

Décryptage

# La propriété intellectuelle à l'heure de l'intelligence artificielle générative

Juin 2024

## Résumé exécutif

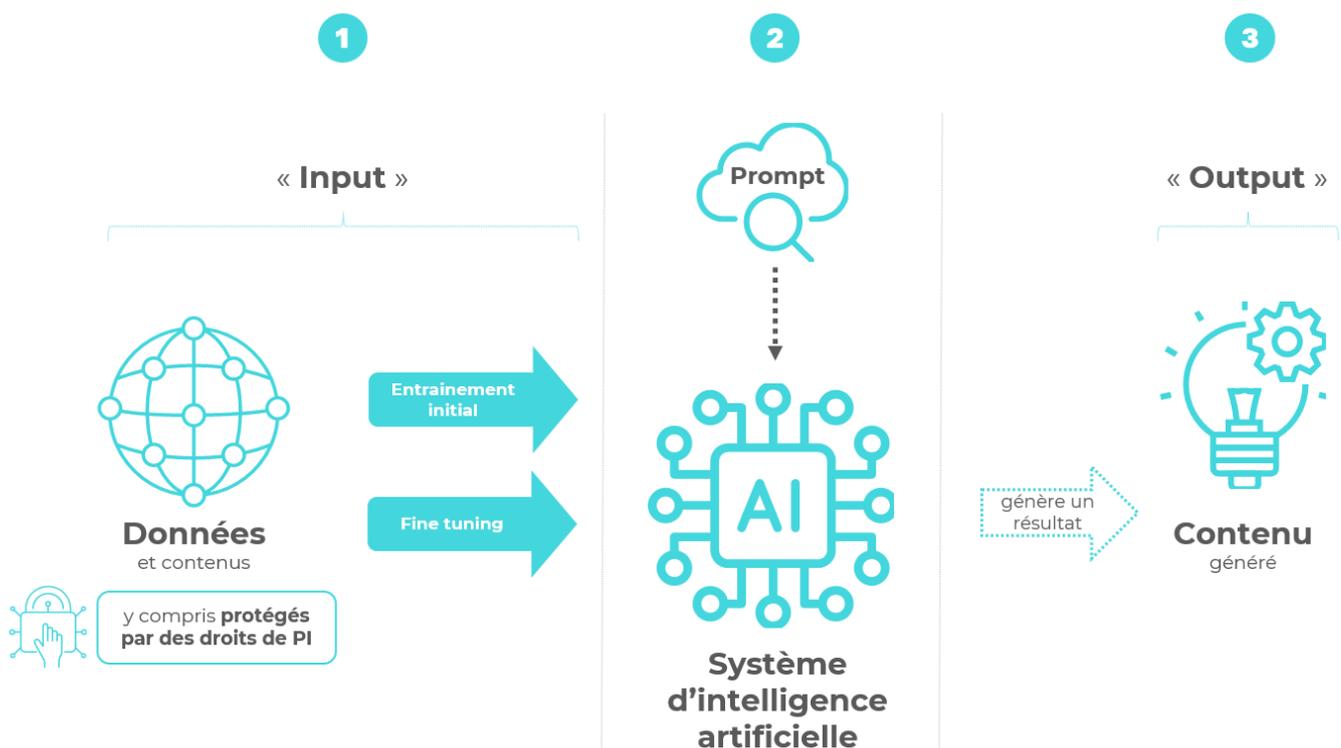
- 1 L'**effectivité des droits de propriété intellectuelle** est une garantie de la protection de la création et un pilier de notre modèle culturel.
- 2 L'émergence de l'IA générative soulève la question de l'**utilisation pour l'entraînement de l'IA de contenus protégés** au titre de la propriété intellectuelle.
- 3 L'exception au droit d'auteur pour fouille de textes et de données, créée par la directive DAMUN, permet une telle utilisation de contenus protégés, tout en octroyant un droit d'opposition (« **opt-out** ») au titulaire du droits.
- 4 De nombreux débats ont émergé sur l'effectivité de cet *opt-out* : le nouveau règlement européen sur l'IA (*AI Act*) renforce ce dispositif en créant un **nouveau régime de transparence** sur les contenus utilisés à des fins d'entraînement. L'Europe s'est ainsi dotée d'un corpus réglementaire robuste pour appréhender cette évolution technologique.
- 5 Nombre des inquiétudes qui demeurent aujourd'hui sur l'*opt-out* seront davantage résolues par des travaux d'ordre technique que par le levier réglementaire : la France et l'Europe doivent être pionnières dans l'**élaboration des standards internationaux** qui feront demain office de normes.
- 6 Au-delà du champ réglementaire, se pose la question du volume de données disponible en Europe pour l'entraînement des modèles d'IA : cela entraîne des conséquences importantes, tant sur la **capacité de nos startups de l'IA à développer de nouveaux modèles** que sur la **diversité linguistique et culturelle de l'IA**.

