

# La détection du cancer colorectal en vidéocoloscopie

Comme vu précédemment, le médecin, lorsqu'il effectue l'examen, peut être amené à manquer jusqu'à 26% des polypes. C'est dans cet optique de réduire ce taux que plusieurs méthodes et outils de détection ont été mis au point.

Dans ce chapitre, on va se consacrer à présenter les techniques mises au point afin de réduire ce taux de polypes manqués qui sont aussi diverses que variées. De plus, on va aussi en déduire et présenter quels peuvent être les outils que l'on peut utiliser pour mettre au point notre méthode permettant de détecter les polypes de manière automatique, en respectant les contraintes présentées précédemment.

## 1.1 Les moyens de détection du cancer colorectal

Parmi tous les moyens qui existent afin de lutter contre ce problème, on peut distinguer deux grandes familles :

- Les outils matériels, qui consistent à proposer un nouvel outil physique (comme un nouveau coloscope), avec des propriétés spécifiques qui permettent d'améliorer la détection des polypes.
- Les outils d'aide à la détection assistée par ordinateur, qui consistent à détecter durant la coloscopie (ou dans des vidéos de coloscopies) les polypes afin d'aider le médecin dans son analyse.

On va donc s'intéresser maintenant à voir ce que proposent ces deux grandes familles, en termes d'améliorations et de limitations.

### 1.1.1 Les moyens matériels de détection du cancer colorectal

Outre la vidéocoloscopie (SD ou HD) qui est la méthode de détection la plus répandue, d'autres moyens matériels ont été mis en place afin d'améliorer les taux de détection de

polypes et d'adénomes. Dans les paragraphes suivants, sont présentés ceux ayant eu un impact réel sur le sujet et commercialisés aujourd'hui.

### Full Spectrum Endoscopy (FUSE)

Basé sur un endoscope modifié, le FUSE se distingue par l'ajout de 2 caméras de chaque côté du coloscope (figure 1.1). Cela permet au médecin de voir le côlon à 330 degrés [DMS14] et donc de voir normalement plus facilement la paroi du côlon, et bien sûr, le canal opérateur reste disponible afin d'effectuer des biopsies ou de procéder au retrait de polypes et d'adénomes.



FIGURE 1.1 – Endoscope FUSE

La colonne d'endoscopie est, elle, équipée de 3 écrans qui retranscrivent l'image des 3 caméras (figure 1.2).

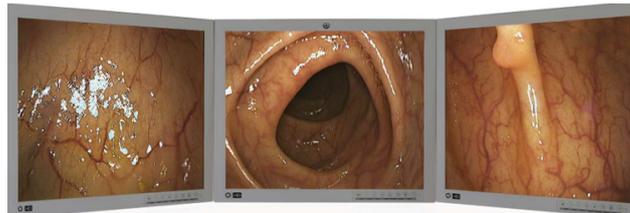


FIGURE 1.2 – Visualisation des images avec le FUSE

Comparée à la coloscopie SD à lumière blanche, il y a une meilleure détection des polypes durant l'examen (le taux d'adénomes manqués chute de 41% à 7% en utilisant le FUSE) [GSH<sup>+</sup>14]. Cependant, cette technique nécessite que le médecin apprenne à se servir de ce nouvel outil, ce qui change le protocole opératoire, et représente donc un point faible de cette méthode en terme d'utilisabilité.

### Narrow Band Imaging (NBI)

Le Narrow Band Imaging (NBI, ou imagerie à bande étroite en français) est une technique de coloscopie, développée par Olympus, qui met l'accent sur les longueurs d'ondes

bleue (415 nm) et verte (540 nm) pour améliorer certains détails de la muqueuse [PRW11]. Cette accentuation est obtenue par des filtres optiques qui n'autorisent que les lumières bleue et verte à passer dans l'endoscope. Ce filtre s'active sur simple appui d'un bouton, ce qui permet au médecin de basculer entre le mode classique (lumière blanche) au mode NBI. La figure 1.3 montre le principe du NBI depuis la source lumineuse jusqu'au capteur de l'imageur. Des études ont montré que le taux de polypes manqués chute de 57% à 31% en comparaison à l'endoscopie en lumière blanche. Il en est de même pour le taux d'adénomes manqués qui lui passe de 49% à 27% [GBC<sup>+</sup>11]. Cependant, contrairement à la coloscopie en lumière blanche, l'intensité lumineuse du NBI est plus faible (figure 1.4) et rend donc la lecture moins aisée.

