

# Les Réseaux Bayésiens pour l'aide à la maintenance des voies ferrées

Laurent Bouillaut  
INRETS-LTN  
2, Avenue du Général Malleret Joinville  
94114 Arcueil  
[laurent.bouillaut@inrets.fr](mailto:laurent.bouillaut@inrets.fr)

**Résumé** – Ces travaux traitent du problème de l'aide à la maintenance des voies ferrées. Nous nous intéressons dans un premier temps à la classification d'évènements discrets organisés en séquence temporelle. Les réseaux bayésiens dynamiques sont utilisés pour cette modélisation en utilisant une base de données comme ensemble d'apprentissage. L'aspect dynamique de ces réseaux probabilistes est mis à profit au sein d'une boucle de rétroaction qui permet l'inférence d'un état présent ou futur à partir d'un état passé. Cette aptitude est testée sur un problème concret qui concerne la labellisation des points singuliers de l'infrastructure des transports ferroviaires, en vue d'aide à la classification des défauts de rails. La seconde partie traite de l'utilisation des diagrammes d'influences et des résultats issus de la première partie de l'article pour définir des politiques de maintenance optimales.

**Mots clés** – Aide à la Maintenance, Réseaux Bayésiens, Diagrammes d'influence, Maintenance des voies ferrées.

## 1. Introduction

L'évolution des infrastructures ferroviaires, au court de ces dernières décennies, a eu pour principale conséquence une très forte augmentation des contraintes exercées sur les voies ; que ce soit en termes de fréquences de passage, de vitesses de circulation, de charges à l'essieu... De nouveaux problèmes de sûreté de fonctionnement sont alors apparus. Parmi eux, l'un des plus critiques est certainement la prévention des ruptures de rails et donc, la détection des défauts mineurs conduisant à ces ruptures. Le développement d'outils, de méthodes... permettant la détection de ces défauts doit permettre la mise en place de nouvelles politiques de maintenance des infrastructures (prédictives, prévisionnelles...).

C'est dans ce but qu'a été développé, dans le cadre d'un projet Predit signé avec la RATP, un multicapteur à courant de Foucault, détectant toute anomalie du rail [6]. Ce capteur permet de détecter les ruptures de rails mais également certains défauts mineurs pouvant conduire à des ruptures. Toutefois, dans ce second cas, le taux de bonnes détections n'est pas parfait et des confusions subsistent entre certaines classes de défauts et de simples irrégularités du rail telles que des soudures ou des éclisses [2].

L'objectif de l'étude présentée dans cet article est de définir des procédures permettant d'améliorer les taux de bonnes détections afin d'obtenir, à terme, un outil d'aide à la maintenance optimal, compte tenu des contraintes (d'infrastructures, de rendement...). Depuis quelques années, de plus en plus de problèmes de fiabilité ou de maintenance ont trouvé leur solution dans l'utilisation des réseaux bayésiens. En effet, comparée aux approches probabilistes standards, l'approche bayésienne offre un certain nombre d'avantages forts intéressants pour les problématiques de maintenance ; citons notamment la possibilité d'intégrer les incertitudes a priori sur le système, la visualisation et la modification des modèles de systèmes (même complexes) est simple et rapide, des algorithmes robustes d'apprentissage, la rétropropagation d'information permettant de faire évoluer des certitudes sur le système quelles que soient les relations de causalité...[4] Les applications présentées dans cet article seront donc basées de réseaux bayésiens et de diagrammes d'influence.

Dans un premier temps, nous introduirons très brièvement les principaux aspects théoriques de ces deux outils (plus de détails pouvant être trouvés dans la littérature) [4]. Après quoi, nous présenterons plus en détails leur application dans le cadre de l'aide à la détection et à la classification de défauts mineurs en diminuant les taux de confusion avec des points singuliers (soudures, éclisses...). Enfin, la détection de défauts étant améliorée, une politique de maintenance préventive peut être développée de façon optimale. Pour cela, nous utilisons également des réseaux bayésiens dynamiques.

