

# Comment auditer un système d'IA pour détecter des biais discriminatoires ?

## Réponse courte

L'audit d'un système d'IA pour détecter des biais discriminatoires repose sur une méthodologie combinant **analyse statistique**, **tests techniques** et **évaluation juridique**. L'AI Act impose aux systèmes à systèmes à haut risque un **système de gestion des risques** incluant des tests de biais avant et après le déploiement. L'employeur doit vérifier que les résultats algorithmiques ne désavantagent pas certains groupes protégés.

L'audit doit mesurer les **taux de sélection par critère protégé**, tester le système avec des **profils synthétiques** et évaluer la pertinence des variables utilisées. Les résultats doivent être documentés et conservés pour démontrer la **diligence de l'employeur** en cas de contrôle ou de contentieux devant le tribunal du travail.

## Définition

L'**audit de biais algorithmique** est un processus d'évaluation systématique visant à identifier, mesurer et corriger les distorsions discriminatoires dans les résultats produits par un système d'intelligence artificielle. Il constitue une obligation pour les systèmes classés à haut risque par l'AI Act et une bonne pratique recommandée pour tout système d'IA utilisé en RH.

Cet audit couvre trois dimensions : l'analyse des **données d'entraînement** (représentativité, qualité), l'évaluation du **modèle algorithmique** (variables, pondérations, corrélations) et le contrôle des **résultats en production** (impacts différenciés par groupe protégé).

## Questions fréquentes

### Comment auditer un système d'IA pour détecter des biais discriminatoires ?

L'audit combine analyse statistique des données, tests sur profils synthétiques et évaluation juridique. Il mesure les taux de sélection par critères protégés et calcule les métriques d'équité. L'AI Act (article 9) impose un système de gestion des risques pour les systèmes à haut risque.

### L'audit de biais peut-il être réalisé en interne uniquement ?

Un audit interne régulier est insuffisant. L'AI Act recommande de le compléter par un audit externe annuel par un tiers indépendant spécialisé. L'équipe d'audit doit associer compétences techniques (data science), juridiques et métiers RH.

### Que faut-il enregistrer dans les logs d'un système d'IA RH ?

L'AI Act (article 12) impose l'enregistrement automatique des événements pendant toute la durée d'utilisation. Ces logs doivent permettre la traçabilité des décisions, l'identification des biais détectés et la justification des mesures correctives prises.

### Quelle documentation conserver après un audit de biais IA ?

L'AI Act (article 11) impose une documentation technique complète incluant les résultats des tests de biais et les mesures correctives. Cette documentation constitue une preuve déterminante de la diligence de l'employeur en cas de contentieux ou contrôle.

### Quelle est la fréquence recommandée pour un audit de biais algorithmique ?

Un audit initial avant déploiement, des audits périodiques semestriels et un audit ponctuel en cas d'incident. Un audit externe annuel par un tiers indépendant est recommandé pour compléter les audits internes selon les standards techniques de l'AI Act.

### Quelles métriques d'équité utiliser dans un audit IA ?

Les métriques principales sont le disparate impact ratio (règle des 4/5), l'equalized odds, la demographic parity et la calibration. Ces indicateurs permettent de mesurer les écarts de traitement entre groupes protégés et de détecter les biais statistiquement significatifs.

## Conditions d'exercice

L'audit de biais est encadré par des exigences réglementaires et des standards techniques.

Exigence	Détail
AI Act - Article 9	Système de gestion des risques couvrant l'identification, l'évaluation et l'atténuation des risques de biais
AI Act - Article 10	Tests de qualité des données d'entraînement : représentativité, pertinence, absence d'erreurs
AI Act - Article 11	Documentation technique incluant les résultats des tests de biais et les mesures correctives
AI Act - Article 12	Traçabilité par enregistrement automatique des événements (logs) pendant toute la durée d'utilisation
Fréquence	Audit initial avant déploiement, audits périodiques (semestriels recommandés) et audit ponctuel en cas d'incident
Indépendance	Audit interne régulier complété par un audit externe annuel par un tiers indépendant spécialisé
Critères protégés testés	Sexe, âge, nationalité, handicap, situation familiale, origine ethnique, religion, orientation sexuelle

## Modalités pratiques

L'audit suit une méthodologie structurée en phases successives.

Phase	Détail
<b>Cadrage</b>	Définir le périmètre de l'audit, les critères protégés à tester, les métriques d'équité retenues et les seuils d'alerte
<b>Analyse des données</b>	Examiner la composition des données d'entraînement par critère protégé, identifier les sous-représentations et les corrélations problématiques
<b>Tests statistiques</b>	Mesurer les taux de sélection par groupe (disparate impact ratio), calculer les métriques d'équité (equalized odds, demographic parity, calibration)
<b>Tests synthétiques</b>	Soumettre des profils identiques ne différant que par un critère protégé et comparer les résultats (paired testing)
<b>Analyse des variables</b>	Identifier les variables proxy corrélées à des critères protégés et évaluer leur pertinence objective
<b>Rapport d'audit</b>	Documenter les résultats, les biais détectés, les recommandations et le plan d'action correctif avec un calendrier
<b>Suivi des corrections</b>	Vérifier l'efficacité des mesures correctives lors de l'audit suivant

## Pratiques et recommandations

**Définir** des seuils d'alerte quantitatifs dès le cadrage de l'audit, en utilisant la règle des 4/5 (un taux de sélection inférieur à 80 % de celui du groupe le plus favorisé constitue un indicateur de discrimination) comme point de départ.

**Associer** des compétences pluridisciplinaires à l'équipe d'audit : data scientists pour l'analyse technique, juristes pour l'évaluation de conformité et professionnels RH pour la contextualisation des résultats.

**Automatiser** le monitoring continu des métriques d'équité en production, via des tableaux de bord permettant de détecter les dérives en temps réel sans attendre l'audit périodique.

**Communiquer** les résultats d'audit à la délégation du personnel et au DPO de l'entreprise pour garantir la transparence et alimenter le dialogue social sur l'utilisation de l'IA.

## Cadre juridique

Référence	Objet
AI Act - Article 9	Système de gestion des risques pour systèmes à haut risque
AI Act - Article 10	Exigences de qualité des données d'entraînement
AI Act - Article 11	Documentation technique obligatoire
AI Act - Article 12	Traçabilité et enregistrement automatique des événements
Art. <u>L.251-1</u>	Interdiction de la discrimination dans les relations de travail
Art. <u>L.252-1</u>	Charge de la preuve partagée en matière de discrimination
RGPD - Article 35	Analyse d'impact relative à la protection des données

L'audit de biais algorithmique est une obligation légale pour les systèmes d'IA à haut risque et une bonne pratique indispensable pour tout système RH. L'absence d'audit expose l'employeur à un risque de **responsabilité aggravée** en cas de contentieux pour discrimination.

Les résultats d'audit constituent des preuves déterminantes devant le tribunal du travail pour démontrer la diligence de l'employeur ou, inversement, sa négligence.

Les contenus sont rédigés et mis à jour régulièrement à partir de sources officielles. Leur usage ne remplace pas une consultation juridique et doit être validé par un professionnel du droit.