## Introduction

L'essor de l'intelligence artificielle générative et l'émergence dans le monde de modèles de fondation entraînés grâce à l'apprentissage auto-supervisé (*self-supervised learning*) sur des volumes de plus en plus vastes de données place les interactions entre intelligence artificielle et propriété intellectuelle au centre du débat. L'utilisation à des fins d'entraînement de contenus (textes, images, sons, etc.) protégés par le droit de la propriété intellectuelle (le droit d'auteur notamment) soulève la question de l'adéquation des protections dont disposent les titulaires des droits sur ces contenus.

Les enjeux sont considérables, tant pour nos capacités d'innovation et notre maîtrise de l'intelligence artificielle que pour la pérennité de notre modèle culturel : il est par conséquent impératif de concilier la préservation de la création avec le développement sur le sol européen de modèles de fondation riches et performants.

## IA et contenus protégés : quelles interactions ?



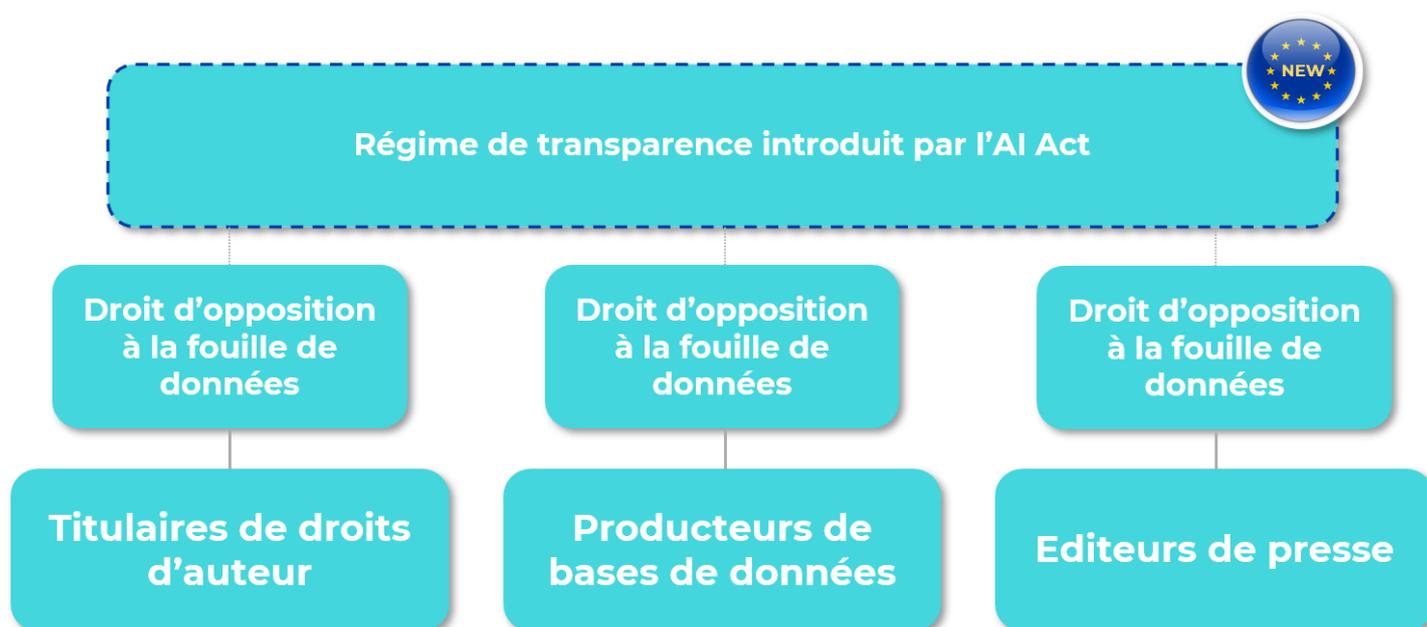
Pour être performant, un modèle d'IA générative nécessite d'être entraîné à partir d'importants jeux de données et de contenus préexistants. Ces données et contenus peuvent faire l'objet d'une protection au titre de la propriété intellectuelle, par exemple par le **droit d'auteur** ou le **droit des producteurs de bases de données**.

