



HAL
open science

La place de l'intelligence artificielle dans la prédiction d'issues périnatales défavorables en obstétrique : une revue de la littérature

Lara Hollingworth

► **To cite this version:**

Lara Hollingworth. La place de l'intelligence artificielle dans la prédiction d'issues périnatales défavorables en obstétrique : une revue de la littérature. Médecine humaine et pathologie. 2023. dumas-04567345

HAL Id: dumas-04567345

<https://dumas.ccsd.cnrs.fr/dumas-04567345v1>

Submitted on 3 May 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



École de Sages-Femmes de Nice

UNIVERSITE COTE D'AZUR
Faculté de Médecine
ECOLE DE SAGES-FEMMES du CHU de NICE

La place de l'intelligence artificielle dans la prédiction d'issues périnatales défavorables en obstétrique : une revue de la littérature

Lara HOLLINGWORTH
Née le 16 Mai 1996
A Keighley, Royaume Uni

Mémoire présenté et soutenu le 20 Mars 2023
Directeur de mémoire : Dr BEREDER Jean-Marc

DIPLOME D'ETAT de SAGE-FEMME

2023

Remerciements

Un grand remerciement à mon directeur de mémoire, Dr Jean Marc BEREDER, pour son temps précieux, sa patience et sa bienveillance. Sans son expertise et son apport important, ce travail de mémoire n'aurait pas été possible.

Merci à Mme Alexandra MUSSO pour son soutien et son rôle de guidante de mémoire.

Merci à Mme Marielle BOURGEOIS pour son soutien et son rôle de cadre.

Merci à l'École de sages-femmes de Nice dans son intégrité pour ces dernières 4 années.

Un remerciement à ma famille entière pour leur soutien et d'avoir toujours cru en moi et mes projets - tout particulièrement à Amanda, Finn, Bridie, Kate, Andrew et Roo.

Un remerciement à ma future consœur, Camille CAFFIER, une étoile brillante qui a su illuminer même les jours les plus sombres. *Per aspera ad astra.*

Un remerciement particulier à Agathe DEVAUCHELLE pour son aide précieuse, son sourire et sa bienveillance dans la relecture de ce travail.

Ce mémoire est dédié à ma grande mère : Dr Ann FINGRET, qui n'est plus de ce monde mais à jamais dans mon cœur. Celle qui a toujours soutenu et nourri mon âme scientifique et de soignant. Je sais que tu es là avec moi tous les jours, j'espère t'avoir rendue fière.

Une dernière dédicace à notre reine Elizabeth II, qu'elle repose en paix :

"It has been women who have breathed gentleness and care into the harsh progress of mankind." - Queen Elizabeth II, Christmas broadcast, 1966.

God save the Queen.

Table des matières

Remerciements	2
Table des matières	3
Liste des Tableaux et Figures	5
Liste des Tableaux	5
Liste de Figures.....	5
Liste des abréviations.....	6
1. Introduction	7
1.1 Contexte : Risques périnataux en obstétrique	7
1.1.1 Morbi-mortalité en obstétrique : un état des lieux sombre	7
1.1.2 État des lieux sur pathologies inclus : prévalence, risques et issues:	8
1.1.2.1 La pré éclampsie	8
1.1.2.2 Le diabète gestationnel.....	9
1.1.2.3 Accouchement prématuré.....	10
1.1.2.4 L'hémorragie du post partum :	12
1.1.2.5 La dystocie des épaules :	13
1.2 IA : Histoire et définitions : synthèse:	15
1.2.1 Historique basique de l'intelligence artificielle :.....	15
1.2.2 Définitions:.....	17
1.3 IA : Solution pour une amélioration de la prédiction des risques ?	21
1.3.1 IA en santé : Motivations	21
1.3.2 Synthèse des méthodes actuelles d'IA en santé :	21
1.3.3 Tendances.....	24
1.3.3.1 Tendances : IA en santé	24
1.3.3.1 Tendances : IA en obstétrique:	25
2. Matériel et méthodes.....	27
2.1 Type d'étude :	27
2.2 Stratégie de recherche.....	27
2.2.1 Critères d'inclusion/ exclusion	27
2.2.2 Éligibilité finale :	27
2.3 Objectif principal.....	29
2.4 Objectif secondaire	29

3.	Résultats	30
3.1	IA en obstétrique : modèles et pathologies :	30
3.1.1	Syndromes prénataux : Diabète gestationnel :	30
3.1.2	Syndromes prénataux : Accouchement prématuré:	35
3.1.3	Syndromes prénataux : Pré éclampsie :	40
3.1.4	Situations per-natales : Analyse du CTG et hypoxie fœtale	44
3.1.5	Situations per-natales : Dystocie des épaules :	48
3.1.6	Situations per-natales : Hémorragie du post partum.....	49
3.1.7	IA en Obstétrique : Morbi-mortalité maternel et néonatale :	50
3.2	Données d'entraînement des modèles	53
3.3	Synthèse des résultats	54
4.	Discussion	59
4.1	Éthique de l'IA en santé.....	59
4.2	Fiabilité de l'IA : Risques, erreurs et lacunes	61
4.2.1	Risques : Erreurs :	61
4.2.2	Risques : Lacunes	61
4.3	Implications pour l'intégration de l'IA en pratique.....	63
4.3.1	Du concept au développement puis au déploiement :	63
4.3.1.1	Baseline pratique : un point de départ :	63
4.3.1.2	Déploiement.....	64
4.3.1.3	Post déploiement.....	65
4.4	Cas d'usages en place à présent :	66
4.4.1	Suog – « Smart Ultrasound in Obstetrics and Gynaecology »	66
4.4.2	Sonio – programme d'aide à la decision en échographie.....	66
4.4.3	QUiPP : Application NHS d'aide à la decision pour MAP :	67
4.5	Acceptabilité, perspectives et conclusion :	68
4.5.1	Acceptabilité : point de vu des patientes.....	68
4.5.2	Perspectives de l'IA en santé.....	69
4.5.3	Conclusion : IA en obstétrique :	71
	BIBLIOGRAPHIE	72
	ANNEXE 1	83

Liste des Tableaux et Figures

Liste des Tableaux

Tableau 1 : Récapitulatif : Facteurs de risques maternels de PE et risques maternels et fœtales de PE

Tableau 2 : Récapitulatif de la morbidité maternelle liée à l'HPP

Tableau 3 : Récapitulatif – Pathologies en obstétrique : taux, tendances et mortalité

Tableau 4 : Comparatif entre prédiction par réseau de neurones et clustering : Lee et al et Souza et al.

Tableau 5 : Synthèse comparatif des modèles d'IA d'analyse de CTG : types, buts et métriques de performances

Liste de Figures

Fig. 1 : Taux de naissance prématurée non spontanée : Zeitlin et al.

Fig. 2 : Diagramme de Venn de l'intelligence artificielle, Khalkar et al.

Fig. 3 : Exemple simplifié de classification d'images par algorithme

Fig. 4 : Nombre d'articles selon base de données : évolution par année.

Fig. 5 : Nombre de citations par années de l'obstétrique et l'IA : Ferdinand DHOBRES et al :

Fig. 6. Work flow de sélection des articles.

Fig. 7 : Répartition des articles sélectionnés selon sujet

Fig. 8 : Intersection entre morbi-mortalité maternelle et fœtale dans le cas d'issues obstétricales défavorables

Fig. 9 : Provenance des données d'entraînement pour les modèles de machine learning

Fig. 10 : Diagramme démontrant les différences entre accuracy (exactitude) et précision

Fig. 11 : Comparatif : AUC en fonction des modèles prédictives de diabète gestationnel

Fig. 12 : Comparatif de sensibilité et spécificité des modèles prédictives d'AP

Fig. 13 : Comparatif de l'AUC des modèles prédictives d'AP utilisant ce métrique

Fig. 14 : Comparatif de l'AUC des modèles prédictives de PE

Fig. 15 : Comparatif de l'AUC des modèles de prédiction de MMS

Fig. 16 : Synthèse des risques de l'IA en santé : Erreurs, biais, lacunes

Fig. 17 : Diagramme démontrant les différences entre accuracy (exactitude) et précision.

Liste des abréviations

- AP : Accouchement prématuré
- ANN : Artificial neural networks
- CTG: Cardiotocography / Cardiotocographie / Monitoring fœtale
- CNN : Convolutional neural networks : réseaux de neurones
- DEGs : Differently expressed genes
- DDE : Dystocie des épaules
- DG: Diabète gestationnel
- DPI : Dossiers patient informatisés
- DT2 : Diabète de type 2
- EBM : Evidence based medicine
- GAJ : Glycémie à jeun
- HAS : Haute autorité de santé
- HDL : High density lipoprotein : lipoprotéines de haute densité
- HPP / HDD : Hémorragie du post partum / Hémorragie de la délivrance
- IA : Intelligence artificielle
- IMC : Indice de masse corporelle
- LR : Logistical regression (regression logistic)
- MAP : Menace d'accouchement prématuré
- MiARN : MicroARN
- ML : Machine Learning
- MMS : Morbidité maternelle sévère
- PE : Pré éclampsie
- SDRA: Syndrome de détresse respiratoire aiguë.
- SVM : Support vector machine

1. Introduction

1.1 Contexte : Risques périnataux en obstétrique

1.1.1 Morbi-mortalité en obstétrique : un état des lieux sombre

État des lieux en France :

L'obstétrique est une spécialité englobant la santé de la femme, plus précisément au moment de la grossesse, l'accouchement et le post partum. Les différentes pathologies choisies pour ce travail de mémoire sont les pathologies les plus communes, avec un potentiel d'issue périnatale défavorable.

Selon un rapport INSERM sorti en 2021 , sur les données de 2013-2015 (1), 262 décès ont été identifiés, soit un décès d'une femme tous les 4 jours en France d'une cause liée à la grossesse. Le ratio de mortalité maternelle est d'environ 10,8 décès pour 100,000 naissances vivantes jusqu'à un an post partum.

La France est connue en tant que pays « exemplaire » au niveau de l'obstétrique, à la fois au niveau de la prise en charge des femmes que sur le niveau de compétences et d'enseignement universitaire des sages-femmes (niveau Bac+6 en France versus 3-4 ans ailleurs en Europe), mais le taux de mortalité maternelle demeure élevé. Sur les données mondiales de l'UNICEF, la France se situe au 20^e rang sur 27 pays de l'Europe pour les années 2016-2017, derrière la Croatie, la Slovénie et les autres pays majeurs européens.

L'enquête de 2016 d'INSERM (1) sur la mortalité maternelle met en valeur l'importance de la compréhension de ces décès, au-delà d'une compréhension étiologique des décès, pour relever des processus erronés qui ont mené ou contribué à ces décès. Il est estimé que 58% de ces décès étaient évitables (1) et dans 66% des cas des décès la prise en charge n'as pas été optimale (1), ce chiffre n'ayant pas baissé de façon significative depuis les années 2000.

Le constat est que la majorité des décès maternels en France sont évitables, nous laissant une marge d'amélioration large.

1.1.2 État des lieux sur pathologies inclus : prévalence, risques et issues:

1.1.2.1 La pré éclampsie

La pré éclampsie (PE) représente 2-8% des grossesses dans le monde, avec une morbi-mortalité significative. (2) En France, elle représente 40,000 cas par an et 1/3 des naissances prématurées (3). Selon un dossier réalisé par INSERM il s'agirait de la 2^e cause de mortalité maternelle. Le pronostic vital de la mère et du fœtus est mis en jeu dans 10% des cas. (3)

Facteurs de risques majeurs:	Risques : pour la mère et l'enfant :
Pathologie cardio-vasculaires préexistantes (2)	Mère :
Primigestes, primiparité (4)	Éclampsie, Hémorragie cérébrale (3)
Tabagisme (4)	Hématome retro- placentaire, décollement placentaire (3)
Antécédents d'hypertension (4)	Insuffisance rénale (3)
IMC > 30	HELLP syndrome :
Antécédents personnels ou familiaux de PE (4)	Hémolyse, transaminases augmentées, thrombopénie → DIC / CIVD coagulation intravasculaire disséminée, hémorragie massive (3)
Pathologies auto-immunes : Diabète, Lupus etc. (5)	Long terme : HTA chronique post partum, AVC, IDM, pathologies rénales, diabète. (3)
Age maternel extrême : < 20 ans, ou > 35ans (5)	Enfant :
Grossesses multiples (5)	- Retard de croissance intra-utérin d'origine vasculaire,
IR chronique (5)	- Petit poids pour l'âge gestationnel
	Conséquences de la prématurité induite :
	SDRA – syndrome de détresse respiratoire aigue
	HIV – Hémorragie intra-ventriculaire
	LPV – Leucomalacie péri-ventriculaire

Tableau 1 : Récapitulatif : Facteurs de risques maternels de PE et risques maternels et fœtales de PE

Traitement :

En dehors des traitements pharmaceutiques préventifs (Antiagrégants plaquettaires, Héparines de bas poids moléculaires (HBPM), vitamine D) et symptomatiques (antihypertenseurs) le seul traitement définitif est la naissance de l'enfant et la délivrance du placenta.

L'enjeu est donc de concilier bénéfice et risque : entre sauver la mère et faire naître le fœtus à un terme acceptable pour sa survie.

1.1.2.2 Le diabète gestationnel

Le diabète gestationnel (DG) représente 16,4 % des grossesses selon l'enquête nationale périnatale de 2021, versus 10,8% en 2016. (6)

Chez la mère :

- Un risque accru d'HTA gravidique, de prééclampsie et de césarienne. Ces risques sont corrélés de façon positive et linéaire au degré de l'hyperglycémie initiale. Le surpoids et l'obésité sont des facteurs de risque de prééclampsie et de césarienne indépendamment de l'hyperglycémie maternelle. Leur association avec le DG augmente les risques de prééclampsie et de césarienne par rapport aux femmes diabétiques ayant un IMC normal (grade B). (7)
- À long terme, un risque augmenté de développer ultérieurement un diabète de type 2. L'étude française « Diagest 2 » a trouvé que 6 ans après l'accouchement, 18 % ayant eu un DG ont développé un diabète de type 2 (DT2) allant jusqu'à 35 % à 11 ans (8). Le CNGOF estime que le risque de développer un DT2 après avoir eu un DG est multiplié par 7 par rapport à la population générale. (Grade B) (7)
- À long terme, le risque de survenue d'un syndrome métabolique est multiplié par 2 à 5 comparativement à la population générale. Le risque de pathologies cardiovasculaires est multiplié par 1,7 environ. (Grade B) (7)
- Risque de récurrence du DG d'environ 30 à 84% selon les études. (Grade B) (7)

Chez le fœtus :

- Risque de macrosomie augmenté (7) : augmentant possiblement les risques d'issues périnatales défavorables liées à la macrosomie : Dystocie des épaules, etc.
- Le risque d'hyperbilirubinémie est faiblement augmenté (grade A) (7)
- À long terme, certaines études montrent que les enfants issus d'une grossesse compliquée d'un diabète gestationnel ont un risque augmenté de surpoids, d'obésité et de développer un diabète type 2 dans leur vie future. (9)

1.1.2.3 Accouchement prématuré

Selon l'enquête nationale périnatale sur les naissances, le taux de menaces d'accouchement prématurés (MAP) nécessitant une hospitalisation reste stable. 4,8% des femmes ont été hospitalisées pour MAP dans le rapport de 2021 versus 5,4% dans le rapport de 2016 (6). La naissance prématurée concerne 15 millions d'enfants dans le monde chaque année, dont 60,000 en France (10). La prématurité a augmenté de 0.8% par an dans le monde entre 1990 et 2010, donc de quasiment 15% en 20 ans (10). Cette augmentation est principalement due à l'augmentation de la prématurité induite d'où la nécessité de travailler sur la prévention et une meilleure prise en charge des pathologies materno-fœtales.

En 2008, la France se situe au 12^e rang parmi 13 pays Européens (11), pour les naissances prématurés non spontanées (Fig.2), témoignant d'une potentielle divergence d'attitude de prise de charge des pathologies et de la prématurité induite.

NAISSANCES PREMATUREES NON SPONTANÉES

Pays	Année 2008	Rang
Estonie	1,1	1
Finland	1,1	2
Malte	1,1	3
Slovaquie	1,3	4
UK / Ecosse	1,3	5
Lithuanie	1,5	6
Suede	1,7	7
Republique Tchèque	1,8	8
Hollande	1,8	9
Belgique	2	10
Norvege	2,1	11
France	2,6	12
Allemagne	3	13

<i>Autriche</i>	<i>No data</i>	<i>No data</i>
<i>Irlande</i>	<i>No data</i>	<i>No data</i>
<i>Pologne</i>	<i>No data</i>	<i>No data</i>
<i>Portugal</i>	<i>No data</i>	<i>No data</i>
<i>Slovenie</i>	<i>No data</i>	<i>No data</i>
<i>Espagne</i>	<i>No data</i>	<i>No data</i>

Fig. 1 : Taux de naissance prématurée non spontanée : Zeitlin et al. (11)

Mortalité néonatale des naissances prématurées :

Le taux de naissances prématurées est en légère diminution (7,1% en 2016, 7,0% en 2021(6)) mais la mortalité néonatale reste élevée : plus de 10% de mortalité pour les enfants nés avant 28SA, 5-10% pour les enfants nés entre 28-31 SA et 1-2% entre 32-34 SA. (10).

Morbidité néonatale des naissances prématurées :

Les risques et la morbidité lié à la prématurité varient selon le terme : Syndrome de détresse respiratoire aiguë (SDRA), hypoxie/anoxie, HIV (hémorragie intraventriculaire), Leucomalacie périventriculaire, cécité d'origine centrale, handicaps moteurs, psycho-sensoriels et émotionnels.

Les conséquences peuvent être lourdes pour ces enfants prématurés en fonction de l'âge gestationnel. Selon l'étude EPIPAGE 1 (12), pour les enfants nés avant 33 SA, il y a des taux élevés de déficits moteurs (14%) et cognitifs (31%). Il y a également une prévalence augmentée de problèmes psychiatriques et épileptiques. Seul 36% des enfants nés dans une prématurité extrême étaient indemnes. La prise en charge des MAP est un véritable enjeu de santé publique— concernant la mère mais surtout l'enfant à naître et séquelles futures.

1.1.2.4 L'hémorragie du post partum :

Mortalité liée aux hémorragies du post partum (HPP) :

En 2010, l'hémorragie demeurait la 1^e cause de morbi-mortalité maternelle (13). Selon le 6^e rapport de l'Enquête nationale confidentielle sur les morts maternelles (1) paru en 2016, l'HPP n'est plus la première cause de décès maternelle en France. Cependant, l'HPP représente 10,7% de la mortalité maternelle survenant dans les 42 premiers jours du post partum. (1)

Selon la HAS (Haute Autorité de Santé), L'HPP représente une perte de sang supérieure à 500 ml dans les 24 h suivant l'accouchement. (14) L'Enquête de 2021, le taux d'HPP est de 11,6% (6). Les HPP sévères sont néanmoins en augmentation, à 3.0% en 2021, par rapport à 1.8% en 2016 (6).

Dans le monde, l'HPP reste la cause majeure de mortalité maternelle, cela concerne 14 millions de femmes par an et 70,000 décès (15). En dehors de la mortalité immédiate, l'HPP peut aussi causer une morbidité sévère – avec des séquelles mentales, physiques et reproductives à vie.

Traumatisme psychologique Anémie Hystérectomie d'hémostase Embolisation des artères / ligature des artères utérines	Le choc hémorragique suivant une HPP peut engendrer : - Nécroses viscérales, rénales - Nécrose de l'hypophyse : Syndrome de Sheehan
--	---

Tableau 2 : Récapitulatif de la morbidité maternelle liée à l'HPP

1.1.2.5 La dystocie des épaules :

En France, la dystocie des épaules (DDE) représente 0,5-1% des accouchements par voie basse. (16)

Risques associés à la DDE :

<u>Mère: (17)</u>	<u>Enfant : (20)</u>
- HPP - Augmentation des déchirures vaginales du 3 ^e ou 4 ^e degré – risque d'incontinences, douleurs chroniques, cicatrisation pathologique, (18) dyspareunies et dysfonction sexuelle (19).	- Augmentation des lésions du plexus brachial (NP3) – Lésions nerveuses, potentielle paralysie, douleurs chroniques associées, handicap permanent possible. - Augmentation de fracture de la clavicule (NP3) – douleur, lésions nerveuses associées - Augmentation de fracture de l'humérus associée (NP3) – douleur, lésions nerveuses associées - Augmentation d'asphyxie périnatale (NP2) – potentielle acidose métabolique associée - Augmentation d'encéphalopathie anoxoischémique (NP3) – potentiel morbi-mortalité associée, avec risque d'handicap tel que la dysplasie cérébrale etc.

Prévention : La DDE est-elle réellement prévisible ?

Selon le CGNOF, il en est conclu que la dystocie des épaules n'est pas prévisible (20). Cependant il existe des facteurs de risques connus.

Facteurs de risques en antepartum :

Pour éviter les complications de la dystocie des épaules, il est recommandé de pratiquer une naissance par césarienne si l'estimation du poids fœtal est: (20)

Supérieur à 4500g si diabète gestationnel associé (Grade C)

Supérieur à 5000g en l'absence de diabète (Grade C)

Pathologie	% des grossesses (FR)	Cas/an (FR)	Taux de mortalité	Citation
PE	Jusqu'à 5%	40 000	Pronostic vitale engagé dans 10% des cas	Inserm
DG	16.4%	N/A	0 directe - risques associés accrues	ENP 2021
MAP	4.8%	60 000	Morbi-mortalité pour l'enfant à naître selon terme	ENP 2021
HPP < 1000mL	8.6%	N/A		ENP 2021
HPP severe > 1000mL	3.0%	N/A	Représente 10.7% des décès maternelles	ENP
DDE	0,5-1%	N/A	Morbidité accrue	RPC CGNOF - DDE 2015

Legende:
Stable
En hausse
Données non disponibles

Tableau 3 : Récapitulatif des prévalences et mortalité associées aux pathologies sélectionnées

1.2 IA : Histoire et définitions : synthèse:

1.2.1 Historique basique de l'intelligence artificielle :

“From the imitation game to artificial intelligence in most parts of life”

En 1943, W. S. McCulloch et W. Pitts (21) conçoivent un modèle de neurones artificiel dont le but est de formaliser le fonctionnement de neurone biologique du cerveau humain. Les débuts de réflexion sur une amplification des connaissances par un système se font en 1945, dans le travail de Vannevar Bush. Puis, en 1950, Alan Turing explore l'idée d'une intelligence possible des ordinateurs en se posant la question "Can machines think?" (22). Les premiers obstacles au développement de ces idées sont le manque de stockage informatique et le coût important des ordinateurs de cette époque. (23) Le ‘proof of concept’ sera amené par Allen Newell, Cliff Shaw, and Herbert Simon, dans leur programme *Logic Theorist* (24), qui visait à mimer le cerveau humain pour la résolution de problèmes. Les grands débuts et les premières appellations « d'intelligence artificielle » étaient lors de la présentation du *Dartmouth Summer Research Project on Artificial Intelligence* (DSRPAI) (25), en 1956 par John McCarthy et Marvin Minsky. Malgré les avis divers sur l'IA, la conclusion de cette conférence était que l'IA était réalisable. En 1957, F. Rosenblatt modifie le neurone de McCulloch et Pitts avec une fonction d'apprentissage et crée le perceptron (21). Malheureusement, 10 ans plus tard, le Perceptron n'a pas réussi à intégrer une application industrielle et est abandonné temporairement : c'est le premier « hiver » de l'IA.

