, É. (1895). *Les règles de la méthode sociologique*. Félix Alcan
- Durkheim, É. (1897). *Le suicide: Étude de sociologie*. Félix Alcan.
- Dwork, C., Hardt, M., Pitassi, T., Reingold, O., & Zemel, R. (2012). Fairness through awareness. In *Proceedings of the 3rd Innovations in Theoretical Computer Science Conference* (pp. 214–226).
- Eagle, N., Pentland, A. (S.), & Lazer, D. (2009). Inferring friendship network structure by using mobile phone data. *Proceedings of the National Academy of Sciences*, 106(36), 15274–15278.
- Edwards, L., & Veale, M. (2017). Slave to the algorithm? Why a right to an explanation is probably not the remedy you are looking for. *Duke Law & Technology Review*, 16(1), 18–84.
- European Union. (2024). *Artificial Intelligence Act*. Official Journal of the European Union.

- Fenton, N., & Neil, M. (2018). *Risk Assessment and Decision Analysis with Bayesian Networks* (2nd ed.). CRC Press.
- Fisher, R. A. (1956). *Statistical methods and scientific inference*. Oliver & Boyd.
- Foucault, M. (2004). *Sécurité, territoire, population. Cours au Collège de France (1977-1978)*. Paris : Gallimard/Seuil.
- Frees, E. W., Derrig, R. A., & Meyers, G. (2014). *Predictive modeling applications in actuarial science*. Cambridge University Press.
- Galton, F. (1886). Regression towards mediocrity in hereditary stature. *Journal of the Anthropological Institute of Great Britain and Ireland*, 15, 246–263.
- Galton, F. (1907). *Vox Populi*. *Nature*, 75, 450–451.
- Gigerenzer, G., Todd, P. M., & the ABC Research Group. (1999). *Simple heuristics that make us smart*. Oxford University Press.
- Guo, C., Pleiss, G., Sun, Y., & Weinberger, K. Q. (2017). On calibration of modern neural networks. In *Proceedings of the 34th International Conference on Machine Learning* (pp. 1321–1330).
- Hacking, I. (1975). *The emergence of probability*. Cambridge University Press.
- Helbing, D. (2012). *Social self-organization: Agent-based simulations and experiments to study emergent social behavior*. Springer.
- Intergovernmental Panel on Climate Change (IPCC). (2021). *Sixth assessment report*. Cambridge University Press.
- Jordan, M. I. (2019). Artificial intelligence—The revolution hasn't happened yet. *Harvard Data Science Review*, 1(1).
- Kahneman, D., & Tversky, A. (1974). Judgment under uncertainty: Heuristics and biases. *Science*, 185(4157), 1124–1131.
- Kalnay, E. (2003). *Atmospheric modeling, data assimilation and predictability*. Cambridge University Press.
- Gnedenko, B. V., & Kolmogorov, A. N. (1968). *Limit distributions for sums of independent random variables*. Addison-wesley.
- Lee, R. D., & Tuljapurkar, S. (1994). Stochastic population forecasts for the United States: Beyond high, medium, and low. *Population and Development Review*, 20(4), 701–735.
- Lorenz, E. N. (1963). Deterministic nonperiodic flow. *Journal of the Atmospheric Sciences*, 20(2), 130–141.
- March, J. G., & Simon, H. A. (1958). *Organizations*. Wiley.

- Matsubayashi, T., Sekijima, K., Ueda, M., & Yoshikawa, S. (2022). Internet search behaviors and suicide in Japan: An analysis of Google search data. *JMIR Public Health and Surveillance*, 8(3), e27918.
- Neyman, J. (1937). Outline of a theory of statistical estimation based on the classical theory of probability. *Philosophical Transactions of the Royal Society of London. Series A, Mathematical and Physical Sciences*, 236(767), 333–380.
- Niculescu-Mizil, A., & Caruana, R. (2005). Predicting good probabilities with supervised learning. In *Proceedings of the 22nd International Conference on Machine Learning* (pp. 625–632).
- Organisation for Economic Co-operation and Development (OECD). (2017). *Technology and innovation in the insurance sector*. OECD Publishing.
- Pentland, A. (2014). *Social physics: How good ideas spread—The lessons from a new science*. Penguin.
- Platt, J. (1999). Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In A. J. Smola, P. Bartlett, B. Schölkopf, & D. Schuurmans (Eds.), *Advances in large margin classifiers* (pp. 61–74). MIT Press.
- Qin, P., Agerbo, E., & Mortensen, P. B. (2003). Suicide risk in relation to socioeconomic, demographic, psychiatric, and familial factors: A national register-based study of all suicides in Denmark, 1981–1997. *American Journal of Epidemiology*, 157(9), 762–770.
- Quetelet, A. (1835). *Sur l'homme et le développement de ses facultés*. Bachelier.
- Reichenbach, H. (1971). *The Theory of Probability: An Inquiry into the Logical and Mathematical Foundations of the Calculus of Probability*. University of California Press.
- Savage, L. J. (1954). *The foundations of statistics*. Wiley.
- Schauer, F. (2006). *Profiles, Probabilities, and Stereotypes*. Harvard University Press
- Schelling, T. C. (1978). *Micromotives and macrobehavior*. Norton.
- Simon, H. A. (1947). *Administrative behavior* (4th ed.). Macmillan.
- Simon, H. A. (1955). A behavioral model of rational choice. *Quarterly Journal of Economics*, 69(1), 99–118.
- Simon, H. A. (1976). From substantive to procedural rationality. In S. J. Latsis (Ed.), *Method and appraisal in economics* (pp. 129–148). Cambridge University Press.
- Surminski, S., & Oramas-Dorta, D. (2014). Flood insurance schemes and climate adaptation in developing countries. *Climate Policy*, 14(5), 664–682.
- Tebeau, M. (2003). *Eating Smoke: Fire in Urban America, 1800–1950*. Johns Hopkins University Press.
- von Mises, R. (1928). *Probability, statistics and truth*. Macmillan.

Weber, M. (1922). *Économie et société*. Mohr.

World Health Organization (WHO). (2014). *Preventing suicide: A global imperative*. WHO Press.

Yoshino, A., Kawashima, T., Kobayashi, T., & Nomura, S. (2021). Predicting suicidal ideation from smartphone-based behavioral data: A machine learning approach. *JMIR Mental Health*, 8(5), e27918.

Zadrozny, B., & Elkan, C. (2002). Transforming classifier scores into accurate multiclass probability estimates. In *Proceedings of the Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 694–699).