L'utilisation de ces contenus (« **input** ») peut intervenir via plusieurs procédés techniques, que ce soit par extraction de données (*data scraping*) ou par fouille de textes et de données (*text and data mining*), et à différents stades, lors de l'entraînement initial du modèle ou lors de phases ultérieures, notamment lors du *fine-tuning* (« réglage fin », optimisation d'un modèle en le réentraînant sur des données spécifiques pour ajuster ses paramètres et ses performances).

Lorsqu'une requête (*prompt*) est saisie par l'utilisateur, le modèle d'IA génère un résultat à partir de l'apprentissage réalisé, communément nommé « **output** ».

Si la distinction entre *input* et *output* présente des avantages sur le plan théorique, cette distinction n'est pas totalement hermétique : par exemple, le *prompt*, par l'information qu'il comprend, pourrait aussi être considéré à certains égards comme relevant de l'*input*.

## Quelles protections pour les titulaires de droits de propriété intellectuelle ?

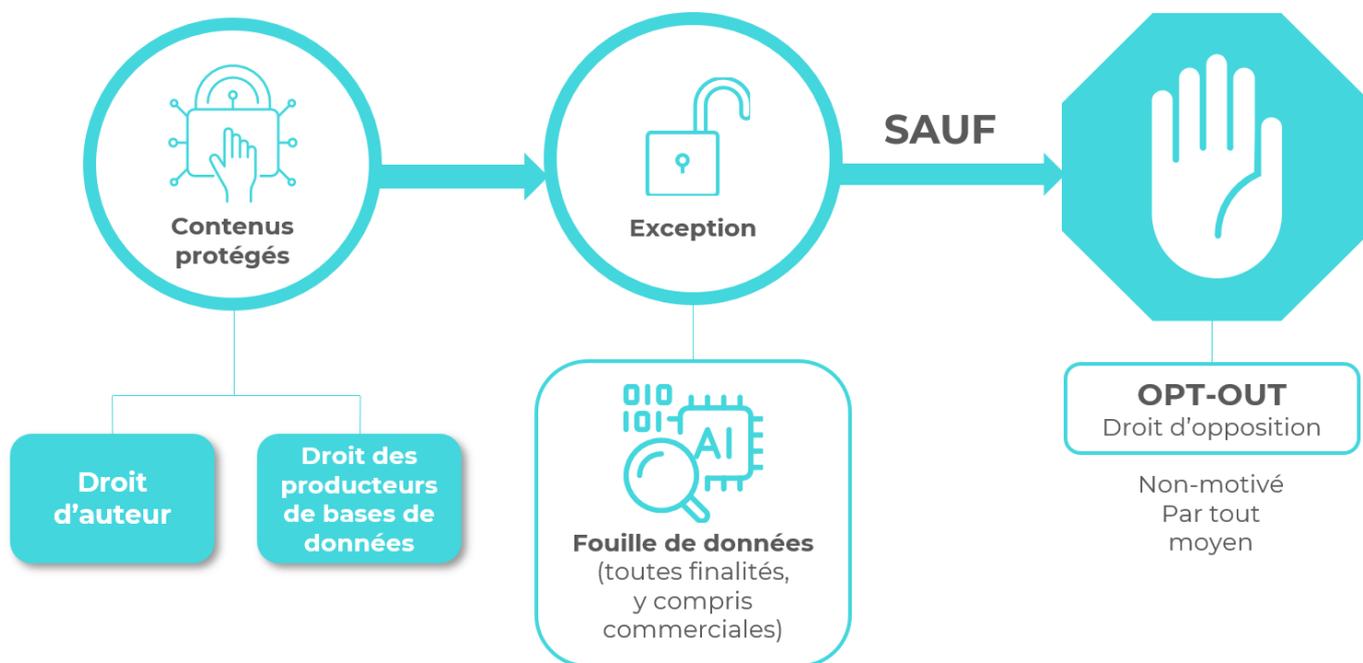


Le droit prévoit plusieurs dispositifs permettant aux titulaires de droits de propriété intellectuelle de protéger leurs contenus. Ce droit a été profondément remanié au niveau européen en 2019 par la directive sur le droit d'auteur et les droits voisins dans le marché unique (dite « **directive DAMUN** ») pour adapter le droit aux évolutions technologiques, notamment en créant la qualification de « **fouille de texte et de données** ». La fouille de données, définie comme « toute technique d'analyse automatisée visant à analyser des textes et des données sous une forme numérique afin d'en dégager des informations, ce qui comprend, à titre non exhaustif, des constantes, des tendances et des corrélations », permet d'apprécier juridiquement l'utilisation de contenus à des fins d'apprentissage.

La directive a introduit une **exception au droit d'auteur** (ainsi qu'au droit des producteurs de bases de données et au droit voisin des éditeurs de presse) **pour autoriser la fouille de texte et de données**, dans des conditions propres à deux cas de figure :

- à des fins de recherche scientifique, par une liste limitative de personnes (organismes de recherche, bibliothèques, etc.) et sans autorisation des titulaires de droits. Cette exception n'est pas applicable si une entreprise associée à l'organisme effectuant la fouille dispose d'un accès privilégié aux résultats de la fouille.