## 2. Aspects théoriques

### 2.1. Les Réseaux Bayesiens

Une définition classiquement rencontrée dans la littérature présente les réseaux bayesiens comme des *représentations graphiques acycliques et probabilistes d'une situation, d'un système, d'une succession d'événements*. Chaque variable aléatoire  $X$  décrivant le système étudié est caractérisée par un nœud, un ensemble d'états  $S_X$  et par des tables de probabilités (TP), resp. des tables de probabilités conditionnelles (TPC), si la variable considérée n'a pas de parents, resp. a des parents. Ces tables contiennent les probabilités que  $X$  soit, à l'instant considéré, dans tel ou tel état de  $S_X$  (resp. dans tel état de  $S_X$ , connaissant les états dans lesquels se trouvent les variables parentes de  $X$ ). La causalité entre les variables aléatoires est symbolisée par des arcs entre les nœuds concernés.

Il est important de noter que, dans ce type de réseaux, chaque variable ne peut être décrite que par un seul nœud. Toutefois, pour répondre aux besoins d'applications évoluant dans le temps, la notion de réseaux bayesiens dynamiques a été développée. Dans ce cas, certaines variables peuvent être décrites par plusieurs nœuds, modélisant leur comportement à différents instants. Ces nœuds sont reliés par des arcs dynamiques représentant l'évolution du temps [5]. C'est cette approche qui sera considérée dans la suite de l'étude.

### 2.2. Les Diagrammes d'Influence

Evolution directe des réseaux bayesiens (dynamiques ou non), les diagrammes d'influences ont pour principale propriété de permettre la modélisation des coûts et des conséquences de prises de décisions sur le système modélisé. Pour cela, deux nouveaux types de nœuds sont définis : Les nœuds de décisions (variables sur lesquelles l'utilisateur a un contrôle total) et les nœuds d'utilité (permettant de connaître le coût d'une décision). Depuis presque dix ans, cet outil a trouvé une grande place dans le domaine de l'aide à la maintenance et à la sûreté de fonctionnement. [8] [9].

## 3. Application à la détection de défauts de surface

### 3.1. Présentation du système étudié

La première étape de notre étude consistait à diminuer le nombre de confusions entre de vrais défauts et de simples points singuliers à voie (tels que des soudures ou des éclisses). Nous disposons pour cela d'une base de données de la RATP répertoriant l'ensemble des interventions de maintenance sur les voies du métro parisien (type d'intervention, points kilométriques...). Or, du fait des règles de pause des rails, des contraintes techniques... l'infrastructure d'une voie ferrée est très fortement structurée. Le séquençage des points singuliers n'est donc pas complètement aléatoire et un certain nombre de modèles statistiques sont identifiables. Nous souhaitons utiliser ces connaissances statistiques a priori fortes pour augmenter notre certitude dans l'apparition de points singuliers et ainsi diminuer le nombre de confusions avec des défauts réels.

Plusieurs modèles ont été réalisés, considérant que seuls les  $n$  derniers points singuliers (leurs distances, leur nature) pouvaient influencer la nature du  $n+1$ ème points singulier. Trois classes ont été considérées : Les soudures (JS), les éclisses (JE) et les joints de cœurs des appareils de voie (JA). Dans cet article, nous ne présenterons que les résultats du modèle final. Toutefois, les différents modèles proposés, leur comparaison ainsi qu'une présentation de leur sensibilité à la propagation d'erreur peuvent être trouvées dans [3] [1].

### 3.2. Résultats du modèle final

Dans ce modèle, nous avons considéré que seules les deux dernières détections ( $X_{k-1}$  et  $X_{k-2}$ ) pouvaient avoir une influence significative sur l'état de la détection actuelle ( $X_k$ ). La figure 1 présente ce réseau bayésien dynamique modélisant une IOHMM [10]. La variable d'entrée  $U$  représente l'information relative aux distances entre les différentes détections, permettant de définir les tables de probabilités des différents nœuds, et la variable de sortie  $Y$  contient les probabilités que  $X$  appartienne à chacune des trois classes considérées.