Les années 80 ont permis l'éveil et l'avancement de l'IA grâce à deux points : un financement plus soutenu et la disponibilité de nouveaux algorithmes. La naissance des techniques dite de « Deep learning » par John Hopfield and David Rumelhart (26), permettent aux ordinateurs d'apprendre des données qui leur sont mises à disposition. En 1985, Y. LeCun publie un premier algorithme d'apprentissage pour un réseau de neurones à seuil (27) : ce modèle est capable de reconnaître les 5 premières lettres de l'alphabet.

La notion d' « expert systems » voit le jour avec Edward Feigenbaum, où l'ordinateur apprend des prises de décisions des experts pour pouvoir guider les prises de décisions des non-experts.

La mise en avant de l'IA au sein de la population générale était en 1997, le grand maître d'échec, Gary Kasparov joue aux échecs contre un programme d'ordinateur. Sa défaite

contre Deep Blue (créé par IBM) démontre au grand public la puissance possible de l'IA et nourri les fantasmes sur la puissance informatique sur le long terme.

L'histoire de l'IA est inextricablement liée à la puissance des ordinateurs de chaque époque ; aujourd'hui nous ne sommes presque plus limités. A l'ère actuelle, nos journées sont rythmées par une utilisation, voir dépendance, d'outils informations. Notre dépendance sur ces outils génère des données informatiques, qui sont à la fois intéressantes en vue d'une amélioration de la vie quotidienne et dangereux éthiquement sur un potentiel profit à tirer avec des intentions qui ne sont pas toujours claires.

1.2.2 Définitions:

Les définitions et les thèmes suivants ne sont en aucun cas un glossaire exhaustif. Ils ne concernent uniquement les bases et définitions nécessaires pour ce travail de mémoire.

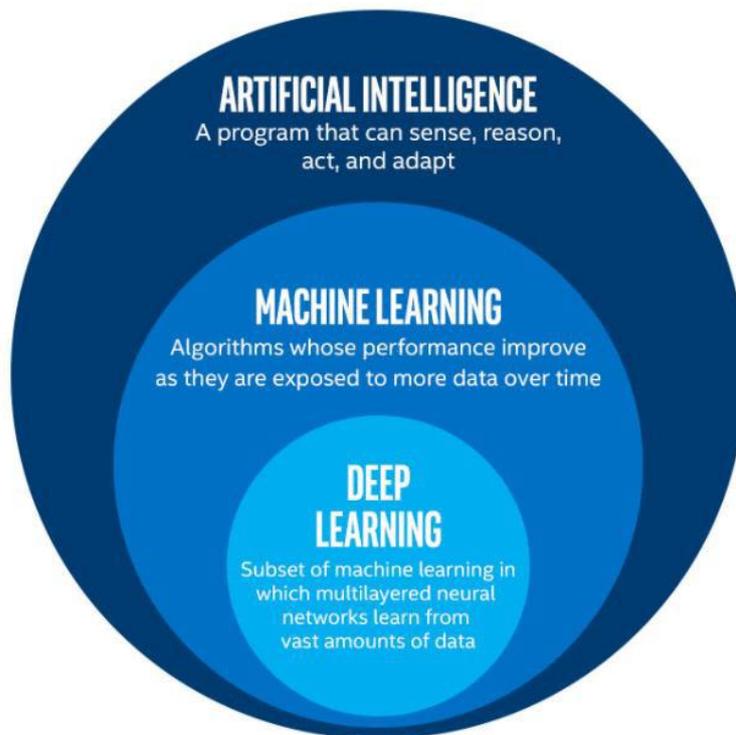


Fig. 2 – Diagramme de Venn de l'intelligence artificielle (28)

- **Intelligence artificielle :**

Marvin Minsky, père fondateur de l'intelligence artificielle, la décrit à Dartmouth en 1956 comme « La construction de programmes informatiques capables d'accomplir des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisantes par des êtres humains » (29)

Une définition plus moderne et élargie est donnée par le Parlement Européen : « tout outil utilisé par une machine afin de reproduire des comportements liés aux humains, tel que le raisonnement, la planification et la créativité » (30). Cette définition inclue donc les comportements dépassant les capacités des êtres humains.

- **Algorithme:**

Description de suites d'étapes numériques permettant d'obtenir un résultat final à partir d'éléments d'entrée. (31)

Ex : œufs + sucre + beurre + farine → 180°C pendant 30 min → gâteau

- **Machine learning (ML)**

Sous-type d'IA, permettant aux algorithmes d'apprendre des données qu'on lui fournit, via des modèles mathématiques. Le but est d'obtenir les paramètres d'un modèle pour améliorer sa performance. (31)

- **Deep learning (DL):**

Sous type de ML : apprentissage automatique sous forme de « neural networks » aussi appelés réseaux de neurones. Il est possible que ces réseaux aient plusieurs couches de neurones cachées. Il s'agit de réseaux beaucoup plus complexes mais aussi plus précis.

○ *Neural networks = Réseaux de neurones :*

Les réseaux de neurones imitent le cerveau humain avec de multiples couches de neurones:

Entrée d'information → traitement : poids + biais/seuil → sortie d'information

Si la valeur à la sortie de l'information (output) excède le seuil déterminé par ce neurone, il active le neurone et passe le data à la prochaine couche dans le réseau.

Les réseaux neuronaux convolutifs (Convolutional neural network = CNN) sont un sous-type de neural networks : le motif de connexion entre les neurones est inspiré par le cortex visuel des animaux pour la reconnaissance d'images et de pixels. Les (CNN) sont souvent utilisés pour la reconnaissance d'image au niveau de l'imagerie médicale.

- **Apprentissage supervisé :**

L'apprentissage supervisé est une sous-catégorie du machine learning. Il utilise des jeux de données étiquetées pour entraîner des algorithmes à classer des données. On peut subdiviser l'apprentissage supervisé en deux problèmes :

Classification : « comment classer des données »

Sert à classer en fonction d'étiquettes qui sont des valeurs discrètes. L'algorithme reconnaît certaines entités spécifiques et tente d'en tirer des conclusions sur « *comment ces entités devraient être définies ou étiquetées* ».

Exemple basique : Ces images sont des « nourrissons humains » : on attribue l'étiquette de « nourrisson humain ». Après lui avoir fourni des données d'entraînement, on peut ensuite tester cet algorithme avec un set de données de test : on lui fournit ces images à classer :

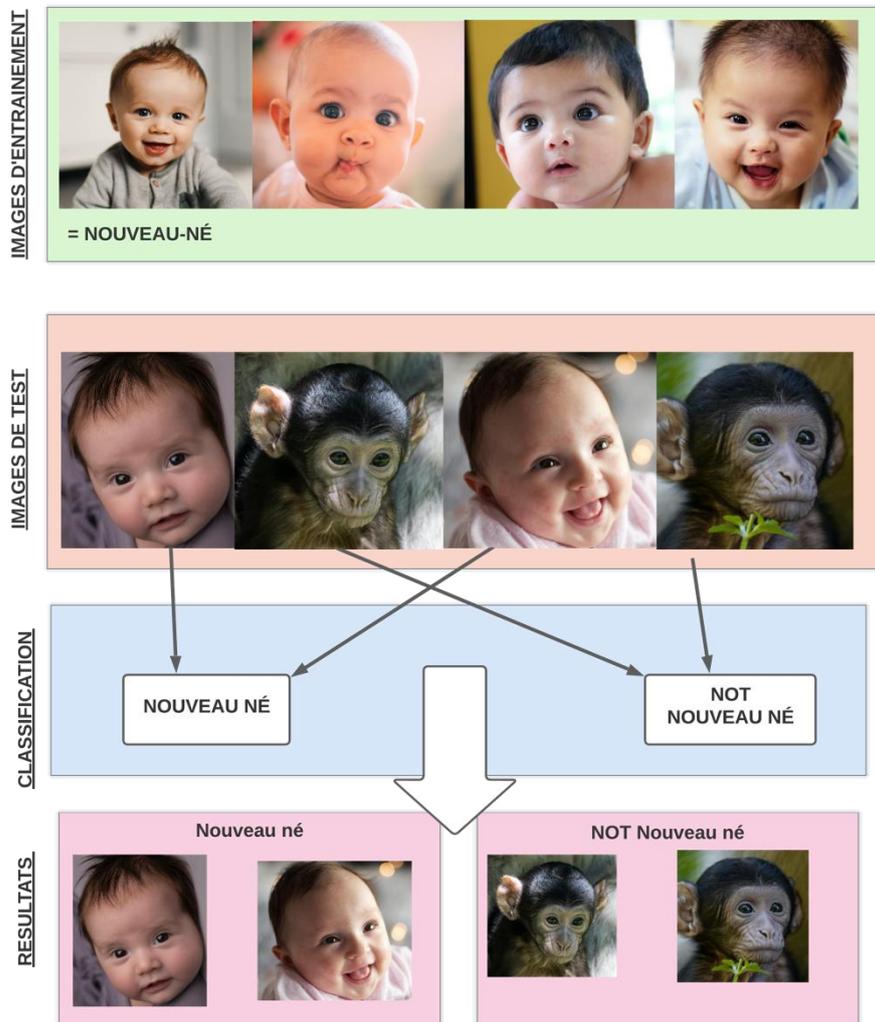


Fig. 3 : Exemple simplifié de classification d'images par algorithme

Régression : « quelle relation entre différentes données continues »

Utilisée pour comprendre la relation entre des variables dépendantes et indépendantes. Elle sert à classer en fonction des étiquettes qui sont des valeurs continues. Elle est plutôt utilisée pour faire des projections. Au sein des régressions on retrouve la régression linéaire, logistique et polynomiale.

Un exemple très basique serait de rentrer des données d'entraînement sous forme de : poids de bébé + terme de grossesse + biométries Hadlock et attribuer un poids de naissance. On pourrait ensuite créer une régression, sous forme de courbe, utile pour prédire la tendance des poids de naissance selon le terme et les biométries selon Hadlock

- ***Unsupervised learning = Apprentissage non supervisé :***

Dans ce type d'apprentissage, l'algorithme classe les différentes données, sans donner d'étiquettes. Cette analyse permet de découvrir des caractéristiques et motifs communs aux données. (32)

○ *Clustering :*

Les données sont regroupées en « clusters » pour pouvoir ensuite établir une classification. L'algorithme groupe les données selon des similarités ou différences.

○ *Réduction de dimension :*

Le nombre de dimensions d'entrée de données est réduit. Les données à l'entrée ont trop de paramètres, empêchant une analyse ou visualisation correcte (32). La réduction de dimensions permet de diminuer les dimensions sans perdre la valeur des données à leur état de base.

1.3 IA : Solution pour une amélioration de la prédiction des risques ?

1.3.1 IA en santé : Motivations

La médecine et le domaine de la santé se transforment avec le monde. L'augmentation exponentielle de la population mondiale, de la mondialisation et donc l'augmentation de NCDs (non-communicable disease) se présente comme des problématiques pesant sur le futur de l'humanité. Les NCDs représentent 41 millions de décès par an (74% des décès mondiale) (33) et il est estimé qu'elles représenteront plus de 75% des décès. (34). La prévention de ces décès repose sur la santé publique globale et préventive avec une vision « One Health ».

L'IA se présente comme solution pour répondre aux « lacunes » cognitives, humaines, et scientifiques. L'espoir est que l'IA puisse nous aider à avancer dans le domaine de la santé, à la fois au niveau diagnostic, pronostic, et pharmaceutique, offrant une prise en charge globale mais aussi personnalisé.

1.3.2 Synthèse des méthodes actuelles d'IA en santé :

L'utilisation de l'IA est possible dans quasi tous les cadres de la santé : de l'organisation à la prévention :

- Aide au suivi
- Aide à l'organisation
- Automatisation des tâches administratives
- Aide à la recherche
- **Aide au diagnostic**
- **Aide à la décision**
- **Médecine préventive et prédictive**

Pour préciser d'avantage, on peut se focaliser sur la partie diagnostic, décisionnelle et prévention de l'IA en santé. L'IA en santé est complexe – beaucoup de modèles différents sont utilisés, nous ne détaillerons uniquement les modèles les plus communs (explications non exhaustives).

Modèles de prediction:

Combinant le data mining et le machine learning, l'analyse prédictive a permis un avancement au niveau de la qualité des soins et une amélioration de l'issue pour les patients.

Les données utilisées pour un modèle prédictif peuvent être très variées et peuvent même s'intercaler : cliniques, paracliniques et biologiques mais aussi culturels et socio-économiques. Ces données peuvent aussi être analysées sous le format de DPI – Dossiers patient informatisés.

Systemes d'aide à la décision : CDSS (Clinicien decision support systems)

Avec les modèles prédictifs, l'analyse des milliers de dossiers et leurs issues, il est possible d'établir une intelligence artificiel avec une « expérience » bien plus importante que n'importe quel médecin humain. Il s'agit d'un algorithme d'aide à la décision. Il convient de rappeler que cette aide à la décision n'a, à aucun moment, comme but de remplacer le clinicien. La prise de décision repose toujours sur le clinicien lui-même, le finalité de ces algorithmes et de les soutenir dans leurs compétences déjà établies.

Classification

Appartenant à l'apprentissage supervisé, la classification permet de classer différentes données selon une ou plusieurs étiquettes données. Dans le domaine de la santé, la classification est utilisée depuis longtemps, pour pallier aux limites de compréhension, de temps et de biais humain. La reconnaissance d'image, sous-type de la classification, est utilisée de façon courante pour l'imagerie médicale, l'histopathologie et l'anatomopathologie.

Bio-informatique -

La bio-informatique représente un partenariat entre les sciences numériques et informatiques avec la biologie. . Comprenant l'étude du génome (génomique), du transcriptome, du protéome, du métabolome, de l'exome et du microbiote ces technologies rassemblées sous le sigle des « -omics » permet l'étude du corps humain mais aussi de son fonctionnement par ses voies biologiques. Intégrant l'étude des séquences génétiques, des interactions entre protéines et de leurs fonctions dans les processus biologiques, la bio-informatique permet une meilleure compréhension de la physiologie mais aussi de la pathogenèse. La puissance de l'intelligence artificielle permet d'extraire des informations de banques de données très larges, que ce soit une séquence du genome, de protéome, du métabolome, ou du transcriptome. De la même façon que l'IA est appliquée aux bases de données avec des centaines de variables, l'IA est appliqué au sein de la bio-informatique en

utilisant les mêmes outils. Dans la dernière décennie, le progrès des technologies de séquençage fut grand avec des séquençages de plus en plus rapide et étendus. La « boîte à outils » informatique reste la même, alors que la quantité et qualité des données croient de manière exponentielle – la bio-informatique est donc peut être la clé dans la recherche scientifique dans les années à venir.

1.3.3 Tendances

1.3.3.1 Tendances : IA en santé

Depuis les années 80 et l'intégration générale de l'IA dans le domaine de la santé, le nombre d'études n'a cessé d'augmenter, avec une augmentation exponentielle dans les années 2000-2010. Intégrant quasi toutes les spécialités médicales, il est estimé que plus de 27 000 articles ont été publiés entre 1977 et 2018 (35).

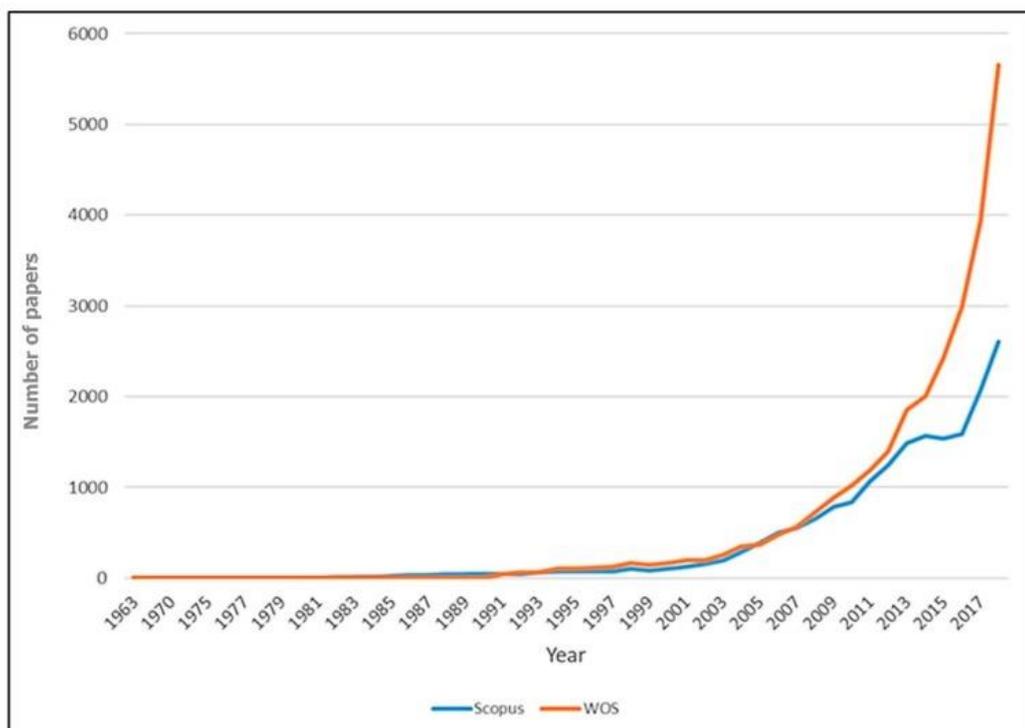


Fig. 4 : Nombre d'articles selon base de données : évolution par année. (35)

La pandémie de Covid 19 (SARS-COV2) a engendré une transformation digitale, avec l'intelligence artificielle prenant d'avantage d'importance. La Commission Européenne a produit un rapport sur ces effets (36). Covid-19 a renforcé et amplifié beaucoup d'opportunités mais également beaucoup de préoccupations autour de l'IA.

Pendant cette pandémie, il y a eu d'avantage :

- D'utilisation et adoption de l'IA dans la recherche à la fois scientifique et médicale, avec des applications dans la télémédecine diagnostique et épidémiologique.
- D'innovation pour affronter cette crise, comme l'utilisation des données pour l'estimation des taux d'infection.

D'acceptation de l'utilisation de la robotique dans le monde du travail et une bascule vers le travail, l'éducation et l'administration faits en ligne. Le tele-working est de mieux en mieux accepté avec des bénéfices sociaux et environnementaux.

- De partage de données entre entreprises mais dans le sens entreprises-gouvernement
- D'opportunités pour une meilleure adaptation du monde du travail / éducation lors de futures pandémies avec confinement (mise en place des plateformes, cyber sécurité avancé etc.)

Cependant, ces technologies de l'information et de la communication comportent des risques faisant naître des craintes :

- Sur le détournement d'usage de données à caractère personnelles collectées pour la réponse à la pandémie, avec des interrogations par rapport à une éventuelle surveillance de masse et une démocratie réduite.
- Sur les campagnes de désinformation dans le but d'ébranler la confiance des populations dans la cohésion sociale et les institutions publiques européennes.
- Sur la cyber sécurité dans l'Espace européen.

Alors que la pandémie Covid 19 a participé à une véritable transformation digitale, on ne peut nier le creusement des écarts entre les populations défavorisées et celles qui ne le sont pas et ce surtout dans des groupes vulnérables (personnes âgés, personnes très jeunes, groupes socio-économiques défavorisés). Il est nécessaire de prendre ces inquiétudes en compte pour profiter pleinement des avancées technologies apportées. Le but n'est plus de revenir à la "normalité" post Covid-19 mais plutôt d'avancer vers une société mieux connectés avec une meilleure garantie humaine pour le futur, incluant l'IA.

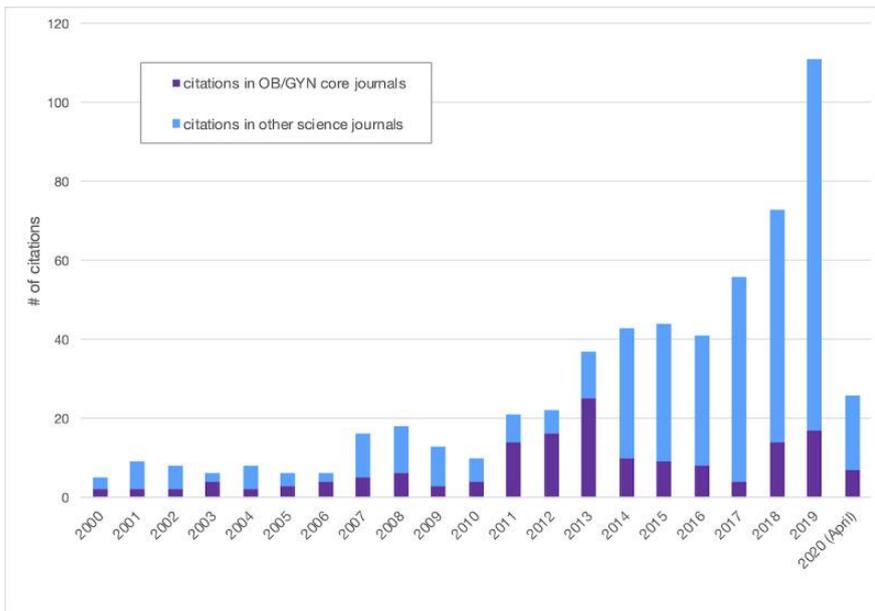
1.3.3.1 Tendances : IA en obstétrique:

L'obstétrique représente une spécialité exposé aux risques. Selon l'assureur de responsabilité professionnel, MACSF, cette spécialité figure dans le top 5 des professions de santé les plus mises en cause devant les juridictions civiles et en 2021, 59 % des mis en cause ont été condamnés. (37)

Plusieurs obstacles bloquent l'IA dans les potentiels de transformations des pratiques qu'elle offre et une opportunité pour surmonter les freins organisationnels. Alors que des études de haute qualité avec une méthodologie de recherche respectant les standards de qualité de l'EBM (evidence based medicine) existent en obstétrique, beaucoup de sujets sont encore débattus. Un exemple est l'étude des CTG (cardiotocographie), fondamentale dans la détermination du bien être fœtal. Néanmoins la variabilité d'interprétation inter et intra observateur pose problème. Cette analyse, qui reste un des arguments cliniques principaux

dans la prise en charge, reste encore subjective. L'IA représente un usage possible dans la recherche d'une meilleure interprétation et une meilleure prise en charge clinique par la suite.

Il y a également une volonté de personnaliser la médecine clinique. Une prise en charge globale et personnalisée est déterminante dans la médecine de précision et prévention. Nous partons d'une médecine générale pour venir à une médecine du futur, personnalisé et adapté à chaque patient, prenant en compte une vision globale de leurs pathologies.



La présence de l'IA au sein de l'obstétrique ne fait qu'augmenter. Une revue systématique de la littérature publiée en 2022 (38) a déterminé une tendance croissante du nombre d'articles lié à l'IA dans le domaine de l'obstétrique dans les 20 dernières années.

Fig. 5 : Nombre de citations par années de l'obstétrique et l'IA : Ferdinand DHOBRES et al : (38)

2. Matériel et méthodes

2.1 Type d'étude :

Revue de la littérature

2.2 Stratégie de recherche

Pour ce travail l'outil de recherche utilisé était PubMed par mots clés MESH.

La période d'étude s'étend de 2015 à 2022 avec des articles en anglais.

Pour la recherche initiale, les mots clés utilisés sont (**Artificial intelligence**) AND (**Obstetrics**). Avec les résultats de ce premier filtre de recherche, sont sélectionnés uniquement les articles concernant les pathologies explorées dans ce projet de recherche : prééclampsie, diabète gestationnel, menace d'accouchement prématuré, hémorragie du post partum, monitoring fœtale / hypoxie fœtal et dystocie des épaules.