- quelle que soit la finalité (y compris commerciale), si l'accès au contenu est fait de manière licite. Dans ce cas, le titulaire du droit d'auteur (ou le producteur de base de données) dispose d'un **droit d'opposition** concernant cette exception et peut ainsi refuser que ses contenus protégés fassent l'objet d'une fouille et soient utilisés à des fins d'apprentissage. Ce droit d'opposition des titulaires de droit est communément appelé « **opt-out** ».

## L'opt-out au centre du débat



La forte accélération des usages de l'IA générative à partir de 2023 a généré d'importants débats sur l'adéquation par rapport aux évolutions technologiques de ce dispositif, transposé en droit français en 2021 mais auparavant peu utilisé dans la pratique.

Deux principaux points d'attention dominent actuellement le débat public :

- *Comment manifester son droit d'opposition de manière certaine et s'assurer de sa prise en compte par les acteurs procédant à de la fouille de textes et de données ?*
- *Comment savoir qu'un contenu protégé par des droits de PI est utilisé à des fins d'apprentissage de systèmes d'IA pour être en mesure d'exercer son droit d'opposition ?*

Ces deux interrogations soulèvent ainsi deux thématiques : (i) les **modalités d'exercice et de publicité de l'opt-out** et (ii) la **transparence** vis-à-vis des contenus utilisés à des fins d'apprentissage.

## Quelles modalités d'exercice de l'opt-out ?

La directive DAMUN prévoit que l'opt-out doit être exercé « *de manière appropriée, notamment **par des procédés lisibles par machine*** ».

En droit français, le décret 2022-928 du 23 juin 2022 précisent les modalités d'exercice de l'opt-out :

- L'opposition du titulaire de droit n'a **pas à être motivée**.
- L'opposition du titulaire de droit peut être exprimée **par tout moyen**. Pour les contenus mis à la disposition du public en ligne, l'opposition peut notamment être exprimée au moyen de procédés lisibles par machine, y compris des métadonnées, et par le recours à des conditions générales d'utilisation d'un site internet ou d'un service.

Le titulaire de droit dispose ainsi d'une **importante latitude** pour manifester son opposition à ce que de la fouille de textes et de données soit réalisée sur ses contenus.

Au-delà de l'aspect juridique, l'enjeu est de s'assurer que cette manifestation de l'opt-out est en pratique bien portée à la connaissance des acteurs de l'IA. Le **protocole d'exclusion des robots** (« **robots.txt** »), fichier texte placé à la racine d'un site web, permet d'indiquer aux outils de recherche robotisés les zones d'un site à ne pas explorer : il s'agit d'une première brique, simple, effective et reconnue permettant de manifester son droit d'opposition.