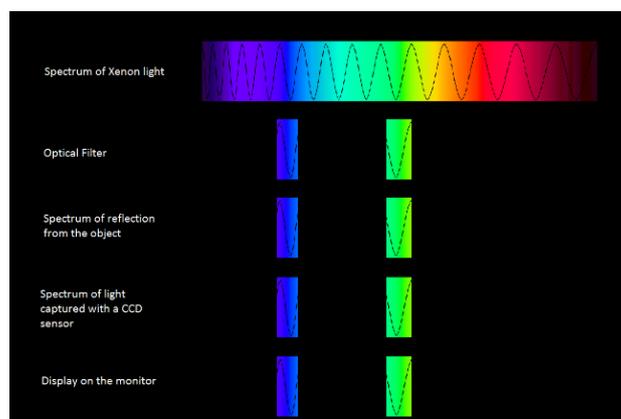


FIGURE 1.3 – Fonctionnement du NBI

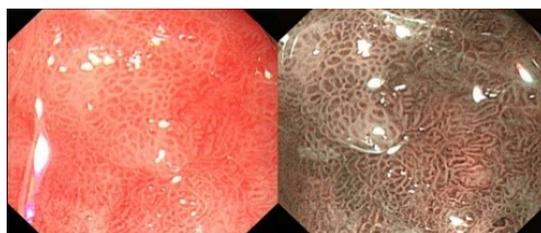


FIGURE 1.4 – Comparaison entre endoscopie à lumière blanche et endoscopie NBI

### Fujinon Intelligent Color Enhancement (FICE)

Le FICE utilise un endoscope classique avec une source de lumière au Xénon [Fuj07] qui possède un spectre lumineux s'étendant entre 400 et 700 nm. La lumière part de l'endoscope et est réfléchi sur la paroi du côlon qui est récupérée par un capteur CCD (charge-coupled device, dispositif à transfert de charge en français). Puis l'information du capteur est convertie en image. Contrairement au NBI, une étape de traitement d'images est effectuée en sélectionnant des filtres virtuels afin de faire apparaître des zones intéressantes du côlon. Le FICE permet de sélectionner les images spectrales avec les longueurs

d'ondes appropriées pour maximiser la différence dans le spectre de réflexion. Cela permet de reconstruire des images à contraste élevé pour une grande variété de tissus dans le corps. Le FICE effectue le traitement d'image (application des filtres) et le médecin peut passer facilement de la coloscopie classique au mode FICE. La figure 1.5 montre le principe du FICE depuis la source lumineuse jusqu'au capteur de l'imageur.