Une seconde recherche a été entreprise avec des mots clés plus précis par rapport aux différentes pathologies :

- *Pre-eclampsia and Artificial intelligence*
- *Postpartum hemorrhage and Artificial intelligence*
- *Pre-term labor and Artificial intelligence*
- *Gestational diabetes and Artificial intelligence*
- *CTG and Artificial intelligence*
- *Machine learning and CTG*

Le résultat de cette sélection était 74 articles.

2.2.1 Critères d'inclusion/ exclusion

Sont inclus de ce travail uniquement des études remplissant les critères d'inclusion : datant de 2015-2022, uniquement en anglais et concernant l'être humain.

Sont exclus de ce travail les études ne portant pas sur les pathologies citées plus haut, hors dates précisés, dans une langue autre que l'anglais.

2.2.2 Éligibilité finale :

Une analyse plus précise a permis de retirer :

3 articles ont par rapport au manque de traduction en anglais correct

1 article a été retiré par rapport au manque de précision entre diabète gestationnel et diabète de type 1 patent, présent avant la grossesse.

Le résultat final de cette sélection est : 71 articles

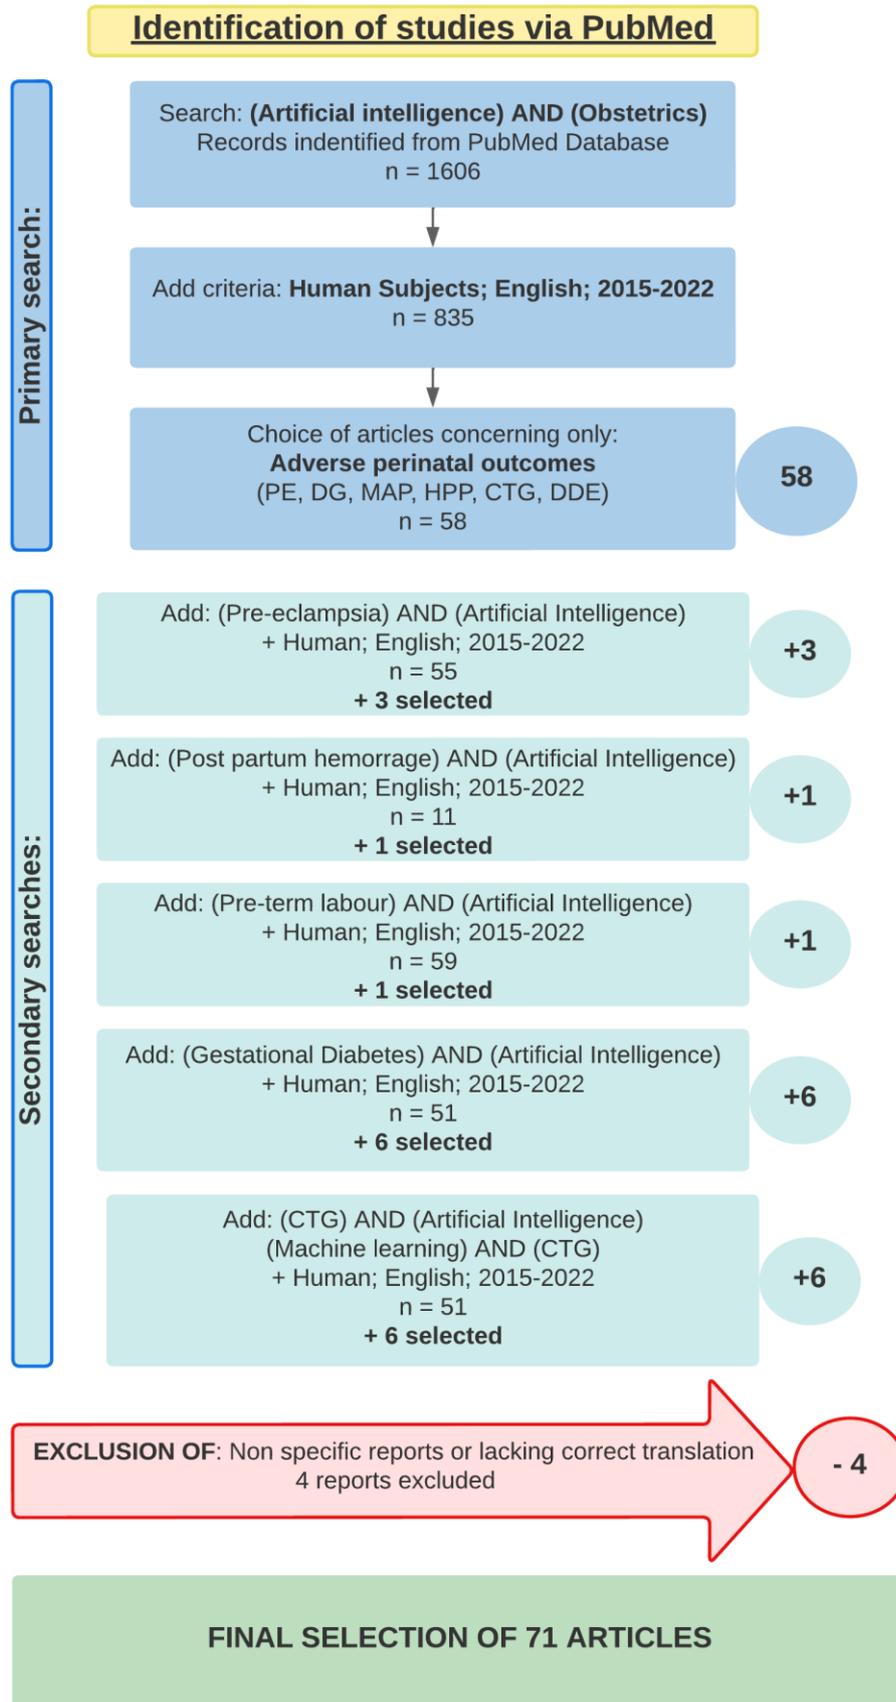


Fig. 6. Work flow de sélection des articles

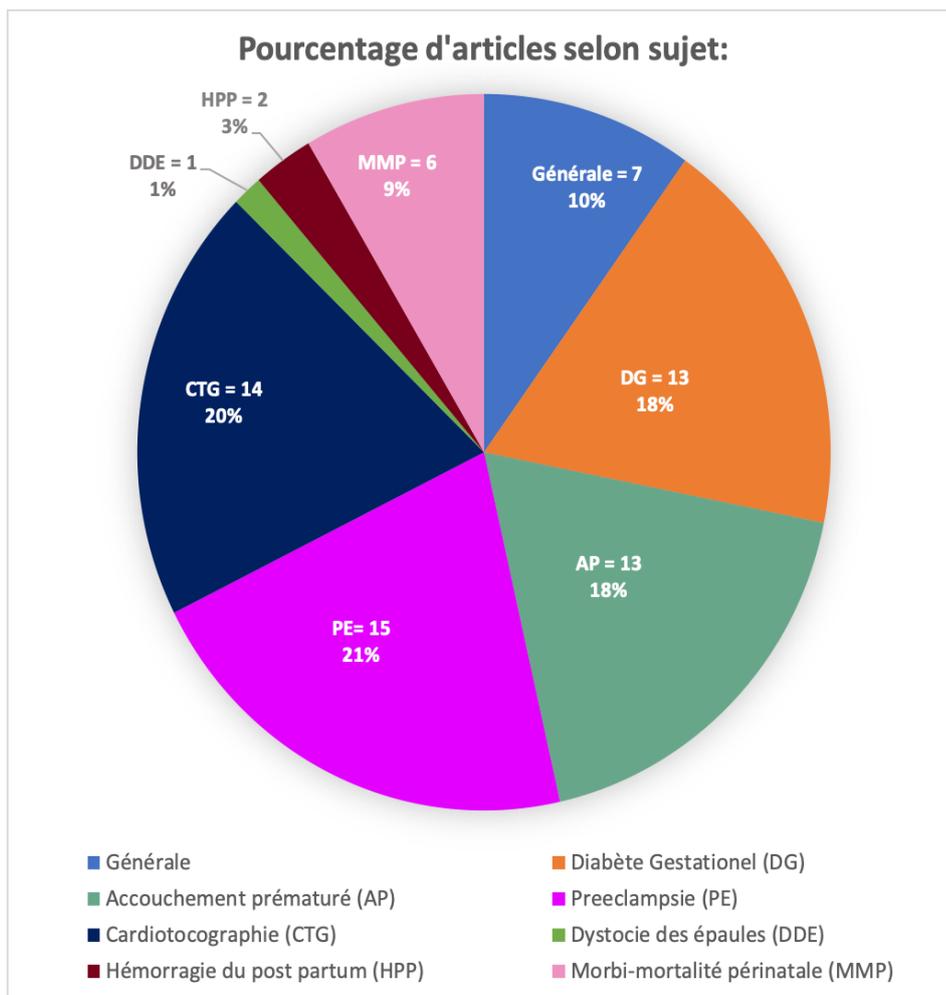


Fig. 7 : Pourcentage des articles sélectionnés selon sujet

Variabilité du sujet entre les articles sélectionnés :

Les sujets les plus fréquemment étudiés par l'IA au sein de l'obstétrique étaient, par ordre décroissant: La pré-éclampsie avec 21% des articles sélectionnés. Suivi par l'étude des cardiotocographies (CTG) à 20% puis le diabète gestationnel et l'accouchement prématuré correspondant à 18% des articles chacun.

2.3 Objectif principal

Décrire et définir la place de l'intelligence artificielle dans la prédiction d'événements de mauvais pronostics ou d'issues défavorables en obstétrique.

2.4 Objectif secondaire

Définir les perspectives et critères à suivre pour une mise en place performante, acceptable et éthique de l'IA au sein de l'obstétrique.

3. Résultats

3.1 IA en obstétrique : modèles et pathologies :

3.1.1 Syndromes prénataux : Diabète gestationnel :

Actuellement, le dépistage en France est fait sur facteurs de risque, en 2 temps : (39)

- *Age maternel > 35 ans*
- *Antécédents maternels de diabète gestationnel ou macrosomie lors des grossesses antérieures*
- *Antécédents familiaux de 1^{er} degré de diabète de type 1*
- *IMC > 25*

En premier lieu la mesure du glycémie à jeun (GAJ) au 1^{er} trimestre :

- *Si GAJ \geq 0,92g/L : diagnostic positif pour un diabète gestationnel*
- *Si GAJ > 1,26g/L : diagnostic positif pour un diabète de type 2 méconnu*

Ensuite entre 24-28 SA, le dépistage par HGPO (hyperglycémie provoqué par voie orale) 75g , avec mesure de la glycémie a T0, T60 min, T120 min. Une seule valeur au-dessus des normes est suffisante pour poser le diagnostic de diabète gestationnel :

- *T0 : 0,92g/L*
- *T 60 min : 1,80 g/L*
- *T 120 min : 1,52g/L*

Malgré ces méthodes de dépistage et de prévention, la prévalence de diabète gestationnel, de macrosomie et de complications liées, tend à augmenter : La prévalence de diabète gestationnel était de 16,4% en 2021, versus 10,8% en 2016 (6) et 7,2 % en 2010 (13). Le dépistage en France reste ciblé, mais concerne 76,1% des grossesses en 2021 (6). Le dépistage universel est évidemment plus sensible à la détection des cas, mais le rapport coût-efficacité n'est pas bénéfique dans les populations à faible risque et engendre plus d'interventions thérapeutiques. Le dépistage ciblé permet de limiter le nombre de faux négatifs mais aussi le coût financier associé au dépistage. Cependant il est estimé qu'il peut conduire à méconnaître jusqu'à 45% des cas de diabète gestationnel. (40)

Ces points témoignent de la nécessité d'avoir des solutions pour améliorer la prise en charge. Les méthodes de dépistage, taux de participation et prise en charge et ce potentiellement à l'aide de l'intelligence artificielle.

Programmes d'aide à la décision clinique :

Les modèles d'aide à la décision pour le diabète gestationnel sont nombreux. University College Dublin a développé un programme d'aide à la décision basé sur du machine learning, combinant données cliniques, historiques et biologiques pour mieux identifier les femmes enceintes à risque de diabète gestationnel (41). Le modèle théorique a atteint une performance de $AUC = 0,792$.

La place d'une éventuelle aide électronique pour les cliniciens est aussi présente dans le cas de la télésanté. Le dépistage demeure plus complexe dans le cadre de milieux à ressources limitées. Une application (42) a été créée pour le dépistage de diabète gestationnel dans le cadre de ressources limitées, nécessitant uniquement un smartphone avec réseau internet et deux variables : la glycémie à jeun et l'âge maternel. Le modèle utilise un algorithme de type SVM (support vector machine) qui obtient une performance de $AUC-ROC = 0.780$, une Spécificité = 100% et une Sensibilité de 88.7%. On peut conclure de l'efficacité d'un modèle aussi simple et adaptable aux milieux ruraux.

Modèles prédictifs

L'utilisation de modèles prédictifs est applicable à la prédiction du diabète gestationnel.

Un modèle a été créé par l'Université de Qingdao en Chine (43) pour la prédiction de risque de diabète gestationnel en l'absence d'analyses sanguines au premier trimestre de grossesse – utilisant uniquement des données cliniques simples. Des différences significatives ont été observées pour l'âge, l'IMC avant la grossesse, périmètre abdominale au T1, gestité, présence de SOPK, menstruations irrégulières et antécédents familiaux de diabète, entre les patientes avec et sans diabète gestationnel.

Stratification de risque précoce :

Un modèle de machine learning créé en Chine (44), utilisant des informations cliniques facilement accessibles dans les consultations combinées avec des marqueurs sériques, vise à prédire le risque de diabète gestationnel au premier trimestre. En combinant l'IMC pré-conceptionnelle, l'âge maternel, glycémie à jeun et le taux d'ALAT (alanine aminotransferase) un modèle de prédiction a été créé. Le modèle de type XGBoost est plus performant que le modèle plus simple de régression logistique, avec un AUC de 0.742. Ce genre d'algorithme, d'utilisation simple, permet d'évaluer le risque plus précocement que ce qui est fait en pratique actuellement (15 semaines de gestation versus 24-28 semaines d'aménorrhée = 22-26 semaines de gestation). Une prédiction de risque plus précoce permet

une prise en charge précoce, que ça soit pour de la prévention primaire, secondaire ou tertiaire.

Modèles de prédiction de risque utilisant les données des dossiers cliniques :

La création de modèles de stratification de risque peut aussi utiliser les informations des dossiers numérisés (DPI). Cette utilisation permet une évaluation automatique avec un diagnostic plus performant à l'entrée du patient.

Un modèle de machine learning (45) créé en collaboration avec l'Institut d'Alan Turing, permet d'identifier des femmes à bas et haut risque de développer un diabète gestationnel. Ce modèle entraîné sur une des variables non restreinte (2355 variables) a été démontré comme très précis, avec un AUC de 0.846, largement supérieur au standard actuel (AUC = 0,682).

Ainsi, la croissance importante des données est une véritable mine d'or exploitable à des fins de prédiction, stratification de risque et prévention. Dans l'étude de multitude de variables qu'offrent les données numériques de santé, la création de modèles offre des outils de stratification de risque, mais aussi d'avoir une analyse exploratoire permettant de découvrir de nouvelles variables liées aux pathologies recherchées.

Place des réseaux de neurones dans la prédiction de risque : nouvelle tendance avec une meilleure performance

Une étude de Wu et al (46), a évalué la performance de différents modèles de machine learning dans la prédiction de diabète gestationnel précoce. L'Entraînement a été réalisé avec différents modèles: 7 variables (application clinique) et 73 variables (tout variables sélectionnées confondus). En utilisant 73 variables, le modèle de Deep Learning (DNN – Deep Neural Network) a démontré une performance élevée de discrimination avec un AUC = 0.80, bien au-dessus des autres versions (max AUC 0.77).

On peut donc constater ici la performance élevée liée à l'apprentissage profond utilisant des réseaux de neurones

L'étude de ces données a également pu relever de nouveaux facteurs de risques potentiels dans la survenue de DG :

- Un **IMC bas** ($< \text{ou} = 17$) été lié à un sur risque de développer ce syndrome, comparativement à un IMC entre 17 et 18. (11.8% versus 8.7% avec $p = 0.09$).

- Des **taux élevés de T3 totale** ($p < .001$) and **T3 libre** ($p < .001$) avec des taux bas de T4 totale ($p < .001$) et T4 libre ($p < .001$) ont été liés à un DG. (De plus, le taux de T3 et T4 totales étaient supérieur au T3/T4 libre dans la prédiction de diabète gestationnel)
- La **lipoprotéine(a)** a aussi été identifié comme un potentiel marqueur prédictif de ce syndrome.

Ces systèmes restent à valider sur les études à grande échelle.

Une comparaison dans le cadre de prédiction de diabète gestationnel avec l'utilisation des données cliniques, a aussi été fait par Ye et al (47), le but étant d'évaluer si un modèle de Machine Learning utilisant des algorithmes plus complexes que la régression logistique est plus performant. En termes de performance de discrimination, un des modèles de ML était plus performant avec un AUC 73.51% (95% IC 71.36-75.65%), suivi de près par le modèle de régression logistique (LR) avec un AUC 70.9% (95% IC 68.68-73.12%). Dans ces deux modèles la glycémie à jeun (GAJ), l'HbA1c, le taux de triglycérides et l'IMC maternel étaient parmi variables les plus importantes pour la performance de prediction.

Bio-informatique: la place des biomarqueurs dans l'identification et le diagnostic :

Les biomarqueurs peuvent servir pour l'identification des patients dans un but de prévention. En combinant des marqueurs sanguins et des données cliniques un outil Américain (48) a été créé pour détecter des cas potentiels de pathologie et permettre une prise en charge précoce. Ce modèle prédictif a pu détecter des cas de diabète gestationnel avec une précision de 91.7%. Dans l'élaboration de ce modèle, des centaines de marqueurs sériques ont été évalués pour en définir 29 les plus importants liés à ce syndrome. Parmi ces marqueurs, deux marqueurs qui n'ont pas encore été lié à ce syndrome ont été signalés comme prédictive : le fonctionnement thyroïdien altéré (TSH augmenté, T4 diminué, avec T3 totale normale) et le taux de Vitamine B12 diminué.

De plus, la création de cet outil par l'analyse des données a démontré que la prise en compte de la religion peut servir d'outil pour définir différent types de culture, dont certains présentent un surrisque de développer un diabète gestationnel (Ex : religion Hindou, avec une probabilité de développer une diabète gestationnel de 16.8%). Ce raisonnement est bien évidemment limité et les prédispositions génétiques des différentes ethnies sont aussi à prendre en compte. Il y a également un risque éthique lié au fait d'utiliser un outil numérique qui permet de cibler une religion ou une culture.

Les biomarqueurs peuvent également servir de potentiel outil diagnostique précoce pour cette maladie. Un outil de détection par miARN* (MicroARN) circulant (49) a été créé pour le diagnostic de diabète gestationnel précoce au premier trimestre de grossesse. Dans le groupe de femmes avec une diabète gestationnel, deux miARNs étaient surexprimés (miR-223 et miR-23a) contrairement au groupe de contrôle. L'utilisation de ces biomarqueurs de miARN dans un modèle de régression logistique a produit une valeur AUC de 0.91, confirmant leur performance.

Au sein du domaine de proteomics, une analyse quantitative comparative protéome (50) a relevé l'existence de biomarqueurs potentiels pour la détection précoce de diabète gestationnel. L'analyse comparative entre un groupe de femme enceinte à risque de diabète gestationnel et un groupe de contrôle avait pour but l'identification de DEPs* (Differently expressed proteins) plasmatiques durant le premier trimestre de grossesse. Après cet analyse, 5 biomarqueurs ont été identifiés puis revalidés sur 2 autres groupes de cas-témoins : Prenylcysteine oxidase 1 (PCYOX1), beta-ala-his dipeptidase (CNDP1), extracellular matrix protein 1 (ECM1), basement membrane-specific heparan sulfate proteoglycan core protein (HSPG2), thrombospondin4 (TSP-4). La présence/absence de ces biomarqueurs étaient significativement différents entre les groupes à risque et les groupes témoins avec $p < 0.05$.

La recherche de biomarqueurs comprend l'étude de l'épigénome et la méthylation de l'ADN. Une étude de l'épigénome (epigenome wide association) intégré au machine learning (51) a pu identifier des signatures diagnostics sériques sous forme de CpG* (cytosine-phosphate-guanine). Un modèle de SVM a identifié 6 différents sites de CpG qui peuvent, à eux seuls, prédire de façon fiable la survenue de diabète gestationnel, avec un but de diagnostic précoce par marqueurs sériques. Une autre étude (52) avec le même format a pu identifier 5 CpG : un modèle correspondant de LR avait un AUC de 0.8209. Ces études permettent d'ouvrir une voie vers l'exploration du rôle de méthylation ADN dans les pathologies avec de potentiels biomarqueurs diagnostics dans le futur.

3.1.2 Syndromes prénataux : Accouchement prématuré:

Les accouchements prématurés (AP) sont spontanés dans 50% des cas et le plus souvent d'étiologie inconnu (53). Malgré les connaissances sur les facteurs de risques et étiologies, il reste encore un travail de recherche et d'application à faire au niveau de la prévention.

Identification des facteurs de risques, situations cliniques et déterminants de survenue de AP :

L'utilisation de l'intelligence artificielle pourrait permettre l'identification des facteurs de risque pour la mise en place de protocoles de prévention primaire, secondaire et tertiaire.

L'identification des facteurs de risques peut se faire par réseaux de neurones ou par clustering, pour évaluer à la fois les déterminants cliniques et les conditions cliniques liées à l'AP.

<u>Type</u>	Réseau de neurones artificiels (54)	Clustering : K means et fuzzy algorithms: (55)
<u>Identification de :</u>	Déterminants cliniques et historiques dans la survenue de AP	Identification de conditions cliniques associées à l'AP
<u>Résultats :</u>	<ul style="list-style-type: none"> - IMC maternel (0.0164) - Hypertension (0.0131) - Diabète gestationnel (0.0099) - Antécédents de conisation (0.0099) - Antécédent de placenta prævia (0.0099) - Parité (0.0033) - Cervicometrie (0.0001) - Age maternel (0.0001) - Antécédent d'AP (0.0001) - Presence de myomes et adénomyose (0.0001). 	<p>Trois clusters de phénotypes patients avec AP:</p> <ul style="list-style-type: none"> - Sans autres syndrome - Avec des conditions mixtes (dont infections maternelles) - PE, éclampsie, HELLP syndrome ou RCIU. <p>Les pourcentages de AP entre les différentes clusters étaient très variées.</p>
<u>Limites :</u>	La limite de cette étude est le nombre de sujet. Il serait intéressant de continuer cette voie de recherche sur des cohortes plus grandes, voir nationales.	Malgré les différences dans ces caractéristiques maternelles, les issues materno-fœtales n'ont pas différencié

Tableau 4 : Comparatif entre prediction par réseau de neurones et clustering : Lee et al et Souza et al .

Des modèles de prédiction ML et LR peut aussi permettre l'identification de variables associés avec un AP.

