

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE DES SCIENCES

DEPARTEMENT DE MICROBIOLOGIE & BIOCHIMIE



DOMAINE : SCINCES DE LA NATURE ET DE LA VIE

FILIERE : SCIENCE BIOLOGIQUE

OPTION : MICROBIOLOGIE APPLIQUEE

Mémoire présenté pour l'obtention

Du diplôme de Master Académique

Par :

Nasri Ilham

Hedidane Inas

Kahali Aya

Intitulé :

**L'intelligence artificielle en microbiologie
Alimentaire**

Soutenu devant le jury composé de :

Dr. **Rahali Abdallah** Université Mohamed Boudiaf M'sila

Président

Dr. **Geutouache Mourad**

Université Mohamed Boudiaf M'sila

Rapporteur

Dr. **Ariech Mounira** Université Mohamed Boudiaf M'sila

Examineur

Année universitaire : 2024 /2025

Dédicace

« Et leur dernière invocation sera : Louange à Dieu, Seigneur de l'univers. »

J'offre ma réussite à mon âme ambitieuse qui ne m'a jamais déçue.

*"À celle qui a le paradis sous ses pieds, celle qui a rendu les épreuves plus faciles par ses prières, à cette femme exceptionnelle qui a toujours souhaité me voir en ce jour — **MA CHÈRE MAMAN.**"*

***À L'ÂME DE MON PÈRE,** que Dieu lui accorde Sa miséricorde, dont l'absence n'a jamais effacé la présence dans mon cœur. Il reste ma force silencieuse et mon exemple éternel, j'espère que mes sentiments te parviennent et que tu es fier de ceux qui portent ton nom, eux qui ont prouvé que tu étais le meilleur éducateur, le meilleur enseignant, le meilleur père et le meilleur défunt."*

*À mes sœurs chéries, **HADJER** et **AÇIL**, pour leur affection sincère, leur soutien constant et leur présence rassurante à mes côtés.*

*« À mon seul et mon petit, mon cher frère , que Dieu renforce mon bras grâce à toi et fortifie mon âme par ta présence. » mon cher **YAHIA.***

*" À mon futur mari et à mes enfants à venir",
ce travail est pour vous, avec tout mon amour et mes rêves d'avenir.*

Le jour de ma joie, je ne peux oublier ma famille et mes amies sœurs

*Enfin, je tiens à exprimer toute ma gratitude et ma reconnaissance envers mes amies et
compagnes de route dans ce travail : **ILHAM ET AYA.***

*Louange à Dieu, avec amour, reconnaissance et gratitude pour le commencement et la
fin.*

INAS

Dédicace

Avec tout mon amour, je dédie ma réussite et mon diplôme :

*À celui qui a scellé mon nom avec lui, qui m'a soutenu sans limites et m'a donné de manière inconditionnelle, à celui qui m'a appris que le monde est un combat et que son arme est la connaissance et le savoir. Sur mon chemin, il est mon guide, mon soutien, ma force, mon refuge, ma fierté **MON PÈRE***

*Dieu a placé le paradis sous ses pieds, par ses prières elle m'a apporté son soutien et sa présence sans faille, dans mes moments de faiblesse et de peur, elle a su faire jaillir en moi la lumière : elle est ma lumière, elle est le secret de ma force et de ma réussite, mon paradis : **MA MÈRE***

***À MES SŒURS CHÉRIES**, complices fidèles de chaque instant, présentes dans les joies comme dans les épreuves, dans les rires comme dans les silences. Avec vous, j'ai appris la force de l'amour fraternel, la profondeur du lien qui unit, et la chaleur d'un soutien sincère. Vous êtes ma sérénité, ma joie et ma force discrète.*

***À MES DEUX PETITS FRÈRES**, au cœur innocent et à l'âme pure, vous avez été une source de joie et d'espoir, un soutien sincère que vous ne mesurez peut-être pas. Votre présence dans ma vie est une bénédiction, et votre simplicité m'a donné la force en silence.*

*Vous êtes tous ma fierté, ma famille, mon trésor précieux.
Je vous dédie ce succès, car il est autant le vôtre que le mien.*

*À tous ceux qui m'ont apporté force et conseils, ont cru en moi et m'ont soutenu dans les moments difficiles pour arriver là où je suis, mes collègues et amis **(INAS, AYA)**.*

***À MES AMIS** qui ont passé avec moi les meilleurs jours et souvenirs et les plus belles coïncidences qui nous ont réunis à université, merci pour tout.*

« Ce diplôme est le fruit de votre amour et de votre soutien, et le début d'un nouveau chapitre rempli d'espoir et de défis.

ILHAM

Dédicace

Avant toute chose,

Je rends grâce à Dieu, le Tout-Puissant, pour m'avoir guidée, soutenue et accordé la patience et la force nécessaires tout au long de ce parcours. Sans Sa volonté, rien n'aurait été possible.

À MON PÈRE,

Merci pour ta force tranquille, tes conseils justes et ton soutien constant. Tu as toujours été là, avec discrétion mais avec une présence rassurante qui m'a portée dans les moments difficiles. Ta confiance en moi m'a donné le courage d'avancer.

À MA MÈRE,

Merci pour ton amour infini, ta patience et tous les sacrifices que tu as faits en silence. Tu es mon pilier, celle qui m'a appris à persévérer et à croire en moi. Ta tendresse et ton énergie m'accompagnent chaque jour.

À MES SŒURS,

Merci pour votre tendresse, votre patience, vos mots doux et vos gestes attentionnés. À vos époux et à vos enfants, merci pour leur gentillesse, leur compréhension et leur soutien naturel.

À MON FRÈRE,

Merci pour ton soutien discret mais sincère. Ta bienveillance, celle de ton épouse et de vos enfants, a été un vrai réconfort pour moi.

À MES AMIES FIDÈLES,

Merci pour votre présence, vos encouragements, et votre capacité à m'écouter sans jamais juger. Votre soutien m'a aidée à garder le cap dans les moments d'incertitude.

À UN ÊTRE CHER,

Ton passage dans ma vie a été précieux. Je garde en mémoire ce que tu m'as apporté, ta présence à un moment clé, ton écoute et ton soutien. Merci pour tout ce que tu as laissé de beau.

À toutes les personnes dans ma vie que j'aime —

Merci d'être là, dans les bons comme les mauvais moments.

À VOUS TOUS,

Ce mémoire vous est dédié, avec toute ma gratitude et mon affection sincère.

AYÀ

Remerciement

Avant tout développement sur cette expérience il apparait opportun de commencer ce travail par des remerciements.

Nous louons Dieu, le Généreux, pour la réussite, la bénédiction et la santé qu'Il nous a accordées, et surtout pour le courage qu'Il nous a insufflé afin de mener à bien ce travail. Sans Sa grâce, nous ne serions jamais arrivés jusque-là.

À ceux qui nous ont tant appris au cours des cinq dernières années, depuis nos écoles secondaires jusqu'à l'université qui nous a accueillis pour réaliser notre objectif principal.

À tous ceux qui ont contribué à rendre cette expérience des plus enrichissantes : nos camarades, nos enseignants, Et chaque travailleur du département de microbiologie et biochimie, l'ensemble de l'équipe administrative de notre université, ainsi que l'équipe des laboratoires.

Nous tenons à exprimer notre profonde gratitude à M. [*Geutouache Mourad*], notre directeur de mémoire, pour sa supervision précieuse, ses conseils avisés et sa présence constante tout au long de ce travail. Son expertise et sa rigueur scientifique ont été inestimables dans la préparation de ce mémoire.

Nous remercions également Mme [*Ariech Mounira*], évaluatrice de ce travail, pour avoir accepté d'évaluer notre mémoire et pour ses remarques constructives qui ont contribué à son amélioration.

Nos remerciements vont aussi à M. [*Rahali Abdallah*], président du jury, pour l'honneur qu'il nous a fait en présidant cette soutenance, ainsi que pour l'intérêt qu'il a porté à notre travail.

Nous exprimons également notre profonde reconnaissance à nos familles, pour leur soutien constant tout au long de notre parcours académique, depuis notre enfance.

Nos sincères remerciements vont également à l'ensemble du corps enseignant de la Faculté des Sciences de la Nature et de la Vie pour leur encadrement, ainsi qu'à toute la promotion 2025.

pufin nous ne saurons pas terminer sans mentionner ceux qui de près ou de loin ont contribué notre réussite; ainsi qu'envers l'ensemble du Jury pour avoir accepté d'évaluer ce travail. Trouvez en ces mots notre profonde gratitude.

Sommaire

Résumé	i
Liste des abréviations	ii
Liste des figures	ii
Liste des tableaux	iii
Introduction.....	1
Chapitre I: Généralités sur l'intelligence artificielle et microbiologie alimentaire.....	2
1. Définition et concepts de l'IA :	2
1.1. • Définition :	2
1.2. • Principaux concepts de l'intelligence artificielle :	2
1.3. • Applications de l'IA :	4
1.4. • Introduction à la microbiologie alimentaire :	4
2. • Principaux contaminants microbiens des aliments :	5
3. • L'importance du contrôle microbiologique dans l'industrie alimentaire :	7
Chapitre II : intelligence artificielle et analyse microbiologique des aliments.....	8
1. : détection automatisée des pathogènes alimentaires :	8
1.1. Mécanismes de construction de réseaux de capteurs :	8
1.2. Application de l'apprentissage automatique aux réseaux de capteurs :	8
2. microscopie assistée par IA séquençages et analyse des données génomiques :	9
2.1 Le microscope et la microbiologie :	9
2.2. Le séquençage des génomes :	10
2.3. Séquençage et analyses des données génomique :	13
3. Prédiction et modélisation de la croissance microbienne :	14
4. Contribution de L'AI dans la sécurité alimentaire :	16
4.1. Agriculture de précision et optimisation des ressources :	16
4.2. Traçabilité et sécurité sanitaire :	17
4.3. Réduction du gaspillage alimentaire :	17

4.4.	Soutien aux petits exploitants agricoles :	17
4.5.	Prevision des crises alimentaires :	17
5.	rôle de L'IA dans la gestion des bases de données en microbiologie :	17
5.1.	Analyse de données génomiques et métagénomiques :	17
5.2.	Amélioration de la qualité des données et des diagnostics:	18
5.3.	Extraction d'informations à partir de textes non structurés :	18
5.4.	Prédiction de cibles thérapeutiques et de vaccins :	18
Chapitre III : technique et outils d IA en microbiologie alimentaire.		19
1.	Apprentissage automatique (Machine Learning):	19
1.1.	Branches de Apprentissage automatique :	19
1.2.	L'apprentissage en profondeur 'Deep learning:.....	20
2.	Réseaux neuronaux et leur application en microbiologie alimentaire	21
2.1.	Définitions et principes des réseaux neuronaux :	21
2.2.	Applications des réseaux neuronaux en microbiologie alimentaire :	21
3.	Avantages et limites des méthodes basées sur l'IA	22
3.1.	Avantages des méthodes basées sur l'IA	22
3.2.	Limites des méthodes basées sur l'IA :	23
Chapitre IV : Études de Cas et Impacts de l'IA en Microbiologie Alimentaire		24
1.	Études de cas : Applications de l'IA en microbiologie alimentaire	24
1.1.	Infographie : Applications de l'IA en Microbiologie Alimentaire.	26
2.	Défis et contraintes de l'implémentation de l'IA :	27
2.1.	Qualité et quantité des données :	27
2.2.	Interprétabilité des modèles:	28
2.3.	Coûts d'implémentation et expertise requise :	28
2.4.	Contraintes réglementaires :	28
3.	Perspectives et évolutions futures de l'IA dans l'agroalimentaire se déclinent en plusieurs axes clés :	28

3.1. Vers une IA explicable (XAI):	28
3.2. Intégration avec l'IoT et les capteurs intelligents :.....	28
3.3. Personnalisation des modèles IA:.....	29
3.4. Synergie avec la biologie computationnelle :.....	29
Conclusion Générale et Recommandations :	29
Conclusion :	31
Références bibliographiques :.....	32

ملخص

شهد علم الأحياء الدقيقة الغذائية تحولاً جذرياً بفضل دمج تقنيات الذكاء الاصطناعي، التي أتاحت إمكانيات متقدمة في مراقبة جودة الأغذية، الكشف عن الملوثات، وتحليل التفاعلات الميكروبية الدقيقة. فالذكاء الاصطناعي، من خلال خوارزميات التعلم الآلي (Machine Learning) والتعلم العميق (Deep Learning)، يمكنه تحليل كميات هائلة من البيانات الميكروبيولوجية الناتجة عن اختبارات مخبرية أو أجهزة استشعار في خطوط الإنتاج، واستخلاص أنماط دقيقة تتيح الكشف المبكر عن المخاطر البيولوجية مثل البكتيريا الممرضة (Salmonella, Listeria, E. coli) هذه القدرة على الرصد الآني والإنذار المبكر تساعد في الوقاية من تفشي الأمراض المنقولة عن طريق الغذاء. علاوة على ذلك، تلعب تقنيات الذكاء الاصطناعي دوراً جوهرياً في تحليل بيانات التسلسل الجينومي وبيانات الميتاجينوم، التي تمثل تحدياً بسبب حجمها وتعقيدها. فالخوارزميات المتقدمة تستطيع تصنيف الكائنات الحية الدقيقة، حتى تلك غير القابلة للزراعة، وتحديد أدوارها في تلف الأغذية أو تحسين خواصها. ويساعد هذا في فهم العلاقات بين الميكروبات في البيئة الغذائية، وتأثيرها على الاستقرار الميكروبي، والنشاط الأيضي، وطول فترة صلاحية المنتج. إلى جانب ذلك، تُستخدم تقنيات الذكاء الاصطناعي لتطوير نماذج تنبؤية تعتمد على البيانات البيئية (مثل درجة الحرارة، الرطوبة، الضوء) والخصائص الكيميائية الحيوية للغذاء) مثل نشاط الماء، قيمة (pH)، بهدف التنبؤ بمعدل نمو الميكروبات وتقدير العمر الافتراضي للمنتج. هذه النماذج تدعم صناع القرار في ضبط شروط التخزين والتوزيع وتخفيض نسب الفاقد والهدر الغذائي. كما ساهم الذكاء الاصطناعي في بروز مفهوم التغذية الدقيقة (Precision Nutrition)، إذ يمكن بناء خطط غذائية شخصية تستند إلى تحليلات الميكروبيوم المعوي والجينات الفردية، وهو ما يُعد تطوراً نوعياً في العلاقة بين الغذاء والصحة. ومن خلال هذا الربط بين علم الأحياء الدقيقة والتقنيات الحاسوبية، أصبح بالإمكان توجيه المنتجات الغذائية وفقاً لحالة الفرد الصحية والميكروبية، بما يعزز التوازن البكتيري في الأمعاء ويقلل من خطر الإصابة بالأمراض المزمنة. رغم ذلك، لا تزال هناك تحديات تواجه هذا التوجه، أبرزها الحاجة إلى بيانات موثوقة وقياسية، وفهم محدود لآليات عمل الخوارزميات بالنسبة للمستخدمين غير المختصين، إضافة إلى القيود التنظيمية التي تُعيق أحياناً استخدام هذه التكنولوجيا في النطاق الصناعي. كما يُعد تفسير نتائج النماذج عاملاً بالغ الأهمية لزيادة ثقة المصنعين والمستهلكين على حد سواء، خاصة عندما ترتبط القرارات بمسائل تتعلق بسلامة الغذاء وصحة الإنسان. في ضوء هذه المستجدات، يظهر الذكاء الاصطناعي كأداة استراتيجية تُعزز من قدرة الأنظمة الغذائية على التكيف مع التحديات المتزايدة في مجال السلامة والجودة، وتُساهم في بناء سلاسل توريد غذائية أكثر ذكاءً واستدامةً، ما يعكس توجهاً عالمياً نحو توظيف التكنولوجيا لخدمة الأمن الغذائي والصحة العامة.