En pratique en France, les principaux organismes de gestion collective communiquent largement depuis 2023 sur l'exercice de leur droit d'opposition, que ce soit publiquement (conditions générales d'utilisation, communiqués de presse, etc.) ou par l'envoi de courriers d'information adressés à la plupart des acteurs technologiques.

Néanmoins, l'effectivité du droit d'opposition ne doit laisser place à aucun doute : un effort collectif doit être réalisé pour **élaborer des standards techniques communs**, qui

feront office de **normes reconnues par tous** en matière d'exercice du droit d'opposition. Des progrès ont été réalisés récemment sur ce point, par exemple avec le TDM Reservation Protocol (développé par le World Wide Web Consortium) ou les outils Do Not Train (développés par Spawning.ai) : ces outils techniques prévoient un protocole web capable d'exprimer la réserve des droits de propriété intellectuelle vis-à-vis de la fouille de textes et de données. Ils peuvent s'apparenter à un « *procédé lisible par machine* » (tel que prévu par le décret du 23 juin 2022). Le TDM Reservation Protocol est ainsi qualifié par le Syndicat national de l'Édition (SNE) de « *une réponse technique efficace* ».

→ L'enjeu principal est d'aboutir à l'avenir à des **standards harmonisés** faisant consensus à l'échelle internationale pour **garantir un droit d'opposition simple et effectif** pour tout titulaire de droit de propriété intellectuelle, quelle que soit sa taille, sa nationalité ou le type d'œuvre concerné.

## Transparence vis-à-vis des contenus utilisés

La nécessité pour un titulaire de droits de propriété intellectuelle de déterminer si son contenu fait l'objet d'une fouille de textes et de données a placé le sujet de la transparence sur les jeux de données utilisés à des fins d'apprentissage au cœur des négociations du règlement européen sur l'IA (AI Act). Pour répondre à cette difficulté, l'AI Act comprend dans sa version finalisée un **nouveau régime de transparence pour les modèles d'IA à usage général**.

Ce nouveau régime de transparence, inédit dans le monde, constitue un nouveau « bloc » réglementaire pour garantir l'effectivité du droit d'opposition, en offrant aux titulaires de droits de propriété intellectuelle une plus grande visibilité sur l'utilisation de leurs œuvres à des fins d'apprentissage de l'IA. Conformément à l'AI Act, le futur bureau européen de l'intelligence artificielle devra élaborer la typologie des informations à publier par les fournisseurs de modèles d'IA.



## FOCUS



## Transparence des jeux de données utilisés :

### que prévoit l'AI Act ?

Les fournisseurs de modèles d'IA à usage général devront mettre à la disposition du public un **résumé suffisamment détaillé des contenus utilisés pour l'entraînement** du modèle, selon un formulaire (*template*) élaboré par le futur bureau européen de l'IA.

Ce résumé devra avoir être généralement complet en termes de contenu plutôt que détaillé sur le plan technique afin de permettre aux titulaires de droit d'exercer et de faire respecter leurs droits, par exemple :

- ✓ en énumérant les **principales collections ou séries de données qui ont servi à l'entraînement** du modèle, telles que les **grandes bases de données privées ou publiques** ou les **archives de données** ;
- ✓ en fournissant une **explication narrative** sur les **autres sources** de données utilisées.

→ L'AI Act prévoit que le futur bureau européen de l'intelligence artificielle devra élaborer le formulaire (*template*) et la typologie des informations à publier par les acteurs de l'IA. Il est nécessaire que ces exigences soient équilibrées : à la fois (i) **techniquement faisables**, (ii) à la portée des fournisseurs de modèles d'IA à usage général **sans leur faire supporter une charge excessive**, (iii) compatibles avec la **protection des secrets d'affaires et des informations commerciales confidentielles** [condition prescrite par le considérant 107 de l'AI Act] et (iv) permettant aux titulaires de droits de propriété intellectuelle de disposer d'**informations suffisantes pour exercer leur droit d'opposition**.

→ Un **dialogue approfondi** associant les professionnels de l'IA et les organisations de gestion collective sera nécessaire pour remplir ces objectifs.

→ Le régime de transparence sur les jeux de données utilisés prévu par l'AI Act permet de renforcer l'effectivité du droit d'opposition introduit par la directive DAMUN. Ces deux dispositifs sont à même de constituer un **corpus juridique robuste** pour (i) **garantir aux titulaires de droit l'effectivité** de leur droit d'opposition, (ii) **sans pour autant freiner le développement de modèles d'IA** générative en Europe.