Une étude Canadienne (56), a créé des modèles pour la prédiction d'éventuel AP chez les femmes nullipares. Tous modèles confondus ont atteint une valeur prédictive négative de 95-97% pour l'accouchement prématuré spontané au 1^{er} et 2^e trimestre. En ce qui concerne l'identification des facteurs de risques le modèle de LR a pu identifier 13 variables associés avec un surrisque d'AP dont : Diabète type 1 ou 2 (Type 1 AOR 4.21; 95% IC: 3.23–5.42 ; Type 2 AOR: 2.68; 95% IC: 2.05–3.46) et une sécrétion anormale de Pregnancy-associated plasma protéine (AOR: 2.04; 95% IC: 1.802.30).

Classification pour identification :

La classification peut permettre l'analyse des enregistrement tocographiques - l'analyse de l'activité contractile de l'utérus, souvent associé à l'analyse du rythme cardiaque fœtal (RCF), aussi appelé monitoring ou CTG (cardiotocographie). La classification peut permettre une prédiction semi-automatique d'AP. Un exemple est l'utilisation d'apprentissage profond pour une classification semi-automatique des tocographies (57) entre des enregistrements de naissances à terme versus des cas d'accouchements avant-terme). Ce modèle a pu atteindre une sensibilité de 98,2%, spécificité de 97,74% et une précision de 97.9% sur la base de données dans laquelle il a été testé. Ces résultats démontrent l'intérêt de ce genre d'outil comme méthode d'identification semi-automatique des enregistrements à terme versus avant-terme.

Modèles prédictives : AP

Le machine learning peut être appliqué à la prediction de survenue de AP : par modèles prédictives ou calcul de score de risque.

Un modèle conceptuel de prédiction du risque appelé « Risk prediction conceptual model – RPCM » pour la prédiction d'AP a été créé en Inde (58). Trois types de modèles ont été créés puis testés en termes de sensibilité, spécificité et précision: SVM (support machine vector), DT (decision tree) et LR (regression logistique). En termes de performance, le modèle SVM était le plus performant avec une précision de 0.861, une Sensibilité de 0.801 et une Spécificité de 0.702. Lorsque le dataset a été équilibré avec SMOTE (synthétique minority over-sampling technique), la performance du modèle SVM était encore meilleure avec une précision de 0.909, une Sensibilité de 0.891 et une Spécificité de 0.783.

L'utilisation de ML dans la prediction d'AP est aussi possible sous forme de calcul de score de risque. Parmi les différentes étiologies de AP, un des facteurs de risque connu est l'inflammation causé par une dysbiose cervico-vaginale (59). Un étude cas-témoins a pu tester

un modèle de prédiction par calcul de risque d'AP par analyse de fluides cervico-vaginales par qPCR (60). Les modèles de calcul de risque (SVM et classification par arbre de décision) ont démontré des différences significatives entre les groupes AP et group témoin (accouchement à terme), avec $p = 0.001$. La performance était correcte avec une Sensibilité de 71% et Spécificité de 59%, améliorés lors de l'ajout du mesure de taux de leucocytes dans le sang avec $Se = 77%$ et $Sp = 67%$. L'échantillonnage de fluide cervico-vaginale est non-invasive et simple à réaliser, combiné avec une étude de qPCR, ce calcul de risque est faisable en pratique clinique (en milieu hospitalier).

La prédiction automatisé et simplifié peut aussi inclure l'utilisation de dossiers médicaux numérisés. Une modèle de prédiction utilisant le Deep learning (DL) par dossiers médicaux numérisés (61) a été réalisé en combinant un traitement du langage naturel et un modèle de DL sous le forme de récurrent neural networks (RNN). Les modèles de RNN ont pu atteindre un AUC de 0.827 et un $Se = 0.965$. Ce modèle a pu aussi reconfirmer des facteurs de risques associés avec AP de façon significative : Grossesse gémellaire, cervicometrie court, syndrome hypertensive, LES (lupus érythémateux systémique), hydroxy chloroquine sulfate. Cet étude prometteur a pu prédire un éventuel AP jusqu'à 8 semaines avant sa survenue : ce laps de temps est une avancé majeur dans la prise en charge, permettant la un traitement et preparation de l'AP (corticothérapie maturative fœtale, tocolyse).

L'utilisation de biomarqueurs : omics, transcriptomics, et proteomics :

Il est admis que l'étiologie des accouchements prématurés est multifactoriel, une vision globale est donc favorable à la prévention et prise en charge de ce syndrome. L'utilisation des biomarqueurs et plus précisément des « omics » est donc adapté.

Un revue de la littérature (62) confirme l'importance d'une approche combiné incluant des biomarqueurs tels que les CMP et le cfRNA.

Les microparticules circulants, aussi appelés CMPs, sont des vacuoles composés d'une bicouche lipidique, présent dans différentes parties du corps dont le plasma. Leur mesure est utilisé dans différentes champs de recherche en tant que « biopsie liquide ». La présence des CMPs dans le cadre de la grossesse fait intervenir des voies de signalisation d'inflammation. Certains signatures de protéines associés aux CMPs plasmatiques spécifiques sont liés à un surrisque significative de AP future et ce déjà à 10-12 semaines de gestation. Ces CMPs, dosé par prise de sang, permetts un potentiel système d'alerte précoce. Néanmoins, l'étude de CMPs est limité par le

fait que les techniques d'études en laboratoire sont coûteuses et complexes. Des recherches sont en cours pour permettre l'extraction et l'étude des CMPs de manière plus simple.

Le dosage de ARN libre spécifiques, « Cell free RNA » (cfRNA) dans le plasma maternel est prédictive des AP (62). De plus un séquençage qPCR assay sur le cfRNA plasmatique de deux cohortes de femmes enceintes (63) (terme versus accouchement prématuré) analysé par machine learning a relevé un set de marqueurs prédictives. La performance de ce méthode est démontré avec un AUC = 0.81 (63).

L'analyse de l'ADN circulant dans le sang maternel peut identifier la présence de cellules d'origine placentaire ou membranaires. La présence de ces cellules en quantité augmenté est associé avec un possibilité de micro-fractures au niveau des membranes amniotiques et donc potentiel facteur prédictive dans la rupture des membranes avant terme, donc prédictive pour un éventuel accouchement prématuré. (63)

L'utilisation d'une stratégie proteomics peut être combinés à des données cliniques validés pour une meilleure prédiction d'AP. Une étude (64) propose une utilisation conjointe de l'étude 'proteomic' et 'metabolomic' du liquide amniotique combiné à la cervicométrie (mesure du col utérin par échographie endovaginale). Il n'y avait pas de différence significative entre les mesures de col entre les patientes ayant accouché avant et après 34 semaines de gestation démontrant que l'utilisant seule d'une cervicométrie n'est pas assez prédictive pour l'AP. Cependant, l'utilisation combinée des données cliniques, démographiques et omics par un modèle de Deep learning a démontré une bonne performance prédictive avec un AUC de 0.890 (IC 95% 0.810–0.970) pour un accouchement avant 34 semaines de gestation et un AUC de 0.890 (0.790–0.990) pour un accouchement dans les 28 jours post amniocentèse. Cette étude démontre donc qu'une vision globale, de « omics » combinés à des données cliniques permet une bonne prédiction des AP et donc une prise en charge adaptée.

Le transcriptome représente l'ensemble des ARN issus de la transcription du génome. Déjà présent en médecine, son étude a été facilitée par la montée en puissance et la simplicité croissante des méthodes de séquençage. Une étude Coréenne (65) a analysé le transcriptome en séquençant l'ARNm de deux groupes de femmes : groupe (AP) et groupe témoins

(accouchement à terme). Suite à cette analyse, des gènes exprimés de façon différentes, des « Differently expressed genes », DEGs, ont été identifiés dans le groupe AP. En intégrant les profils d'expression génétiques de différents groupes ethniques d'autres études, une voie d'activation des T-cells (lymphocytes T) a été identifiée. La combinaison de dysregulation des DEGs et la voie d'activation de T-cells a été confirmée. Ces DEGs sont donc marqueurs prédictifs d'AP. Cependant, ces échantillons ont été prélevés au moment de la mise en travail ; ils sont donc prédictifs d'un AP mais ne sont pas des biomarqueurs car ils ne permettent pas de prédire à distance (avant le début des symptômes) la survenue d'un accouchement prématuré.

L'étude du transcriptome et donc du microARN (ARNmi) du sang total et des monocytes périphériques peut être prédictive. Un séquençage de l'ARN sur échantillon de sang total et monocytes périphériques a été fait et analysé par Gene Ontologie et EdgeR (66). Des différences significatives ont été observées entre le groupe cas et témoins pour 9 ARNmi dans le sang totale et 14 ARNmi dans les monocytes périphériques. Les gènes atteints interviennent dans de multiples voies de signalisation immunitaires dont l'interleukin-2. Cette étude nous permet de identifier des mesures prédictives mais surtout une meilleure compréhension de la pathogenèse de l'accouchement prématuré spontané.

Aide à la décision Clinique :

Une étude (67) utilise le data mining pour construire un modèle d'aide à la décision pour des patientes enceintes, à haut risque de AP, avant un éventuel cerclage du col utérin. Le but du modèle est de prédire si la grossesse évoluera après 26 semaines de gestation et si l'ajout d'un éventuel cerclage serait indiqué pour prolonger la grossesse. Dans un deuxième temps il vise à développer un modèle de prédiction du moment d'accouchement dans un groupe de femmes à haut risque post-cerclage. 4 modèles de classification ont été créés pour le projet d'aide à la décision. Le modèle le plus performant était un modèle à base de forêt aléatoire (Random Forest) avec une moyenne géométrique de 0.96 et une Sensibilité de 1.00 pour la prédiction de prolongation de grossesse au-delà de 26 semaines. Pour le modèle de prédiction du moment d'AP dans la cohorte à haut risque, le modèle de Random Forest avait une valeur de corrélation de 0.752. Ces deux outils seront très utiles dans un contexte où les décisions cliniques ne sont pas toujours simples et la gestion d'un éventuel AP nécessite une prise en charge globale.

3.1.3 Syndromes prénataux : Pré éclampsie :

Malgré les années de recherche et les avancées de la médecine, la pathogenèse de la pré éclampsie demeure incomplète. En matière de prévention, en dehors de la surveillance des signes cliniques et un éventuel signalement des facteur de risques, nous sommes limités. Il y a un besoin fondamental de pouvoir phénotyper les patientes (68) et mieux comprendre la survenue de ce syndrome. Ce genre de phénotypage nécessite des études avec un nombre de sujets très large, rendant difficile leur mise en place.

Néanmoins, il est possible que des nouvelles méthodes, dont l'intelligence artificielle puisse combler cette brèche en complétant les connaissances actuelles avec du big data, de analyse exploratoire approfondie et de la bio-informatique.

Modèles prédictifs et machine learning :

Prédiction précoce :

La prédiction précoce de la PE est important pour sa prise en charge. Un modèle de prédiction par machine learning (69) a été créé en utilisant uniquement des données cliniques et biologiques disponibles à partir des consultations prénatales (des 16 SG). Le modèle de prédiction obtenu pour la détection de PE précoce a atteint un AUC de 0.89 (IC 95% 0.84–0.95), une valeur vrai positive (VVP) de 72.3% et un taux de faux-positifs de 8.8%. La puissance de ce genre de modèle est élevée, démontrant l'utilité de l'IA dans l'analyse et l'utilisation des données déjà disponibles à partir des consultations de base.

Prédiction moyenne par utilisation des données des dossiers médicaux :

La prédiction de la PE est aussi possible en utilisant les informations disponibles dans les dossiers médicaux numérisés. Un modèle (70) de prédiction de PE précoce par ML a été créé à partir des données cliniques des dossiers numérisés en début de 2^e trimestre. 38 paramètres (disponibles facilement à partir des consultations anténatales normales) ont été analysés. Les variables les plus importantes pour la prédiction étaient la GAJ, puis la PAM (pression artérielle moyenne), puis l'IMC. Le modèle construit avec XGBoost a démontré une capacité de discrimination excellente, avec Exactitude = 0.920, une Précision de 0.447 et un AUC de 0.83, même avec modèle utilisable par le patient de façon indépendante. Ce genre de modèle incluant le patient dans la prévention est une avancée majeure : d'une médecine paternaliste a une médecine globale, responsabilisant d'avantage le patient dans sa prise en charge.

Prédiction de PE tardive (*late onset*) :

Un autre modèle (71) de prédiction de PE tardive (après 34 semaines) par ML a été créé en utilisant des données numérisées combinées aux données biologiques. La sélection de paramètres a été fait par reconnaissance de motifs et une analyse non supervisée par cluster. Pour ce modèle, les variables les plus influentes dans la prédiction étaient: PAS (pression artérielle systolique), taux d'urée et créatinine sanguines, taux de plaquettes, natrémie, taux de leucocytes, calcémie et protéinurie. Avec un modèle utilisant une descente de gradient stochastique pu atteindre une Exactitude de 0.973 et un taux de faux positive de 0.009.

Alors que l'utilisation des outils de prédiction analysant les bases de données hospitalières est bénéfique, l'utilisation des données par des assurances est potentiellement non-éthique (la gouvernance des données doit assurer une garantie humaine). Un modèle a été conçu en utilisant 95 variables démographiques et d'antécédents médicaux (72) fournis par les bases de données des assurances. Une analyse par Forêt aléatoire (Random Forest) a pu extraire 17 variables prédictives de PE. Une validation géographique a démontré la performance de ce modèle avec un AUROC de 0.88 (IC 95% 0.88-0.89).

La bio-informatique et la PE : pathogenèse, pathophysiologie, génétique et biomarqueurs :

Pathogenèse et pathophysiologie:

L'analyse des microARN (ARNmi) exosomal dans des cas de PE précoce et tardives en comparaison a des patients sans pathologie hypertensive (73) a pu démontrer des signatures spécifiques. L'analyse de ces échantillons d'ARNmi a été fait par technologie « Nano string ». D'autres signatures spécifiques de ARNmi présents dans la cadre de la PE ont aussi été découverts (74). Ce genre de découverte est une avancée majeure non seulement en tant qu'outil de diagnostic de PE mais aussi dans la compréhension de sa pathogenèse.

Une analyse de gènes et leur méthylation peut permettre une meilleur compréhension des voies biologiques contribuant à la survenue de PE. Une analyse compréhensive des DEGs et méthylation dans le cadre de PE (75) a démontré 536 gènes régulés positivement (up-regulated) avec une hypométhylation et 322 régulés négativement (down-regulated) avec une hyperméthylation. En analysant ces gènes par un programme de Gene Ontology, leur association avec différentes voies a été démontré, dont la phosphorylation peptidyl-tyrosine, la régulation de transcription, la migration des leucocytes, les voies de cellules lymphocytes T (T cell), adhésion cellulaire, la réponse de l'immunité innée et l'angiogenèse (entre autres).

Ce genre d'analyse offre une ouverture sur des implications génétiques et de la pathogenèse de pré éclampsie.

L'analyse génétique et PE:

La découverte de gènes hub est récente mais donne un nouveau regard sur l'importance de certains gènes dans la pathologie. Les gènes hub sont des gènes avec un taux de connectivité supérieure à la normale – en conséquence ils peuvent agir sur plusieurs voies biologiques (non connectées entre elles) et sont potentiellement clés dans la pathogenèse de maladies avec une étiologie génétique. Une étude (76) utilisant l'analyse intégrative de données de microarray a pu identifier des gènes hub liés à la survenue de PE. En plus de la présence (connue) de DEGs dans le cadre de PE, cette étude a démontré la présence de DEGs intervenant dans des processus biologiques hormonaux, immunitaires, stéroïdiens, de signalisation et métabolique. Avec cet analyse 17 gènes hub ont été identifiés, puis testés dans modèle de ML de type SVM. Leur performance est démontrée par un AUC de 0.958 dans le set d'entraînement et 0.834 dans le set de test. Ces gènes hub sont donc de potentiels biomarqueurs pour la PE. Une autre étude (77) a pu identifier 24 gènes hub différents (et 24 ARNmi reliés) dans le cadre de PE, liés à l'accroissement de la réponse inflammatoire, le système rénine-angiotensine et la voie 'JAK-STAT' (lié à l'immunité, l'apoptose, la division cellulaire et la tumorigenèse). L'implication de la voie JAK-STAT a aussi été démontrée dans une étude évaluant les ARNmi et ARNci (ARN circulants). (77)

L'analyse par microarray permet l'identification des gènes clés dans la pathogenèse de PE précoces, permettant une meilleure compréhension des mécanismes moléculaires qui sont liés, cibles potentielles de prévention et prise en charge. 628 DEGs sur ou sous régulés ont été identifiés dans le cas de PE précoce (78), dont 4 modules de gènes hub et 26 gènes hub significatifs. Ces gènes sont liés à l'interaction cellule-cellule, cellule-matrice, aux voies métaboliques placentaires, et stress oxydatif – ils jouent un rôle fondamental dans la compréhension de la pathogenèse de pré éclampsie précoce.

Biomarqueurs sanguins et PE :

L'établissement de liens et d'éventuels biomarqueurs sanguins est crucial dans la prévention de PE. Si, par simple prise sanguine, on peut estimer un risque de survenue de PE on peut donc entamer une stratégie de prise en charge adapté. Un modèle de régression logistique (79) a identifié plusieurs paramètres sanguins comme étant significatifs dans la prédiction de PE : le taux et volume des plaquettes, la distribution de la largeur des plaquettes, du ratio entre plaquette et cellules plus larges, temps de thrombine, taux de fibrinogène, taux de triglycérides, taux de LDH, taux d'azote uréique sanguin. Ces marqueurs témoignent du composant coagulo-vaso-rénale de la PE. A partir de cette étude : le taux d'azote uréique sanguine (OR=1.583), le volume moyen de plaquettes (OR=1.858), le taux de triglycérides (OR=1.104) et d'LDH (OR=1.020) ont été démontré comme prédictifs pour la survenue de PE.

« Indices » placentaires pour une meilleure compréhension de la PE :

De nouvelles découvertes sur le placenta, nous mène d'avantage à conclure sur son implication majeure dans les syndromes materno-fœtaux et la pléthore d'informations qu'il contient.

Avec une étude E-WAS (Epigenome wide association study) sur le placenta (80), plusieurs gènes hypo-méthylés (dont ceux associés avec la fusion du trophoblaste) ont été associé à la survenue de PE précoce. Les taux de méthylations ont été liés à la sévérité clinique alors que certains échantillons intermédiaires ont démontré des issues materno-fœtales antagonistes. La complexité de ces gènes et leur méthylation démontrent la complexité du syndrome de PE avec des réponses complexes et adaptatives au niveau materno-fœtale.

L'étude du ARNm placentaire (81) a été fait dans le but d'identifier d'éventuels biomarqueurs permettant un dépistage de PE. Un modèle de classification a pu atteindre 82.2% d'exactitude. Cet étude démontre l'importance de potentiels indices au sein du placenta. Le questionnement et limites de ces biomarqueurs repose sur l'accessibilité de ces échantillons dans un but de prévention et leur éventuelle validation par d'autres études plus approfondies.

3.1.4 Situations per-natales : Analyse du CTG et hypoxie fœtale

« De l'utilisation du stéthoscope de Pinard à l'intelligence artificielle » (82) - l'histoire de l'analyse du rythme cardiaque fœtale a beaucoup évolué depuis les dernières années et l'influencé de l'intelligence artificiel, mais son analyse et étude ne date pas d'hier.

L'enregistrement du rythme cardiaque fœtal (RCF) est fait avec des machines de cardiocographie (CTG) – mesurant le RCF et l'activité utérine en temps réelle (aussi appelé monitoring). L'analyse des tracés de CTG a été longuement étudié et enseigné aux professionnels intervenant dans le cadre de la périnatalité. Cependant, sa lecture est variable et operateur dépendant. Servant souvent d'élément clé dans l'étude a posteriori des cas cliniques dans un cadre médico-légal dans l'éventualité d'issues défavorables, il est d'autant plus important de standardiser le plus possible l'analyse d'anomalies du RCF et leur prise en charge. L'analyse sous forme de tracés se prête particulièrement bien à l'intelligence artificielle par son format plus ou moins standardisé et par l'analyse en continue de deux variables interagissant ensemble pour la détection d'anomalies ou situations pathologiques. De plus, les tracés de CTG sont des données collectées en routine (dans les pays développées) et constituent une base de données dont l'analyse et l'utilisation par modèles d'AI serait bénéfique non seulement pour des patientes singulières mais pour l'obstétrique en générale. Le débat sur l'analyse du CTG est continue - par lecture seule, le CTG a une spécificité basse dans la détection d'hypoxie fœtale (83), élément majeur dans la morbi-mortalité néonatale, dû à la variabilité d'interprétation inter-operateur. L'intelligence artificielle est potentiellement clé pour une lecture standardisée et plus sûre dans le futur.

Analyse de CTG par IA

L'intelligence artificielle est sujet de beaucoup de discussions dans le domaine de la santé et surtout au niveau de sa fiabilité. Beaucoup de cliniciens (et patients) se questionnent sur sa performance et précision – comment peut-on s'aligner avec un clinicien avec des années d'expérience ? Un modèle (84) créé pour l'analyse automatique des CTG par intelligence artificielle a trouvé une exactitude comparable aux obstétriciens, avec des 70-95% des conclusions identiques entre l'IA et l'obstétricien expérimenté.

L'utilisation de classification par *Legendre Deep Neural Networks* (LDNN) (85) pour l'analyse du CTG a aussi été évalué. Le modèle LNN classifie le CTG se basant sur le RCF et les contractions utérines (CU) et était plus performant que d'autres types de NN (dont

Volterra neural networks), nécessitant moins d'exigences informatiques et une convergence avec un taux d'erreur moyennement moins élevé.

Bien être fœtal : hypoxie-anoxie néonatale

Le but majeur du CTG est la détection du bien être fœtale et à l'inverse un état de détresse fœtale, dont l'hypoxie / anoxie, permettant une prise en charge adaptée (extraction fœtale / césarienne code rouge).

Les modèles de Deep learning sont particulièrement intéressants pour l'analyse des CTG par neural networks :

Un modèle de Deep learning par *fully convolutional networks* (FCN) (86) a été créé et analysé sur des données rétrospectives de CTG et leur issue analysée par le score d'Apgar à la naissance. Le modèle a pu établir une analyse des différentes catégories de CTG proche des praticiens avec un coefficient de Kappa de Cohen (coef. d'accord) de 0.525 et un AUC de 0.892 pour les 6 catégories données de CTG. Le modèle avait une meilleure sensibilité pour la prédiction d'états fœtaux non rassurants (0.528 vs 0.132) mais une valeur de faux-positifs plus élevés que les cliniciens (0.632 vs 0.012). Ces résultats témoignent de l'utilité de ce modèle mais aussi de son utilisation par un clinicien expérimenté.

L'utilisation de *Convolutional neural networks* (CNN) dans l'évaluation du bien être fœtal par CTG (87), surpasse la pratique clinique, avec une sensibilité de 42% versus 34%, dans la détection d'états fœtaux non rassurants avec un taux de faux positif comparable.

Un modèle de *Deep neural network* (DNN) (88) pu être développé avec un AUC de 0.73 ± 0.04 , surpassant les autres modèles testés (SVM, K-means, un autre DNN, LSTM).

Un autre type de réseau de neurones appelés auto-encodeurs (89) a aussi démontré une performance dans la prédiction de l'état fœtal à partir de l'analyse du CTG. Ce modèle a pu atteindre une Sensibilité de 99.716, une Spécificité de 97.500 et une moyenne géométrique de 98.602 avec une exactitude de 99.503.