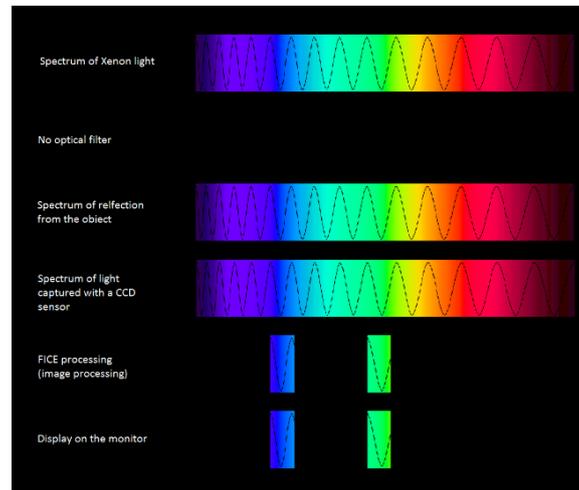


FIGURE 1.5 – Fonctionnement du FICE

### Coloscopie en imagerie autofluorescente (AFI)

Basée sur un coloscope modifié, cette technique fait appel au principe d'autofluorescence. Le principe de fluorescence est le suivant : quand la lumière réagit avec la matière, des photons sont absorbés. Il y a alors une transition électronique depuis le plus bas niveau d'énergie  $S_0$  vers des niveaux plus élevés  $S_1$ ,  $S_2$  ou  $S_n$ . Les niveaux les plus hauts sont atteints si l'énergie est assez élevée. Ensuite intervient une reconversion de l'énergie interne qui permet de revenir au niveau  $S_1$   $V_n$ . On passe alors du niveau  $V_n$  au niveau  $V_0$  grâce à des interactions entre des molécules de fluorophore et de solvant. Et ce n'est seulement qu'au moment de la transition depuis le niveau  $S_1$   $V_0$  qu'intervient le phénomène de fluorescence [Alb01] (voir figure 1.6).

Techniquement parlant, la fluorescence est l'émission de photons depuis un état singulier  $S_1$ . L'intensité du spectre de fluorescence dépend de la population de molécules excitées à l'état  $S_1$   $V_0$ .

L'électron suit un circuit fermé : il commence à  $S_0$   $V_0$  vers l'état  $S_n$   $V_m$ , puis par reconversion interne, va à l'état  $S_1$   $V_0$ . Ensuite, il passe à l'état  $S_0$   $V_0$  avec une émission de photons (la fluorescence). Mais la fluorescence n'est pas permanente, elle a une durée de vie qui varie de la nanoseconde à la picoseconde. Il existe par ailleurs deux types de fluorescence : l'endogène et l'exogène [AEW92].

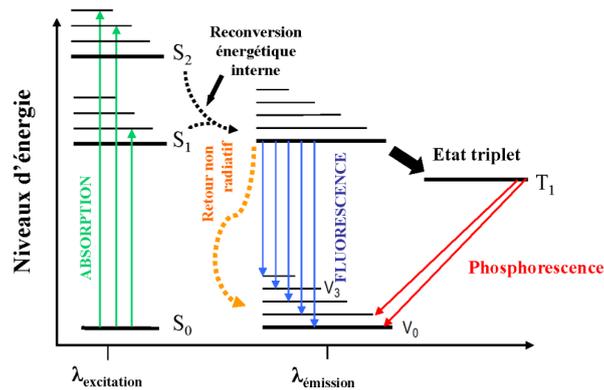


FIGURE 1.6 – Diagramme de Jablonski

L'autofluorescence est aussi appelée fluorescence endogène. Elle est basée sur des fluorophores naturels qui sont présents dans le corps du patient et certains de ces fluorophores peuvent révéler la présence de cellules cancéreuses.

Côté technique, la source de lumière blanche est séparée en lumière d'excitation (à une longueur d'onde particulière, comprise entre 400 et 500 nm) et en lumière verte. Puis, en récupérant la lumière réfléchie, une image est affichée à l'écran [ITA<sup>+</sup>13](voir figure 1.7).

L'avantage de cette technique est de permettre une meilleure détection des lésions [RHP<sup>+</sup>10] [MFS<sup>+</sup>12]. Cependant, elle peut aussi révéler des zones sans lésions et entraîne alors de nombreuses fausses détections [RKH14].