الكلمات المفتاحية: الذكاء الاصطناعي، علم الأحياء الدقيقة الغذائية، التعلم الآلي، التسلسل الجينومي، التغذية الدقيقة، السلامة الغذائية، جودة الأغذية، الكائنات الدقيقة، النماذج التنبؤية، الاستشعار الذكي، الأمراض المنقولة بالغذاء، استدامة النظام الغذائي.

Abstract

The field of food microbiology has undergone a profound transformation through the integration of artificial intelligence (AI), which has enabled major advances in food quality monitoring, contaminant detection, and the analysis of complex microbial interactions. Using machine learning and deep learning algorithms, AI can process massive volumes of microbiological data from laboratory tests or sensors embedded in production lines to detect pathogens such as Salmonella, Listeria, or E. coli at an early stage. This real-time monitoring and early warning capability helps prevent outbreaks of foodborne illnesses effectively. Moreover, AI plays a crucial role in interpreting large and complex datasets from genomic and metagenomic sequencing. It allows for the classification of microorganisms, including those that cannot be cultured, and provides insights into their roles in food spoilage or enhancement. This supports a deeper understanding of microbial dynamics, metabolic activity, and shelf-life stability. In addition, AI-powered predictive models based on environmental conditions (temperature, humidity, light) and biochemical parameters (pH, water activity, etc...) are used to estimate the shelf life of products and optimize storage strategies, thereby reducing food waste. AI also contributes to the development of precision nutrition, which tailors diets based on the analysis of the gut microbiome and individual genetic profiles, enhancing health and disease prevention. Despite these promising advances, several challenges remain, including data quality, algorithm transparency, and regulatory constraints. Developing explainable models is essential to build trust among food producers and consumers. In this context, AI emerges as a strategic tool to enhance food safety, sustainability, and the resilience of the global food system.

Keywords: Artificial intelligence, Food microbiology, Machine learning, Genomic sequencing, Metagenome, Shelf-life prediction, Microbiome, Precision nutrition, Food safety, Food quality, Microorganisms, Predictive models, Smart sensors, Foodborne diseases, Food system sustainability.

Résumé

Le domaine de la microbiologie alimentaire a connu une transformation profonde grâce à l'intégration de l'intelligence artificielle (IA), qui a permis des avancées majeures dans la surveillance de la qualité des aliments, la détection des contaminants, et l'analyse des interactions microbiennes complexes. Grâce aux algorithmes d'apprentissage automatique et d'apprentissage profond, l'IA peut analyser de vastes ensembles de données microbiologiques issues de tests de laboratoire ou de capteurs intégrés aux lignes de production, pour détecter précocement les agents pathogènes tels que *Salmonella*, *Listeria* ou *E. coli*. Cette capacité à surveiller en temps réel et à déclencher des alertes permet de prévenir efficacement les risques d'intoxication alimentaire. Par ailleurs, l'IA joue un rôle clé dans l'interprétation des données issues du séquençage génomique et du métagénome, souvent volumineuses et complexes. Elle permet de classifier les micro-organismes, y compris ceux non cultivables, et de comprendre leur impact sur la détérioration ou l'amélioration des caractéristiques des produits alimentaires. Cela contribue à une meilleure compréhension de la dynamique microbienne, de l'activité métabolique et de la durée de conservation. En outre, des modèles prédictifs alimentés par des données environnementales (température, humidité, lumière) et biochimiques (pH, activité de l'eau, etc...) permettent d'estimer la durée de vie des produits et d'optimiser les conditions de stockage, réduisant ainsi le gaspillage alimentaire. L'intelligence artificielle contribue également au développement de la nutrition personnalisée, basée sur l'analyse du microbiome intestinal et du profil génétique de l'individu, renforçant ainsi la prévention des maladies chroniques et le bien-être général. Malgré ces avancées, plusieurs défis persistent, notamment la qualité des données, la transparence des algorithmes et les restrictions réglementaires. Il est essentiel de développer des modèles interprétables pour instaurer la confiance chez les industriels et les consommateurs. Dans ce contexte, l'IA s'impose comme un levier stratégique pour assurer la sécurité, la durabilité et la résilience du système alimentaire mondial.

Mots-clés : Intelligence artificielle, Microbiologie alimentaire, Apprentissage automatique, Séquençage génomique, Métagénome, Durée de conservation, Microbiome, Nutrition personnalisée, Sécurité alimentaire, Qualité des aliments, Micro-organismes, Modèles prédictifs, Capteurs intelligents, Maladies d'origine alimentaire, Durabilité alimentaire.

Liste des abréviations

IA: Intelligence Artificielle .

ML : Machine Learning (apprentissage automatique).

CNN :Convolutional Neural Network (réseau de neurones convolutifs) .

RNN : Recurrent Neural Network (réseau de neurones récurrents).

DNN : Deep Neural Network (réseau profond) .

ANN :Artificial Neural Network (réseau de neurones artificiels).

Liste des figures

Figure I.1.principaux concepts de IA	2
FigureI.2. Application de IA dans divers domaines.....	3
FigureII.1.Technique de Maxam-Gilbert.....	11
Figure II.2Technique de Maxam-Gilbert.....	11
Figure II.3.La méthode de séquençage de sanger.....	12
Figure II.4.Technologie de séquençage.....	13
Figure II.5. Histogrammes de nombre de points observé pour chaque variable.....	15

Figure II.6.Importance des caractéristiques du modèle XGBoost développé.....	15
Figure III.1.les subdivisions et les applications de laprentissage automatique.....	19
Figure IV.1. Applications d IA en microbiologie alimentaire.....	24
Figure IV.2.Perspectives futures de l'intelligence artificielle en microbiologie alimentaire.....	28
Figure IV.3.Intelligence artificielle en microbiologie alimentaire.....	29

Liste des tableaux

TableauI.1.Comparison des principaux microbes contaminant des aliments	6
TableauIV.1.Application des IA en microbiologie alimentaire.....	24

Introduction

Introduction

L'intégration de l'intelligence artificielle (IA) en microbiologie alimentaire représente un changement de paradigme dans le domaine de la sécurité et de la qualité des aliments. Traditionnellement, la détection des agents pathogènes dans les produits alimentaires reposait sur des méthodes agricoles, certes fiables, mais souvent chronophages et complexes. Ce retard dans l'obtention des résultats peut retarder les mesures préventives, augmentant ainsi le risque de maladies d'origine alimentaire.

L'émergence de l'intelligence artificielle offre des perspectives prometteuses pour relever ces défis. L'apprentissage automatique et l'imagerie optique, en particulier, se sont révélés efficaces pour accélérer et améliorer la détection des bactéries pathogènes. Par exemple, une étude de (Ma *et al.*,2023) a démontré que l'utilisation de l'algorithme YOLOv4, combiné à l'imagerie optique, permettait une identification rapide et précise d'*E. coli* sur la laitue romaine, même en présence de divers microbes et résidus alimentaires. Cette approche a permis d'identifier avec succès 11 échantillons contaminés sur 12, suggérant son application potentielle dans des matrices alimentaires complexes.

Outre la détection, l'IA facilite également l'analyse de vastes ensembles de données microbiologiques, améliorant ainsi la surveillance et le contrôle des contaminants alimentaires. L'IA est largement utilisée pour soutenir la recherche et le développement en biotechnologie industrielle, notamment dans le secteur alimentaire. Les entreprises de biotechnologie s'appuient de plus en plus sur les outils d'IA pour améliorer leurs procédés et garantir la sécurité de leurs produits.

Dans ce travail, nous proposons l'utilisation de l'intelligence artificielle comme solution prometteuse pour la gestion des épidémies de maladies d'origine alimentaire. Par exemple, le système FINDER, développé par (Sadi Lek *et al.*,2018), utilise des données de recherche et de sites web anonymes pour détecter instantanément les maladies d'origine alimentaire. Ce système a permis d'identifier les restaurants présentant des risques sanitaires, améliorant ainsi l'efficacité des inspections et contribuant à la prévention des épidémies.

En résumé, l'intégration de l'IA en microbiologie alimentaire transforme radicalement les pratiques traditionnelles en offrant des solutions innovantes pour la détection rapide des agents pathogènes, l'analyse précise des données et la gestion proactive des risques sanitaires. Cette synergie entre technologie et microbiologie ouvre la voie à des améliorations significatives en matière de sécurité alimentaire et de protection de la santé publique.

Partie bibliographique

Chapitre I :

Généralités sur l'intelligence artificielle et microbiologie alimentaire

Chapitre I: Généralités sur l'intelligence artificielle et microbiologie alimentaire.

1. Définition et concepts de l'IA :

1.1. • Définition :

L'intelligence artificielle (IA) est le terme utilisé pour décrire l'utilisation d'ordinateurs et de technologies afin de simuler un comportement intelligent et une pensée critique comparables à ceux d'un être humain. John McCarthy a d'abord décrit le terme IA en 1956 comme la science et l'ingénierie de la création de machines intelligentes (Amisha *et al*, 2019).

1.2. • Principaux concepts de l'intelligence artificielle :

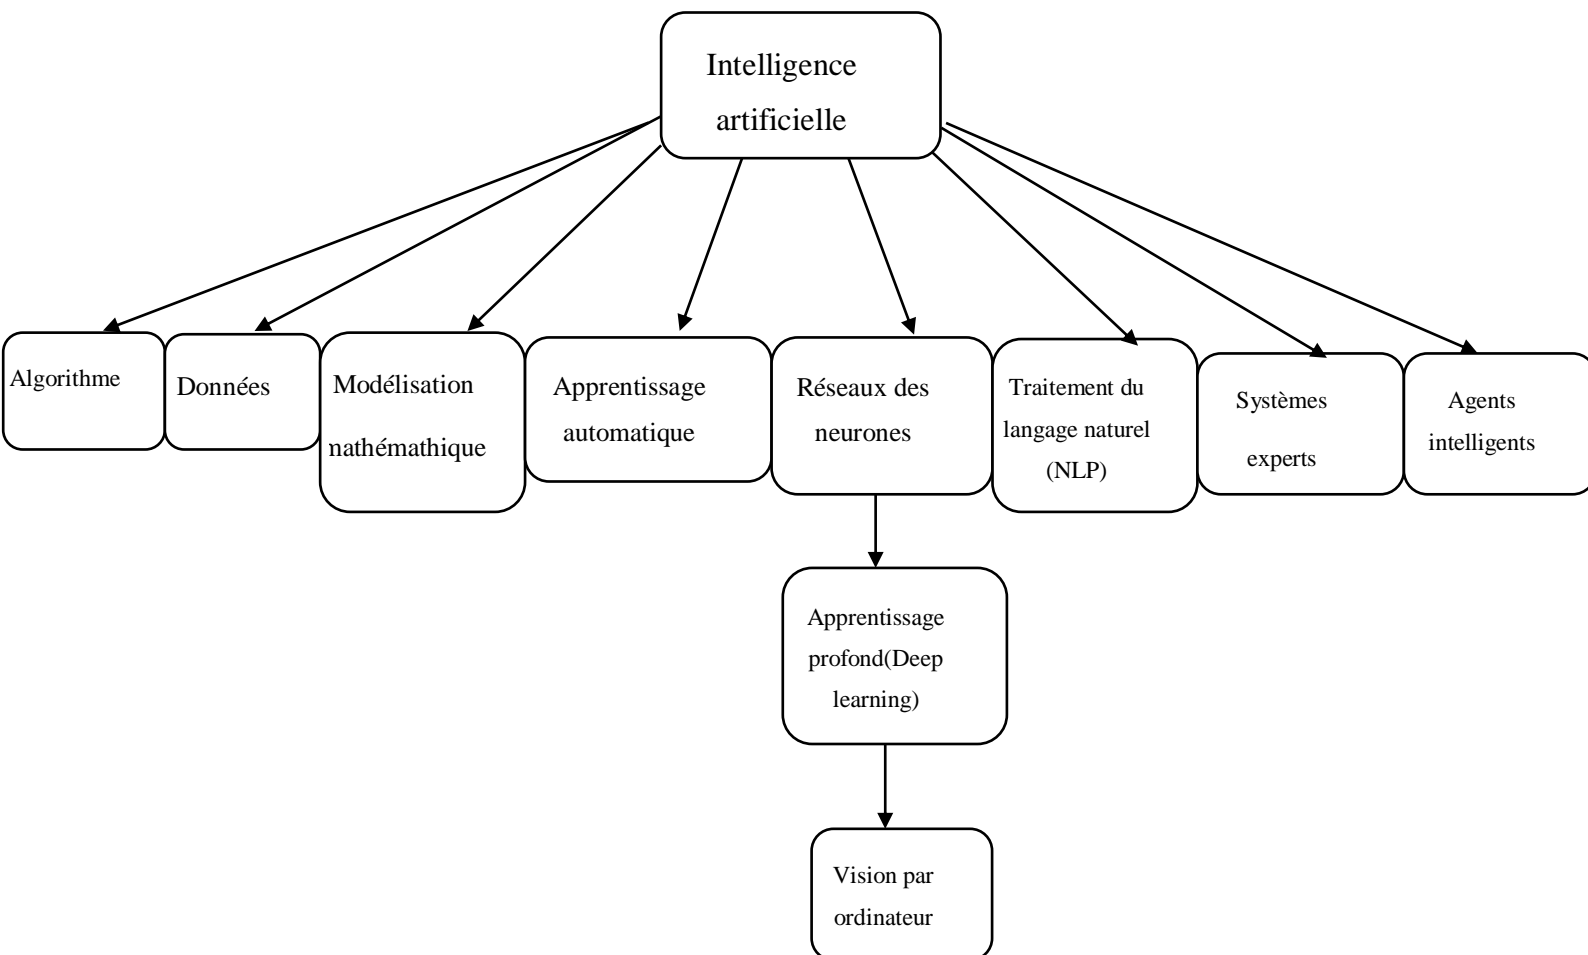


Figure I .1 : principaux concepts d'intelligence artificielle.

-Histoire et évolution de l'IA :

Alan Turing est reconnu comme l'un des fondateurs de l'informatique et de l'intelligence artificielle (IA). En 1950, il a proposé le "test de Turing", qui évalue la capacité d'un ordinateur à

imiter le comportement humain de manière indiscernable. Ce test est basé sur l'idée que le comportement intelligent d'un ordinateur se mesure par sa capacité à atteindre des performances cognitives équivalentes à celles d'un être humain (Mintz et Brodie, 2019).

Les années 1980 et 1990 ont vu un regain d'intérêt pour l'IA, avec l'utilisation de techniques comme les réseaux neuronaux artificiels et les systèmes experts flous dans divers contextes, notamment en santé. En 2016, une grande partie des investissements en IA était consacrée aux applications de santé, reflétant l'importance croissante de l'IA dans ce domaine (cbinsights,2017).

L'intelligence artificielle progresse rapidement, surpassant les capacités humaines dans divers domaines comme la traduction, la composition musicale, la détection d'objets, les diagnostics médicaux et la programmation (Buttazzo, 2023).

Dans le domaine de la microbiologie alimentaire, l'IA progresse en analysant des données pour prédire la croissance microbienne, détecter les contaminants et optimiser la sécurité alimentaire. Cela pourrait révolutionner la détection précoce des risques alimentaires et améliorer les processus de production.