Figure 1. Réseau Bayésien dynamique à deux tranches de temps modélisant une IOHMM

Enfin, la prise de décision liée à  $Y$  est enrichie par des modèles spécifiques de la classe JA. En effet, comme nous l'avons observé dans l'analyse des premiers modèles [1] [3], les joints d'appareils répondent, du fait de leur structure, à un certain nombre de modèles probabilistes identifiables à partir de la base SIAM. Cependant, ces derniers sont d'ordre 4. La première solution aurait été de considérer des réseaux bayésiens à trois tranches de temps. Mais la complexité des phases d'apprentissage pour des tels réseaux modélisant notre problème nous a fait préférer une solution plus simple : Nous avons placé, en parallèle du réseau de la figure 1, un second réseau bayésien, à trois tranches de temps, ne s'intéressant qu'à la détection des quelques modèles caractérisant, de façon exclusive, les joints d'appareils. Les tableaux 1a et 1b introduisent les résultats obtenus par le réseau de la figure 1 et par sa version améliorée.

Nature du joint	Classification			Nature du joint	Classification		
	JS	JE	JA		JS	JE	JA
JS	<b>97.4 %</b>	2.6 %	0 %	JS	<b>97.4 %</b>	2.6 %	0 %
JE	50.6 %	<b>49.2 %</b>	0.2 %	JE	45.8 %	<b>53.7 %</b>	0.5 %
JA	40.2 %	57 %	<b>2.8 %</b>	JA	10.4 %	11.1 %	<b>78.5 %</b>

Tableaux 1 : Tables de confusion du réseau bayésien à deux tranches de temps (a) et de sa version améliorée (b).

Nous pouvons remarquer que cette évolution du réseau bayésien de la figure 1 nous apporte un grand gain d'information. Les résultats obtenus ne sont, bien entendus, pas aussi bons que ceux classiquement obtenus lors d'applications de diagnostic. Toutefois, l'objectif de cette étude est la fusion de ces informations avec celles issues du classifieur local (fournies par le capteur). De plus, l'application présentée dans cet article s'appuie uniquement sur une observation statistique et globale du réseau ferré du métro parisien. Les résultats obtenus apportent donc une information importante sur la structure de la voie, permettant d'augmenter la certitude dans la détection des points singuliers au rail et donc de diminuer les taux de confusion entre défauts réels et simples irrégularités de la voie.

#### 4. Application à l'aide à la maintenance

La seconde étape de notre étude consiste alors, après intégration des informations relatives à l'apparition ou non de tel ou tel type de défaut sur la voie, de mettre en place une politique de maintenance adaptée et optimisée en fonction des différentes contraintes (telles que le coût d'intervention, le temps d'occupation des voies, les limitations de trafic liées au type de réparation choisie...). Cette approche passe, dans un premier temps, par la détermination d'un type de périodicité de maintenance puis par l'optimisation du type d'intervention sur site. Pour cela, nous utilisons les diagrammes d'influences introduits à la section 2.2. [8] [9].

##### 4.1. Choix d'une périodicité de maintenance

La définition des différentes contraintes, liées à la mise en place d'une intervention de maintenance, permet de déterminer un certain nombre de variables caractérisant notre problème, telles que : Le type d'utilisation de la voie considérée (entretien, exploitation), l'apparition ou non d'un défaut (l'état de cette variable étant directement lié aux résultats de la section précédente), les différents types d'interventions possibles (meulage, remplacement partiel du rail...), les différentes périodicités de maintenances...

La prise en compte des informations statistiques issues de retours d'expériences ou d'avis d'experts permet d'établir les relations de causalité entre ces variables et de définir leur TP ou TPC. Après ces différentes étapes, nous obtenons le diagramme d'influence introduit par la figure ci-dessous.