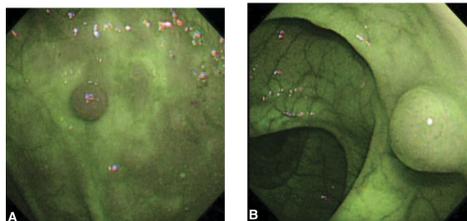


FIGURE 1.7 – Images issues de la technique AFI

## Chromoendoscopie

La chromoendoscopie vise à améliorer la précision dans le diagnostic lors de l'endoscopie gastro-intestinale, en utilisant différents colorants. En particulier, deux types de colorants sont utilisés en chromoendoscopie :

- Des colorants de surface qui ne réagissent pas avec les cellules de la muqueuse mais qui accentuent le relief pour optimiser le diagnostic des lésions (par exemple, le carmin d'indigo)

- Des colorants essentiels qui réagissent spécifiquement avec certaines cellules de la muqueuse et permettent de deviner leur nature (par exemple, le bleu de méthylène)

La chromoendoscopie utilisant le carmin d'indigo est la méthode d'exploration de la muqueuse la plus utilisée. Cette méthode permet de définir plus précisément les irrégularités de relief et surface des lésions. Le colorant est appliqué directement sur la muqueuse avec un cathéter durant l'examen [RKH14]. Puis le médecin compare le motif de la zone d'intérêt à la classification Kudo (figure 1.8)[KTN<sup>+</sup>96].

Mais avant d'effectuer une chromoendoscopie, une coloscopie classique est requise. Elle ne sera utilisée que sur des zones suspectes ou des lésions planes dans l'optique de définir les bords de la lésion détectée par coloscopie. Ainsi, les biopsies peuvent être mieux effectuées et les polypectomies ont une meilleure précision. La chromoendoscopie permet également de faire une reconnaissance des motifs afin de deviner l'histologie de la lésion.