1.3. • Applications de l'IA :

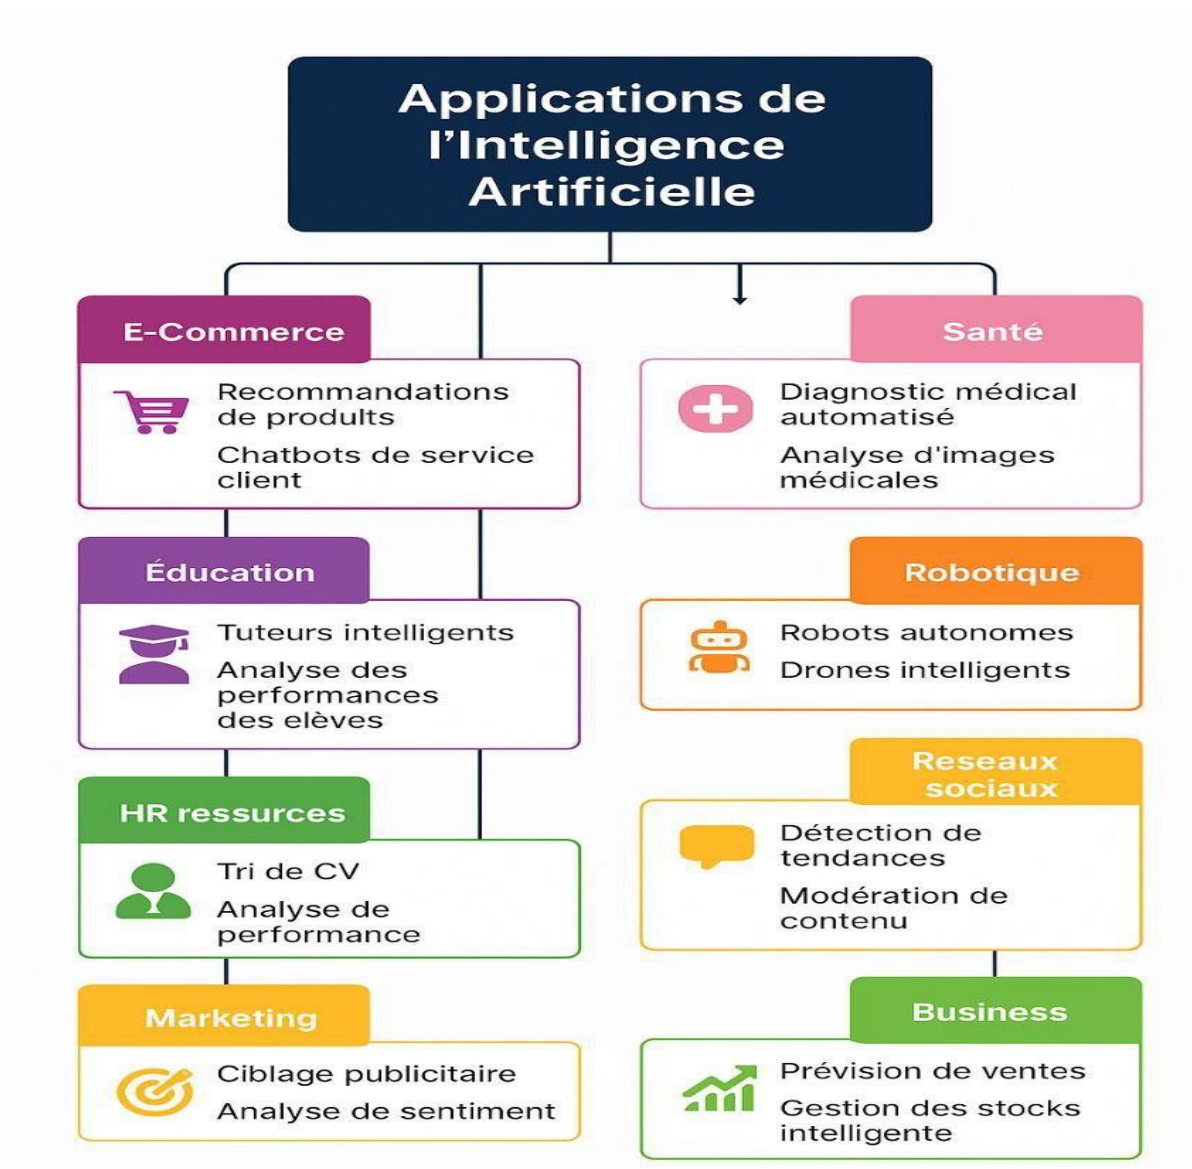


Figure I.2: Applications de l'IA dans divers domaines.

1.4. • Introduction à la microbiologie alimentaire :

La fabrication de nombreux produits alimentaires repose sur le métabolisme de micro-organismes bénéfiques, appelés microflore positive. Ces micro-organismes, tels que les bactéries lactiques et les levures, jouent un rôle crucial dans la fermentation et l'affinage d'aliments comme le fromage et la charcuterie. Ils contribuent à la conservation et à l'acquisition des propriétés sensorielles des produits (Dorel *et al* 2025).

En parallèle, la microbiologie alimentaire étudie également la flore d'altération, qui détériore les aliments sans toujours nuire à la santé, ainsi que les micro-organismes pathogènes transmis par les aliments, responsables de maladies infectieuses.

•Microflore Positive

- Bactéries lactiques : Utilisées dans la fabrication de yaourts et fromages.
- Levures : Exemple, *Saccharomyces cerevisiae* utilisée pour la bière et le pain.

•Microflore d'Altération

- *Pseudomonas sp.* : Détérioration des aliments sans impact direct sur la santé.

Microflore Pathogène

- *Listeria monocytogenes* : Cause de la listériose.
- *Salmonella sp.* : Cause des salmonelles.

Les micro-organismes jouent un rôle crucial dans l'industrie agroalimentaire et la biotechnologie industrielle. Dans l'industrie agroalimentaire, ils sont utilisés pour la fermentation et la transformation de produits alimentaires, comme les fromages et les boissons alcoolisées. En biotechnologie industrielle, ces micro-organismes sont exploités pour produire des molécules chimiques telles que des antibiotiques (par exemple, *Streptomyces sp.*), des polysaccharides (*Porphyridium cruentum*), et de l'éthanol (*Saccharomyces cerevisiae*). De plus, des organismes microbiens génétiquement modifiés sont utilisés pour produire des composés pharmaceutiques comme l'insuline humaine.

2. • Principaux contaminants microbiens des aliments :

La sécurité sanitaire des aliments est un enjeu crucial pour la santé publique, car les aliments peuvent être contaminés par divers agents, notamment microbiens. La contamination microbiologique implique la présence de micro-organismes pathogènes tels que bactéries et virus, responsables de nombreuses toxi-infections alimentaires. Parmi les principaux agents microbiens, on trouve :

Salmonella spp. : Bactérie responsable de la salmonellose, une des toxi-infections alimentaires les plus fréquentes. Elle se retrouve principalement dans la viande (notamment la volaille), les œufs, les produits laitiers crus, ainsi que dans certains fruits et légumes crus. La contamination survient souvent par ingestion d'aliments crus ou insuffisamment cuits, et la bactérie peut résister au froid mais est détruite par la cuisson (Scallan *et al* 2011) .

Listeria monocytogenes : Responsable de la listériose, maladie grave surtout chez les personnes immunodéprimées et les femmes enceintes. Elle est présente dans les produits prêts à consommer comme les charcuteries, fromages à pâte molle et poissons fumés (Swaminathan et Gerner, 2007) .

Escherichia coli entérohémorragique (ex. O157:H7) : Peut provoquer des diarrhées sanglantes et le syndrome hémolytique et urémique. Les sources principales sont la viande hachée insuffisamment cuite, le lait cru et les légumes-feuilles contaminés (Rangel *et al*, 2005).

Campylobacter spp. : Première cause de gastro-entérite bactérienne en Europe, se trouvant surtout dans la volaille crue, le lait cru et l'eau non traitée (Kaakoushet *al*, 2015).

Clostridium botulinum : Bactérie produisant une toxine neurotoxique responsable du botulisme. Elle est associée aux conserves mal stérilisées, charcuteries maison et poissons en conserve (Lindström *et al*, 2006).

Staphylococcus aureus : Produit des entérotoxines résistantes à la chaleur, causant des intoxications alimentaires. Il est souvent lié aux plats préparés manipulés à la main, produits laitiers et pâtisseries (Le Loir *et al*, 2003).

Norovirus : Principal virus responsable de gastro-entérites virales d'origine alimentaire, souvent transmis par les fruits de mer (coquillages) et fruits/légumes crus contaminés (Patelet *al*, 2009).

Ces micro-organismes peuvent contaminer les aliments à différents stades, depuis la production jusqu'à la consommation, par contact avec des matières fécales, des surfaces ou des mains souillées. La prévention repose sur des pratiques strictes d'hygiène, une cuisson adéquate, et une surveillance rigoureuse des aliments. Par ailleurs, la lutte contre d'autres contaminants comme les pesticides, mycotoxines, métaux toxiques et radionucléides complète cette approche globale de la sécurité alimentaire.

•Tableau I.1 : comparaison des principaux microbes contaminants

Type	Microbe	Source	Effets	Aliments risqué
Bactérie	<i>Salmonella ssp.</i>	Œufs, volailles	Fièvre, diarrhée	Viandes, œufs
Bactérie	<i>Listeria monocytogenes</i>	Sol, eau, lait cru	Méningite, fausse couche	Fromages, charcuteries
Bactérie	<i>Escherichia coli O157 :H7</i>	Fèces animales, légumes cru	Diarrhée sanglante	Viande hachée, crudités
Bactérie	<i>Campylobacter jejuni</i>	Volailles, eau	Diarrhée, fièvre	Poulet, lait
Moisissure	<i>Aspergillus Flavus</i>	Grains, fruits secs	Aflatoxines(cancer)	Céréales, noix
Moisissure	<i>Penicillium spp.</i>	Stockage humide	Mycotoxine variées	Fruits, céréales
Virus	Norovirus	Eau souillée contact humain	Gastro-entérite	Fruits de mer, salades
Virus	Hépatite A	Eau, mains contaminées	Hépatite(jaunisse)	Coquillages, fruits crus
Parasite	<i>Toxoplasma gondi</i>	Viande crue, chats	Risque grossesse	Viande crue
Parasite	<i>Gardia lamblia</i>	Eau contaminée	Diarrhée, fatigue	Légumes, eau non traitée

desaliments

3. •L'importance du contrôle microbiologique dans l'industrie alimentaire :

Le contrôle microbiologique est crucial dans l'industrie alimentaire pour plusieurs raisons essentielles :

1/ Garantir la sécurité sanitaire : Il permet de détecter et d'éliminer les micro-organismes pathogènes (*Salmonella*, *Listeria*, *E. coli*) qui peuvent provoquer des intoxications alimentaires graves, protégeant ainsi la santé des consommateurs (Brackett, 2020).

2/ Assurer la qualité des produits : Le contrôle microbiologique identifie aussi les micro-organismes altérants responsables de la détérioration des aliments (goût, odeur, texture), ce qui aide à maintenir la qualité organoleptique et la durée de vie des produits (Cuq, 2016).

3/ Respecter les normes réglementaires : Les analyses microbiologiques permettent de vérifier la conformité aux critères imposés par les réglementations (ex. Règlement CE 2073/2005), évitant ainsi sanctions et rappels comtaux (Guiraud, 2012).

4/ Optimiser les processus de production : En contrôlant les matières premières, l'environnement, les équipements et les produits finis, ce contrôle aide à identifier les points critiques et à appliquer

les bonnes pratiques d'hygiène (HACCP), renforçant l'efficacité et la sécurité du système de production (Guiraud, 2012).

5/ Renforcer la confiance des consommateurs : La transparence dans le contrôle microbiologique est un gage de sérieux et de qualité, essentiel pour la réputation des marques et la fidélisation des clients.

Le contrôle microbiologique dans l'industrie alimentaire est indispensable pour protéger la santé publique, garantir la qualité et la conformité des produits, optimiser la production et préserver la confiance du marché.

Chapitre II :

IA et analyse microbiologique des aliments

Chapitre II : intelligence artificielle et analyse microbiologique des aliments

1. : détection automatisée des pathogènes alimentaires :

Les agents pathogènes d'origine alimentaire représentent un défi majeur pour la sécurité alimentaire. Les méthodes traditionnelles basées sur la culture sont souvent chronophages et exigeantes en main-d'œuvre, tandis que les technologies modernes présentent des limites, notamment la nécessité d'une expertise spécialisée ou d'équipements coûteux. Par conséquent, les réseaux de capteurs, tels que les nez électroniques et les réseaux de capteurs optiques, utilisent plusieurs éléments de détection interactifs pour générer des empreintes uniques pour différentes analyses.

Cette revue met en lumière les dernières avancées en matière de conception de réseaux de capteurs et de matériaux couramment utilisés. Nous présentons quatre principes clés pour la construction de réseaux de capteurs : la détection des composés organiques volatils (COV), les capteurs à base d'anticorps, la physiologie et le microenvironnement de surface bactérienne, et l'activité métabolique. Nous abordons également l'utilisation de l'apprentissage automatique (AA) (Machine learning – (ML)) pour interpréter les réseaux de capteurs et leurs résultats. Enfin, nous explorons les défis de la détection multi-pathogènes et les tendances émergentes dans ce domaine.

1.1. Mécanismes de construction de réseaux de capteurs :

Les réseaux de capteurs reposent sur le principe de « réactivité croisée », fondamentalement différent des méthodes immunologiques. En général, un réseau de capteurs vise à recueillir des informations complètes sur l'enveloppe cellulaire entière ou sur un mélange de métabolites. Les informations partielles obtenues par un seul capteur peuvent être intégrées à des modèles de reconnaissance de formes ultérieurs pour l'identification bactérienne. L'une des principales différences entre les bactéries réside dans la structure de leurs parois cellulaires.

1.2. Application de l'apprentissage automatique aux réseaux de capteurs :

L'apprentissage automatique est largement utilisé en chimio métrie, notamment en SERS, et en bio-informatique, pour explorer les enveloppes cellulaires bactériennes et les identifier en vue d'une reconnaissance taxonomique. Cependant, l'association de réseaux de détection et d'apprentissage automatique est un domaine de recherche relativement nouveau qui a suscité un intérêt croissant au cours de la dernière décennie. Les réseaux de détection sont généralement conçus pour une réactivité croisée, ce qui signifie qu'ils ne présentent pas de relation linéaire claire avec l'analyse. De plus, les schémas associés aux différentes espèces bactériennes sont obscurcis (Wang *et al.* 2024).

Afin d'améliorer l'identification des agents pathogènes, l'Union européenne (UE) a financé le projet PATHFINDER (Rapid and reliable detection of foodborne pathogens by employing multiplexing

biosensor technology) visant à détecter de faibles concentrations de diverses espèces bactériennes dans les produits alimentaires. Le projet PATHFINDER utilisait des biocapteurs capables d'identifier les bactéries grâce à un signal distinctif. Par exemple, un biocapteur pourrait être constitué d'un anticorps capable d'identifier et de se lier aux bactéries, à l'instar du système immunitaire humain (Mishra *et al*, 2024 ; Yamada *et al*, 2016).

En utilisant trois pathogènes alimentaires courants comme modèles, les scientifiques ont étudié la capacité de différents biocapteurs à détecter simultanément plusieurs espèces bactériennes. Pour simuler la contamination alimentaire, ils ont introduit différentes concentrations de bactéries telles que *Salmonella*, *Listeria* et *Campylobacter* dans des plats préparés avec du poulet cru ou cuit (Mishra *et al*, 2024 ; Yamada *et al*, 2016).

Après la multiplication des bactéries, les chercheurs ont évalué la sensibilité de différentes méthodes de détection. La méthode privilégiée utilisait des billes de polystyrène microscopiques recouvertes d'anticorps capables de piéger les bactéries. Cette technique a facilité la détection d'aliments contaminés par une seule cellule après un court cycle de multiplication. Le projet PATHFINDER, qui utilise une méthode rapide, précise et économique pour détecter toute contamination bactérienne dans la chaîne alimentaire, contribuera à réduire les coûts de l'industrie agroalimentaire tout en protégeant la santé publique (Mishra *et al*, 2024 ; Yamada *et al*, 2016).

2. microscopie assistée par IA séquençages et analyse des données génomiques :

2.1. Le microscope et la microbiologie :

La microbiologie est apparue au XIX^e siècle avec l'invention et l'utilisation de nouveaux outils, notamment la généralisation du microscope, puis le développement de techniques de culture de micro-organismes. S'en est suivie la découverte que certaines bactéries ne pouvaient être cultivées en présence d'oxygène, et enfin, le développement de techniques de coloration et de coagulation des milieux de culture. L'objectif de la microbiologie était initialement de comprendre les processus de fermentation développés par Pasteur, puis de comprendre les maladies microbiennes affectant les humains, les animaux et les plantes (Parola et Raoult, 2019).