En comparaison aux réseaux de neurones, un modèle innovant a été créé sur la base de « *image based time-frequency* » (90). Une représentation graphique du RCF est transformé en spectrogramme puis ensuite en images échelle de gris 8-bit puis analysé par un sous type de SVM. Ce genre de modèle a atteint une précision de classification moins bonne avec Se = 63.45% et Sp 65.88%.

Distinction entre fœtus sain et pathologique par CTG : cas de RCIU

L'analyse de CTG peut également être utilisée pour détecter une éventuelle pathologie fœtale ou retentissement de pathologie maternel chez le fœtus, et ce de façon précoce. Dans le cas de retard de croissance intra-utérine (RCIU), la prise en charge précoce est primordiale. Un modèle de machine learning a été créé pour distinguer des fœtus sains versus des fœtus atteints de RCIU par l'analyse du CTG (91). Par un modèle de Random Forest, la précision de classification était de 0.911 (IC 95% 0.860, 0.961).

CTG, bien être fœtale et choix du voie d'accouchement : Classification

De manière générale, le choix de la voie d'accouchement lors du travail spontané sans critères cliniques spécifiques, repose sur une lecture et analyse visuelle du CTG par l'opérateur. Le bien être fœtal tout au long du travail, conditionne le choix d'un accouchement par voie basse, sinon, en cas d'anomalies de RCF ou souffrance fœtale, un accouchement en urgence par voie haute (césarienne) ou extraction instrumentale.

La classification par AI peut éventuellement apporter de l'aide aux cliniciens dans leurs décisions. Un modèle de machine learning (92) avec 17 paramètres de CTG a été créé pour la classification de voie d'accouchement. Entraîné sur des données rétrospectives des issues de différents CTG, il permet de classer le CTG et aider à la prise de décision. Le modèle Random Forest a pu atteindre exactitude 91.1%, Se 90%, AUROC 96.7%, démontrant son utilité en clinique, accompagnant l'expertise du clinicien.

Un outil d'aide à la décision (CDSS) a aussi été formulé sur la même base de classification des tracés de CTG (93). Une combinaison de classificateurs avec Fishers Linear Discriminant Analysis (FLDA), Random Forest (RF) and Support Vector Machine (SVM) a pu atteindre des résultats prometteurs : Se : 87% (IC 95% 86-88%), Sp : 90% (IC 95% : 89-91), AUC : 96% (IC 95% 96-97), Mean square error 9% (IC 95% 9-10).

Dans le même genre, un modèle de classification de CTG permettant un nouveau système d'aide à la décision pour l'évaluation du bien être fœtale a été créé en utilisant à la fois l'IAGA (*Improved Adaptive Genetic Algorithm*) et Extreme Machine Learning (94). La précision de ce modèle de classification a pu atteindre 94% d'exactitude, permettant une bonne évaluation du bien-être de l'enfant à naître.

Conclusion : Limites et perspectives

En conclusion, il est simple de constater la performance des différents types d'algorithmes d'aide à la prise de décision ou de classification des CTGs. La question de la fiabilité et de l'explicabilité de ces modèles s'imposent, or, l'enjeu principal est le bien être fœtal.

Malgré leur performance, il est important d'aussi évaluer la concordance entre applications numériques et cliniciens (*inter-rate reliability*). Ceci peut être mesuré à l'aide de l'indice Kappa de Cohen, mesurant l'accord entre plusieurs techniques ou cliniciens. Une revue systématique et méta-analyse, évaluant la pertinence de l'IA dans l'analyse de CTG pendant le travail pour améliorer le pronostic fœtal (95) a été menée en 2019. En termes de *inter-rater reliability* (concordance) l'indice moyenne Kappa de Cohen était de 0.49 (IC 95% 0.32–0.66) représentant un accord modéré entre cliniciens et intelligence artificielle. En ce qui concerne l'issue fœtale, l'utilisation d'IA pour la lecture de CTG n'as pas eu d'incidence sur les taux d'acidose néonatale, de pH au cordon < 7.20, de score APGAR < 7 à 5 min de vie, de la voie d'accouchement, du transfert en néonatalogie, des convulsions néonatales ou de décès périnataux / néonataux. Cette méta-analyse a été tout de même limitée dans le nombre d'articles inclus (9) et dans les différentes plateformes utilisées.

Cependant, il faut prendre en compte la complexité de l'intelligence artificielle et la vitesse à laquelle ces technologies se développent. Il est possible et logique que ces techniques s'améliorent par le futur et permettront un jour une meilleure analyse du CTG.

En attendant, les perspectives futures d'analyse basique de CTG par IA sont validées et permettent des utilisations intelligentes dès maintenant. Il est possible que créer des systèmes de feedback constants avec des effecteurs automatiques (réversibles par le clinicien si besoin) permettant d'intervenir quasi-instantanément. Un exemple (96) est l'autofeedback de l'analyse du CTG lié à l'administration en pompe électrique d'ocytocine, comparable aux voitures automatisées qui freinent lors de la présence de piétons / objets dans leur chemin : des systèmes reliés au CTG arrêtent la pompe d'ocytocine en cas de décélération, en attendant l'intervention d'un clinicien.

3.1.5 Situations per-natales : Dystocie des épaules :

La survenue de dystocie des épaules est grave pour la mère et l'enfant, avec un potentiel de morbi-mortalité aigu pour la mère et l'enfant à naître. Alors que le consensus général d'experts estime que la dystocie des épaules (DDE) n'est pas prévisible (20), il est admis la présence des facteurs de risques associés à une sur-incidence de DDE. Dans la pratique clinique actuel les facteurs de risques retenus pour la prise en charge sont une macrosomie fœtale et la présence de diabète gestationnel.

En utilisant des données des dossiers médicaux numérisés, un modèle de prédiction a été développé pour la survenue de DDE (97). Dans la cohorte de validation le modèle a atteint une performance correcte avec une AUC de 0.866 versus pratique de prédiction ne tenant compte uniquement de l'estimation de poids fœtal combiné à la présence de diabète, AUC = 0.745 ± 0.044).

L'établissement de ce modèle a permis d'identifier de façon claire des facteurs prédictifs, avec un β positive :

- Estimation de poids fœtale ($\beta = 0.164$)
- Antécédent de diabète Type 1 / 2 ($\beta = 0.047$)
- Antécédent de DDE ($\beta = 0.04$)
- Fœtus de sexe féminin ($\beta = 0.04$)
- Périmètre abdominale ($\beta = 0.03$)

De plus, certains facteurs protecteurs ont été identifiés, avec une valeur β négative :

- Diamètre bipariétale ($\beta = -0.08$)
- Taille maternel ($\beta = -0.03$)

Quel apport clinique pour une éventuel prédiction de DDE?

Pouvoir prédire l'éventuel survenue de DDE permet de mieux prendre en charge la patiente et son enfant à naître, en minimisant les risques associés. D'éventuels changements à la prise en charge peuvent être entrepris : appel de l'obstétricien, césarienne, etc.

3.1.6 Situations per-natales : Hémorragie du post partum

L'hémorragie du post partum (HPP) représente 10,7% des décès maternels en France (1). Les facteurs de risques sont connus, mais le taux d'HPP en France ne semble pas diminuer : il est estimé que l'HPP sévère (saignements > 1000mL) concernait 3% des accouchements en 2021 en comparaison à 1.8% en 2016 (6). L'incidence des HPP non sévère (Saignements > 500mL mais < 1000mL) est estimé à 8% (6). Dans le monde, l'HPP est l'une des premières causes de décès des femmes enceintes (15)

L'utilisation de machine learning permet un nouveau regard sur les données disponibles, permettant de relever de nouveaux facteurs de risques et potentiellement améliorer la prévention et la prise en charge en amont.

(N.B en France l'HPP est considéré comme un saignement > 500mL, il est sévère si > 1000mL. Ailleurs dans le monde et pour ces études, l'HPP est considéré comme un saignement > 1000mL)

Deux types de modèles ont été testés (98) : deux modèles statistiques (regression logistique avec et sans un régression de type lasso) et 2 modèles de ML (RF et XGBoost). Le modèle XGBoost a démontré une performance supérieure aux autres modèles avec une performance discriminative supérieur dans la prédiction d'HPP avec un C statistique* de 0.93 (95% IC 0.92–0.93). Ce genre d'outil est potentiellement utilisable à l'admission pour pouvoir estimer le risque d'HPP et enclencher une prise en charge adaptée en cas de risque supérieur à la norme.

D'autres modèles (99) de machine learning et Deep Learning ont été créé utilisant données sur 25 ans. 5 modèles de ML (LR, SVM, RF, Boosting très et decision tree) ont été créés et un modèle de DL avec réseaux de neurones. 11 variables cliniques ont été utilisés pour la prediction de risque de HPP. Le modèle de régression logistique était le plus performant avec un AUC de 0.708, une exactitude (accuracy) de 0.686, un taux de faux positive de 0.312 et de faux négatifs de 0.398. Cette analyse a pu aussi mettre en lumière différentes variables prédictives de l'HPP : semaine de gestation, poids maternel à l'admission et avant la grossesse.

Le machine learning permet d'analyser une masse importantes de données pour pouvoir créer des modèles pouvant de prédire l'HPP. Ces modèles ne nécessitent pas d'analyses complexes donc seront aussi adaptés à des situations rurales. Ces modèles de prédiction de risque permettront aussi la création de score de calcul de risque, permettant de préparer en aval des moyens techniques, humaines et médicaux pour éviter l'HPP.

3.1.7 IA en Obstétrique : Morbi-mortalité maternel et néonatale :

La morbi-mortalité maternelle et néonatale englobe le sujet principal de ce travail. Les issues défavorables en obstétrique peuvent concerner toutes les femmes et leurs nouveau-nés. Parmi les différentes pathologies spécifiques vu précédemment, il est aussi possible de prédire de manière générale les issues périnatales défavorables. Ce genre d'outil permettra d'alerter et de mettre en place le transfert du patient vers une structure avec un plateau technique adapté. Il est important de noter également que la morbi-mortalité maternelle et néonatale sont souvent liées : l'exemple d'une rupture utérine – il y a une morbi-mortalité considérable pour la mère mais aussi le risque l'hypoxie-anoxie ischémique pour l'enfant à naître.

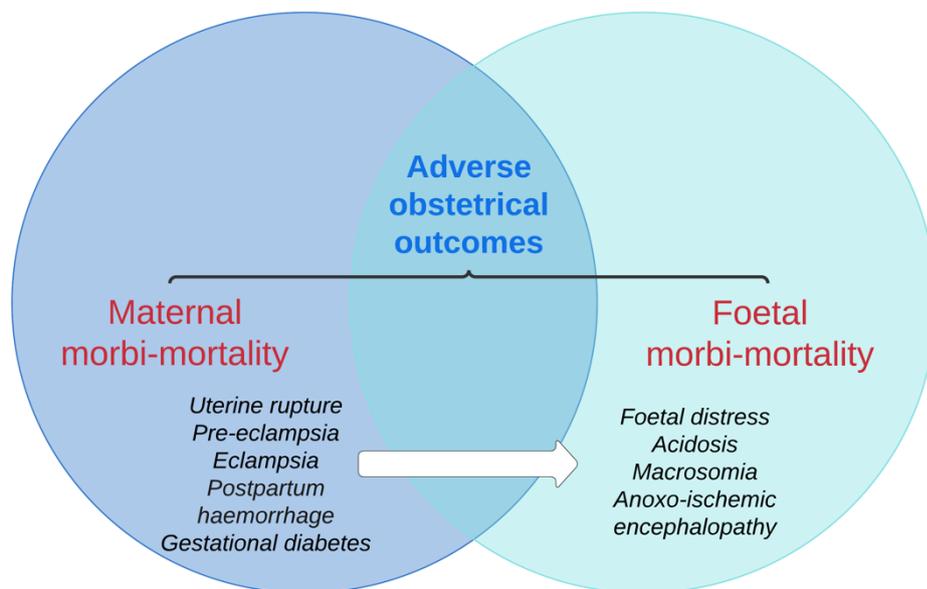


Fig. 8 : Intersection entre morbi-mortalité maternel et fœtale dans le cas d'issues obstétricales défavorables

Prediction des complications et morbi-mortalité obstétricale

L'utilisation des dossiers patient informatisés (DPI) pour la création de modèles de prédiction est aussi adapté à la prédiction des complications materno-fœtales en obstétrique (100). Avec 35 variables des dossiers patients informatisé dont des paramètres démographiques, biologiques, des constantes et du suivi du travail, un projet de machine learning a été créé pour la prédiction des complications obstétricales. Un modèle de type Gradient Boosted a démontré un AUC de 0.786 (légèrement supérieur au modèle de LR). Le

modèle final a pu détecter 52% des issues défavorables. Cependant son utilité en pratique clinique reste à démontrer par d'autres études.

Morbidité maternelle sévère (MMS)

La morbidité maternelle sévère (MMS) est un indicateur de santé de la femme important dans l'évaluation de nos pratiques. En France, en 2012, l'INSERM a lancé l'étude EPIMOMS (101) pour répondre aux questions non résolues sur la morbidité maternelle sévère. L'objectif de cette étude était de proposer une définition consensuelle de MMS, mesurer son incidence, ses facteurs de risques, et son évaluation. Un deuxième objectif était de concevoir un outil d'alerte précoce de MMS permettant de prédire l'évolution d'une issue défavorable en 'Near-miss' ou décès maternel. A ce jour, aucune liste définitive définissant de façon claire de MMS a été trouvée.

Pour pouvoir commencer à prédire et prévenir la MMS il est important de pouvoir correctement l'identifier. Un modèle basé sur l'étude des DPI (dossiers patients informatisés) (102) a été créé pour la détection automatique de MMS et les facteurs de risques associés. Ce modèle américain de ML a pu dépasser le modèle de référence du CDC (Centers for Disease Control and Prevention) avec un AUC de 0.94 versus 0.80. De plus, la valeur prédictive positive était meilleure : 0.22 versus 0.35. Cette étude a également permis de valider plusieurs variables prédictives novatrices dont: déséquilibre ou troubles hydroélectrolytiques, syndrome inflammatoire à réponse systémique (SIRS) et l'acidose.

Un modèle d' « ensemble ML » (103) a été utilisé pour la détection de vrai MMS dans des bases de données périnatales. L'algorithme SuperLearner a surpassé le criblage actuel au niveau de la valeur prédictive positive (VPP) = 0.77 vs. 0.64 et au niveau de la précision équilibrée = 0.99 vs. 0.86. Cependant ce n'était pas le cas pour le true positive detection rate (0.008 vs. 0.32) et la valeur prédictive négative. Ce genre de modèle, malgré sa puissance n'a pas pu améliorer la détection de cas de MMS.

Après avoir identifié et défini les cas de SMM il est possible de créer des modèles de stratification des risques pour l'identification de groupes à risques. Un algorithme basé sur l'étude des DPI (dossiers patient informatisé) (104) et les codes diagnostic utilisés et extraits combinés au ML a été créé. Le modèle de régression de type Lasso a pu identifier un groupe de patientes appartenant au décile le plus élevé de risque (2-3x fois la norme). Ce genre d'identification de groupe peut servir par la suite pour mettre en place un système d'alerte pour la prise en charge des patientes dès leur admission.

Morbi-mortalité néonatale

La morbidité néonatale est déterminant pour la santé tout au long de la vie de l'enfant. La mortalité néonatale est un indicateur de santé de la population globale et reflète aussi la qualité de la prise en charge médicale, sociale et préventive.

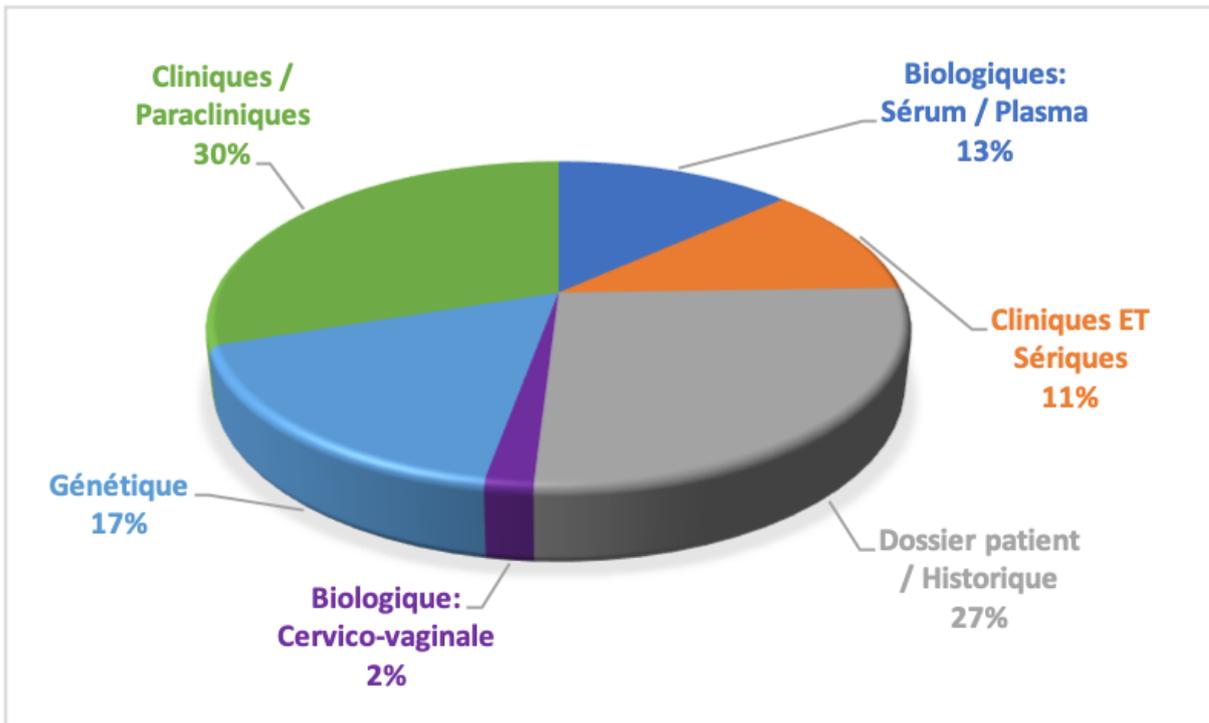
Un communiqué de l'INSERM en 2022 annonce l'augmentation significative de la mortalité infantile en France. Une étude de l'INSERM (105) collaborant avec l'AP-HP a relevé les décès infantiles de 2001 à 2019 : 53 077 décès de nourrissons ont été identifiés, soit un taux de mortalité moyen de 3,63/1 000. Un quart de ces décès sont survenus au cours du 1^{er} jour de vie et près de la moitié (47.8%) sont survenus au cours de la période néonatale précoce (6 premiers jours de vie). La mortalité néonatale précoce est en légère augmentation : 1,83/1000 en 2016 versus 1,64/1000 en 2005 (106). Ces valeurs témoignent d'une problématique de santé publique importante, où la France a tendance à s'éloigner des progrès des autres pays, de la même façon que les tendances de mortalité maternelle. L'intelligence artificielle est potentiellement la clé pour une meilleure prédiction, prévention en prise en charge de la santé des nouveau nés et mères.

Un modèle de ML pour la prédiction d'issues néonatales sévèrement défavorables lors du 2^e stade de travail a été conçu en utilisant les bases de données DPI (dossiers patients informatisés) (107). Ce modèle de type gradient boosting a été créé pouvant analyser plus de 21 millions points de données collectés en antepartum, à l'admission et pendant le 1^{er} stade de travail. L'issue néonatale sévèrement défavorables (SANO) a été défini comme soit : un pH au cordon ≤ 7.1 ou un APGAR à 5 ou 10 minutes ≤ 7 . Ce modèle a pu atteindre un AUC de 0.761 (IC 95% 0.748–0.774). Ce type de travail de ML permet une prédiction plus précise mais aussi une prise en charge personnalisée et en temps réel en prenant compte de la stratification de risque.

La prédiction de décès néonatale périnatale par le biais de ML a été comparé aux modèles utilisant une régression logistique simple (108). Il y avait une différence légère en termes de performance (non significative) mais le modèle de ML avait surtout un meilleur bénéfice net : une meilleure classification correcte des décès périnataux (entre FN et FP). Ce genre de modèle de ML peut être utilisé dans la prédiction de décès périnatal pour améliorer la prise en charge. Cette étude est limitée car elle évaluait les cas de décès périnataux en milieu subsaharien, incluant des femmes HIV +, des cas de paludisme etc. Cependant, la valeur prédictive de ce genre de modèle doit potentiellement être autant applicable à des cas moins complexes dans des pays développés comme la France.

3.2 Données d'entraînement des modèles

Les différentes données d'entraînement des modèles étaient variables entre données historiques (antécédents personnelle et familiale), des dossiers numérisés (DPI), cliniques (poids, taille, TA) et paracliniques (sériques, plasmatiques, cervico-vaginales, CTG). Une majorité des données étaient cliniques et/ou paracliniques.



*Fig. 8 : Provenance des données d'entraînement pour les modèles de machine learning
Analyse de l'ensemble des articles retenus : répartitions des données*

3.3 Synthèse des résultats

Il est complexe d'évaluer les différents modèles de façon comparative car les métriques de performance des modèles ne sont pas toujours comparables. La métrique de performance la plus commune entre les études était le AUC. Pour une synthèse très basique de puissance des études, un comparatif entre les études ayant utilisé le AUC comme métrique de performance a été fait.

Diabète gestationnel - modèles d'intelligence artificiel : Synthèse :

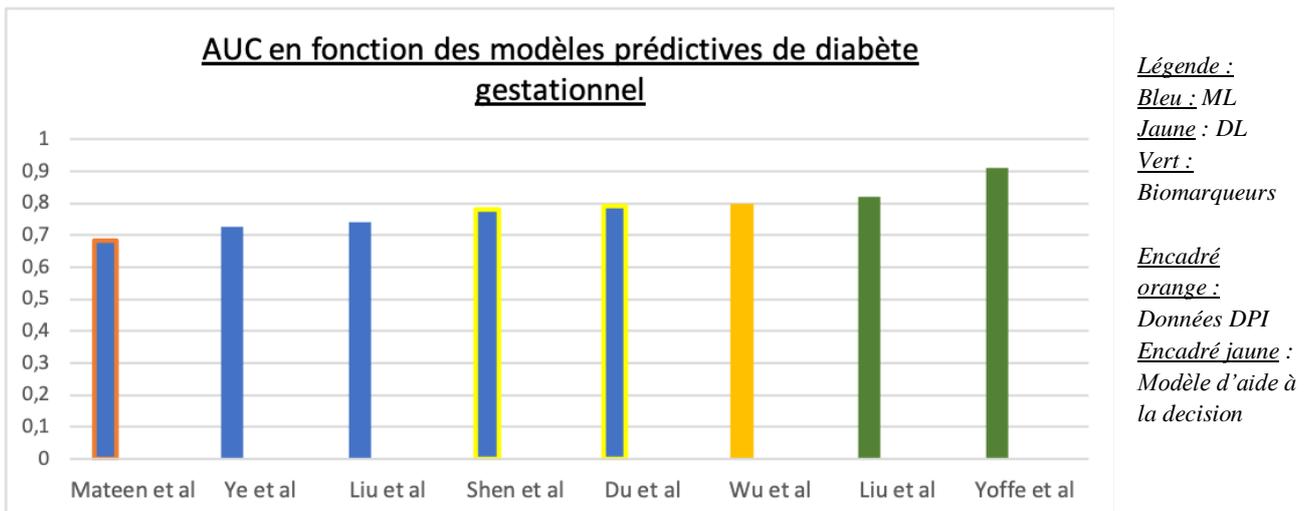


Fig. 11 : Comparatif : AUC en fonction des modèles prédictives de diabète gestationnel

Parmi les différents modèles évalués par AUC on peut conclure sur deux points. Dans un premier temps, parmi les modèles basés sur des données cliniques, le modèle de Deep learning est plus performant que ceux de ML simple. Dans un deuxième temps, les modèles utilisant des biomarqueurs ont une performance supérieure que l'utilisation des données cliniques / biologiques seuls. La puissance des biomarqueurs identifiés par intelligence artificielle est à approfondir sur d'autres études.