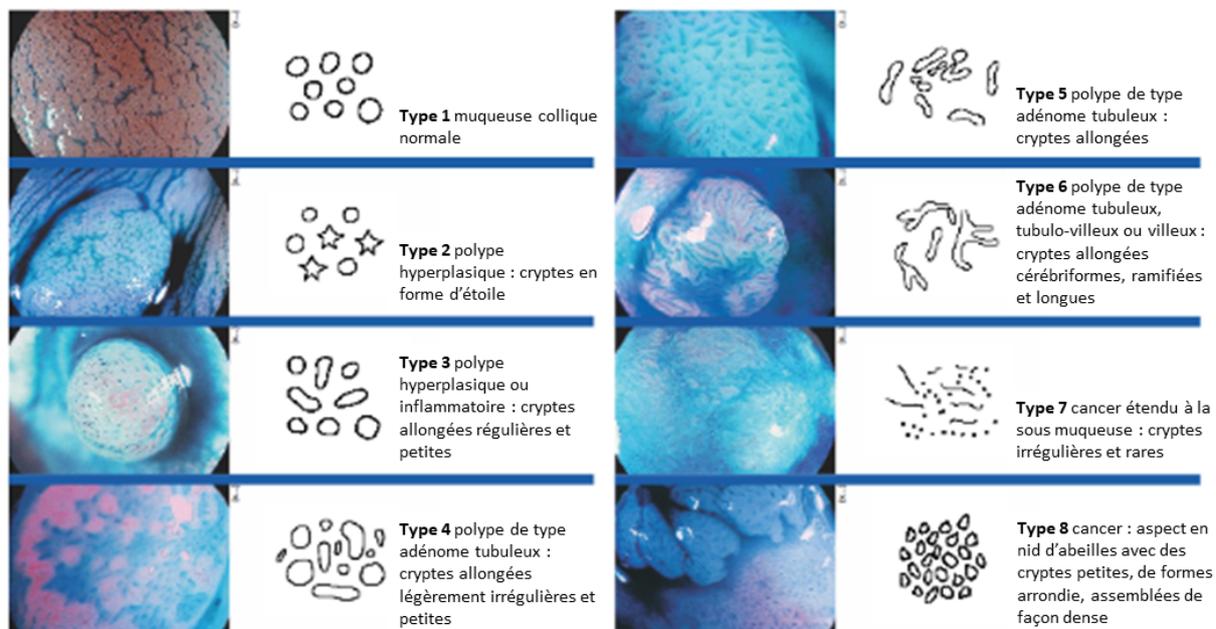


FIGURE 1.8 – Classification Kudo pour la reconnaissance de motifs

La chromoendoscopie est donc utile pour la détection des adénomes plans et pour mieux définir les contours d'une lésion [LHN<sup>+</sup>06] [BB10]. Cependant, elle ne doit pas être effectuée avant une coloscopie conventionnelle. Finalement, elle peut être utile dans le diagnostic des lésions mais une biopsie est toujours nécessaire afin d'effectuer une analyse histologique.

## Endomicroscopie

L'endomicroscopie est un examen coloscopique basé sur un endomicroscope qui est soit un microscope miniaturisé couplé à un endoscope, soit un microscope intégré à un endo-

scope spécifique. Le microscope utilise un laser à argon (488 nm) [RKH14] et fonctionne avec l'ajout d'un agent de contraste injecté au patient (fluorescine). Il permet au médecin de faire une biopsie virtuelle durant un examen (figure 1.9). Le but de cette méthode est de faire un diagnostic rapide des lésions. Des études récentes ont montré la très bonne précision dans le diagnostic : 80% à 95% de détection [LYS<sup>+</sup>13].

Cependant, cet examen requiert la présence à la fois d'un hépatogastroentérologue et d'un histologiste afin de déterminer la dangerosité d'une lésion. Et l'agent de contraste peut provoquer une coloration jaune de la peau pour le patient [KBV<sup>+</sup>04].

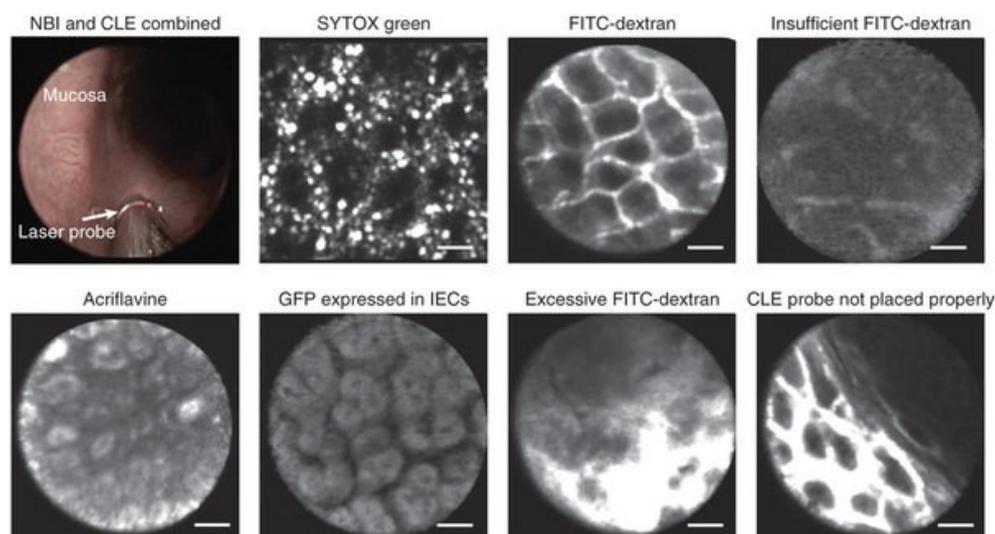


FIGURE 1.9 – Illustration de l'endomicroscopie (Source : Society for Mucosal Immunology)

### Capsule endoscopique

La capsule endoscopique est une méthode d'endoscopie utilisant une capsule avec de l'électronique embarquée (figure 1.10). Elle est constituée d'un ou deux capteurs vidéo pour enregistrer les images du côlon, d'un processeur de traitement des données et une antenne radio-fréquence pour envoyer les images à un récepteur externe [AHR<sup>+</sup>15] (datalogger). Le récepteur externe est relié à un jeu d'antennes qui sont collées sur le corps du patient pour récupérer les données de la capsule et les stocker dans le datalogger.