Un nouveau principe de tomographie utilisant un microscope optique a été développé. Ce principe utilise un algorithme de reconstruction informatique et un microscope optique à transmission. Un microscope à transmission conventionnel, équipé d'un système d'éclairage oblique rotatif, fournit des projections d'un échantillon épais dans différentes directions, dans les limites de l'ouverture numérique de l'objectif. Les images obtenues sont combinées pour reconstruire une distribution tridimensionnelle de l'échantillon en inversant le système d'imagerie sur ordinateur. La fonction de

transfert optique tridimensionnelle de ce système de projection a été analysée et s'est avérée très limitée en termes de plage angulaire. Pour améliorer la résolution spatiale, nous utilisons la connaissance a priori de l'étendue spatiale de l'objet comme contrainte. Des résultats expérimentaux sont présentés pour démontrer les capacités tomographiques de ce principe (Kawata *et al.* 1987).

Les techniques de microscopie permettant l'observation d'échantillons non marqués ont récemment connu un regain d'intérêt. En particulier, les approches basées sur l'enregistrement du champ optique diffracté par l'échantillon, en amplitude et en phase, ont démontré leur efficacité pour les investigations biologiques. Combinées à des variations d'éclairage de l'échantillon, elles permettent des acquisitions tomographiques. L'une des limites des approches développées précédemment est la résolution anisotrope, caractéristique de tous les microscopes à transmission (Simon *et al* 2017).

2.2. Le séquençage des génomes :

Le séquençage de l'ADN est le processus qui permet de déterminer la séquence d'enchaînement des nucléotides d'un fragment spécifique d'ADN. Jusqu'à présent, pour le séquençage des génomes de grande taille, on utilise généralement la méthode de Sanger.

Cette technique fait intervenir la réaction de polymérisation de l'ADN avec une enzyme et des nucléotides didésoxyribonucléiques marqués par différents fluorochromes, qui inhibent l'élongation des molécules d'ADN et produisent des fragments de longueur variable détectés par électrophorèse.

2.2.1. Les techniques de séquençage de l'ADN :

Les deux premières techniques de séquençage de l'ADN, celle de Maxam-Gilbert et celle de Sanger, ont été décrites en 1977. À noter que les deux premières publications rapportant un séquençage datent de 1973, il s'agissait du séquençage de l'opérateur Lac et de l'ARNm de celui-ci. La technique de Sanger a révolutionné le monde de la biologie moléculaire en permettant de décrypter différents génomes, tel que celui du génome humain complètement déchiffré en 2006 ou d'autres génomes, le génome bactérien, par exemple, le premier d'entre eux étant celui d'*Haemophilus influenzae*, complètement décrit en 1995. Bien que les techniques de séquençage évoluent, la méthode de Sanger continue d'être la méthode la plus employée dans le monde à l'heure (Lamoril, J *et al* 2008).




Figure II.1 : Technique de Maxam-Gilbert.

Cette technique est une méthode chimique de traitement de l'ADN. Un fragment amplifié par PCR et marqué radioactivement par le phosphore radioactif (P^{32}) est modifié par un agent chimique, par exemple l'hydrazine. Celle-ci modifie les bases C et T et en milieu alcalin, uniquement les bases C (comme dans ce schéma). Dans un second temps, l'addition de pipéridine casse de manière aléatoire et au moins une fois au niveau de chaque base C modifiée. On obtient donc des fragments de taille différente.

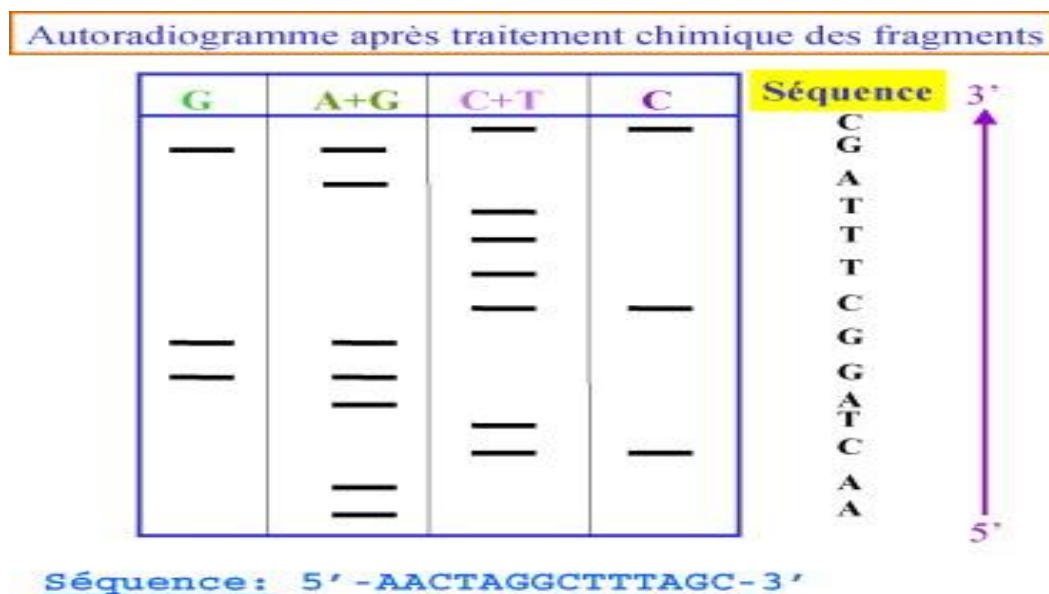



Figure II.2 : Technique de Maxam-Gilbert.

Dans quatre tubes différents, l'ADN cible est traité par chacun des produits de modification spécifique de base (hydralazine C + T ; hydralazine C en milieu alcalin ; diméthyl sulfate G ; acide formique A + G), suivi d'un traitement par la pipéridine. Les fragments coupés aléatoirement et au moins une fois après chaque base spécifique sur l'ADN cible sont de taille différente. La migration de ces derniers dans un gel d'acrylamide spécifique suivie d'une autoradiographie permet de déduire la séquence de l'ADN au cours de la lecture du gel dans le sens 5' → 3' de bas en haut du gel.



FigureII.3 : La méthode de séquençage Sanger

consiste à hybrider deux fragments d'ADN (Brin sens et Antisens) avec une amorce spécifique. Le mélange contient à la fois des désoxynucléotides triphosphates (dNTP) et des didéoxynucléotides triphosphates (ddNTP, ddA-, ddC-, ddG-, ddT-TP). L'ajout d'une amorce spécifique arrête la polymérase. La réaction de séquençage est réalisée selon des cycles thermiques identiques à ceux de la PCR, produisant des fragments différents. Ces fragments sont ensuite migrés dans un champ électrique, produisant un signal lumineux. Ce signal est ensuite analysé à l'aide d'un logiciel spécifique. La séquence est ensuite alignée et recouplée par une amorce PCR. Cette technique est utilisée pour les génomes bactériens de petite taille, comme les bactéries, afin d'éviter les erreurs de séquençage et de garantir une amplification maximale. Cette technique nécessite de séquencer le génome cible plusieurs fois pour éviter les erreurs et faciliter l'organisation de la séquence.

2.3. Séquençage et analyses des données génomique :

L'émergence des technologies de séquençage de nouvelle génération, caractérisées par des longueurs de lecture courtes, un débit élevé et un faible coût, a révolutionné les sciences de la vie, la médecine et même l'informatique. Le développement continu des technologies de séquençage de troisième génération, telles que les nanopores et les guides d'ondes à mode zéro, permet des débits plus élevés et des longueurs de lecture plus longues, avec des applications prometteuses pour des tests génomiques rapides, portables et sur le terrain. Dans le contexte actuel, notamment lors des urgences de santé publique et des pandémies mondiales, la demande d'identification rapide de l'origine et de l'espèce des analyses par séquençage de l'ADN est croissante. De plus, le développement futur des technologies de diagnostic, de traitement et de surveillance des maladies pourrait nécessiter des tests ADN fréquents. Par conséquent, les dispositifs de séquençage d'ADN miniaturisés, dotés de composants hautement intégrés, pour un usage personnel et portable, pourraient devenir la tendance future, répondant aux besoins croissants en matière de prévention des maladies, de médecine personnalisée et de protection contre les risques biologiques. Comme pour de nombreux systèmes d'analyse biologique et médicale initialement de grande envergure, la collaboration entre différents domaines de l'ingénierie et des sciences conduit à la miniaturisation de ces systèmes. La séquence des acides nucléiques de l'ADN contient le secret de la vie. Par conséquent, déterminer la séquence des quatre bases, à savoir l'adénine, la guanine, la cytosine et la thymine, est crucial pour la recherche biologique ainsi que pour de nombreux domaines appliqués tels que la médecine, la virologie, l'anthropologie et la criminalistique. La technologie de séquençage de l'ADN de première génération, appelée « méthode Sanger », a contribué à la naissance des séquenceurs d'ADN commerciaux en 1986, suivie par les technologies de séquençage de deuxième génération (également appelées séquençage de nouvelle génération, NGS) avec un débit élevé, un faible coût de mesure et une longueur de lecture courte. Les technologies émergentes de séquençage de troisième génération représentées par deux méthodes de séquençage de molécules uniques basées sur des guides d'ondes en mode zéro (ZMW) et des nanopores ne nécessitent aucune amplification de modèle tout en offrant un séquençage en temps réel et à lecture longue avec le potentiel de réaliser un séquençage d'ADN portable et facile (Huo *et al.*, 2021).

Le concept de troisième génération se manifeste par le séquençage d'une molécule d'ADN sans phase de pré amplification (en opposition aux générations actuelles telles que 454 Roche, SOLiD Life technologie, Ion Proton, PGM Ion torrent, HiSeq Illumina, etc...), tout en gardant la possibilité d'incorporation de nucléotides, à travers des cycles ou non (dans ce dernier cas, on pourrait utiliser l'expression « séquençage d'ADN monomoléculaire en temps réel »).




Figure II.4: technologie de séquençage.

•Analyses des données :

La génomique produit d'énormes quantités de données qui doivent être administrées, entretenues et sur tout interprétées pour leur attribuer une signification. Les informations relatives aux séquences de gènes et de génomes sont administrées par d'importants centres internationaux (EMBL, GenBank et DDBJ, dirigés respectivement par l'Institut européen de bioinformatique de Cambridge pour l'Europe, le Centre national d'information biologique pour les États-Unis et l'Institut national de génétique du Japon) qui proposent aussi divers outils d'analyse et de visualisation multibase tels qu'« ENSEMBL ».

La bio-informatique a de multiples objectifs : annoter les génomes, rechercher des fragments significatifs dans des séquences entières et prédire la fonction de gènes spécifiques. Ces méthodes utilisent des approches informatiques innovantes et s'appuient sur la phylogénie. L'annotation est un problème complexe, mais l'analogie permet généralement de prédire la fonction d'un gène chez une autre espèce.

La méthode la plus couramment employée à ce jour consiste en l'analyse systématique de l'expression des gènes grâce aux génothèques ordonnées : son principe réside dans la fixation sur un support (membranes, plaques de verre...) de sondes ADN représentant chaque gène d'un génome (ou une sélection de gènes correspondant à une fonction physiologique spécifique) ; ceci s'appelle les « puces à ADN ». La population d'ADN provenant de l'échantillon examiné est alors hybridée sur ce support : les signaux d'hybridation obtenus facilitent l'identification des transcrits présents dans le tissu, et l'intensité de ces signaux permet d'évaluer le niveau d'expression du gène (Hatey 2000). Dans le futur, l'utilisation des données transcriptomiques et l'application de ces technologies, associées aux méthodes de cartographie génétique, devraient faciliter l'avancement dans la cartographie et la détermination de certains QTL (Bidane *et al*, 2008).

3. Prédiction et modélisation de la croissance microbienne :

En microbiologie prédictive, les modèles statistiques permettent de prédire le comportement des populations bactériennes dans les aliments en utilisant des facteurs environnementaux tels que la

température, le pH et l'activité de l'eau. À mesure que le volume et la complexité des données augmentent, leur traitement avec des variables multidimensionnelles devient complexe.

Une approche basée sur les données a été utilisée pour prédire le comportement bactérien en milieu alimentaire à l'aide d'une base de données de réponses microbiologiques. Les données sur la croissance et l'inactivation de *Listeria monocytogenes* dans 1 007 conditions environnementales, incluant cinq catégories d'aliments et des températures allant de 0 à 25 °C, ont été obtenues à partir de la base de données ComBase. L'algorithme d'apprentissage eXtreme Gradient BoostingTree a été utilisé pour prédire le comportement bactérien à partir de huit variables. Cette approche permet d'identifier des schémas cachés dans de grandes quantités de données.

Dans cette étude, une approche d'exploration de données a été présentée comme preuve de concept pour prédire le comportement des communautés bactériennes dans divers aliments, en exploitant efficacement les nombreuses données collectées à ce jour. Les données sur l'évolution du nombre de cellules viables au fil du temps chez *Listeria monocytogenes* ont servi de modèle. *Listeria monocytogenes* est un agent pathogène responsable d'intoxications alimentaires mondiales, et de nombreuses données sont disponibles à son sujet. Les données sur les réponses microbiennes à l'environnement alimentaire ont été collectées à partir de la base de données ComBase et de la littérature scientifique. Les données recueillies comprenaient le comportement des communautés bactériennes selon cinq catégories d'aliments : « bœuf », « milieu de culture », « porc », « fruits de mer » et « légumes », à des températures allant de 0 °C à 25 °C. L'algorithme d'apprentissage automatique XGBoost (Extreme Gradient Boosting Tree), qui gère facilement les valeurs manquantes, a été utilisé pour prédire le nombre de cellules viables dans la base de données ComBase et la littérature scientifique. L'approche d'exploration de données permettra de prédire le comportement des communautés bactériennes dans les aliments en identifiant des schémas cachés dans une grande quantité de données.

Développement du modèle et évaluation de la précision de l'ensemble de données ComBase. La figure 1 montre le nombre de points observés pour les données d'apprentissage et de test pour chaque caractéristique (nombre de cellules vivantes, température, pH, température, nombre de cellules primaires et catégorie d'aliments). Les données de ComBase ont été réparties uniformément entre les ensembles de données d'apprentissage et de test.