Accouchement prématuré : modèles d'intelligence artificiel : Synthèse :

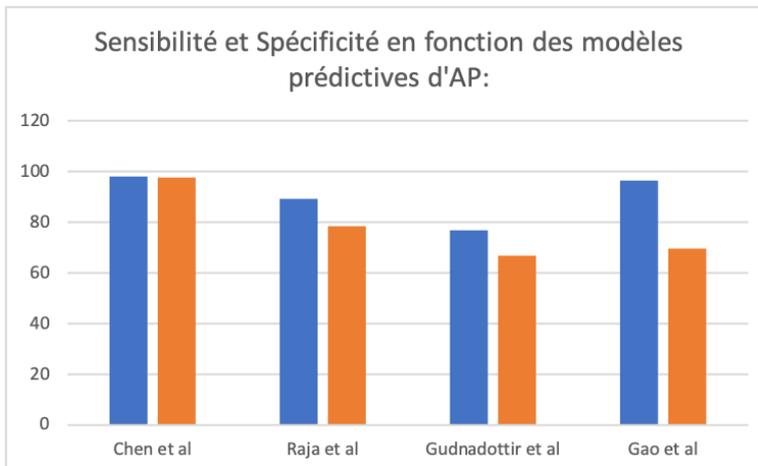


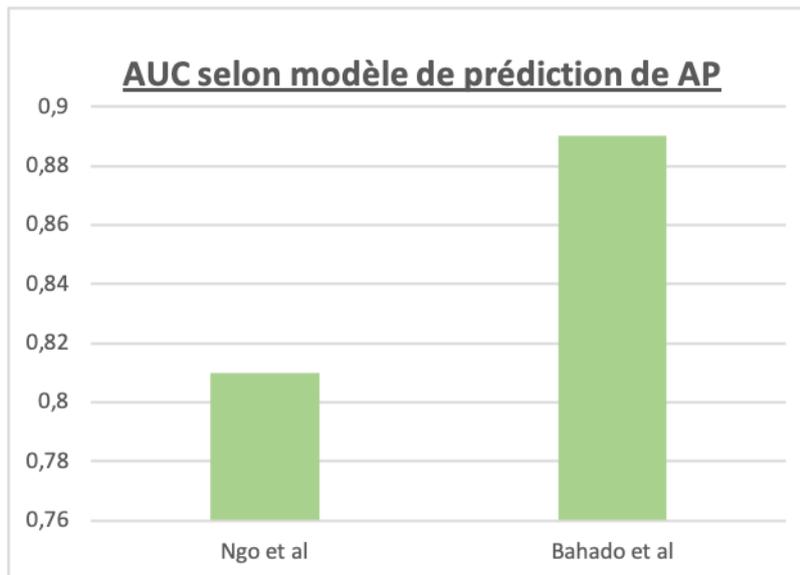
Fig. 12 : Comparatif de sensibilité et spécificité des modèles prédictives d'AP

Légende :

Sensibilité = bleu

Spécificité = orange

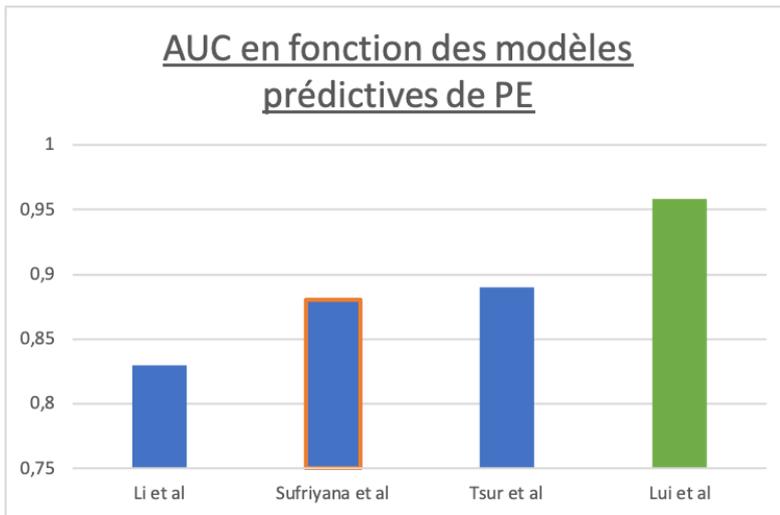
On peut donc conclure que le modèle avec la meilleure performance en termes de Se et Spé, était celle de Chen et al, (57), utilisant les données des CTG pour la prédiction d'AP.



En ce qui concerne les modèles évalués avec la métrique de AUC, le modèle de Bahado et al (64) était le plus performant, utilisant un modèle de multiomics. Ces résultats démontrent l'utilité des biomarqueurs.

Fig. 13 : Comparatif de AUC des modèles prédictives d'AP utilisant ce métrique

Pré éclampsie - modèles d'intelligence artificiel : Synthèse :



Légende :

Bleu : ML

Jaune : DL

Vert : Biomarqueurs

Encadré orange : Données DPI

Encadré jaune : Modèle d'aide à la décision

En ce qui concerne la prédiction de prééclampsie, le modèle prédictif doté d'un biomarqueur était largement plus performant que les autres modèles.

Fig. 14 : Comparatif de l'AUC des modèles prédictives de PE

Analyse CTG - modèles d'intelligence artificiel : Synthèse :

Auteur	But	Type	AUC	Précision	K Cohen	Se %	Spé %
Lui et al	Bien être foetale	DL : FCN	0,892		0,525		
Petrozziello et al	Bien être foetale	DL : CNN				42%	
Ogasawara et al	Bien être foetale	DL : DNN	0,73				
Iraji et al	Bien être foetale	DL: DSSAE				99,7	97,5
Cömert et al	Bien être foetale	Image based				63,5	64,88
Signorini et al	RCIU: Détection	ML RF		0,911			
Ricciardi et al	Voie dacc	ML RF	0,967			90	
Fergus et al	Voie dacc	ML combiné	0,96			87	90

Tableau 5 : Synthèse comparatif des modèles d'IA d'analyse de CTG : types, buts et métriques de performances

(DL = Deep learning, FCN = fully convolutional networks, CNN = convolutional neural networks, DNN = deep neural networks, RF = random forest)

En termes de détection de bien être fœtal, les modèles de Deep learning (DL) ont une performance supérieure. Pour les modèles utilisés pour le choix de la voie d'accouchement, les modèles de machine learning ont une performance comparable et puissant

Prédiction HPP - modèles d'intelligence artificiel : Synthèse :

Dans les deux modèles cités, les métriques de performance sont différentes et les méthodes de prédiction aussi. Il est donc difficile de conclure sur une supériorité.

Le modèle de Venkatesh et al (98), utilisant des données facilement accessibles, permettra éventuellement une évaluation supplémentaire à l'admission, avec un index de corrélation de 0.93 (95% IC 0.92–0.93).

Le modèle de Akazawa et al (99), démontre la supériorité de regression logistique par rapport au ML, mais une performance modérée : avec un AUC de 0.708, une exactitude (accuracy) de 0.686, un taux de faux positive de 0.312 et de faux négatifs de 0.398.

Prédiction morbi-mortalité maternel et néonatal - Synthèse :

En l'absence des résultats de l'étude EPIMOMS, la baseline défini pour ce travail sera celle du modèle prédictif du CDC au États Unis. On voit donc que le modèle d' Escobar et al (100) n'a pas pu dépasser en termes de performance la baseline qu'est le modèle du CDC, mais que le modèle de Gao et al (102) était largement supérieure.

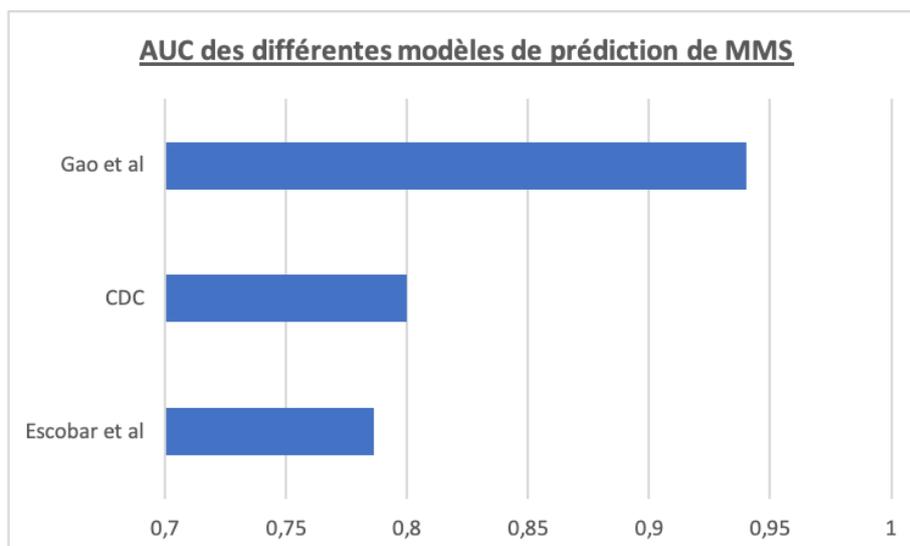


Fig. 15 : Comparatif de l'AUC des modèles de prediction de MMS (morbidité maternel sévère)

En ce qui concerne la morbi-mortalité néonatale :

Un premier modèle de ML (107). a été créé, avec une performance correcte (AUC = 0,761), un deuxième modèle de ML (105) avait également une performance en termes de classification correct des décès (entre FN et FP). Il y a un manque de données sur ce genre de modèle, car peu de modèles existent. Avec ces résultats prometteurs il serait intéressant

d'établir un projet dans le même sens que le projet EPIMOMS pour évaluer les pratiques et erreurs dans la morbi-mortalité néonatale.

4. Discussion

4.1 Éthique de l'IA en santé

Hippocrate, père fondateur de la médecine, décrètera, « primum non nocere » - qu'il faut d'abord ne pas nuire. Les techniques en médecine ont beaucoup évoluées depuis son époque (400 avant JC) mais les principes éthiques de médecine perdurent. Avec chaque nouvelle découverte et amélioration il est important de toujours questionner ce point éthique.

Dans l'utilisation de l'IA au sein de la santé, après évaluation, l'OMS a défini 6 principes guidant une utilisation éthique et responsable - limiter les risques et maximiser les opportunités qu'elle nous offre (109) :

- **La protection de l'autonomie humaine:**

Nous devons toujours garder le contrôle des systèmes de santé IA, y compris pour la sécurité et confidentialité des données. Le consentement éclairé doit être recueilli auprès des patients sur l'utilisation de leurs données dans ce genre de système.

- **La promotion du bien-être, de la sécurité et de l'intérêt majeur des systèmes :**

Les technologies utilisant l'IA doivent satisfaire des critères de sécurité, précision et efficacité avec des cas d'usage bien définis. La satisfaction des critères doit être continue et mesurée par contrôle qualité en pratique pour une amélioration continue.

- **Assurer la transparence, l'explicabilité et l'intelligibilité :**

La transparence doit être assurée par une quantité d'informations suffisantes publiées avant le déploiement du modèle. Ces informations doivent demeurer accessibles et consultables de façon publique pour permettre un débat sur la conception et l'utilisation de ces technologies par tous.

- **Responsabilité et « accountability » :**

Malgré l'autonomie des technologies ; c'est aux auteurs de s'assurer de leur utilisation correcte par des personnes correctement formées.

- **Inclusivité et Équité :**

L'IA pour la santé doit être conçue pour être applicable de façon inclusive et équitable, par le plus grand nombre de personnes, sans distinction de leur âge, sexe, genre, situation socio-économique, ethnicité, orientation sexuelle ou habilité (selon les codes des droits humains).

- **La promotion d'une IA qui est loyale et durable :**

Les développeurs et utilisateurs se doivent d'accéder de façon régulière aux applications d'IA, dans leur utilisation pratique, pour déterminer si la réponse du modèle est adéquate et appropriée. Les modèles devront être conçus dans le but de minimiser leurs conséquences environnementales et énergétiques. Les gouvernements et ministères doivent adresser l'arrivée de l'IA dans le domaine de la santé ; en l'intégrant dans la formation des praticiens adaptés à son utilisation mais aussi en prévoyant la perte d'emploi due à des systèmes automatisés.

L'éthique est intimement liée à l'IA et sa mise en place pour la santé nécessite des considérations particulières sur les risques liés à son utilisation.

4.2 Fiabilité de l'IA : Risques, erreurs et lacunes

L'IA est outil puissant, mais qui n'est pas sans limites et sans risques. L'utilisation de l'IA en général et surtout en santé nécessite la prise en compte des risques et un cadre défini.

Les risques majeurs qui lui sont attribués sont à prendre en compte à toute les étapes de la mise en place de l'IA dans la santé.

4.2.1 Risques : Erreurs :

La notion de risque d'erreur est universelle. Au sein de l'intelligence artificielle il est important de le prendre en compte et de l'évaluer pour pouvoir utiliser les outils d'IA correctement.

Deux formes de risques d'erreurs existent :

- Le risque d'erreur lié à une mauvaise utilisation des outils IA biomédicaux. Ce genre d'erreur est d'origine strictement humaine et peut être négociée par la formation correcte des professionnels, des cas d'usages strictement définis et adaptables aux situations cliniques de façon claire.
- Le risque d'erreur par IA et le risque conséquent de préjudice aux patients. Ce genre de risque est informatique, mais nous restons responsables de ces derniers, ayant le contrôle sur la conception, fonctionnement et maintenance de ces outils.

Une partie des erreurs d'IA est aussi dû aux artefacts et problèmes dans les données qui changent effectivement l'issue du fonctionnement. Cela souligne l'importance des données représentatives et claires.

Les erreurs en général, peuvent aussi être sous la forme de biais. Le biais des données et donc des décisions pris ont un effet « en boule de neige » potentiellement catastrophique pour la prise en charge des patients. En effet, le biais humain peut potentiellement être intégré dans les modèles de IA par un manque de représentativité des données. L'importance des données représentatives est donc primordiale pour ne pas causer de biais dans les systèmes IA, qui peuvent potentiellement mener à une perpétuation des inégalités déjà trop présents au sein de la santé.

4.2.2 Risques : Lacunes

Dans les modèles de IA il peut aussi avoir des lacunes sur plusieurs niveaux, menant à des modèles imprécis, dangereux et non éthiques.

Les lacunes peuvent concerner trois cadres : la responsabilisation (accountability), la sécurité et l'adaptabilité.

La responsabilisation concerne la transparence et l'explicabilité. La transparence dans la conception, fonctionnement et utilisation des modèles est primordiales pour la confiance des cliniciens en ces modèles mais aussi l'éthique.

La sécurité des modèles est surtout cadrée autour de la sécurisation et confidentialité des données à la fois entrant et sortant. Le respect de la vie privée est non seulement impératif d'un point de vue éthique mais aussi légalement avec les lois concernant le RGPD (Réglementation générale de protection du traitement des données personnelles) en vigueur dans l'UE.

Enfin, des lacunes au niveau de l'adaptabilité sont à noter et rectifier. Certains modèles sont performants mais non adaptés voir non adaptables à d'autres situations. Les modèles se retrouvent donc utilisés dans des contextes favorisés, tout en délaissant des cadres défavorisés, ou justement l'IA peut être utile. Cette inadéquation des modèles peut participer à creuser encore les inégalités déjà présentes.

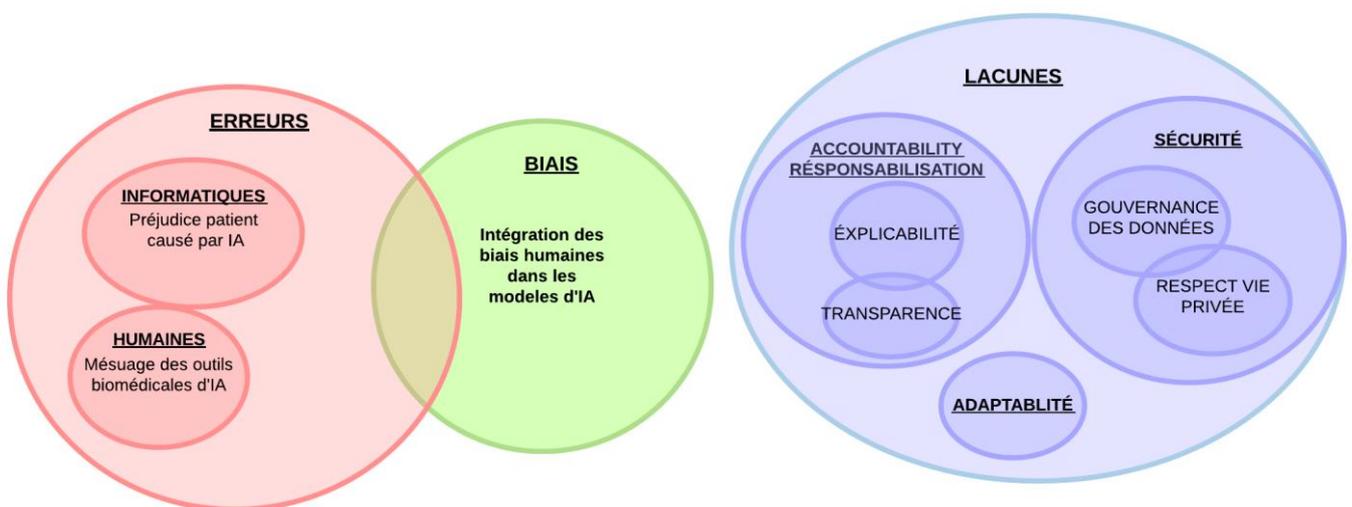


Fig.16 : Synthèse des risques de l'IA en santé : Erreurs, biais, lacunes

4.3 Implications pour l'intégration de l'IA en pratique

4.3.1 Du concept au développement puis au déploiement :

4.3.1.1 Baseline pratique : un point de départ :

Il est nécessaire d'analyser concrètement les pratiques actuelles et définir une baseline valide pour pouvoir s'y référer par la suite. La solution IA a une problématique donnée doit être adaptée aux pratiques actuelles mais aussi adaptables aux différents centres dans laquelle elle sera utilisée. La solution donnée n'est pas « one size fits all » mais plutôt un projet avec une marge de personnalisation pour pouvoir être mise en place de façon concrète sur plusieurs centres.

Ressources nécessaires :

- Il est impératif d'identifier quel sont les ressources nécessaires à la mise en place de l'intelligence artificielle et identifier les points de ressources qui seront des murs infranchissables dans certains cas :
- Question de données représentatives (labélisées) – encadrés par une gouvernance : sécurité et confidentialité
- Possibilité de le faire : faisabilité
- Évaluer l'intérêt clinique.

Securité et confidentialité

D'après les recommandations du Parlement Européen, les modèles IA doivent protéger les données des usagers avec les lois de protection de vie privé en vigueur : GRPD.

De façon précoce dans la conception d'un projet IA il est nécessaire de définir la provenance des données 'input' (entrant – pour entraînement) mais aussi leur destination. Une conception de programme en prenant compte l'issue des données est potentiellement plus complexe mais permet une sécurité supplémentaire et un respect des politiques de confidentialité – on parle de « privacy by design ».

La sécurité est importante d'un point de vue éthique mais également pour établir une relation de confiance avec les usagers.

Contexte et politique d'utilisation future: cas d'usages et utilité

Dans la conception il est important de prendre en compte le contexte d'utilisation : qui sera l'utilisateur et pourquoi ? En définissant les utilisateurs on peut aussi définir le cadre d'usage et le politique d'usage.

Entraînement des algorithmes : soucis de data availability :

L'entraînement d'un éventuel programme conçu nécessite une quantité importante de données et la question de leur qualité et origine est importante.

La qualité des données est primordiale, suivant le concept de GIGO (Garbage in – Garbage out). La qualité des données d'entrée conditionne la qualité des données de sortie.

Il faut prendre en compte plusieurs critères au niveau des données pour s'assurer de la qualité optimale pour l'entraînement des algorithmes : (110)

- Biais de représentation le data doit être représentatif lors de la collection de données il faut être attentif au niveau du : biais de sélection, biais d'exclusion, biais de détection et biais de reportage pouvant mener aux sous ou surreprésentations. (Sans oublier la couverture spatio-temporel : au niveau géographique et dans le temps)
- Accessibilité des données : spécifier leur provenance et les niveaux de standardisation, interopérabilité et sécurité associés.

4.3.1.2 Déploiement

La place du praticien dans le déploiement de nouveaux programmes d'IA en santé :

Les programmes de l'IA au sein de la santé sont créés avec les patients et leurs données au cœur du projet. La place du clinicien dans la conception, déploiement et utilisation des programmes d'IA dans la santé est également primordiale.

Pour que l'IA soit validée et utilisée par les cliniciens il est nécessaire de s'assurer de leur compréhension de ces programmes. Il faut noter l'importance de l'explicabilité des programmes et l'acceptabilité par les cliniciens dans leur pratique quotidienne.

La place de la formation continue médicale est primordiale : ce sont des moments propices à la mise en place de programmes.

La plateforme de « IA en santé » de l'ANAP (111) (Agence nationale de la performance sanitaire et médico-sociale) est une plateforme créée par le gouvernement français pour la mise en avant de projets d'IA au sein de la santé. Sa mise en place permet de créer un espace règlementé et sécurisé pour cette mise en avant et représente un socle de confiance sur laquelle les cliniciens peuvent de baser.

4.3.1.3 Post déploiement

Après la phase de déploiement, la phase de post déploiement est non négligeable pour mesurer la place du projet dans la pratique clinique quotidien et d'assurer la pérennité de son utilisation.

- L'évaluation de l'impact du projet permet de valider sa nécessité. Il est nécessaire de pouvoir définir un impact quantifiable de l'application de IA en faisant référence à la baseline définie en pré-déploiement. Le contraste de performance entre la référence utilisée avant sa mise en place et l'éventuel amélioration qu'apport l'IA permet de quantifier son impact.
- L'évaluation de la valeur des données sortantes (output) : Il est nécessaire de privilégier plutôt des données de petite quantité mais de haute qualité mais aussi d'évaluer leur puissance des données extrapolables par la suite.
- La gouvernance des données est primordiale pour assurer une IA sécurisée, éthique et sûre. Des règles claires ont été établies par les lois du RGPD, mais la gouvernance des données ne s'y limite pas : la sécurité et la transparence sur l'issue des données permet de créer une IA de confiance.
- La maintenance d'un éventuel programme d'IA est nécessaire pour assurer non seulement son fonctionnement mais aussi sa sécurité. La maintenance intègre aussi les mise a jours, voire mise à niveau en cas d'avancement au niveau des connaissances. La maintenance assure une qualité optimale et continue et donc un fonctionnement sur de façon constante. Cette maintenance doit être assuré par des laboratoires labélisés et formés.

4.4 Cas d'usages en place à présent :

Dans le cadre de l'obstétrique, plusieurs projets d'utilisation concrète d'IA existent. Ce sont des projets dont l'utilisation est encore en phase « test », mais l'espoir est que ces technologies soient intégrées progressivement dans la pratique clinique quotidien.