L'examen se déroule d'une façon totalement différente de la coloscopie. Après un nettoyage du côlon grâce à une solution à base de polyéthylèneglycol (comme en coloscopie), le patient ingère la capsule sous la supervision du médecin puis peut retourner à sa routine habituelle. Pendant ce temps, la capsule prend des photos du côlon (figure 1.11, au rythme de 4 à 35 images par seconde pendant environ 8 heures). Une fois l'examen terminé, le médecin récupère le boîtier récepteur afin de regarder toutes les images pour chercher la présence de polypes ou d'adénomes (à titre d'exemple, une capsule endoscopique prend en moyenne 150 000 images que le médecin analyse en 1h et 30 minutes). Il s'agit donc



FIGURE 1.10 – Capsule endoscopique de la marque Pillcam

ici d'un examen moins contraignant que la coloscopie [WBB<sup>+</sup>13].

Cette méthode possède une sensibilité acceptable pour la détection des polypes grâce aux capsules de seconde génération (plus de 80%) [SHMN<sup>+</sup>11]. Cependant, l'image obtenue est de moins bonne qualité qu'en vidéocoloscopie (à cause de la résolution qui est de 500 pixels par 500 pixels). Et comme la capsule n'est pas "intelligente", le temps de post-traitement des données par le médecin est long. De plus, il est impossible d'effectuer une biopsie ou de retirer les lésions suspectes une fois détectées : il faut alors effectuer une coloscopie.

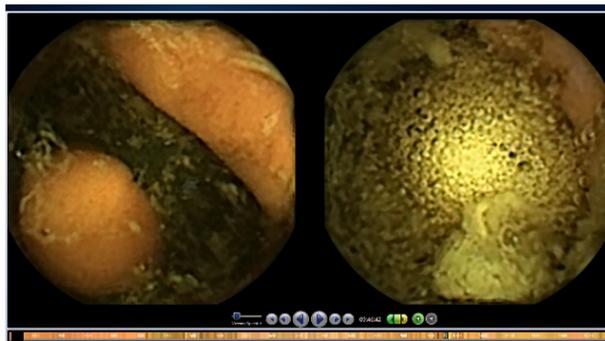


FIGURE 1.11 – Images issues d'une capsule endoscopique

### Coloscopie virtuelle (Colonographie CT)

Contrairement à toutes les méthodes précédentes, la coloscopie virtuelle ne demande pas un endoscope ou une capsule. Elle fonctionne avec un scanner ou une IRM. L'étude

du côlon est effectuée grâce à la reconstruction virtuelle en 3D du côlon à partir des données acquises par le scanner. Cette méthode évolue donc avec les améliorations dans le domaine informatique [BfCCS<sup>+</sup>10]. Afin d'effectuer cet examen, on injecte un agent de contraste et un antispasmodique au patient. Puis on introduit une sonde dans le rectum du patient afin d'y insuffler de l'air ou du dioxyde de carbone. L'acquisition des images s'effectue par des apnées de 25-30 secondes. L'acquisition de toutes les données s'effectue en environ 30 minutes.

L'examen ne requiert pas d'anesthésie et est donc moins invasif. La détection des polypes fonctionne parfaitement pour des polypes dont la taille est supérieure à 10 mm [ADW<sup>+</sup>13] (figure 1.12). Cependant, comme pour la capsule, il est impossible de retirer les lésions suspectes et on ne peut pas voir les lésions planes.