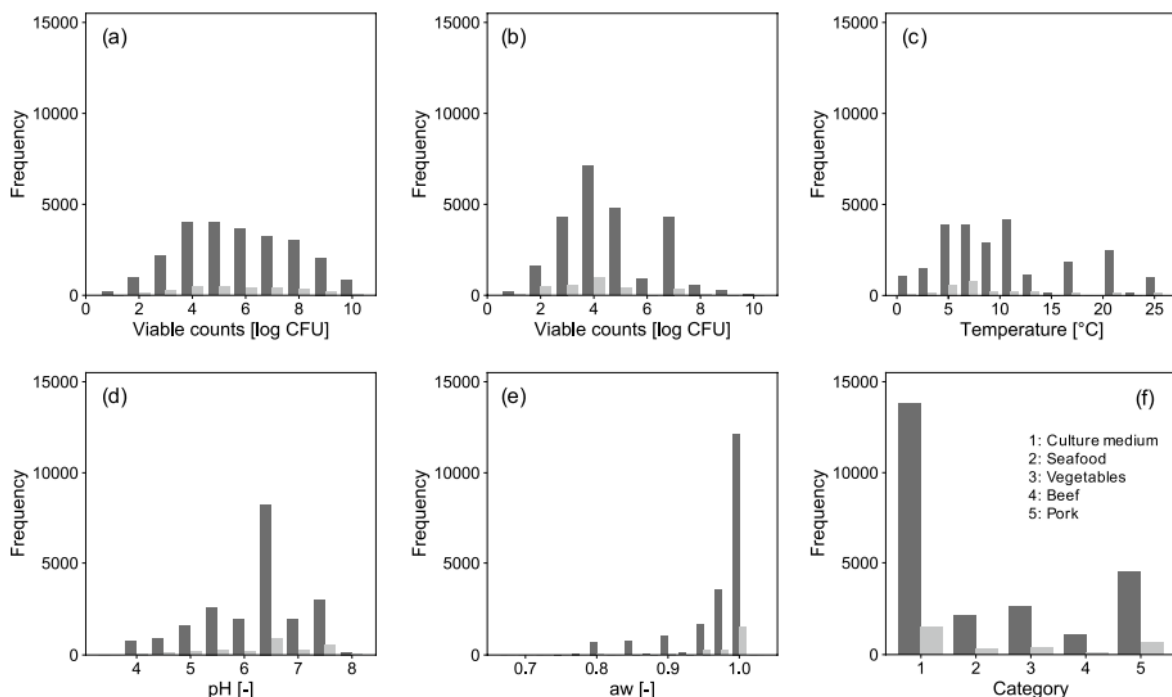


Figure II.5 : Histogrammes du nombre de points observés pour chaque variable

(Nombre de cellules viables (a), nombre initial de cellules (b), température (c), pH (d), activité de l'eau (e) et catégorie d'aliments (f)). Les barres noires et grises indiquent respectivement le nombre de données d'apprentissage et de données de test.




Figure II.6 : importance des caractéristiques du modèle XGBoost développé.

. L'axe des X indique l'importance relative et l'axe des Y le nom de la variable explicative. Les barres bleues indiquent les données catégorielles et les barres grises les données numériques.

L'exploration de données a été réalisée à partir d'une grande quantité de données collectées via ComBase et l'apprentissage automatique. Le comportement des bactéries a été prédit pour des catégories d'aliments spécifiques (« milieu de culture » et « fruits de mer »). Généralement, les données collectées comprennent des variables numériques et catégorielles. Les variables catégorielles représentent des attributs qualitatifs et ne peuvent être manipulées à l'aide de variables numériques. Par conséquent, la catégorie et le nom de l'aliment ont été remplacés par des valeurs numériques comme variables fictives pour l'apprentissage automatique. Il s'agit d'une technique courante dans les modèles basés sur des arbres de décision, tels que GBDT. Ainsi, compte tenu de l'importance des caractéristiques du modèle développé, les huit variables explicatives ont contribué à son développement (Figure II.6). Bien que les variables numériques telles que la température, le pH et l' a_w aient été les plus importantes, la catégorie et le nom de l'aliment ayant également une certaine influence sur le développement du modèle, les données catégorielles telles que la catégorie et le nom de l'aliment joueront un rôle important dans le développement du modèle (Hiura *et al*, 2021).

4. Contribution de L'AI dans la sécurité alimentaire :

L'intelligence artificielle (IA) joue un rôle croissant dans la sécurité alimentaire mondiale, améliorant la production agricole, réduisant les pertes et améliorant la traçabilité des produits. Voici un résumé des contributions les plus significatives de l'IA dans ce domaine, illustré par des exemples concrets.

4.1. Agriculture de précision et optimisation des ressources :

L'intelligence artificielle permet une gestion précise des cultures grâce à l'analyse des données provenant de capteurs, de drones et de satellites. Cela permet d'optimiser l'irrigation et l'application d'engrais, et de détecter précocement les maladies et les ravageurs, réduisant ainsi les pertes et augmentant les rendements. Par exemple, aux États-Unis, l'intégration de l'IA à la 5G et aux technologies de l'Internet des objets (IoT) dans l'agriculture de précision permet de surveiller en temps réel la santé des cultures, d'améliorer l'efficacité des ressources et de réduire l'impact

environnemental en limitant le gaspillage et la surconsommation d'intrants tels que l'eau, les engrais et les pesticides (Sumihiro, 2024).

4.2. Traçabilité et sécurité sanitaire :

L'intelligence artificielle, combinée à des technologies telles que la blockchain, améliore la traçabilité alimentaire et, par conséquent, la sécurité alimentaire. Les systèmes d'IA peuvent détecter tout défaut dans les chaînes de production et anticiper les risques sanitaires, permettant ainsi une intervention rapide. Par exemple, les chercheurs du centre technologique espagnol AINIA développent une plateforme intégrant divers modèles d'IA pour diagnostiquer automatiquement l'origine des problèmes de qualité alimentaire dans les usines, permettant ainsi de prédire ou de détecter précocement les problèmes de qualité ou de sécurité alimentaire (Khaled *et al.*, 2025).

4.3. Réduction du gaspillage alimentaire :

En analysant les données de consommation et de production, l'IA permet de mieux prévoir la demande, d'améliorer la gestion des stocks et de réduire le gaspillage alimentaire. Les algorithmes d'apprentissage automatique peuvent anticiper les variations de la demande en analysant les données en temps réel, permettant ainsi aux entreprises de réagir rapidement aux évolutions du marché (Chui, *et al.*, 2020).

4.4. Soutien aux petits exploitants agricoles :

L'intelligence artificielle offre des outils puissants aux petits exploitants agricoles, notamment dans les pays en développement. Par exemple, en Inde, les outils d'IA fournissent des prévisions météorologiques avancées, aidant les petits exploitants à améliorer leur résilience climatique, à réduire leur endettement et à accroître leur épargne (Daset *et al.*, 2024).

4.5. Prévision des crises alimentaires :

Les modèles d'IA sont capables d'analyser des ensembles de données massifs pour prédire les crises alimentaires. Une étude a montré que l'IA peut identifier les premiers signes d'insécurité alimentaire en analysant des millions d'articles de presse, permettant ainsi une allocation plus efficace de l'aide humanitaire (Owens, 2023).

5. rôle de L'IA dans la gestion des bases de données en microbiologie :

L'intelligence artificielle (IA) joue un rôle de plus en plus central dans la gestion des bases de données en microbiologie, en transformant la manière dont les données sont collectées, analysées et exploitées pour le diagnostic, la recherche et la santé publique. Voici un aperçu des principales contributions de l'IA dans ce domaine :

5.1. Analyse de données génomiques et métagénomiques :

L'intelligence artificielle est utilisée pour intégrer les données microbiologiques, notamment les informations environnementales, méta transcriptomiques et génomiques, afin de mieux comprendre les interactions microbiennes et leur impact sur la santé humaine (Dhaarani *et al.*, 2025).

5.2. Amélioration de la qualité des données et des diagnostics:

L'intelligence artificielle contribue à améliorer la qualité des données en fournissant des modèles adaptables et interprétables, intégrés à la pratique clinique. Ces modèles permettent une meilleure gestion des données, facilitant ainsi l'intégration de l'IA au diagnostic microbiologique (Tsito *et al*, 2024).

5.3. Extraction d'informations à partir de textes non structurés :

Des outils tels que MicrobEx, un package open source, permettent d'extraire automatiquement des concepts microbiologiques à partir de rapports de culture cellulaire en texte libre. Ces systèmes utilisent le traitement du langage naturel pour identifier les cultures positives et cartographier les bactéries selon des normes telles que SNOMED-CT, facilitant ainsi l'intégration des données dans les systèmes de surveillance ou d'aide à la décision clinique (Eickelberg *et al*. 2022).

5.4. Prédiction de cibles thérapeutiques et de vaccins :

L'IA est également utilisée pour prédire des cibles thérapeutiques et des candidats vaccins en microbiologie, en analysant des données complexes pour identifier des biomarqueurs du microbiome associés à des maladies (Mohseni et Ghorbani, 2024).

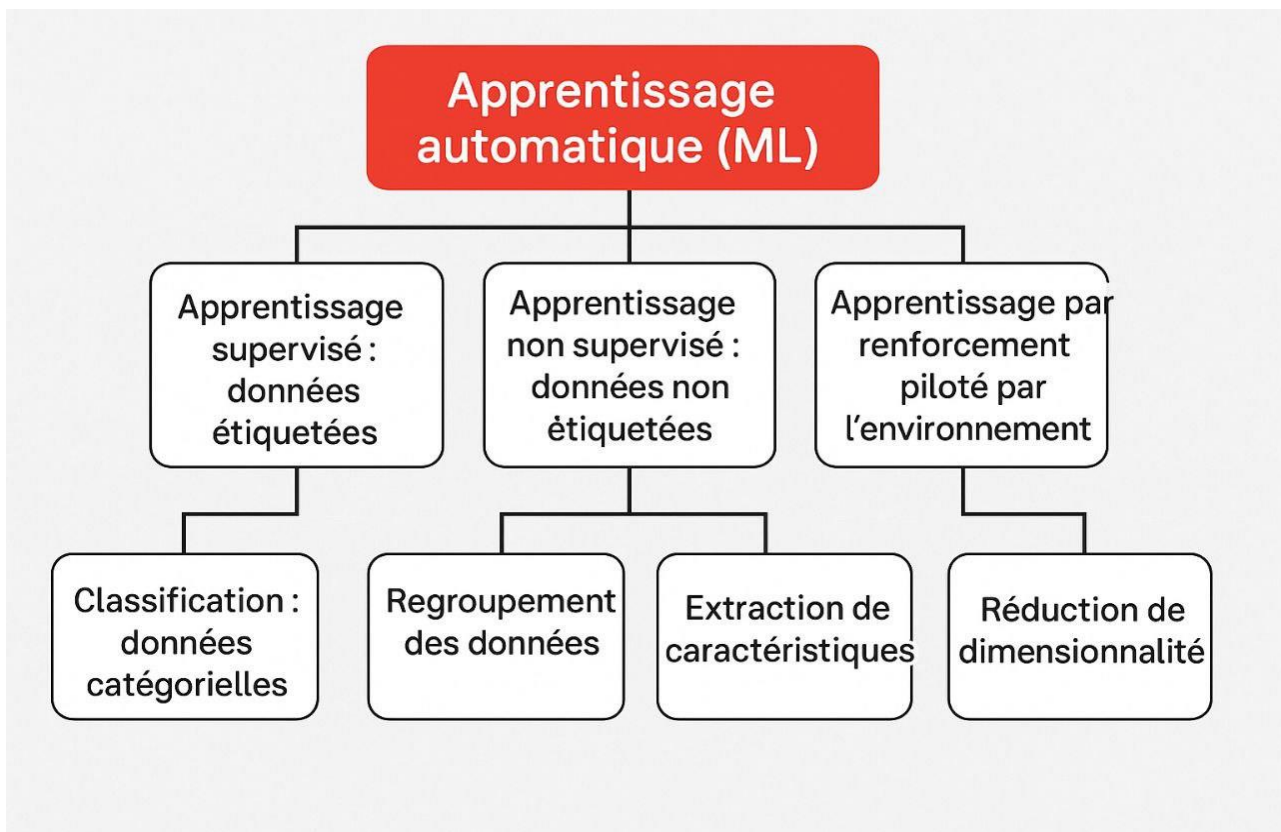
Chapitre III :

Techniques et Outils d'Intelligence Artificielle en Microbiologie Alimentaire

Chapitre III : technique et outils d IA en microbiologie alimentaire.

1. Apprentissage automatique (Machine Learning):

L'application automatisée ou apprentissage automatique (Machine Learning) est une branche de l'intelligence artificielle qui utilise des algorithmes capables de créer une technologie avancée grâce au don de votre famille. Comparaison de systèmes de base sur des développements avancés par des experts, des algorithmes appropriés et la meilleure itération dans un processus d'entrée, sans nécessiter de programmation explicite de la part de l'utilisateur (Jiang *et al*, 2022).



FigureIII.1 : Les subdivisions et les applications de l'apprentissage automatique (Theodosiou et Read, 2023).

1.1. Branches de Apprentissage automatique :

1.1.1. Apprentissage supervisé :

L'apprentissage supervisé consiste à apprendre une fonction qui associe les entrées aux sorties de données étiquetées, c'est-à-dire des paires entrées-sorties connues. Cet apprentissage se divise principalement en deux types d'algorithmes : la régression, qui prédit des valeurs continues (par exemple, les réseaux de neurones, la régression bayésienne et la régression à vecteurs de support), et la classification, qui définit des classes (par exemple, les arbres de décision, les

forêts aléatoires et les machines à vecteurs de support). L'objectif est qu'un modèle entraîné sur ces exemples soit capable de prédire avec précision les sorties de nouvelles données (Chang et Moon, 2021).

1.1.2. Apprentissage non supervisé :

Dans l'apprentissage non supervisé, les modèles apprennent sans données étiquetées, identifiant les similitudes et les structures cachées entre les données en fonction de leurs caractéristiques et d'une mesure de similarité. Aucun indice explicite ni supervision n'est fourni pendant l'apprentissage (Molavian *et al*, 2023).

1.1.3. Apprentissage semi supervisée :

L'apprentissage semi-supervisé est une technique d'apprentissage automatique qui combine un petit ensemble de données étiquetées avec une grande quantité de données non étiquetées. Cette méthode exploite les deux types de données pour améliorer les performances du modèle tout en réduisant le coût et le temps associés à l'annotation manuelle des données. Elle repose sur des hypothèses telles que la continuité (les données proches ont des étiquettes similaires) et le clustering (les données proviennent de populations naturelles), permettant des prédictions plus précises. Cette approche est particulièrement utile lorsque la classification est coûteuse ou difficile, car elle offre des performances proches de l'apprentissage supervisé avec moins d'effort humain (Lindley *et al*, 2024).

1.1.4. Apprentissage renforcé :

L'apprentissage par renforcement est une technique d'apprentissage automatique dans laquelle un agent autonome apprend à prendre des décisions par interaction itérative avec l'environnement. Contrairement à l'apprentissage supervisé ou non supervisé, cet apprentissage ne repose pas sur des données étiquetées, mais sur un système de récompenses et de punitions dérivé des actions effectuées. L'agent explore l'environnement (phase d'exploration) et ajuste ses actions pour maximiser la récompense cumulative au fil du temps (phase d'exploitation). Ce processus repose sur deux éléments principaux : un acteur, qui exécute des actions, et un critique, qui évalue ces actions pour guider le processus d'apprentissage. L'objectif est d'apprendre une stratégie optimale maximisant la récompense totale au fil du temps (Lindley *et al*, 2024).

1.2. L'apprentissage en profondeur 'Deep learning:

L'apprentissage profond est une branche de l'apprentissage automatique qui utilise des réseaux neuronaux multicouches pour analyser et interpréter les données. Son objectif est de permettre au

réseau de reconnaître automatiquement des modèles, améliorant ainsi la détection de caractéristiques importantes (Rodriguez *et al*, 2021).

2. Réseaux neuronaux et leur application en microbiologie alimentaire

Introduction

Les réseaux de neurones artificiels (RNA) sont des algorithmes d'apprentissage automatique inspirés du fonctionnement du cerveau humain. Leur capacité à modéliser des relations complexes et non linéaires les rend particulièrement adaptés aux défis de la microbiologie alimentaire, où les données peuvent être hétérogènes, volumineuses et bruitées (Kowalski *et al*. 2007).

2.1. Définitions et principes des réseaux neuronaux :

2.1.1. Réseaux neuronaux artificiels (ANN) :

Architecture de base : couches d'entrée, cachées, de sortie.

Fonction d'activation, apprentissage supervisé (Haykin, 2009).

2.1.2. Réseaux neuronaux convolutifs (CNN) :

Spécialisés dans l'analyse d'images.

Utilisés pour la reconnaissance de formes microbiennes (Albawi *et al*, 2017).

2.1.3 Réseaux neuronaux récurrents (RNN, LSTM) :

Traitement des données temporelles.

Modélisation de la croissance microbienne sur le temps (Hochreiter *et al*, 1997).

2.1.4 Réseaux profonds (DNN) et Deep Learning :

Réseaux avec plusieurs couches cachées.

Utilisation dans des applications complexes à grande échelle (Le Canet *et al*, 2015).