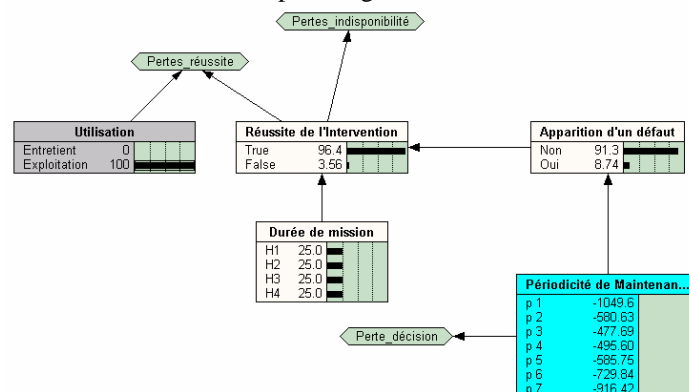


Figure 2. Diagramme d'influence déterminant la périodicité de maintenance optimale.

La détermination des différents états sur lesquels nous avons une certitude (dans notre exemple, la nature de l'utilisation de la voie), permet de définir la périodicité de maintenance qui, selon les critères et contraintes considérées, permet de minimiser le coûts (financier, humain, logistique...).

L'étape suivante consiste alors à déterminer, après détection d'un défaut déterminé, l'intervention optimale à mettre en œuvre.

#### 4.2. Optimisation de l'intervention de maintenance

Pour cela, un certain nombre de variables pertinentes peuvent être identifiées : Le type et la durée de l'intervention, les contraintes d'exploitation minimum à assurer, le type de défaut... La figure 3 présente le diagramme d'influence obtenu pour modéliser ce processus.

Nous pouvons remarquer que, contrairement au diagramme d'influence présenté dans la section précédente, la solution proposée ici s'appuie sur un réseau bayésien dynamique. En effet, la variable modélisant l'apparition ou non d'un défaut est caractérisée par deux nœuds représentant l'évolution possible de cette variable entre les instants  $t$  et  $t+dt$ . Les tables de probabilités du premier nœud sont calculées à partir des valeurs obtenues pour le second nœuds au pas de temps précédent et par les résultats du classifieur de défauts, présenté dans la section 3. Les tables de probabilités conditionnelles caractérisant le second nœud sont obtenues à partir des lois de dégradations caractérisant chaque type de défaut [7].

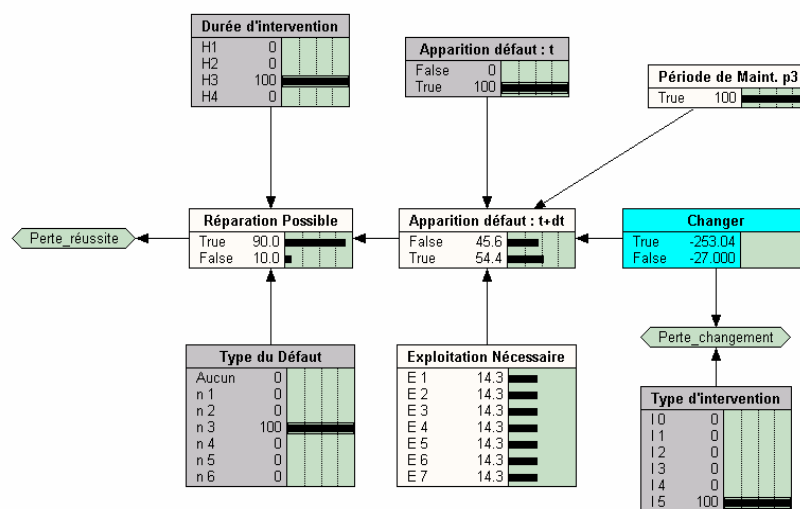


Figure 3. Diagramme d'influence déterminant l'intervention de maintenance optimale.