4.4.1 Suog – « Smart Ultrasound in Obstetrics and Gynaecology »

Un projet innovant de la Sorbonne, intégrant l'IA au sein du suivi obstétricale par échographie (112). Basé sur un modèle de reconnaissance d'image cumulé avec une base de connaissances (Ontology) ce projet vise à devenir un soutien aux cliniciens dans leurs analyses en échographies. C'est un système qui agit en temps réel, au cours de l'échographie, lorsqu'une anomalie fœtale est détectée, propose à l'utilisateur de réaliser des coupes correspondant pour pouvoir poser un diagnostic. Ces images peuvent ensuite être envoyées à des spécialistes pour une éventuelle télé-expertise – accélérant et optimisant la prise en charge anténatale en médecine fœtale. Il s'agit d'un guidage itératif, en temps réel par intelligence artificielle. Le but n'étant pas de remplacer le clinicien mais de le soutenir dans ses compétences pour une efficacité diagnostique optimale. Utilisable et compréhensible par les praticiens, ils utilisent une base d'ontologie pour éviter un effet dit « de black box » – toutes les prises de décisions sont compréhensible par les humaines.

4.4.2 Sonio – programme d'aide à la décision en échographie

Sonio est un projet soutenu par l'École Polytechnique (113), se présentant comme un programme d'aide à la décision en échographies pour les cliniciens pratique de l'échographie prénatal et diagnostic. C'est un « Knowledge based AI » avec un thesaurus de près de 300 pathologies. En temps réel, à chaque étape de l'échographie, l'algorithme propose au praticien la prochaine étape à prendre, créant avec le praticien un « diagnostic pathway » permettant de dépister le mieux possible d'éventuel anomalies. Il a un taux de succès de plus de 95% dans la détection de 7 pathologies les plus communs.

L'intelligence artificielle peut aussi être intégrée dans la pratique clinique sous forme d'application avec algorithme de prediction.

4.4.3 QUiPP : Application NHS d'aide à la décision pour MAP :

Ce projet, appelé QUiPP (114), “User friendly application for the prediction of pre-term labor by clinicians”, est un outil d'aide à la décision pour des praticiens dans la prédiction de menace d'accouchement prématuré (MAP) pour des femmes asymptomatiques à haut risque ou symptomatiques sans antécédents. Il a été conçu pour être utilisé avec les patientes, les incluant dans leur prise en charge dans un cadre de « patient-centered care » pour conclure sur une prise en charge décidé ensemble avec le praticien.

Le programme est un modèle de prédiction utilisant plusieurs critères cliniques et biologiques dont : le taux de fibronectine fœtale sur prélèvement cervico-vaginale et/ou la cervicométrie.

Il prend aussi en compte : les antécédents d'AP et l'âge gestationnel.

Son utilisation a été prévu pour 2 cas :

- La prise en charge des femmes à haut risque d'AP mais qui sont asymptomatiques
- La prise en charge des femmes avec des symptômes, mais non appartenant à un groupe particulièrement à risque.

Le but de ce programme a été de proposer une prise en charge ciblés (plutôt que généralisé) permettant de cibler les moyens cliniques et matérielles sur toutes les femmes à risque.

Les résultats sont prometteurs avec un AUC de 0.763 (115) pour l'utilisation combiné de mesure de fibronectine fœtale sur prélèvement cervico-vaginale et la cervicométrie.

4.5 Acceptabilité, perspectives et conclusion :

4.5.1 Acceptabilité : point de vu des patientes

L'acceptabilité par les patients de l'utilisation de l'IA dans le domaine de la santé est importante à prendre en compte.

Une étude (116) a démontré des bénéfices perçus par les patients, mais aussi leurs inquiétudes : globalement, les bénéfices de l'IA sont bien compris par le public :

Bénéfices perçus :	Inquiétudes :
<ul style="list-style-type: none">- Services plus rapides- Meilleure précision dans la gestion- Disponibilité des services de l'IA : 24h/24h- Une moindre charge de travail au sein des équipes- Prises de décision équitable	<ul style="list-style-type: none">- Sécurité des données : cybersécurité- Biais et qualité de l'IA- Moins d'interactions avec des êtres humains- Erreurs algorithmiques et responsabilité- Limites technologiques

L'inclusion des patients, ou groupe de représentants, est important dans la conception des programmes d'IA dans la santé.

Une revue systématique publiée dans *The Lancet* (117), a démontré que les études sur les connaissances des patients concernant l'IA étaient hétérogènes. Cependant, l'utilisation de l'IA dans la santé était globalement bien acceptée par les patients avec certaines réticences, dont la supervision de l'IA par un clinicien humain.

4.5.2 Perspectives de l'IA en santé

En conclusion, l'intelligence artificielle représente un nouveau regard sur la médecine et la façon de soigner nos patients. L'IA en synergie avec les cliniciens représente une nouvelle équipe pour une nouvelle ère technologique.

La place des cliniciens et l'IA :

« l'IA va-t-il remplacer les cliniciens ? » :

La réponse courte est non. Le but de l'IA à la base et surtout au sein de la médecine, n'est pas le remplacement mais une amélioration. L'automatisation des tâches est utile et utilisée, mais la décision finale repose sur le clinicien.

« There is an AI in team” : Un travail d'équipe entre humains et IA :

Pour une utilisation correcte, l'IA doit être utilisé en équipe avec les cliniciens.

Dès sa conception, des mesures doivent être prises pour assurer un AI conçu avec les cliniciens et patients au centre de son fonctionnement. Son utilisation doit être encadré par des cas d'usages concrètes et une utilisation éthique.

L'AI représente un soutien aux cliniciens, non pas un remplacement. La combinaison des meilleurs outils de machine learning avec les meilleurs atouts des cliniciens humains permettras une prise en charge bien meilleure que l'IA ou le clinicien seul.

New frontiers for medicine: can AI help fill the gaps?

Avec une population mondiale de plus de huit milliards de personnes, après avoir traversé plusieurs années de pandémie, les écarts en termes de santé déjà présents, se font d'avantage ressentir. D'écarts existent entre différentes pays autour du monde, mais également au sein même de certains pays développées. L'écart de soins est une problématique à la fois éthique et générale.

L'IA a été très utile lors de cette pandémie Covid-19: pour le suivi épidémiologique, la création des vaccins et des médicaments, la prediction de risques d'infection, des cas d'infection voir des modèles d'évaluation des mesures préventives. Il est admis que nous serons confrontés à d'autres pandémies dans le futur et les leçons apportés par l'IA seront utiles dans le futur.

En dehors des crises aiguës, la croissance des NCDs (non-communicable diseases) menace la santé de tous et limite l'espérance de vie. L'utilisation de l'IA dans un but de

prévention et gestion de ces NCDs est potentiellement la solution pour répondre au croissance exponentielle des décès liés à ces maladies.

Dans un monde où les ressources ne sont pas partagées de façon équitable, l'IA offre aussi une possibilité d'une meilleure utilisation et partage des ressources, déjà rares dans certaines parties du monde. Une médecine égale n'existe pas mais l'équité est possible : l'utilisation de l'IA par tous les moyens est potentiellement la façon d'arriver à une médecine équitable.

IA : le futur de la médecine personnalisée :

La puissance de l'intelligence artificielle peut être utilisée pour une évaluation des données patients pour offrir une médecine personnalisée. Les technologies et l'étude des données « -omics » offrent un nouveau regard sur les processus biologiques, la pathogenèse et la prévention des maladies.

4.5.3 Conclusion : IA en obstétrique :

L'IA déjà présent dans le domaine de la santé est aussi applicable en obstétrique. Étant une spécialité à risque, gérant à la fois la patiente et son fœtus, il est important de pouvoir mieux prédire les issues défavorables. L'évolution de la morbi-mortalité maternelle et néonatale en France n'est pas satisfaisant.

L'IA offre des possibilités de prédiction pour une meilleure prise en charge, en intra-hospitalier aussi bien qu'en extrahospitalier, par le biais de modèles de prédiction, calcul de score de risque et algorithmes d'aide à la décision - que ce soit par des données cliniques, paracliniques ou biologiques. Les technologies de classification se montrent utiles dans l'analyse des données cliniques pendant le travail, comme la cardiotocographie, pour harmoniser les pratiques.

Pour des pathologies complexes, tel que la pré éclampsie, dans lesquelles certains facteurs n'ont toujours pas été élucidés, l'étude des données de type « -omics » offrent un nouveau regard sur la pathogenèse. La découverte des biomarqueurs permettent des modèles de prédictions bien plus puissants que ceux en place actuellement.

La prise en charge en obstétrique est complexe et risqué. Il est impératif d'offrir une meilleure prise en charge et prévention pour répondre aux risques auxquels nous sommes confrontés. Au sein de la France et les DOM-TOM la variété de l'offre de soins est grande et nous nous devons répondre à ces manquements par des solutions concrètes, pour une santé materno-fœtale équitable. Au sein de l'obstétrique, l'IA n'est pas une solution miracle mais plutôt un soutien sur plusieurs niveaux : pour la recherche, pour les cliniciens et pour la prévention. Nous nous devons d'explorer ces technologies de façon plus appuyée et de s'engager à leur mise en place de manière correcte, adaptée et surtout éthique.

Bibliographie

1. Les morts maternelles en France : mieux comprendre pour mieux prévenir. 6e rapport de l'Enquête Nationale Confidentielle sur les Morts Maternelles (ENCMM), 2013-2015. Saint-Maurice : Santé publique France, 2021 [Internet]. Available from: <http://www.xn--epop-inserm-ebb.fr/wp-content/uploads/2021/01/Rapport-mortalite-maternelle-2013-2015.pdf>
2. Ives CW, Sinkey R, Rajapreyar I, Tita ATN, Oparil S. Preeclampsia—Pathophysiology and Clinical Presentations: JACC State-of-the-Art Review. *J Am Coll Cardiol*. 2020 Oct 6;76(14):1690–702.
3. Pré-éclampsie · Inserm, La science pour la santé [Internet]. [cited 2022 Oct 21]. Available from: <https://www.inserm.fr/dossier/pre-eclampsie/>
4. Merviel P, Touzart L, Deslandes V, Delmas M, Coicaud M, Gondry J. Facteurs de risque de la prééclampsie en cas de grossesse unique. *J Gynécologie Obstétrique Biol Reprod*. 2008 Sep 1;37(5):477–82.
5. Ghesquière L, Clouqueur E, Garabedian C, Tsatsaris V, Houfflin-Debarge V. Peut-on prévenir la pré-éclampsie ? *Presse Médicale*. 2016 Apr 1;45(4, Part 1):403–13.
6. Enquête nationale périnatale | Rapport 2021. 2021;297.
7. RCP DG 2010. *J Gynécologie Obstétrique Biol Reprod*. 2005 Sep;34(5):513.
8. Masson E. Étude DIAGEST 3 :Prévention du diabète de type 2 chez les femmes ayant présenté un diabète gestationnel : Étude DIAGEST 3 : données démographiques et adhésion au programme [Internet]. EM-Consulte. [cited 2022 Apr 20]. Available from: <https://www.em-consulte.com/article/800812/po10-prevention-du-diabete-de-type-2-chez-les-femm>
9. Ardiç C, Çolak S, Uzun K, Salı G, Aydemir T, Telatar G. Maternal Gestational Diabetes and Early Childhood Obesity: A Retrospective Cohort Study. *Child Obes Print*. 2020 Dec;16(8):579–85.

10. Torchin H, Ancel PY, Jarreau PH, Goffinet F. [Epidemiology of preterm birth: Prevalence, recent trends, short- and long-term outcomes]. *J Gynecol Obstet Biol Reprod (Paris)*. 2015 Oct;44(8):723–31.
11. Zeitlin J, Szamotulska K, Drewniak N, Mohangoo A, Chalmers J, Sakkeus L, et al. Preterm birth time trends in Europe: a study of 19 countries. *BJOG Int J Obstet Gynaecol*. 2013;120(11):1356–65.
12. Marret S, Marchand-Martin L, Picaud JC, Hascoët JM, Arnaud C, Rozé JC, et al. Brain Injury in Very Preterm Children and Neurosensory and Cognitive Disabilities during Childhood: The EPIPAGE Cohort Study. *PLoS ONE*. 2013 May 2;8(5):e62683.
13. Enquête nationale périnatale 2016. Les naissances et les établissements, situation et évolution depuis 2010 | Direction de la recherche, des études, de l'évaluation et des statistiques [Internet]. [cited 2022 Nov 3]. Available from: <https://drees.solidarites-sante.gouv.fr/publications/rapports/enquete-nationale-perinatale-2016-les-naissances-et-les-etablissements>
14. Haute Autorité de Santé. Prévention et prise en charge de l'hémorragie du postpartum immédiat - Campagne 2017 – Données 2016. 2017.
15. WHO postpartum haemorrhage (PPH) summit [Internet]. [cited 2023 Jan 30]. Available from: [https://www.who.int/publications/m/item/who-postpartum-haemorrhage-\(pph\)-summit](https://www.who.int/publications/m/item/who-postpartum-haemorrhage-(pph)-summit)
16. Deneux-Tharoux C, Delorme P. Épidémiologie de la dystocie des épaules. *J Gynécologie Obstétrique Biol Reprod*. 2015 Dec 1;44(10):1234–47.
17. Mendez-Figueroa H, Hoffman MK, Grantz KL, Blackwell SC, Reddy UM, Chauhan SP. Shoulder dystocia and composite adverse outcomes for the maternal-neonatal dyad. *Am J Obstet Gynecol MFM*. 2021 Jul;3(4):100359.
18. Arnold MJ, Sadler K, Leli K. Obstetric Lacerations: Prevention and Repair. *Am Fam Physician*. 2021 Jun 15;103(12):745–52.
19. Gutzeit O, Levy G, Lowenstein L. Postpartum Female Sexual Function: Risk Factors for Postpartum Sexual Dysfunction. *Sex Med*. 2020 Mar;8(1):8–13.

20. Masson E. Dystocie des épaules : recommandations pour la pratique clinique – Texte court [Internet]. EM-Consulte. [cited 2022 Oct 24]. Available from: <https://www.em-consulte.com/article/1015647/dystocie-des-epaules-recommandations-pour-la-prat>
21. Françoise Soulié-Fogelman. Une histoire (subjective) du deep learning. ActuaIA. :20–4.
22. Turing AM. I.—COMPUTING MACHINERY AND INTELLIGENCE. Mind. 1950 Oct 1;LIX(236):433–60.
23. The History of Artificial Intelligence - Science in the News [Internet]. [cited 2022 Oct 20]. Available from: <https://sitn.hms.harvard.edu/flash/2017/history-artificial-intelligence/>
24. Newell A, Simon H. The logic theory machine—A complex information processing system. IRE Trans Inf Theory. 1956 Sep;2(3):61–79.
25. McCarthy J. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. :3.
26. Hopfield JJ. Neural networks and physical systems with emergent collective computational abilities. Proc Natl Acad Sci. 1982 Apr;79(8):2554–8.
27. Lecun Y. Une procedure d'apprentissage pour reseau a seuil asymmetrique (A learning scheme for asymmetric threshold networks). Proc Cogn 85 Paris Fr. 1985;599–604.
28. Khalkar R, Dikhit A, Goel A. Handwritten Text Recognition using Deep Learning (CNN & RNN). IARJSET. 2021 Jun 30;8:870–81.
29. Georges B. Intelligence artificielle : de quoi parle-t-on ? Constructif. 2019;54(3):5–10.
30. Intelligence artificielle, de quoi parle-t-on ? | CNIL [Internet]. [cited 2022 Oct 20]. Available from: <https://www.cnil.fr/fr/intelligence-artificielle/intelligence-artificielle-de-quoi-parle-t-on>
31. Glossaire de l'intelligence artificielle (IA) | CNIL [Internet]. [cited 2022 Oct 20]. Available from: <https://www.cnil.fr/fr/intelligence-artificielle/glossaire-ia>

32. Tourniaire, P. An introduction to machine learning and computational histopathology. (Cours) Master Sciences de la Vie : UE 5 Biopathologies; 2022 Feb 3; Faculté de médecine de Nice, Université Côte D'Azur.
33. Non communicable diseases [Internet]. [cited 2023 Feb 3]. Available from: <https://www.who.int/news-room/fact-sheets/detail/noncommunicable-diseases>
34. Modelling and prediction of global non-communicable diseases | BMC Public Health | Full Text [Internet]. [cited 2023 Feb 3]. Available from: <https://bmcpublichealth.biomedcentral.com/articles/10.1186/s12889-020-08890-4>
35. Tran BX, Vu GT, Ha GH, Vuong QH, Ho MT, Vuong TT, et al. Global Evolution of Research in Artificial Intelligence in Health and Medicine: A Bibliometric Study. *J Clin Med*. 2019 Mar 14;8(3):360.
36. De NS, Gomez-Gonzales E, Gomez GE, Martens B, Iglesias PM, Vespe M, et al. European Commission: Artificial Intelligence and Digital Transformation: early lessons from the COVID-19 crisis [Internet]. JRC Publications Repository. 2020 [cited 2023 Feb 3]. Available from: <https://publications.jrc.ec.europa.eu/repository/handle/JRC121305>
37. MACSF.fr. Gynécologie - Rapport annuel 2021 [Internet]. MACSF.fr. [cited 2023 Feb 3]. Available from: <https://www.macsfr.fr/le-risque-des-professionnels-de-sante-en-2021/risque-des-professions-de-sante/g/gynecologie-obstetrique-medicale>
38. Dhombres F, Bonnard J, Bailly K, Maurice P, Papageorgiou AT, Jouannic JM. Contributions of Artificial Intelligence Reported in Obstetrics and Gynecology Journals: Systematic Review. *J Med Internet Res*. 2022 Apr 20;24(4):e35465.
39. Masson E. Quand dépister le diabète gestationnel ? [Internet]. EM-Consulte. [cited 2023 Jan 18]. Available from: <https://www.em-consulte.com/article/277482/article/quand-depister-le-diabete-gestationnel>
40. Masson E. Intérêt du dépistage du diabète gestationnel et comparaison des stratégies ciblée et systématique [Internet]. EM-Consulte. [cited 2023 Jan 18]. Available from: <https://www.em-consulte.com/article/277481/article/interet-du-depistage-du-diabete-gestationnel-et-co>

41. Du Y, Rafferty AR, McAuliffe FM, Wei L, Mooney C. An explainable machine learning-based clinical decision support system for prediction of gestational diabetes mellitus. *Sci Rep.* 2022 Jan 21;12(1):1170.
42. Shen J, Chen J, Zheng Z, Zheng J, Liu Z, Song J, et al. An Innovative Artificial Intelligence-Based App for the Diagnosis of Gestational Diabetes Mellitus (GDM-AI): Development Study. *J Med Internet Res.* 2020 Sep 15;22(9):e21573.
43. Wang J, Lv B, Chen X, Pan Y, Chen K, Zhang Y, et al. An early model to predict the risk of gestational diabetes mellitus in the absence of blood examination indexes: application in primary health care centres. *BMC Pregnancy Childbirth.* 2021 Dec 8;21(1):814.
44. Liu H, Li J, Leng J, Wang H, Liu J, Li W, et al. Machine learning risk score for prediction of gestational diabetes in early pregnancy in Tianjin, China. *Diabetes Metab Res Rev.* 2021 Jul;37(5):e3397.
45. Mateen BA, David AL, Denaxas S. Electronic Health Records to Predict Gestational Diabetes Risk. *Trends Pharmacol Sci.* 2020 May;41(5):301–4.
46. Wu YT, Zhang CJ, Mol BW, Kawai A, Li C, Chen L, et al. Early Prediction of Gestational Diabetes Mellitus in the Chinese Population via Advanced Machine Learning. *J Clin Endocrinol Metab.* 2021 Mar 8;106(3):e1191–205.
47. Ye Y, Xiong Y, Zhou Q, Wu J, Li X, Xiao X. Comparison of Machine Learning Methods and Conventional Logistic Regressions for Predicting Gestational Diabetes Using Routine Clinical Data: A Retrospective Cohort Study. *J Diabetes Res.* 2020;2020:4168340.
48. McLaren R, Haberman S, Moscu M, Atallah F, Friedmann H. A Novel and Precise Profiling Tool to Predict Gestational Diabetes. *J Diabetes Sci Technol.* 2021 Jul;15(4):891–6.
49. Yoffe L, Polsky A, Gilam A, Raff C, Mecacci F, Ognibene A, et al. Early diagnosis of gestational diabetes mellitus using circulating microRNAs. *Eur J Endocrinol.* 2019 Nov;181(5):565–77.

50. Mavreli D, Evangelinakis N, Papantoniou N, Kolialexi A. Quantitative Comparative Proteomics Reveals Candidate Biomarkers for the Early Prediction of Gestational Diabetes Mellitus: A Preliminary Study. *Vivo Athens Greece*. 2020 Apr;34(2):517–25.
51. Liu Y, Geng H, Duan B, Yang X, Ma A, Ding X. Identification of Diagnostic CpG Signatures in Patients with Gestational Diabetes Mellitus via Epigenome-Wide Association Study Integrated with Machine Learning. *BioMed Res Int*. 2021;2021:1984690.
52. Liu Y, Wang Z, Zhao L. Identification of diagnostic cytosine-phosphate-guanine biomarkers in patients with gestational diabetes mellitus via epigenome-wide association study and machine learning. *Gynecol Endocrinol Off J Int Soc Gynecol Endocrinol*. 2021 Sep;37(9):857–62.
53. Prématurité · Inserm, La science pour la santé [Internet]. Inserm. [cited 2023 Jan 23]. Available from: <https://www.inserm.fr/dossier/prematurite/>
54. Lee KS, Ahn KH. Artificial Neural Network Analysis of Spontaneous Preterm Labor and Birth and Its Major Determinants. *J Korean Med Sci*. 2019 Apr 29;34(16):e128.
55. Souza RT, Cecatti JG, Passini R, Pacagnella RC, Oliveira PF, Silva CM, et al. Cluster analysis identifying clinical phenotypes of preterm birth and related maternal and neonatal outcomes from the Brazilian Multicentre Study on Preterm Birth. *Int J Gynaecol Obstet Off Organ Int Fed Gynaecol Obstet*. 2019 Jul;146(1):110–7.
56. Arabi Belaghi R, Beyene J, McDonald SD. Prediction of preterm birth in nulliparous women using logistic regression and machine learning. *PloS One*. 2021;16(6):e0252025.
57. Chen L, Xu H. Deep neural network for semi-automatic classification of term and preterm uterine recordings. *Artif Intell Med*. 2020 May;105:101861.
58. Raja R, Mukherjee I, Sarkar BK. A Machine Learning-Based Prediction Model for Preterm Birth in Rural India. *J Healthc Eng*. 2021;2021:6665573.
59. Gudnadottir U, Debelius JW, Du J, Hugerth LW, Danielsson H, Schuppe-Koistinen I, et al. The vaginal microbiome and the risk of preterm birth: a systematic review and network meta-analysis. *Sci Rep*. 2022 May 13;12:7926.