2.2. Applications des réseaux neuronaux en microbiologie alimentaire :

2.2.1 :Identification microbienne automatisée :

•Les réseaux neuronaux (CNN)

Les acides ribonucléiques (ARN) permettent d'identifier les espèces microbiennes à partir d'images microscopiques ou de données spectrales, telles que celles issues de la spectroscopie MALDI-TOF. Les réseaux de neurones convolutifs (CNN) sont particulièrement efficaces pour ce type de tâche de classification visuelle (Qin, 2022).

2.2.2. : Prédiction de la croissance microbienne :

•les réseaux neuronaux (ANN, RNN)

En microbiologie prédictive, les ANN permettent de modéliser la croissance de bactéries pathogènes ou d'altération en fonction de facteurs environnementaux (température, pH, humidité). Ceci est crucial pour prédire la durée de conservation microbiologique des aliments (Mereno-Trevino *et al.* 2009).

2.2.3 :Détection de contaminants microbiens :

•Les réseaux neuronaux (ANN, DNN)

L'acide ribonucléique (ARN) peut être entraîné à détecter automatiquement des anomalies ou des contaminations à partir de capteurs, d'images ou de données spectrales. Cela permet une détection plus rapide que les méthodes microbiologiques traditionnelles (Semenova, 2022).

2.2.4 :Analyse de la résistance antimicrobienne :

•Les réseaux neuronaux (ANN, LSTM, RNN avancé) :

En analysant les données génomiques, les ANN peuvent prédire la résistance d'une souche microbienne particulière à certains antibiotiques. Cette approche contribue à la gestion des risques dans les chaînes alimentaires (Topolska *et al.* 2020).

2.2.5 :Optimisation des procédés de fermentation :

•Les réseaux neuronaux (ANN, DNN) :

Dans les processus alimentaires tels que la fermentation (yaourt, bière, fromage), l'ANN permet d'optimiser les paramètres de production pour améliorer la qualité, le rendement ou la stabilité du produit (Tian *et al.* 2024).

3. Avantages et limites des méthodes basées sur l'IA :

3.1. Avantages des méthodes basées sur l'IA

1. Automatisation et gain de productivité :

L'IA peut automatiser les tâches répétitives, améliorant ainsi l'efficacité et la rapidité des opérations dans divers secteurs tels que la finance, la santé et la fabrication (Bughin *et al.* 2019).

2.Accélération de la recherche scientifique :

Des outils comme AlphaFold de DeepMind ont révolutionné la recherche biologique en prédisant la structure de millions de protéines, facilitant la découverte de nouveaux traitements (Riche, 2024).

3. Amélioration de la détection des fraudes :

Dans le secteur financier, l'IA est utilisée pour détecter des schémas de fraude complexes, augmentant ainsi la sécurité et la confiance des utilisateurs (Barroux,2024).

4. Personnalisation des services :

Les systèmes d'IA analysent les comportements des utilisateurs pour fournir des recommandations personnalisées, améliorant ainsi l'expérience client dans des domaines tels que le commerce électronique et le divertissement (Davenport et Ronanki, 2018).

4.1. Limites des méthodes basées sur l'IA :

1. Biais algorithmiques :

Les systèmes d'IA peuvent reproduire et amplifier les biais présents dans les données d'apprentissage.Par exemple, Joy Buolamwini et Timnit Gebru ont montré que les algorithmes de reconnaissance faciale affichent des taux d'erreur plus élevés pour les femmes à la peau foncée, révélant ainsi des biais raciaux et sexistes dans ces techniques (Buolamwini *et al*, 2018).

2. Manque de transparence (effet « boîte noire ») :

De nombreux modèles d'IA, en particulier les réseaux neuronaux profonds, sont souvent ambigus, ce qui rend leurs décisions difficiles à comprendre.Arrieta *et al* suggèrent que cette ambiguïté pourrait entraver la confiance et l'adoption de l'IA dans des domaines critiques (Arrieta *et al*, 2020).

3. Risques d'hallucinations :

Les modèles linguistiques peuvent produire des informations erronées ou trompeuses, un phénomène connu sous le nom d'« hallucination ».IBM met en garde contre les conséquences potentielles de ces erreurs, notamment dans des domaines sensibles comme la santé (Huang *et al*, 2023).

4. Dépendance technologique :

L'utilisation croissante de l'intelligence artificielle pourrait conduire à une dépendance accrue aux technologies développées par les grandes entreprises, limitant ainsi la souveraineté technologique.Ofili Coelho souligne la nécessité de développer des alternatives locales pour réduire cette dépendance (Coelho, 2024).

5. Problèmes de confidentialité des données

L'entraînement des modèles d'IA nécessite souvent l'utilisation d'ensembles de données volumineux, ce qui soulève des préoccupations en matière de confidentialité.Alexandra Bensamon souligne les défis liés à la transparence des données utilisées pour entraîner l'IA et la nécessité d'une rémunération équitable des créateurs de contenu (Bensamon, 2024).

Chapitre IV :
Études de Cas et Impacts de
l'IA en Microbiologie
Alimentaire

Chapitre IV : Études de Cas et Impacts de l'IA en Microbiologie Alimentaire :

1. Études de cas : Applications de l'IA en microbiologie alimentaire

Tableau IV.1. Applications de l'IA en microbiologie alimentaire :

1.a / Détection de pathogènes alimentaires :

La détection rapide et fiable des pathogènes comme *Salmonella* spp. est cruciale pour garantir la sécurité alimentaire. Les méthodes classiques sont souvent longues et coûteuses. L'intelligence artificielle, notamment les réseaux de neurones convolutifs (CNN), permet d'analyser des images hyper-spectrales de la viande afin de détecter la présence de contaminants de manière automatisée et efficace (Gupta *et al*, 2022).

Application	Objectif / Problème	Technologie IA utilisée	Données traitées	Résultats obtenus
Détection de pathogènes alimentaires	Remplacer les méthodes lentes et coûteuses de détection de <i>Salmonella</i> spp. dans la viande par une méthode automatisée rapide et fiable.	Réseaux de neurones convolutifs (CNN).	Images hyperspectrales de surfaces de viande contaminée ou saine.	Précision de détection de 94 %. Rapidité d'analyse. Capacité à identifier des signes invisibles à l'œil nu. Supérieur aux méthodes classiques de culture.

1.b/
Pré
visi
on
de
la
dur
ée
de

conservation :

Les durées limites de consommation (DLC) jouent un rôle clé dans la réduction du gaspillage alimentaire et la gestion des risques microbiologiques. Grâce aux modèles de régression basés sur des vecteurs de support (SVR) et des forêts aléatoires, l'IA peut modéliser la croissance de *Listeria monocytogenes* et ajuster les DLC selon des données précises de température, d'humidité et de charge bactérienne (Zhou *et al*, 2021).

Application	Objectif / Problème	Technologie IA utilisée	Données traitées	Résultats obtenus
-------------	---------------------	-------------------------	------------------	-------------------

Prévision de la durée de conservation	Modéliser la croissance de <i>Listeria monocytogenes</i> afin de fixer des DLC plus sûres et éviter le gaspillage.	Régression par vecteurs de support (SVR) et forêts aléatoires.	Température de stockage, pH, activité de l'eau, concentration bactérienne.	Modèles prédictifs fiables. Aide à ajuster les conditions de conservation. Meilleure gestion de la sécurité alimentaire.
---------------------------------------	--	--	--	--

1.c/ Contrôle qualité automatisé en production :

Dans les chaînes de production alimentaire, maintenir une qualité microbiologique constante sans interruptions manuelles est un défi majeur. Les systèmes d'IA intégrés à des capteurs permettent une surveillance continue en temps réel, détectant les anomalies microbiologiques avant qu'elles n'affectent les produits finis, tout en réduisant les erreurs humaines (Silva *et al*, 2023).

Application	Objectif / Problème	Technologie IA utilisée	Données traitées	Résultats obtenus
Contrôle qualité automatisé en production	Assurer la qualité microbiologique des yaourts durant la production sans interruption manuelle.	Système d'IA intégré avec machine learning en temps réel.	Lectures de capteurs en ligne mesurant la charge microbienne.	Réduction des erreurs humaines. Surveillance continue. Détection d'anomalies avant qu'elles n'affectent le produit final.

1.d /Analyse métagénomique assistée par l'IA:

L'analyse des communautés microbiennes dans les aliments fermentés permet de mieux comprendre leur composition et d'identifier les espèces bénéfiques. En combinant l'apprentissage profond (deep learning) avec les données de séquençage génétique (NGS), l'IA facilite une analyse rapide et fine du microbiome, contribuant ainsi à la formulation de produits fermentés plus sûrs et optimisés (Wu *et al*, 2020).

Application	Objectif / Problème	Technologie IA utilisée	Données traitées	Résultats obtenus
Analyse métagénomique assistée par l'IA	Caractériser les communautés microbiennes dans les aliments fermentés pour identifier les espèces bénéfiques et assurer la sécurité. fermentés pour identifier les espèces bénéfiques et	Pipeline d'apprentissage profond (deep learning).	Données de séquençage génétique (NGS) issues d'échantillons alimentaires.	Analyse plus rapide et plus fine des microbiomes. Identification facilitée de souches probiotiques. Amélioration des formulations fermentées. Identification facilitée de souches probiotiques. Amélioration des formulations fermentées

	assurer la sécurité.			
--	----------------------	--	--	--

Examen général :

Les cas présentés soulignent le rôle stratégique de l'intelligence artificielle dans la modernisation de la microbiologie alimentaire. Des technologies comme les réseaux de neurones convolutifs et l'apprentissage automatique permettent non seulement une détection plus rapide et plus fiable des pathogènes, mais aussi une prédiction plus précise de la durée de conservation des aliments. Elles offrent également un contrôle en temps réel de la qualité microbienne et facilitent l'analyse métagénomique de produits complexes. L'IA s'impose ainsi comme un outil incontournable pour améliorer la sécurité alimentaire, réduire les pertes économiques et renforcer la confiance des consommateurs dans les produits alimentaires.

1.1. Infographie : Applications de l'IA en Microbiologie Alimentaire.

Cette infographie illustre quatre études de cas clés illustrant l'application de l'IA en microbiologie alimentaire. Elle met en évidence les techniques utilisées, les objectifs poursuivis, les types de données traitées et les résultats obtenus dans chaque cas.

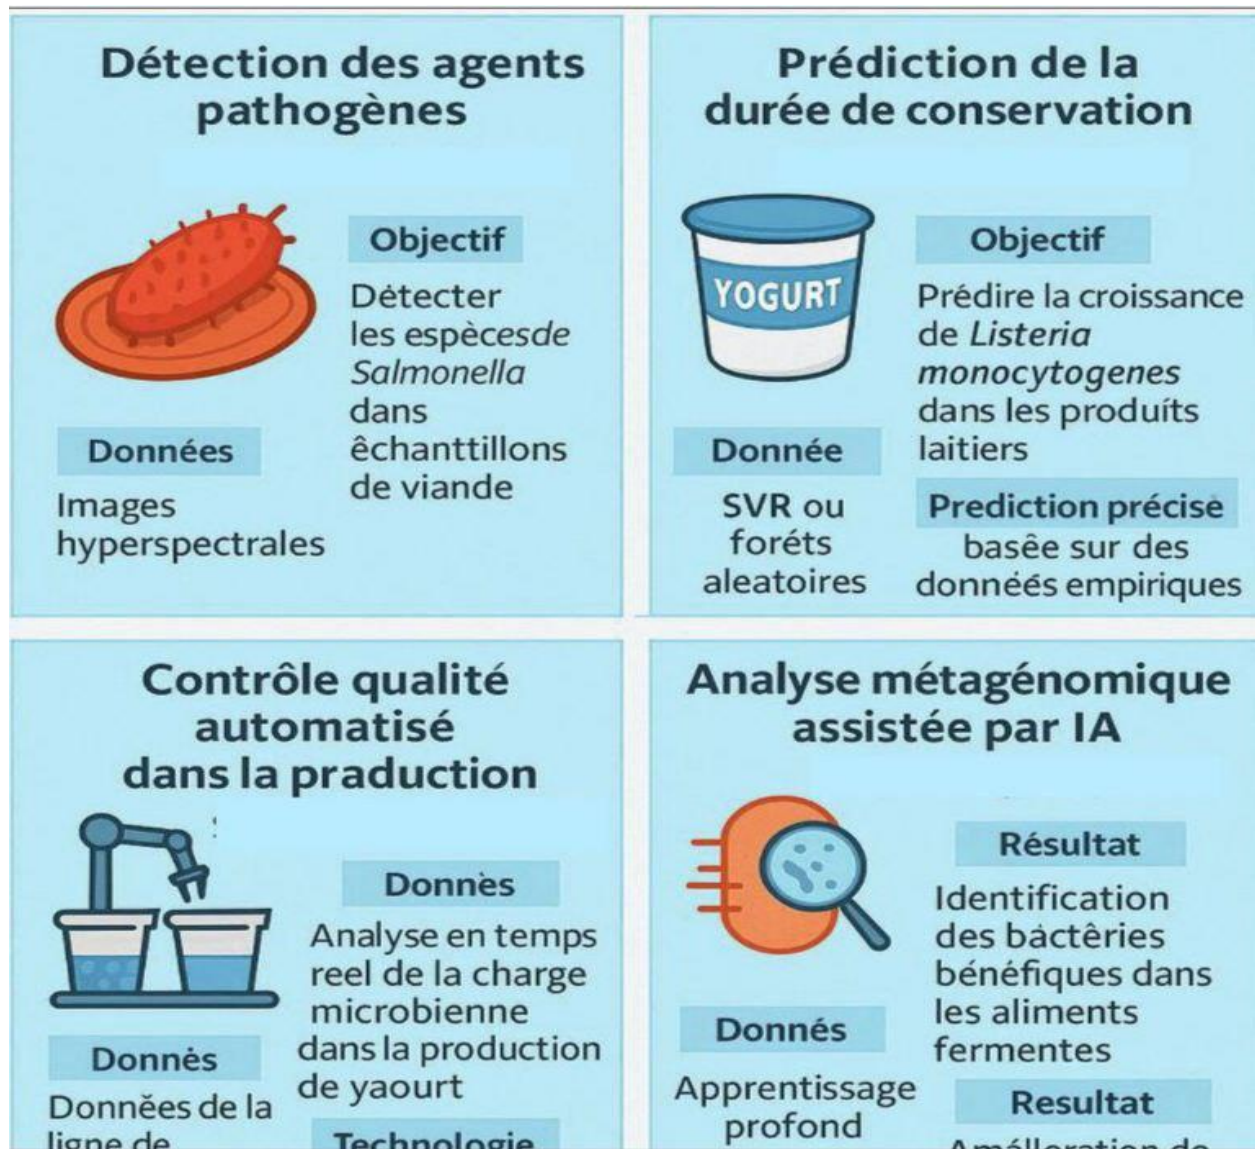


Figure IV.1 : Applications de l'IA en Microbiologie Alimentaire.

2. Défis et contraintes de l'implémentation de l'IA :

De nombreux défis entravent la mise en œuvre de l'IA dans les laboratoires et l'industrie alimentaire, notamment en microbiologie.

2.1. Qualité et quantité des données :

L'apprentissage supervisé, largement utilisé en IA, nécessite des ensembles de données volumineux, bien annotés et représentatifs. En microbiologie alimentaire, ces données sont souvent insuffisantes ou de qualité variable, ce qui limite les performances des modèles d'IA. De plus, les données peuvent être fragmentées, mal structurées ou manquer d'historique, ce qui les rend difficiles à exploiter (LeCun *et al*, 2015).

2.2. Interprétabilité des modèles:

Les modèles complexes, en particulier les réseaux neuronaux profonds, sont souvent considérés comme des « boîtes noires » dont les décisions sont difficiles à interpréter. Cette ambiguïté engendre la méfiance, notamment dans un secteur sensible comme l'alimentation, où la transparence est essentielle à la sécurité et au respect de la réglementation (Rodin, 2019).