Un tel diagramme d'influence permet, lorsqu'un défaut est détecté et connaissant le niveau de dégradation, la nature du défaut, les contraintes à assurer..., de déterminer s'il est pertinent d'intervenir et si oui, de quelle façon et à quel coût.

## 5. Conclusion

L'approche bayésienne est depuis quelques années couramment utilisée pour des problèmes de maintenance ou de fiabilité [8] [9] ; les réseaux bayésiens et les diagrammes d'influence répondant parfaitement aux besoins et contraintes de ces thématiques.

Dans cet article, nous avons présenté, à travers une application dédiée à la surveillance des voies ferrées, les avantages que pouvaient présenter les réseaux bayésiens et les diagrammes d'influence pour développer des outils d'aide à la maintenance.

Nous nous sommes tout d'abord intéressés à une application d'aide au diagnostic de défauts. Dans cette première partie, les réseaux bayésiens dynamiques nous ont permis de modéliser la succession de points singuliers à la voie (soudures, éclisses...) et ainsi, diminuer les confusions possibles entre ces irrégularités du rail et des défauts réels. La détection et la classification de défauts, réalisées par un capteur à courant de Foucault [6], en est alors améliorée.

La seconde partie de notre étude reposait alors sur l'utilisation des résultats issus de ce classifieur pour mettre en place, lorsqu'un défaut est détecté, une politique de maintenance optimale des voies (selon la nature du défaut, son niveau de gravité, le type de voie concernée, les contraintes d'exploitation, les coûts de maintenance...). Les diagrammes d'influence obtenus ont permis de déterminer les meilleures périodes d'intervention ainsi que le type de maintenance à effectuer en fonction de l'état d'avancement du défaut.

## 6. Références

- [1] A. Ben Salem, L. Bouillaut, P. Aknin, P. Weber, *Dynamic Bayesian Networks for classification of rail defects*, 4th IEEE SMC Society International Conference on Intelligent Systems Design and Applications, Budapest, Hungary, Août 2004.
- [2] M. Bentoumi, P. Aknin, G. Bloch. *On-line defect diagnosis with eddy current probes and specific detection processing*, EPJAP, Vol. 23, no.3, 2003, pp. 227-233.
- [3] L. Bouillaut, P. Weber, A. Ben Salem, P. Aknin, *Use of Causal Probabilistic Networks for the improvement of the Maintenance of Railway Infrastructure*, IEEE International Conference on Systems Man and Cybernetics, The Hague, The Netherlands, Octobre 2004.
- [4] F.V. Jensen, *An Introduction to Bayesian Networks*, UCL Press, London, 1996.
- [5] K.P. Murphy, *Dynamic Bayesian Networks: Representation, Inference and Learning*, PhD Dissertation, University of California, Berkeley, 2002.
- [6] L. Oukhellou, P. Aknin, J-P Perrin. *Dedicated sensor and classifier of rail head defects for railway systems*, Control Engineering Practice 7, 1999, pp. 57-61.
- [7] B. Prasil, R. Moulin, *Etude statistique de la méthode de contrôle des rails en voie*, Revue Générale des Chemins de Fer, Juin 1981, pp. 327-340.
- [8] H. Procaccia, M-C. Suhner, *Démarche bayésienne et applications à la sûreté de fonctionnement*, Hermès Science Publications, janvier 2003.
- [9] P. Weber, M-C. Suhner, *Aide au choix de Stratégie de Maintenance par Simulation de Réseaux Bayésiens*. Congrès international pluridisciplinaire Qualité et Sûreté de Fonctionnement, Qualita'01, 2001, pp.302-307.
- [10] P. Weber, L. Jouffe, *Reliability Modelling with Dynamic Bayesian Networks*, 5th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes, SAFEPROCESS'03, Washington, D.C., USA, June 9-11, 2003.