

OPTIMISATION D'ARBRE DE DÉCISION POUR UN PROBLÈME DE DÉTECTION PRÉCOCE D'ANOMALIES FOETALES.

Rémi Besson ¹ & Erwan Le Pennec ² & Stéphanie Allasonnière ³

¹ *CMAP, Route de Saclay 91128 Palaiseau, remi.besson@polytechnique.edu*

² *CMAP, Route de Saclay 91128 Palaiseau, erwan.le-pennec@polytechnique.edu*

³ *Université Paris Descartes 75006 Paris, stephanie.allasonniere@parisdescartes.fr*

Résumé. Dans ce travail nous nous intéressons à l'apprentissage de bonnes stratégies de diagnostic pour la recherche échographique d'anomalie chez le fœtus. Nous commençons par apprendre notre environnement via des techniques bayésiennes de maximum d'entropie puis nous formalisons notre problème comme un processus de Markov décisionnel. Des techniques d'apprentissage par renforcement et des idées provenant de la recherche de plus court chemin sur un graphe (algorithme A*, AO*) sont mises en oeuvre pour trouver des solutions optimales.

Mots-clés. Arbres de décision, Apprentissage par renforcement, Maximum d'entropie.

Abstract. In this work we investigate the learning problem of good diagnostic policies in foetal abnormalities search by ultrasound. We start by learning our environment via bayesian method such that maximum entropy approach and then we write our problem as a Markov Decision Process. Reinforcement learning methods and ideas from algorithms looking for shortest path in a graph such that A*, AO* are adapted in order to find good diagnostic policies.

Keywords. Decision Trees, Reinforcement learning, Maximum Entropy.

1 Introduction

Lorsqu'une femme enceinte se présente chez son obstétricien celui-ci utilisera toujours l'échographie en première instance pour s'assurer du bon développement du fœtus et vérifier l'absence de pathologie. Pour cela le médecin fera un certains nombres de mesures classiques comme par exemple la clarté nucale. Il dispose d'une totale liberté pour la plus grande partie de l'examen où aucun protocole fixe ne régit la recherche de maladie rare chez le fœtus. Or c'est bien là tout le problème, le très grand nombre d'anomalies possibles (de l'ordre de 300), la difficulté d'observer certaines malformations et le temps forcément limité dont dispose le médecin motivent notre travail. Nous cherchons à systématiser l'examen de dépistage afin qu'en moyenne les médecins arrivent plus rapidement au diagnostic.

Notre problème peut se modéliser de manière naturelle par les arbres de décision introduit par Breiman (1984). Il s'agit en effet, à chaque état de connaissance (résumé des présences/absences des anomalies observées) de proposer l'anomalie la plus informative à observer pour laquelle nous recevrons une réponse de l'obstétricien : présente/absente.

L'optimisation des arbres de décision a été intensément étudiée depuis les années 70. Les algorithmes originels (Breiman (1984) et Quinlan (1986)) sont gloutons en ce sens qu'ils cherchent à minimiser l'entropie (i.e l'incertitude, le désordre) de la variable aléatoire cible (chez nous la pathologie) en se bornant à l'horizon de la question suivante.

Un grand nombre de travaux se sont ensuite attaqués à la nécessité d'ajouter un coût à chaque question, l'objectif devenant un compromis entre baisse de l'entropie et coût des questions (Lomax et Vadera (2011) pour un panorama des Cost Sensitive Decision Trees). Enfin grâce aux progrès de l'informatique de ces dernières années les arbres de décision sont devenus incontournables en intelligence artificielle pour des applications en théorie des jeux, notamment avec les Monte Carlo Tree Search (Browne et al. (2012)). Le principal défi consiste à explorer intelligemment l'arbre afin de choisir la branche la plus prometteuse sur le long terme.

Ceci étant dit notre problème est spécifique pour plusieurs raisons. Tout d'abord nous construiront notre arbre à partir de données d'experts alors que ceux-ci sont plutôt traditionnellement construit sur un échantillon d'observations. De plus les dernières avancées ont principalement été faites dans un contexte adversarial typique de théorie des jeux où l'algorithme minimax cherche à minimiser les gains de l'adversaire ce qui n'est pas notre cas. Nous avons proposé un premier algorithme de type Iterative Dichotomiser 3 (ID3) pour ce problème, il constituera notre brique de départ pour les prochains algorithmes que nous proposerons.

2 De quelles données dispose-t-on ?

Une des difficultés spécifiques de notre sujet d'étude est l'absence de réelle base de données. Les hôpitaux n'ont pas encore de base de données mutualisée et aucun hôpital n'a, à lui seul, de données suffisamment représentatives concernant les maladies rares, pas même Necker, centre de référence national.