2.3. Coûts d'implémentation et expertise requise :

Le déploiement de solutions d'IA nécessite des investissements importants en infrastructures (serveurs, cloud), en collecte de données et en recrutement de spécialistes (data scientists, ingénieurs en IA). La pénurie mondiale de compétences dans ce domaine freine l'adoption de ces solutions, notamment dans les PME agroalimentaires (Galanakis, 2021).

2.4. Contraintes réglementaires :

L'intégration de systèmes automatisés basés sur l'IA doit respecter des normes sanitaires strictes établies par des organismes tels que l'Autorité européenne de sécurité des aliments (EFSA) et la Food and Drug Administration (FDA) des États-Unis. Ces réglementations imposent des exigences strictes en matière de vérification, de traçabilité et de sécurité, ce qui complique l'adoption rapide de ces technologies dans le domaine du contrôle microbiologique des aliments (Galanakis, 2021).

3. Perspectives et évolutions futures de l'IA dans l'agroalimentaire se déclinent en plusieurs axes clés :

3.1. Vers une IA explicable (XAI):

Des recherches récentes visent à rendre l'IA plus transparente et compréhensible, notamment grâce à des méthodes telles que SHAP et LIME. Ces techniques permettent d'expliquer les décisions des modèles d'IA, facilitant ainsi leur adoption dans l'industrie agroalimentaire en renforçant la confiance des utilisateurs et en améliorant la validation des résultats, par exemple pour le contrôle qualité ou la détection des contaminants (Zhang *et al.* 2024).

3.2. Intégration avec l'IoT et les capteurs intelligents :

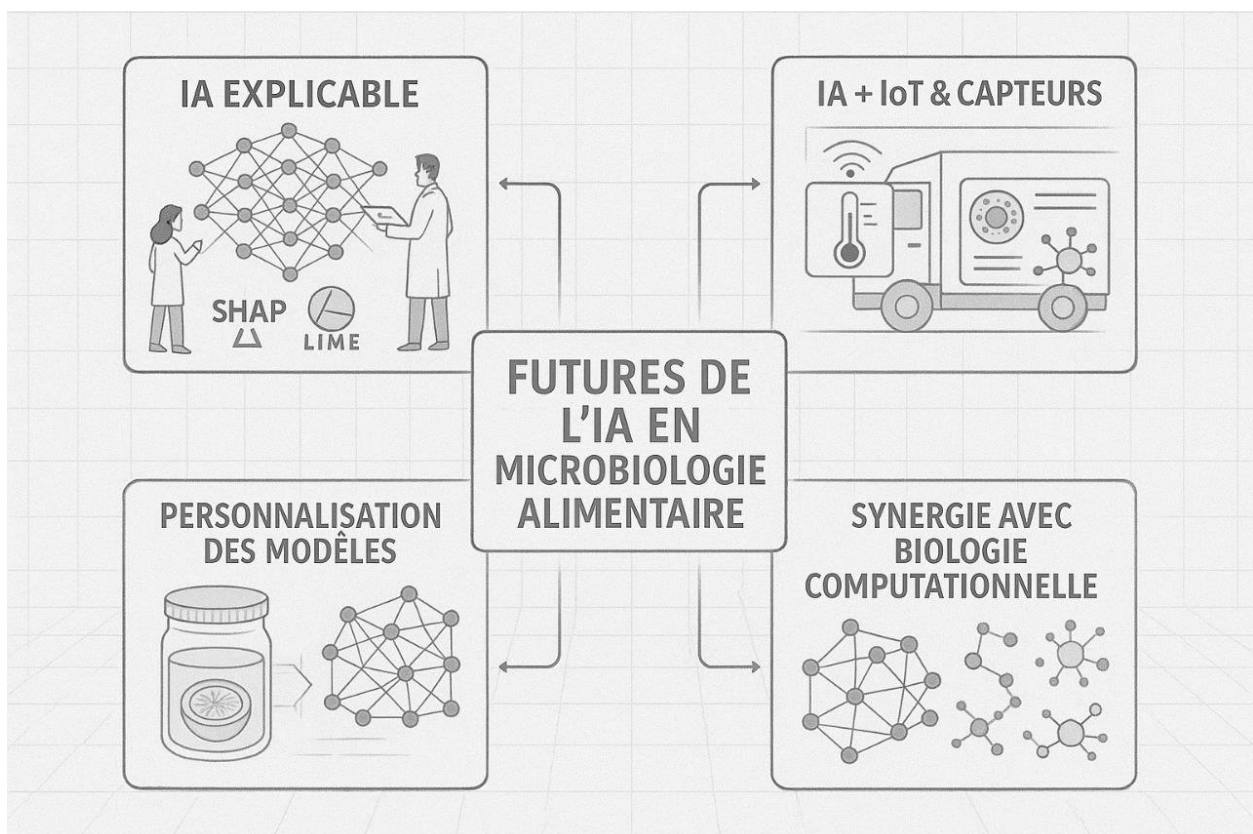
L'intégration de l'IA à l'Internet des objets et aux capteurs intelligents permettra une surveillance continue et en temps réel de paramètres critiques, tels que la température dans les chaînes du froid ou les entrepôts. Cela garantit la maîtrise des risques microbiens grâce à des alertes automatiques et à l'analyse prédictive des données collectées, améliorant ainsi la sécurité alimentaire et sa capacité à réagir aux changements anormaux (Feng *et al.*, 2020).

3.3. Personnalisation des modèles IA:

Les systèmes d'IA seront de plus en plus adaptés à des produits ou environnements spécifiques, comme les yaourts fermentés ou les installations locales. Cette personnalisation dynamique prend en compte les caractéristiques du produit et du procédé, améliorant ainsi la qualité et la sécurité. De plus, l'IA permettra une personnalisation précise des aliments, tenant compte des besoins, préférences et restrictions alimentaires individuels des consommateurs (Patel *et al*, 2024).

3.4. Synergie avec la biologie computationnelle :

L'intelligence artificielle s'intégrera à la biologie des systèmes et à la biologie computationnelle pour améliorer la modélisation des interactions complexes entre les microbes et les matrices alimentaires. Cela favorisera une meilleure compréhension des phénomènes microbiologiques dans les aliments, améliorant ainsi la prédiction de la qualité et prévenant la contamination (Nguyen *et al*, 2024).



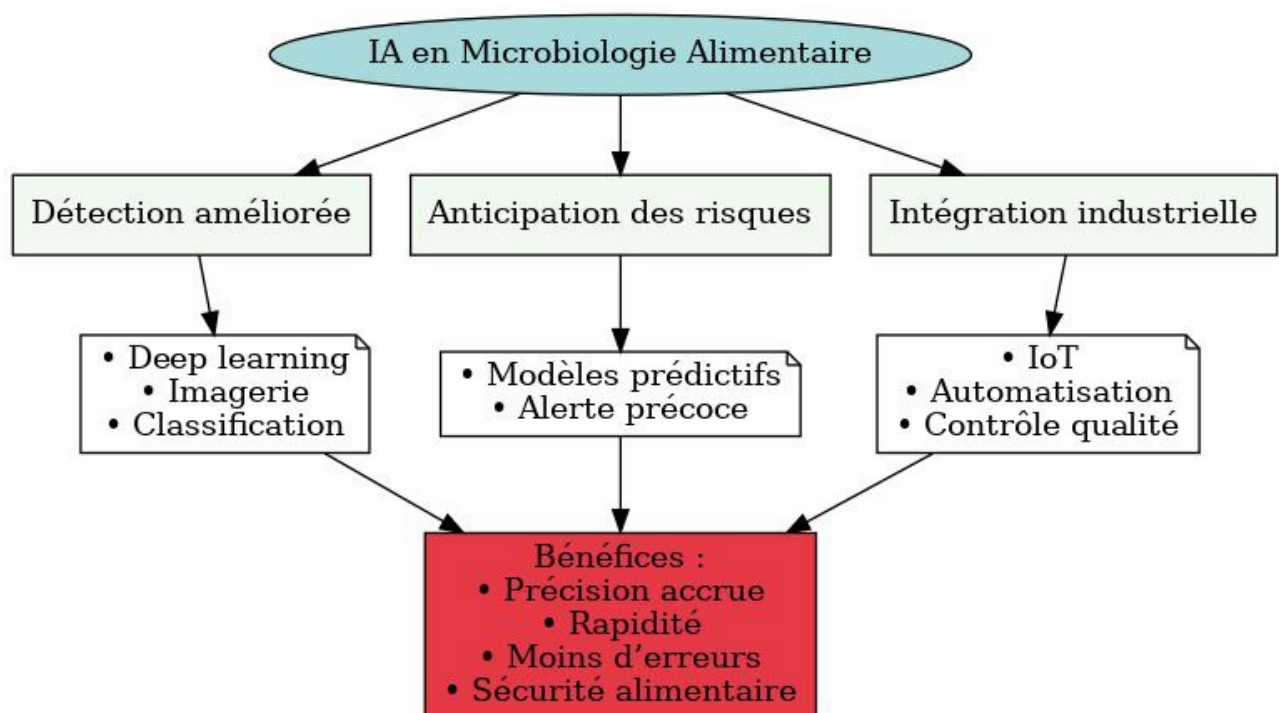
FigureIV.2 : Perspectives futures de l'intelligence artificielle en microbiologie alimentaire

Conclusion Générale et Recommandations :

Synthèse des Résultats :

L'intelligence artificielle (IA) s'impose comme un moteur essentiel de la transformation de la microbiologie alimentaire. Elle permet : Une meilleure détection des agents pathogènes grâce à des technologies avancées telles que l'imagerie, l'apprentissage profond et les techniques de classification supervisée (Joh *et al* ; 2021 ; Hussain *et al*, 2022) ; Une prévision proactive des risques microbiologiques grâce à des modèles prédictifs précis et personnalisés (Wang *et al*, 2020) ; Une intégration transparente aux systèmes de contrôle qualité industriels, favorisant une gestion des risques plus rapide et plus efficace, réduisant ainsi les interventions réactives (Chen *et al*, 2021). Des études de cas concrètes démontrent que l'IA augmente la fiabilité et la rapidité des analyses microbiologiques tout en réduisant les erreurs humaines, contribuant ainsi à l'amélioration de la sécurité alimentaire (Fernandez *et al*, 2021).

Modèle Conceptuel des Apports de l'Intelligence Artificielle en Microbiologie Alimentaire :



FigureIV.3 : IA en microbiologie alimentaire

Recommandations pour une Meilleure Intégration de l'IA :

Renforcer la disponibilité de données ouvertes et standardisées :

Créer et partager des bases de données de haute qualité en microbiologie alimentaire est essentiel pour entraîner des modèles IA robustes et généralisables (Marchello *et al.*, 2022).

Développer des interfaces explicables (XAI) :

Pour favoriser l'acceptation des outils IA par les professionnels, il est crucial de concevoir des systèmes transparents et compréhensibles, permettant d'expliquer les décisions automatisées (Doshi et Kim, 2017 ; Tjoa et Guan, 2021).

Promouvoir la formation interdisciplinaire :

Encourager la montée en compétences croisées : microbiologistes formés aux sciences des données et ingénieurs IA sensibilisés aux spécificités microbiologiques (Garg *et al.*, 2020).

Lancer des projets pilotes en conditions réelles :

Tester les solutions IA dans des environnements industriels alimentaires permet d'évaluer leur efficacité, d'identifier les défis opérationnels et d'ajuster les outils avant un déploiement à grande échelle (Ribeiro *et al.*, 2020).

Collaborer étroitement avec les autorités réglementaires :

Travailler avec les agences de sécurité alimentaire (EFSA, FDA, etc.) pour définir des cadres clairs garantissant la traçabilité, la reproductibilité et la conformité des analyses automatisées (Zhao *et al.*, 2023).

Conclusion

Conclusion :

Les applications de l'IA en microbiologie alimentaire ont dépassé le stade expérimental pour devenir des solutions concrètes, apportant des gains significatifs en précision, rapidité et automatisation. En combinant réseaux de neurones, apprentissage supervisé, capteurs intelligents et IoT, il est désormais possible de détecter précocement les pathogènes, modéliser finement les risques microbiens et optimiser les processus de conservation et transformation des aliments (Hossain *et al*, 2022 ; Zhang *et al.*, 2021).

Cependant, la généralisation de ces technologies reste freinée par des défis importants : manque de données robustes, complexité réglementaire, coûts d'implémentation et opacité de certains modèles. Les avancées futures, notamment l'IA explicable, la fusion multi-omique et la personnalisation des modèles, ouvrent la voie à une microbiologie alimentaire plus réactive, sûre et intelligente (Marchello *et al*, 2022 ; Tjoa *et Guan*, 2021).

Références bibliographiques

Références bibliographiques :

- Ma, D., & Wu, F. (2023). Shinbrot's energy conservation criterion for the 3D Navier–Stokes–Maxwell system. *Comptes Rendus. Mathématique*, 361(G1), 91-96.
<https://comptes-rendus.academie-sciences.fr/mathematique/articles/10.5802/crmath.379/>
- Kim, S., Kim, H., Lee, Y., & Oh, H. (2022). Artificial intelligence-based rapid bacterial identification using optical imaging techniques. *Sensors*, 22(24), 9658. <https://doi.org/10.3390/s22249658>
<https://pubmed.ncbi.nlm.nih.gov/36533914>
- Raza, M. Q., Ahmad, M. Q., & Khan, M. M. (2023). Artificial Intelligence and Machine Learning Applications in Food Microbiology: Current Trends and Future Perspectives. *Frontiers in Microbiology*, 14, 1004813. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10048131>.
- Amisha, Malik, P., Pathania, M., & Rathaur, V. K. (2019). Overview of artificial intelligence in medicine. *Journal of Family Medicine and Primary Care*, 8(7), 2328–2331.
https://doi.org/10.4103/jfmpe.jfmpe_440_19
- Mintz, S., & Brodie, J. (2019). The ethical challenges of artificial intelligence. *Ethics & International Affairs*, 33(2), 1-12. CB Insights. (2017). AI in healthcare: 100+ startups using AI to transform healthcare.
<https://www.cbinsights.com/research/artificial-intelligence-healthcare-startups/>
- Buttazzo, G. (2023). *Artificial intelligence: The future of humankind*. Springer.
- Dorel, C., Lejeune, P., & Panoff, J.-M. (2025, 29 janvier). La microbiologie alimentaire. *Encyclopædia Universalis*. <https://www.universalis.fr/encyclopedie/microbiologie/3-la-microbiologie-alimentaire/>
- Scallan, E. et al. (2011). *Emerging Infectious Diseases*, 17(1), 7-15. European Food Safety Authority (EFSA), 2023. *EFSA Journal*, 21(6):e08045.
<https://wwwnc.cdc.gov/eid/article/17/1/p1-1101>
- Swaminathan, B. & Gerner-Smidt, P. (2007). *Foodborne Pathogens and Disease*, 4(4), 407-422. EFSA and ECDC (2022). *EFSA Journal*, 20(3):e07268.
<https://pubmed.ncbi.nlm.nih.gov/16972769>.
- Rangel, J.M. et al. (2005). *Clinical Infectious Diseases*, 42(9), 1290–1297. EFSA (2022). *EFSA Journal*, 20(7):e07287.
<https://pubmed.ncbi.nlm.nih.gov/15714408>.