60. Park S, Oh D, Heo H, Lee G, Kim SM, Ansari A, et al. Prediction of preterm birth based on machine learning using bacterial risk score in cervicovaginal fluid. *Am J Reprod Immunol N Y N* 1989. 2021 Sep;86(3):e13435.
61. Gao C, Osmundson S, Velez Edwards DR, Jackson GP, Malin BA, Chen Y. Deep learning predicts extreme preterm birth from electronic health records. *J Biomed Inform.* 2019 Dec;100:103334.
62. Lamont RF, Richardson LS, Boniface JJ, Cobo T, Exner MM, Christensen IB, et al. Commentary on a combined approach to the problem of developing biomarkers for the prediction of spontaneous preterm labor that leads to preterm birth. *Placenta.* 2020 Sep 1;98:13–23.
63. Ngo TTM, Moufarrej MN, Rasmussen MLH, Camunas-Soler J, Pan W, Okamoto J, et al. Noninvasive blood tests for fetal development predict gestational age and preterm delivery. *Science.* 2018 Jun 8;360(6393):1133–6.
64. Bahado-Singh RO, Sonek J, McKenna D, Cool D, Aydas B, Turkoglu O, et al. Artificial intelligence and amniotic fluid multiomics: prediction of perinatal outcome in asymptomatic women with short cervix. *Ultrasound Obstet Gynecol Off J Int Soc Ultrasound Obstet Gynecol.* 2019 Jul;54(1):110–8.
65. Yoo JY, Hyeon DY, Shin Y, Kim SM, You YA, Kim D, et al. Integrative analysis of transcriptomic data for identification of T-cell activation-related mRNA signatures indicative of preterm birth. *Sci Rep.* 2021 Jan 27;11(1):2392.
66. Paquette AG, Shynlova O, Wu X, Kibschull M, Wang K, Price ND, et al. MicroRNA-transcriptome networks in whole blood and monocytes of women undergoing preterm labour. *J Cell Mol Med.* 2019 Oct;23(10):6835–45.
67. Rawashdeh H, Awawdeh S, Shannag F, Henawi E, Faris H, Obeid N, et al. Intelligent system based on data mining techniques for prediction of preterm birth for women with cervical cerclage. *Comput Biol Chem.* 2020 Apr;85:107233.
68. Myatt L. The prediction of preeclampsia: the way forward. *Am J Obstet Gynecol.* 2022 Feb;226(2S):S1102-S1107.e8.

69. Marić I, Tsur A, Aghaeepour N, Montanari A, Stevenson DK, Shaw GM, et al. Early prediction of preeclampsia via machine learning. *Am J Obstet Gynecol MFM*. 2020 May;2(2):100100.
70. Li YX, Shen XP, Yang C, Cao ZZ, Du R, Yu M da, et al. Novelelectronic health records applied for prediction of pre-eclampsia: Machine-learning algorithms. *Pregnancy Hypertens*. 2021 Dec;26:102–9.
71. Jhee JH, Lee S, Park Y, Lee SE, Kim YA, Kang SW, et al. Prediction model development of late-onset preeclampsia using machine learning-based methods. *PloS One*. 2019;14(8):e0221202.
72. Sufriyana H, Wu YW, Su ECY. Artificial intelligence-assisted prediction of preeclampsia: Development and external validation of a nationwide health insurance dataset of the BPJS Kesehatan in Indonesia. *EBioMedicine*. 2020 Apr;54:102710.
73. Pillay P, Vatish M, Duarte R, Moodley J, Mackraj I. Exosomal microRNA profiling in early and late onset preeclamptic pregnant women reflects pathophysiology. *Int J Nanomedicine*. 2019;14:5637–57.
74. Luo S, Cao N, Tang Y, Gu W. Identification of key microRNAs and genes in preeclampsia by bioinformatics analysis. *PloS One*. 2017;12(6):e0178549.
75. Xu W, Ru P, Gu Z, Zhang R, Pang X, Huang Y, et al. Comprehensive Analysis of Differently Expressed and Methylated Genes in Preeclampsia. *Comput Math Methods Med*. 2020;2020:2139270.
76. Liu K, Fu Q, Liu Y, Wang C. An integrative bioinformatics analysis of microarray data for identifying hub genes as diagnostic biomarkers of preeclampsia. *Biosci Rep*. 2019 Sep 30;39(9):BSR20190187.
77. Liu S, Xie X, Lei H, Zou B, Xie L. Identification of Key circRNAs/lncRNAs/miRNAs/mRNAs and Pathways in Preeclampsia Using Bioinformatics Analysis. *Med Sci Monit Int Med J Exp Clin Res*. 2019 Mar 5;25:1679–93.

78. Kang Q, Li W, Xiao J, Yu N, Fan L, Sha M, et al. Identification of potential crucial genes associated with early-onset preeclampsia via bioinformatic analysis. *Pregnancy Hypertens.* 2021 Jun;24:27–36.
79. Han Q, Zheng W. A new predicting model of preeclampsia based on peripheral blood test values. :8.
80. Wang T, Xiang Y, Zhou X, Zheng X, Zhang H, Zhang X, et al. Epigenome-wide association data implicate fetal/maternal adaptations contributing to clinical outcomes in preeclampsia. *Epigenomics.* 2019 Jul;11(9):1003–19.
81. Guo R, Teng Z, Wang Y, Zhou X, Xu H, Liu D. Integrated Learning: Screening Optimal Biomarkers for Identifying Preeclampsia in Placental mRNA Samples. *Comput Math Methods Med.* 2021;2021:6691096.
82. Jauniaux E, Prefumo F. Fetal heart monitoring in labour: from pinard to artificial intelligence. *BJOG Int J Obstet Gynaecol.* 2016;123(6):870–870.
83. Miller L. Intrapartum Fetal Monitoring: Liability and Documentation. *Clin Obstet Gynecol.* 2011 Mar;54(1):50.
84. Lu Y, Qi Y, Fu X. A framework for intelligent analysis of digital cardiotocographic signals from IoMT-based foetal monitoring. *Future Gener Comput Syst.* 2019 Dec 1;101:1130–41.
85. Alsayyari A. Fetal cardiotocography monitoring using Legendre neural networks. *Biomed Tech (Berl).* 2019 Dec 18;64(6):669–75.
86. Liu LC, Tsai YH, Chou YC, Jheng YC, Lin CK, Lyu NY, et al. Concordance analysis of intrapartum cardiotocography between physicians and artificial intelligence-based technique using modified one-dimensional fully convolutional networks. *J Chin Med Assoc J CMA.* 2021 Feb 1;84(2):158–64.
87. Petrozziello A, Jordanov I, Aris Papageorghiou T, Christopher Redman WG, Antoniya Georgieva. Deep Learning for Continuous Electronic Fetal Monitoring in Labor. *Annu Int Conf IEEE Eng Med Biol Soc IEEE Eng Med Biol Soc Annu Int Conf.* 2018 Jul;2018:5866–9.

88. Ogasawara J, Ikenoue S, Yamamoto H, Sato M, Kasuga Y, Mitsukura Y, et al. Deep neural network-based classification of cardiocograms outperformed conventional algorithms. *Sci Rep.* 2021 Jun 28;11(1):13367.
89. Iraj MS. Prediction of fetal state from the cardiocogram recordings using neural network models. *Artif Intell Med.* 2019 May;96:33–44.
90. Cömert Z, Adnan Fatih Kocamaz, Subha V. Prognostic model based on image-based time-frequency features and genetic algorithm for fetal hypoxia assessment. *Comput Biol Med.* 2018 Aug 1;99:85–97.
91. Signorini MG, Pini N, Malovini A, Bellazzi R, Magenes G. Integrating machine learning techniques and physiology based heart rate features for antepartum fetal monitoring. *Comput Methods Programs Biomed.* 2020 Mar;185:105015.
92. Ricciardi C, Improta G, Amato F, Cesarelli G, Romano M. Classifying the type of delivery from cardiocographic signals: A machine learning approach. *Comput Methods Programs Biomed.* 2020 Nov;196:105712.
93. Fergus P, Selvaraj M, Chalmers C. Machine learning ensemble modelling to classify caesarean section and vaginal delivery types using Cardiocography traces. *Comput Biol Med.* 2018 Feb 1;93:7–16.
94. Ravindran S, Jambek AB, Muthusamy H, Neoh SC. A novel clinical decision support system using improved adaptive genetic algorithm for the assessment of fetal well-being. *Comput Math Methods Med.* 2015;2015:283532.
95. Balayla J, Shrem G. Use of artificial intelligence (AI) in the interpretation of intrapartum fetal heart rate (FHR) tracings: a systematic review and meta-analysis. *Arch Gynecol Obstet.* 2019 Jul;300(1):7–14.
96. Devoe LD. Future perspectives in intrapartum fetal surveillance. *Best Pract Res Clin Obstet Gynaecol.* 2016 Jan;30:98–106.
97. Tsur A, Batsry L, Toussia-Cohen S, Rosenstein MG, Barak O, Brezinov Y, et al. Development and validation of a machine-learning model for prediction of shoulder

dystocia. *Ultrasound Obstet Gynecol Off J Int Soc Ultrasound Obstet Gynecol*. 2020 Oct;56(4):588–96.

98. Venkatesh KK, Strauss RA, Grotegut CA, Heine RP, Chescheir NC, Stringer JSA, et al. Machine Learning and Statistical Models to Predict Postpartum Hemorrhage. *Obstet Gynecol*. 2020 Apr;135(4):935–44.
99. Akazawa M, Hashimoto K, Katsuhiko N, Kaname Y. Machine learning approach for the prediction of postpartum hemorrhage in vaginal birth. *Sci Rep*. 2021 Nov 19;11(1):22620.
100. Escobar GJ, Soltesz L, Schuler A, Niki H, Malenica I, Lee C. Prediction of obstetrical and fetal complications using automated electronic health record data. *Am J Obstet Gynecol*. 2021 Feb;224(2):137-147.e7.
101. dit L par césarienne associé à un risque plus élevé de complications graves 01/04/2019 A com. [:fr]Etude EPIMOMS[:en]EPIMOMS Study[:] [Internet]. EPOPé. [cited 2023 Jan 30]. Available from: <https://www.xn--epop-inserm-ebb.fr/grandes-enquetes/etude-epimoms>
102. Gao C, Osmundson S, Yan X, Edwards DV, Malin BA, Chen Y. Learning to Identify Severe Maternal Morbidity from Electronic Health Records. *Stud Health Technol Inform*. 2019 Aug 21;264:143–7.
103. Cartus AR, Naimi AI, Himes KP, Jarlenski M, Parisi SM, Bodnar LM. Can Ensemble Machine Learning Improve the Accuracy of Severe Maternal Morbidity Screening in a Perinatal Database? *Epidemiol Camb Mass*. 2022 Jan 1;33(1):95–104.
104. Clapp MA, McCoy TH, James KE, Kaimal AJ, Roy H, Perlis null. Derivation and external validation of risk stratification models for severe maternal morbidity using prenatal encounter diagnosis codes. *J Perinatol Off J Calif Perinat Assoc*. 2021 Nov;41(11):2590–6.
105. #. Augmentation significative de la mortalité infantile en France [Internet]. Salle de presse | Inserm. 2022 [cited 2023 Jan 30]. Available from: <https://presse.inserm.fr/augmentation-du-taux-de-mortalite-infantile-en-france-depuis-2012/44892/>

106. La mortalité infantile est stable depuis dix ans après des décennies de baisse - Insee Focus - 117 [Internet]. [cited 2023 Jan 30]. Available from: <https://www.insee.fr/fr/statistiques/3560308>
107. Guedalia J, Sompolinsky Y, Novoselsky Persky M, Cohen SM, Kabiri D, Yagel S, et al. Prediction of severe adverse neonatal outcomes at the second stage of labour using machine learning: a retrospective cohort study. *BJOG Int J Obstet Gynaecol*. 2021 Oct;128(11):1824–32.
108. Mboya IB, Mahande MJ, Mohammed M, Obure J, Mwambi HG. Prediction of perinatal death using machine learning models: a birth registry-based cohort study in northern Tanzania. *BMJ Open*. 2020 Oct 19;10(10):e040132.
109. WHO issues first global report on Artificial Intelligence (AI) in health and six guiding principles for its design and use [Internet]. [cited 2023 Feb 2]. Available from: <https://www.who.int/news/item/28-06-2021-who-issues-first-global-report-on-ai-in-health-and-six-guiding-principles-for-its-design-and-use>
110. Sveinsdottir T, Troullinou P, Aidlinis S, Delipalta A, Finn R, Loukinas P, et al. The Role of Data in AI [Internet]. The University of Edinburgh; 2020 Dec [cited 2022 Nov 8]. Available from: <https://zenodo.org/record/4312907>
111. IA en Santé : plateforme des solutions d'intelligence Artificielle en Santé [Internet]. IA en Santé. [cited 2023 Jan 30]. Available from: <https://ia.anap.fr/>
112. Jacquenod L. Projet SUOG [Internet]. Sorbonne Université - Faculté de Médecine. 2020 [cited 2023 Jan 30]. Available from: <https://medecine.sorbonne-universite.fr/projet-suog/>
113. Stirnemann JJ, Besson R, Spaggiari E, Rojo S, Loge F, Peyro-Saint-Paul H, et al. Description and clinical validation of a real-time AI diagnostic companion for fetal ultrasound examination [Internet]. medRxiv; 2021 [cited 2022 Nov 2]. p. 2021.05.25.21257630. Available from: <https://www.medrxiv.org/content/10.1101/2021.05.25.21257630v2>
114. QUIPP: A tool to predict spontaneous preterm birth [Internet]. [cited 2022 Dec 23]. Available from: <https://quipp.org/>

115. Development and validation of predictive models for QUiPP App v.2: tool for predicting preterm birth in women with symptoms of threatened preterm labor - Carter - 2020 - Ultrasound in Obstetrics & Gynecology - Wiley Online Library [Internet]. [cited 2023 Jan 30]. Available from:
<https://obgyn.onlinelibrary.wiley.com/doi/10.1002/uog.20422>
116. Musbahi O, Syed L, Le Feuvre P, Cobb J, Jones G. Public patient views of artificial intelligence in healthcare: A nominal group technique study. *Digit Health*. 2021;7:20552076211063680.
117. Young AT, Amara D, Bhattacharya A, Wei ML. Patient and general public attitudes towards clinical artificial intelligence: a mixed methods systematic review. *Lancet Digit Health*. 2021 Sep 1;3(9):e599–611.
118. Exactitude et précision. In: Wikipédia [Internet]. 2022 [cited 2023 Feb 5]. Available from:
https://fr.wikipedia.org/w/index.php?title=Exactitude_et_pr%C3%A9cision&oldid=199630894
119. Technology I. Precision Vs. Accuracy [Internet]. Information Technology. 2017 [cited 2023 Feb 5]. Available from: <https://wp.stolaf.edu/it/gis-precision-accuracy/>
120. Odds ratio. In: Wikipédia [Internet]. 2022 [cited 2023 Feb 5]. Available from:
https://fr.wikipedia.org/w/index.php?title=Odds_ratio&oldid=194865743

Annexe I – Glossaire:

Définitions cliniques :

- Pré éclampsie :

Se manifestant cliniquement par une hypertension gravidique associé à une protéinurie significative après 20 semaines d'aménorrhée, la pré éclampsie est bien défini comme pathologie de façon concrète à travers les domaines qui la prennent en charge : l'obstétrique, la maïeutique et l'anesthésie réanimation. Longtemps difficilement comprise dans la physiopathologie, des études de commencent à mettre un lumière sur les processus pouvant être potentiellement apporter des réponses en termes de prévention.

- Menace d'accouchement prématuré :

Le menace d'accouchement prématuré (MAP) survient entre 22 et 36 SA révolues et se caractérise par l'association de modifications cervicales et de contractions utérines (CU) régulières et douloureuses qui conduiront à l'accouchement prématuré en l'absence d'intervention médicale.

- Dystocie des épaules :

La dystocie des épaules se définit par « l'absence de dégagement des épaules du fœtus après expulsion de la tête, rendant nécessaire le recours à des manœuvres obstétricales autres que la traction douce de la tête ou la manœuvre de restitution », selon les recommandations de pratique clinique de la CNGOF. (20)

Définitions : métriques de performance statistique des modèles de prédiction :

- AUC = Area under ROC (aussi appelé AU-ROC) :

Mesure de la performance de classification binaire : évaluation de la sensibilité d'un modèle : son aptitude à détecter les vrai positives.

Interprétation du score : Plus proche de 1 = plus sensible = plus puissant.

- Spécificité et Sensibilité :

Autre expression de l'aptitude d'un modèle à classer :

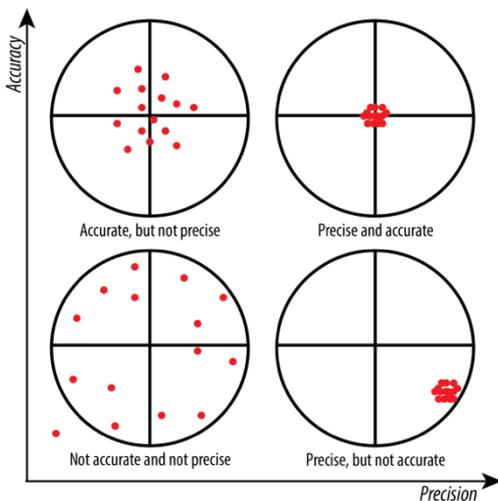
Spécificité : C'est la probabilité du résultat négatif de test (T-) chez les patients définis comme non malades (M-) appelée également taux de vrais négatifs.

$$Spé = p(T-/M-)$$

Sensibilité : Probabilité (p) du résultat positif du test (T+) chez les sujets « malades » (M+) telle qu'elle est définie par le gold standard appelée également taux de vrais positifs.

$$Se = p(T+/M+)$$

Interprétation du score : Dépend du contexte, si il faut plutôt privilégier la sensibilité (il faut impérativement détecter tous les malades) ou spécificité (on ne veut pas traiter a tort).



- Accuracy versus précision :

L'exactitude (*accuracy*) est la proximité des résultats de mesure avec la valeur réelle (true value). La précision montre dans quelle mesure la répétabilité (ou reproductibilité) dans des conditions inchangées affine les résultats. (118)

Fig. 17 : Diagramme démontrant les différences entre accuracy (exactitude) et précision. (119)

- Odds Ratio / risque relatif rapproché (OR) versus AOR (Adjusted odds ratio) :

Démontre le degré de dépendance entre deux variables aléatoires qualitatives.

Signification : (120)

OR < 1 → l'événement est moins fréquent dans le groupe A que dans le groupe B ;

OR = 1 → l'événement est aussi fréquent dans les deux groupes ;

OR > 1 → l'événement est plus fréquent dans le groupe A que dans le groupe B.

- Adjusted odds ratio :

Il s'agit d'un odds ratio ajusté pour prendre en compte d'autres variables prédictives dans le modèle.

- Coefficient de corrélation :

Valeur entre -1 et 1 ; indiquant la corrélation entre deux variables.

- Valeur prédictive positive VPP versus Valeur prédictive négative VPN :

VPP : La probabilité que la condition soit présente lorsque le test est positif.

VPN : La probabilité que la condition ne soit pas présente lorsque le test est négatif.

Tous les deux sont dépendent de Se, Spé et de la prévalence.

- Indice Cohen de Kappa :

Indice qui sert à mesurer l'accord entre deux évaluateurs ou entre deux méthodes de classification. Sa mesure est le degré de concordance entre évaluateurs, appelé la *fidélité inter-évaluateur*.

- Mean squared error :

Mean squared error (MSE) appelée *erreur quadratique moyenne*, mesure le taux d'erreur dans un modèle statistique. Il mesure la différence moyenne entre les valeurs observés et les valeurs prédits.

- C statistique = C index :

Un C-index est l'estimation d'une probabilité de concordance des valeurs d'un modèle

Titre : La place de l'intelligence artificielle dans la prédiction d'issues périnatales défavorables en obstétrique : une revue de la littérature

Résumé :

La morbi-mortalité maternelle et néonatale en France reste élevée et 66 % des décès maternels sont considérés comme étant évitables.

L'intelligence artificielle est potentiellement une clé dans une meilleure gestion des pathologies fréquentes en obstétrique. Depuis ses débuts dans les années 1940, l'IA n'a pas cessé d'augmenter en puissance avec une utilisation exponentielle depuis les années 2000.

Son utilisation en obstétrique représente un atout puissant dans la prédiction, la classification, l'aide à la décision, mais aussi la découverte de biomarqueurs.

L'éthique est inextricablement liée à l'IA et sa mise en place en santé nécessite des considérations particulières et une prise en compte des risques associés à son utilisation.

L'IA représente une nouvelle ère de médecine personnalisée avec une meilleure utilisation de ressources et une meilleure équité de soins dans le monde. L'IA n'a pas pour but de remplacer des cliniciens, mais représente une nouvelle équipe avec une performance supérieure.

Objectif : Décrire et définir la place de l'intelligence artificielle dans la prédiction d'événements de mauvais pronostics ou d'issues défavorables en obstétrique. Dans un deuxième temps, décrire les enjeux éthiques associés à son utilisation et la marche à suivre pour une mise en place correcte.

Méthode : Revue de la littérature

Résultats : L'IA offre une multitude de solutions de prédiction et prévention pour l'amélioration des issues materno-fœtaux. Les modèles prédictifs utilisant des données cliniques, biologiques et paracliniques permettent la prédiction de risque : l'utilisation des réseaux de neurones est actuellement la tendance la plus performante du machine learning. Avec la prédiction de risque, des programmes d'aide à la décision existent pour pouvoir aider le clinicien, soutenant ses compétences. La classification permet d'identifier les phénotypes de personnes à risque, mais aussi de classer des données paracliniques telles que la cardiocardiographie. Sur l'horizon, l'utilisation de la bio-informatique a démontré une performance de prédiction par l'utilisation des biomarqueurs, mais aussi une meilleure compréhension des maladies, avec des réponses clé concernant la pathogenèse et la physiopathologie.

Conclusion : Au sein de l'obstétrique, l'IA représente un nouvel outil puissant dans la prédiction des risques périnataux. Son utilisation est primordiale pour offrir une meilleure prise en charge équitable, sans négliger les considérations éthiques non-négociables associées à son utilisation.

Mots-clés : Intelligence Artificiel, issues défavorables, Obstétrique, perinatal, Prédiction, Éthique

Title: The role of artificial intelligence in the prediction of adverse perinatal outcomes in obstetrics: a literary review

Abstract:

Maternal and neonatal morbidity and mortality in France remains high and 66% of maternal deaths are considered to be avoidable. Artificial intelligence is potentially a key to better management of frequent pathologies in obstetrics. Since its beginnings in the 1940s, AI has steadily increased in power with exponential use since the 2000s. Its use in obstetrics represents a powerful asset in prediction, classification, decision support, but also the discovery of biomarkers.

Ethics are inextricably linked to AI and its implementation in health requires special considerations and taking into account the risks associated with its use. AI represents a new era of personalized medicine with better use of resources and greater equity of care around the world. AI is not intended to replace clinicians, but represents a new team with superior performance.

Objectives: To describe and define the role of AI in the prediction of adverse perinatal outcomes in obstetrics. Secondly to describe the ethical considerations associated with the use of AI in health and describe the steps necessary to its use in a correct manner.

Method: Literary review

Results: AI offers a multitude of prediction and prevention solutions for improving maternal-fetal outcomes. Predictive models using clinical, biological and paraclinical data allow risk prediction: the use of neural networks is currently the most successful trend in machine learning. Furthermore, decision support programs exist to help the clinician, supporting their skills. Classification also exists, making it possible to identify the phenotypes of people at risk, but also to classify paraclinical data such as cardiotocography. On the horizon, the use of bioinformatics has demonstrated predictive performance through the use of biomarkers, but also a better understanding of diseases, with key answers concerning pathogenesis and physiopathology.

Conclusion: Within obstetrics, AI represents a powerful new tool in the prediction of perinatal risks. Its use is essential to provide better equitable care, without neglecting the non-negotiable ethical considerations associated with its use.

Key-words : artificial intelligence, adverse outcomes, obstetrics, perinatal, prediction, ethics