Nous appellerons syndrome un ensemble d'anomalies. Nous disposons dans un premier temps de données fournies par les obstétriciens de l'hôpital Necker. Ces données sont issues de la littérature et indiquent les prévalences estimées des syndromes et des probabilités estimées des anomalies sachant les syndromes. Nous introduisons les notations suivantes : pour $i \in \{1, \dots, p\}$

$$A_i = \begin{cases} 1 & \text{si le foetus présente l'anomalie de type } i \\ 0 & \text{sinon.} \end{cases}$$

Nous notons les différents syndromes : $S \in \{s_1, \dots, s_K\}$. On dispose de $P[S = s_j] =: P[S_j]$,

$P[A_i = 1 | S = s_j] =: P[A_i | S_j]$ ainsi que de $P[A_i = 0 | S = s_j] =: P[\bar{A}_i | S_j]$. Pour l'instant, nous disposons de quelques trois cent anomalies différentes recensées pour environ 80 syndromes, précisément $p = 307$ et $K = 81$. On notera que deux personnes peuvent avoir le même syndrome sans présenter les mêmes anomalies. De même deux individus peuvent avoir des anomalies en commun mais présenter des syndromes différents.

Une limite évidente de nos données est le fait que nous ne disposons que des lois marginales des anomalies conditionnellement aux syndromes et non des lois conjointes. On ne pourra pas faire l'hypothèse que les anomalies sont conditionnellement indépendantes sachant le syndrome. Cette hypothèse rendrait notamment possible le fait d'avoir un syndrome sans présenter aucune de ses anomalies typiques ce qui est absurde.

La connaissance des $P[A_i | S_j]$ ne donne pas d'information sur les $P[A_{i_1}, \dots, A_{i_k} | S_j]$ si l'hypothèse d'indépendance conditionnelle n'est pas vérifiée. On peut imaginer deux anomalies individuellement très probables pour tel syndrome mais qui seront très rarement observées ensemble (voir même jamais si ce sont des anomalies incompatibles comme par exemple une macrocéphalie et une microcéphalie).

Le calcul de ces probabilités jointes ne peut se faire exactement et nécessite une estimation. Pour cela nous devons ajouter de l'information. L'approche retenue a été d'attribuer des valeurs aux $P[A_{i_1}, \dots, A_{i_k} | S_j]$ de telle sorte que l'entropie soit maximale. En effet, notre problème revient à ajouter de l'information tout en cherchant à en rajouter le moins possible sur ce que l'on ne connaît pas. Cette condition justifie l'utilisation de l'estimation par maximisation de l'entropie. On parle de maxent (maximum d'entropie) [Jaynes (1963), Cover et Thomas (1991), Berger et Della Pietra (1996)].

Il s'agit d'une approche bayésienne, puisque l'on suppose connaître certaines propriétés de la loi à estimer (classiquement sa moyenne, chez nous les lois marginales) et on cherche la distribution d'entropie maximale vérifiant ces contraintes. Dans notre cas, nous exigeons de notre distribution estimée de vérifier le fait que l'on ne peut pas avoir un syndrome sans présenter au moins deux de ses anomalies typiques. En effet, on ne parle pas de syndrome lorsque l'on observe une anomalie isolée.

3 L'optimisation de l'arbre de décision.

Rappelons que notre objectif est de guider les obstétriciens au cours de l'examen échographique. Notre algorithme doit à chaque état de connaissance proposer l'anomalie suivante la plus intéressante à aller observer.

Soit \mathbb{S} l'ensemble des états possibles, c'est-à-dire en adoptant la notation en ternaire (1=présence, 0=absence, 2=non encore observée) $\mathbb{S} = \{(2, \dots, 2), (1, 2, \dots, 2), \dots, (0, \dots, 0)\}$. Un vecteur $s \in \mathbb{S}$ résume toute l'information obtenue au cours d'un examen échographique. On note \mathbb{A} l'ensemble des actions : $\mathbb{A} = \{a_1, \dots, a_{300}\}$.

Nous cherchons à apprendre une politique (stratégie) de diagnostic qui à tout état associe une action : $\pi : \mathcal{S} \rightarrow \mathcal{A}$. Nous nous sommes placés dans le contexte des processus décisionnels de Markov. Si l'on note s_t l'état visité au temps t , il est clair que les probabilités de transition vérifient : $P[s_{t+1} | s_t, s_{t-1}, \dots, s_0, a] = P[s_{t+1} | s_t, a]$.