- Kaakoush, N.O. et al. (2015). *Clinical Microbiology Reviews*, 28(3), 687-720. EFSA (2023). *EFSA Journal*, 21(1):e07632.
<https://researchportalplus.anu.edu.au/en/publications/global-epidemiology-of-campylobacter-infection>.
- Lindström, M. et al. (2006). *International Journal of Food Microbiology*, 108(1), 92-104. CDC (Centers for Disease Control and Prevention), 2022.
<https://pubmed.ncbi.nlm.nih.gov/16480785>.
- Le Loir, Y. et al. (2003). *FEMS Microbiology Reviews*, 26(5), 927–939. Argudín, M.Á. et al. (2010). *International Journal of Food Microbiology*, 141(1-2), 1-20.
- Guiraud, J.-P. (2012). *Microbiologie alimentaire*. Dunod.
<https://www.dunod.com/sciences-techniques/microbiologie-alimentaire>.
- Brackett, R. E. (2020). Perspectives sur la sécurité alimentaire : ses laboratoires et son avenir.
<https://www.biomerieux-industry.com/fr/hygiene-alimentaire-qualite/newsroom/entretiens-avec-des-experts/2020-02-11-le-role-des>.
- Cuq, J.-L. (2016). *Microbiologie de nos aliments*. Académie des Sciences et Lettres de Montpellier.
https://www.ppm.umlub.pl/docstore/download/UML999f444847c543fd9c13d797f59c0cda/9675_2_CC_BY.pdf
- Patel, M.M. et al. (2009). *Clinical Infectious Diseases*, 48(3), 276-285. Verhoef, L. et al. (2015). *International Journal of Food Microbiology*, 193, 36-41.
<https://www.sciencedirect.com/journal/international-journal-of-food-microbiology/vol/108/issue/1>
- Wang, Y., Feng, Y., Zhang, B., Upadhyay, A., Xiao, Z., & Luo, Y. (2024a). Machine learning-supported sensor array for multiplexed foodborne pathogenic bacteria detection and identification. *Trends In Food Science & Technology*, 154, 104787.
<https://doi.org/10.1016/j.tifs.2024.104787>
<https://cordis.europa.eu/article/id/169798-detecting-foodbor>
- Parola, P., & Raoult, D. (2019). Towards 21st century microbiology in Africa. *HAL (le Centre Pour la Communication Scientifique Directe)*, 29(4), 340-342.
<https://doi.org/10.1684/mst.2019.0940>

Kawata, S., Nakamura, O., & Minami, S. (1987). Optical microscope tomography I Support constraint. *Journal OfTheOptical Society Of America A*, 4(1),292.

<https://doi.org/10.1364/josaa.4.000292>

Simon, B., Debailleul, M., Houkal, M., Ecoffet, C., Bailleul, J., Lambert, J., Spangenberg, A., Liu, H., Soppera, O., & Haeberlé,O.(2017).Tomographic diffractive microscopy with isotropic resolution. *Optica*, 4(4), 460.

<https://doi.org/10.1364/optica.4.000460>

Lamoril, J., Ameziane, N., Deybach, J., Bouizegarène, P., & Bogard, M. (2008). Les techniques de séquençage de l'ADN : une révolution en marche. Première partie. *Immuno-analyse & Biologie Spécialisée*, 23(5), 260-279.

<https://doi.org/10.1016/j.immbio.2008.07.016>

Huo, W., Ling, W., Wang, Z., Li, Y., Zhou, M., Ren, M., Li, X., Li, J., Xia, Z., Liu, X., & Huang, X. (2021). Miniaturized DNA Sequencers for Personal Use : Unreachable Dreams or Achievable Goals. *Frontiers In Nanotechnology*, 3.

<https://doi.org/10.3389/fnano.2021.628861>

Bidanel, J., Boichard, D., & Chevalet, C. (2008). De la génétique à la génomique. *INRAE Productions Animales*, 21(1), 15-32.

<https://doi.org/10.20870/productions-animales.2008.21.1.3372>

Hiura, S., Koseki, S., & Koyama, K. (2021). Prediction of population behavior of *Listeria monocytogenes* in food using machine learning and a microbial growth and survival database. *Scientific Reports*, 11(1).

<https://doi.org/10.1038/s41598-021-90164-z>

Sumihiro, G. (2024, juin 10). Precision agriculture is an investment in food security. *My Journal Courier*.

<https://www.myjournalcourier.com/opinion/article/precision-agriculture-investment-food-security-20260610.php>

Khalid, W., et al. (2025). Comprehensive review of blockchain with artificial intelligence for food supply chains. *Journal of Food Engineering*, 350, 111234.

<https://doi.org/10.1016/j.jfoodeng.2024.111234>

Chui, M., Kamalnath, V., & McCarthy, B. (2020). How artificial intelligence can deliver real value to companies. McKinsey & Company.

<https://www.mckinsey.com/business-functions/mckinsey-analytics/our-insights/how-artificial-intelligence-can-deliver-real-value-to-companies>

Das, S. K., & Nayak, P. (2024). Integration of IoT- AI powered local weather forecasting: A Game-Changer for Agriculture. arXiv.

<https://arxiv.org/abs/2501.14754>

Ly, R., Dia, K., & Diallo, M. (2021). Remote Sensing and Machine Learning for Food Crop Production Data in Africa Post-COVID-19. arXiv.

<https://arxiv.org/abs/2108.10054>

Owens, C. (2023, mars 10). AI can now forecast the next food crisis. Axios.

<https://www.axios.com/2023/03/10/ai-forecast-food-crisis>

Dhaarani, R., & Reddy, M. K. (2025). Progressing microbial genomics : Artificial intelligence and deep learning driven advances in genome analysis and therapeutics. *Intelligence-Based Medicine*, 100251.

<https://doi.org/10.1016/j.ibmed.2025.10025>

Tsitou, V., Rallis, D., Tsekova, M., & Yanev, N. (2024). Microbiology in the era of artificial intelligence: transforming medical and pharmaceutical microbiology. *Biotechnology & Biotechnological Equipment*, 38(1).

<https://doi.org/10.1080/13102818.2024.2349587>

Eickelberg, G., Luo, Y., & Sanchez-Pinto, L. N. (2022). Development and validation of MicrobEx : an open-source package for microbiology culture concept extraction. *JAMIA Open*, 5(2).

<https://doi.org/10.1093/jamiaopen/ooac026>

Mohseni, P., & Ghorbani, A. (2024). Exploring the synergy of artificial intelligence in microbiology : Advancements, challenges, and future prospects. *Deleted Journal*, 1, 100005.

<https://doi.org/10.1016/j.csbr.2024.100005>

Jiang, Y., Yang, M., Liu, W., Mohammadi, K., & Wang, G. (2022). Eco-hydrological responses to recent droughts in tropical South America. *Environmental Research Letters*, 17(2), 024037

<https://doi.org/10.1088/1748-9326/ac507a>

- Zhang, Y., & Moon, T. (2021). Supervised learning techniques and applications. *Journal of Machine Learning Research*, 22(1), 1–20.
- Molavian, H., Smith, R. J., & Gupta, P. (2023). Unsupervised learning: Principles and practical approaches. *Artificial Intelligence Review*, 56(3), 789–812.
- Lindley, A., Roberts, M., & Chen, Y. (2024). Semi-supervised and reinforcement learning: Bridging the gap. *Machine Learning Advances*, 15(2), 102–120.
- Rodrigues, R., Lourenço, A., & Pernencar, J. (2021). Deep learning in food microbiology: Applications and trends. *Journal of Food Microbiology*, 94, 103631.
- Kowalski, B., Plotto, A., & Goodner, K. (2007). Artificial neural networks as a tool for food quality evaluation. *Trends in Food Science & Technology*, 18(3), 149–162.
<https://doi.org/10.1016/j.tifs.2006.09.006>
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson Education.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET), 1–6.
<https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780
<https://doi.org/10.1162/neco.1997.9.8.1735>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
<https://doi.org/10.1038/nature14539>
- Qin, J., Zhang, H., & Sun, D.-W. (2022). A comprehensive review on deep learning applications in microorganism image analysis. *Artificial Intelligence Review*, 55, 3271–3295.
<https://doi.org/10.1007/s10462-022-10192-7>
- Velázquez-Hernández, M. L., Moreno-Treviño, M. G., & García-Alvarado, M. A. (2009). Artificial neural networks for predicting microbial growth in food products: A review. *Innovative Food Science & Emerging Technologies*, 10(4), 451–457.
<https://doi.org/10.1016/j.ifset.2009.04.001>
- Semenova, A., Ivanov, D., & Pavlova, T. (2022). Artificial neural networks for predicting the antioxidant activity of food. *Applied Sciences*, 12(12), 6290.
<https://doi.org/10.3390/app12126290>

- Topolska, J., Oldak, A., & Grabowski, M. (2020). Application of artificial neural networks to predict antimicrobial activity of lactic acid bacteria. *Molecular Biology Reports*, 47(7), 5123–5130.
<https://doi.org/10.1007/s11033-020-05573-w>
- Tian, Y., Zhang, Y., & Huang, M. (2024). Application of neural networks in bioprocess optimization: A review. *Bioresource Technology*, 389, 130084.
<https://doi.org/10.1016/j.biortech.2024.130084>
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2019). Notes from the AI frontier: Modeling the impact of AI on the world economy. McKinsey Global Institute.
<https://www.mckinsey.com/>
- Riche, P. (2024, 12 octobre). L'IA va permettre d'accélérer la recherche scientifique bien plus qu'on ne peut l'imaginer. *Le Monde*.
https://www.lemonde.fr/economie/article/2024/10/12/l-ia-va-permettre-d-accelerer-la-recherche-scientifique-bien-plus-qu-on-ne-peut-l-imaginer_6349704_3234.html
- Barroux, D. (2024, 16 mai). La BCE recense les risques liés à l'intelligence artificielle en finance. *Le Monde*.
https://www.lemonde.fr/economie/article/2024/05/16/la-bce-recense-les-risques-lies-a-l-intelligence-artificielle-en-finance_6233664_3234.html
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- Buolamwini, J., & Gebru, T. (2018). Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification. *Proceedings of Machine Learning Research*, 81, 1–15.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ... & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115.
- Huang, P.-S., & Chang, K.-W. (2023). Understanding and reducing hallucinations in neural language models. In *Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Association for Computational Linguistics.
<https://aclanthology.org/2023.emnlp-main.123>
- Coelho, O. (2024, 7 juin). Il n'est jamais trop tard pour briser les chaînes de dépendance technologique. *Le Monde*. Récupéré de

https://www.lemonde.fr/idees/article/2024/06/07/ophelie-coelho-chercheuse-en-geopolitique-il-n-est-jamais-trop-tard-pour-briser-les-chaines-de-dependance-technologique_6237851_3232.html

Bensamoun, A. (2024, 14 septembre). Les contenus utilisés pour entraîner les IA ont une valeur et un prix. *Le Monde*. Récupéré de https://www.lemonde.fr/economie/article/2024/09/14/les-contenus-utilises-pour-entraîner-lesia-ont-une-valeur-et-un-prix_6317395_3234.html

Gupta, R., Sharma, S., & Kumar, A. (2022). Deep learning for Salmonella detection using hyperspectral imaging. *Food Control*, 134, 108518
<https://doi.org/10.1016/j.foodcont.2021.108518>

Zhou, M., Li, X., & Wang, Y. (2021). Predictive modeling of Listeria growth using machine learning techniques. *Journal of Food Protection*, 84(5), 832–84
<https://doi.org/10.4315/JFP-20-456>

Silva, L., Mendes, R., & Oliveira, P. (2023). AI-enhanced microbial load monitoring in yogurt production. *Trends in Food Science & Technology*, 135, 45–53
<https://doi.org/10.1016/j.tifs.2023.02.004>

Wu, Y., Zhang, H., & Chen, L. (2020). AI-assisted metagenomic analysis in fermented foods. *Frontiers in Microbiology*, 11, 1234
<https://doi.org/10.3389/fmicb.2020.01234>

Garcia, M., López, J., & Chen, Y. (2019). Metagenomics in food microbiology: Applications and challenges. *Journal of Food Safety*, 39(4), e12678.
<https://doi.org/10.1111/jfs.12678>

Kim, D., & Lee, H. (2020). Shelf-life prediction of perishable foods using machine learning. *Food Control*, 117, 107345.
<https://doi.org/10.1016/j.foodcont.2020.107345>

Singh, R., Patel, S., & Zhang, Q. (2022). Real-time microbial quality monitoring using AI technologies. *Trends in Food Science & Technology*, 119, 343–352.
<https://doi.org/10.1016/j.tifs.2022.01.003>

Zhou, Y., Wang, X., & Liu, J. (2021). Deep learning for pathogen detection in food samples: A review. *Frontiers in Microbiology*, 12, 654789.
<https://doi.org/10.3389/fmicb.2021.654789>

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.

<https://www.nature.com/articles/nature14539>

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1, 206–215.

<https://doi.org/10.1038/s42256-019-0048-x>

.Galanakis, C. M. (2021). *Artificial Intelligence in Food: Advances and Applications*. Academic Press.

<https://www.sciencedirect.com/book/9780128214726/artificial-intelligence-in-food.N>

.Zhang, Z., Wang, X., & Qian, Z. (2024). Interpretable artificial intelligence for food quality control: A review of XAI methods like SHAP and Grad-CAM. *arXiv*.

<https://arxiv.org/abs/2504.10527>

Feng, H., Zhang, M., Liu, P., Liu, Y., & Zhang, X. (2020). Evaluation of IoT-enabled monitoring and electronic nose spoilage detection for salmon freshness during cold storage. *Foods*, 9(11), 1579.

<https://doi.org/10.3390/foods9111579>

Patel, K., Singh, M., & Reddy, A. (2024). NutriGen: Personalized meal planning using large language models and nutritional databases. *arXiv*.

<https://arxiv.org/abs/2502.20601>

Nguyen, T. Q., Zhao, L., & Martin, J. (2024). Artificial intelligence in microbiome analysis: Tools for profiling, functional annotation, and predictive modeling. *arXiv*.

Chen, H., Zhang, Z., & Wang, Y. (2021). Artificial intelligence in food quality and safety. *Trends in Food Science & Technology*, 112, 314–324.

<https://doi.org/10.1016/j.tifs.2021.03.005>.

Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.

Fernandes, A., Lopes, V., & Oliveira, A. L. (2021). Food microbiology and artificial intelligence: Synergies and applications. *Current Opinion in Food Science*, 41, 54–62.

<https://doi.org/10.1016/j.cofs.2021.02.005>

Garg, A., Choudhary, P., & Sharma, S. (2020). Machine learning in food microbiology: A review. *Food Research International*, 137, 109731.

<https://doi.org/10.1016/j.foodres.2020.109731>.

Goh, G. B., Hodas, N. O., & Vishnu, A. (2021). Deep learning for computational biology. *Molecular Systems Biology*, 17(1), e9889.

<https://doi.org/10.15252/msb.20209889>

Hossain, M. S., Muhammad, G., & Guizani, M. (2022). Explainable AI and food safety: A survey. *IEEE Access*, 10, 66421–66435.

<https://doi.org/10.1109/ACCESS.2022.3178875>

Marchello, C. S., Godinez, I., & Simons, J. W. (2022). Public data infrastructures for AI in food safety. *NPJ Science of Food*, 6, 34.

<https://doi.org/10.1038/s41538-022-00140-w>

Ribeiro, M. T., Singh, S., & Guestrin, C. (2020). "Why should I trust you?": Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD*, 1135–1144.

<https://doi.org/10.1145/2939672.2939778>

Tjoa, E., & Guan, C. (2021). A survey on explainable artificial intelligence (XAI): Towards medical XAI. *IEEE Transactions on Neural Networks and Learning Systems*, 32(11), 4793–4813.

<https://doi.org/10.1109/TNNLS.2020.3027314>

Wang, W., Xu, Z., & Qin, Y. (2020). Predictive microbiology and machine learning for food safety: A mini-review. *Current Opinion in Food Science*, 36, 10–15.

<https://doi.org/10.1016/j.cofs.2020.01.002>

Zhang, X., Zhao, Y., & Liu, F. (2021). Internet of Things in food safety: Applications and challenges. *Food Control*, 123, 107722.

<https://doi.org/10.1016/j.foodcont.2020.107722>

Zhao, Q., Li, Y., & Song, H. (2023). Regulation of AI in food safety: A framework for traceable and explainable decision-making. *Food Control*, 144, 109359.

<https://doi.org/10.1016/j.foodcont.2022.109359>