→ En tout état de cause, chaque titulaire de droit de propriété intellectuelle dispose d'un **accès au juge** en cas d'usage illicite ou inapproprié de leurs œuvres. Par ailleurs, la directive DAMUN et le code de la propriété intellectuelle soumettent l'exception pour fouille de textes et de données au « **triple-test** » en cas d'atteinte à l'exploitation normale de l'œuvre de l'auteur ou de préjudice injustifié à ses intérêts légitimes.

Néanmoins, des interrogations peuvent demeurer quant au caractère opérationnel et effectif de l'opt-out, par exemple :

- *Comment s'assurer du respect en toutes circonstances du droit d'opposition ? Existera-t-il à moyen terme des procédés techniques permettant de « vérifier » si des contenus protégés sont utilisés à des fins d'apprentissage en dépit de l'exercice de l'opt-out ?*
- *Comment rendre publiques « en temps réel » les mises à jour des catalogues d'œuvres et de contenus pour lesquels le droit d'opposition a été exercé ?*

Ces interrogations sont importantes pour garantir l'effectivité des droits consacrés dans la directive DAMUN : **elles seront davantage résolues par des travaux d'ordre technique que par de nouvelles modifications réglementaires**. La France et l'Europe doivent être à **l'avant-garde dans l'élaboration de tels procédés techniques** afin d'être moteur dans l'émergence de futurs standards et pratiques qui constitueront demain la norme au niveau international.

## Au-delà du réglementaire, des enjeux majeurs pour l'innovation et la culture

Il est indispensable que le cadre européen et français soit protecteur de la création tout en permettant de conserver un environnement attractif et propice au développement de l'intelligence artificielle en Europe. Au-delà des aspects réglementaires présentés précédemment, ce débat comporte des enjeux sociétaux et économiques importants, tant pour nos capacités d'innovation que pour la vivacité de nos modèles culturels.

L'exercice croissant de l'opt-out en Europe pourrait à terme conduire à un « **assèchement** » du contenu disponible en France et en Europe pour l'entraînement des modèles d'intelligence artificielle. Cela pourrait comporter des conséquences directes sur l'écosystème européen de l'IA :

- L'exercice de l'opt-out peut amplifier la **constitution d'un « marché » de la licence d'utilisation des contenus protégés**, les licences étant conclues entre titulaires de droit et fournisseurs de modèles de fondation. Ce mouvement de contractualisation est parfaitement légitime et relève de la liberté contractuelle de chaque acteur. Cette situation peut cependant interroger sur **la capacité des startups et acteurs de l'IA de plus petite taille** (aux ressources plus limitées) à agir sur ce marché et **à accéder à des contenus** pertinents et en volumes suffisants pour développer leurs propres modèles de fondation. A défaut, **notre capacité à faire émerger en Europe des « champions de l'IA » pourrait s'en trouver impactée**.
- L'hypothèse d'un « assèchement » du contenu accessible en Europe et en France **risque d'écartier les cultures et les langues européennes de l'apprentissage des principaux modèles de fondation**, vraisemblablement au bénéfice de la langue anglaise. Il est dès lors essentiel que des modèles soient développés dans d'autres langues européennes pour conserver une certaine **diversité culturelle dans l'IA**. A défaut, seuls des modèles développés en anglais puis traduits dans d'autres langues seraient disponibles sur le marché. Chaque langue disposant de ses propres schémas et modes de pensée, l'utilisation exclusive de l'anglais dans le développement des modèles de fondation pourrait constituer une difficulté pour l'utilisation de l'IA dans les domaines culturels ou éducatifs. Les initiatives des pouvoirs publics pour appréhender cette question sont à saluer : **l'appel à projets « Communs numériques pour l'IA générative »** lancé par Bpifrance, le projet **LANGU:IA** (tous deux visent notamment à valoriser le patrimoine français, francophone et européen dans l'entraînement d'IA génératives), ou encore l'outil d'IA générative **Albert**, développé par la DINUM pour améliorer le service public, démontrent que la puissance publique se place comme acteur central dans le développement de l'IA générative en français.