Mais qu'est-ce qu'une bonne politique de diagnostic ? En général, il s'agit de minimiser un compromis entre le coût des questions à poser (coûts médicaux, en temps ou en argent) et le coût que supposerait un mauvais diagnostic (Bayer-Zubeck (2005)).

Dans notre cas le coût des questions est négligeable devant le coût potentiel d'une mauvaise classification, les obstétriciens doivent en pratique tout observer afin de s'assurer que le fœtus ne présente aucune maladie rare. Nous ne nous permettrons donc pas de prendre le risque de faire une mauvaise classification dans l'espoir de poser moins de questions. Cependant si le médecin observe deux anomalies graves typiques d'un syndrome en particulier il ne continuera pas davantage et orientera le patient vers des examens complémentaires. Nous pouvons ainsi juger qu'un certain nombre d'états sont des états terminaux, en ce sens que l'entropie y est tellement faible que le syndrome du fœtus ne fait plus de doute. Notre objectif est donc de minimiser en moyenne le nombre de question avant d'arriver à un état terminal, c'est-à-dire :

$$\pi^* = \underset{\pi}{\operatorname{argmin}} \{E_{\pi}[T]\}$$

où T est le temps d'arrêt avant d'atteindre un état terminal. Une quantité d'intérêt sera pour nous

$$v_{\pi}(s) = E_{\pi}[T | s]$$

qui nous informe du nombre moyen de questions restantes à poser si l'on est à l'état s et que l'on applique ensuite la politique π .

Nous avons proposé un premier algorithme de type ID3, tel que pour tout s

$$\pi_0(s) = \underset{a}{\operatorname{argmin}} E[H(S | s, a)] = \underset{a}{\operatorname{argmin}} \sum_{s'} P[s' | s, a] H(s' | s, a)$$

où $E[H(S | s, a)]$ est l'entropie moyenne des deux noeuds fils obtenus après avoir posé la question a à l'état s (et avant d'avoir obtenue la réponse).

Cet algorithme cherche l'action qui fera baisser, en moyenne, le plus vite l'entropie à l'horizon de la question suivante. Nous avons produit un algorithme utilisable en situation réelle, à chaque itération la réponse de l'algorithme est fourni en plusieurs dixièmes de seconde sur un processeur courant. Cela demande de calculer au vol, de manière intelligente, à chaque itération, les probabilités de transition $P[s' | s, a]$ que nous ne pouvons pas stocker. En effet, certains syndromes ont jusqu'à 19 anomalies typiques. Si le vecteur de taille 2^{19} est encore stockable ce n'est pas le cas de celui de taille 3^{19} dont on aurait besoin si l'on souhaitait stocker toutes les probabilités relatives à ce syndrome. Cet algorithme nous sera utile mais il faut lui reconnaître ses limites. Il est glouton et est donc

sujet au bien connu effet de l'horizon : une branche qui semble prometteuse pour notre horizon ne le sera peut-être plus à un horizon plus lointain.

Il s'agit désormais d'améliorer cette politique et les techniques d'apprentissage par renforcement sont adéquates pour répondre à cet objectif (Sutton (1998)). L'idée de l'apprentissage par renforcement est de partir d'une politique quelconque π_0 (pour nous ce sera l'algorithme déjà implémenté ID3), de calculer $v_{\pi_0}(s)$ pour tout s , puis d'améliorer cette politique en prenant

$$\pi_1(s) = \operatorname{argmin}_{a \in \mathbb{A}} E[1 + v_{\pi}(s_{t+1}) \mid s_t, a] = a_1.$$

On calcule ensuite $v_{\pi_1}(s)$, π_2 etc ce qui mène à une amélioration croissante de la politique jusqu'à atteindre en un temps fini la politique optimale puisque le nombre d'états est fini.

La principale difficulté à laquelle nous sommes confrontés est liée à la très grande dimension de notre problème. Or à notre connaissance il n'y a pas dans la littérature actuelle de travaux qui se propose d'apprendre une politique de diagnostic lorsque le nombre d'états est très grand. L'article de Bayer-Zubeck s'intéresse à un problème très semblable au notre mais ses algorithmes seront trop gourmands en calcul pour répondre à notre problématique. En effet le nombre de 22 tests est déjà considéré comme grand par ces auteurs alors que nous en avons 300. Leurs algorithmes fonctionnent sur des observations, entre 267 et 768 au maximum quand nous fonctionnons avec des probabilités fournis par des experts. Si nous souhaitions apprendre une politique à partir de données simulées il nous faudrait au moins 10000 observations pour avoir une population représentative car les syndromes les plus probables sont 1000 fois plus probables que les syndromes les plus rares.

Nous ne pourrions pas calculer explicitement les $v_{\pi}(s)$, ce qui peut-être fait par de la programmation dynamique lorsque le nombre d'état est faible. En ce qui nous concerne nous devons nous contenter de les estimer ce qui peut-être fait par des méthodes de Monte-Carlo (on se place au noeud s et on lance des simulations selon la loi donnée par notre environnement). Le problème est que nous ne pouvons pas mener les simulations de la racine jusqu'au feuille de l'arbre du fait de la grande profondeur de celui-ci. La solution que nous proposons est de s'arrêter à une certaine profondeur de l'arbre lors des simulations (cette profondeur sera dictée par des contraintes de temps de calcul) à partir de laquelle le temps restant avant la fin de l'examen sera estimé par exemple de manière paramétrique :

$$\hat{v}_{\pi}(s) = \sum_{j=1}^{307} \theta_j \mathbb{1}_{\{A_j=1\}} + \alpha_k \sum_{j \in G_k} \mathbb{1}_{\{A_j=0, A_k=1\}},$$

où G_k est le groupe des anomalies liés à l'anomalie A_k , c'est-à-dire les anomalies qui se retrouvent chez les mêmes syndromes que A_k et les θ et α des paramètres à estimer (par minimisation de moindres carrés par exemple).

Il s'agit également d'utiliser les idées des algorithmes de type AO*(Bayer-Zubeck (2005)), qui maintiennent pour chaque noeud une hypothèse optimiste et une hypothèse

pessimiste de $v_\pi(s)$. Il sera ainsi possible d'élaguer l'arbre et d'exclure les sous-arbres les moins prometteurs. En effet, notons $q_\pi(s, a)$ le coût moyen d'un examen commençant à l'état s auquel on applique l'action a puis la politique π . Si l'on a que $q_\pi(s, a)$ appartient à l'intervalle $[q_\pi^{opt}(s, a), q_\pi^{pess}(s, a)]$, $\forall a$ et qu'il existe $a_1, a_2 \in \mathbb{A}$ tels que $q_\pi^{pess}(s, a_2) < q_\pi^{opt}(s, a_1)$ alors on peut écarter sans risque l'action a_1 lorsque l'on est à l'état s .

Cela nous permettra également de mieux orienter les simulations, nous proposons de privilégier l'exploration des branches qui ont une hypothèse optimiste basse car faire des simulations sur des branches ayant des minorants plus élevés dans l'espoir de voir ce minorant augmenter afin d'exclure cette branche constitue une forme de gâchis. Si l'on lance des simulations sur la branche que l'on pense être optimale et qu'elle se révèle l'être en effet alors ces simulations ne seront pas perdues pour le reste de l'optimisation de l'arbre.

En conclusion, précisons que notre premier algorithme a été évalué positivement par les obstétriciens de Necker avec qui nous travaillons : Emmanuel Spaggiari et Julien Stirnemann, tous deux membres de l'équipe du Professeur Yves Ville. La bonne interprétabilité de notre algorithme est appréciée, ses choix paraissent raisonnables aux yeux des médecins. Nous avons de bonnes raisons de penser que ces résultats seront grandement améliorés grâce aux idées proposées dans ce travail.

Bibliographie

- [1] Jaynes, E.T. (1963), *Information Theory and Statistical Mechanics*, The Physical Review, Standford.
- [2] Cover T.M. et Thomas J. A. (2003), *Elements of Information Theory*, *John Wiley and Sons*, Standford.
- [3] Berger A.L., Della Pietra S.A., Della Pietra V.J. (1996), *A Maximum Entropy Approach to Natural Language Processing*, *Association for computational Linguistics*, Columbia.
- [4] Bayer-Zubeck V., Dietterich T.G (2005), *Integrating Learning from Examples into the Search for Diagnostic Policies* *Journal of Artificial Intelligence Research*, Oregon.
- [5] Sutton R.S., Barto A.G. (1998), *Introduction to reinforcement learning* *Bradford Book*, MIT Cambridge.
- [6] Breiman L., Friedman J., Stone C.J, Olshen R.A. (1984), *Classification and regression trees* *Wadsworth Statistics/Probability*, Berkeley.
- [7] Quinlan J.R. (1986), *Induction of decision trees* *Wadsworth Statistics/Probability*, Berkeley.
- [8] Lomax S., Vadera S. (2011), *A survey of cost-sensitive decision tree induction algorithm* *ACM Computing Surveys*, University of Salford.
- [9] Browne C. et al (2012), *A survey of Monte-Carlo Tree Search Methods* *IEEE Transactions On Computational Intelligence And AI In Games*, London U.K.