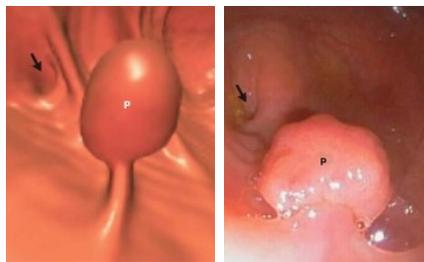


FIGURE 1.12 – Comparaison entre coloscopie virtuelle et la réalité

### 1.1.2 Les méthodes de détection assistée par ordinateur

Malgré toutes les méthodes matérielles (changement de capteurs, angle de vue, fausse couleur, contraste, etc.) mises au point pour améliorer le dépistage du cancer colorectal, et en particulier la détection des polypes, l'examen de référence reste la classique coloscopie (sauf pour des cas de contre indication à sa pratique). C'est pour cela que des méthodes d'aide à la détection assistée par ordinateur (CADe, Computer Aided Detection) sont apparues en ce qui concerne la détection des polypes colorectaux. De façon générale, les systèmes d'aide à la détection numérique sont des systèmes qui assistent les médecins pour l'interprétation des images médicales. Ces systèmes analysent donc les images des examens médicaux dans le but de mettre en évidence des zones suspectes, comme de possibles lésions, dans le but d'offrir au médecin un support pour sa décision. L'application la plus connue de ces systèmes est la détection des tumeurs, que ce soit pour la détection du cancer du sein [FTC<sup>+</sup>07], du cancer des poumons [MGH<sup>+</sup>16] ou du cancer colorectal.

Concernant la détection des polypes, que ce soit au cours des coloscopies ou que ce soit après l'examen (à partir de sa version vidéo enregistrée), il existe plusieurs méthodes afin de détecter les polypes avec des résultats intéressants. Elles s'organisent en trois grandes familles, qui sont les suivantes :

- Les méthodes ad-hoc (dites "hand-crafted")

- Les méthodes basées sur de l'apprentissage profond
- Les méthodes hybrides

Par la suite, ces méthodes vont donc être détaillées afin de décrire le paysage existant en termes d'outils d'aide à la détection dédiés aux polypes ou aux pathologies colorectales, et cela, en les rassemblant par famille de méthodes. Un tableau est proposé à la suite synthétisant les performances de chacune des méthodes présentées.

### Les méthodes ad-hoc

Les méthodes ad-hoc (ou "hand-crafted") sont formées à partir de différents blocs calculatoires, combinés ensemble, et essentiellement basés sur le traitement d'images. Les auteurs de ces méthodes se sont donc confrontés à la détection de pathologies colorectales, et en particuliers les polypes colorectaux. En voici donc un panel représentatif :

- Bernal et al. [BSFE<sup>+</sup>15] (figure 1.13) ont mis au point une méthode basée sur un modèle d'apparence des polypes qui définit les contours du polypes par rapport aux informations des vallées. C'est grâce à l'intégration des vallées qu'il leur est possible de générer des cartes d'énergie (WM-DOVA [BSV13]) qui relate la probabilité de présence d'un polype dans la zone en question. Les performances de leur méthode sont bonnes, et en particulier pour la détection de petits polypes, souvent ratés lors des coloscopies par les médecins. La figure 1.14 illustre les résultats de cette méthode.



FIGURE 1.13 – Illustration de la méthode de Bernal et al. [BSFE<sup>+</sup>15]

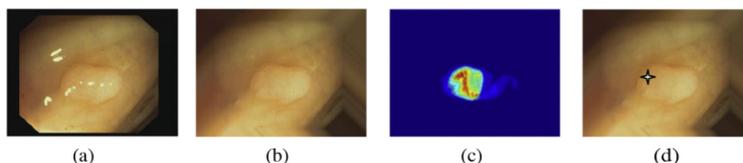


FIGURE 1.14 – Résultat de la méthode de Bernal et al. [BSFE<sup>+</sup>15], (a) image originale, (b) image prétraitée, (c) carte d'énergie, (d) probabilité de localisation du polype

- Zhu et al. [ZFL10] (figure 1.15) proposent une méthode, parfaitement adaptée à la coloscopie virtuelle, basée sur l'estimation de la courbure dans l'image puis ils appliquent la méthode de cartographie de Knutsson afin de détecter les polypes. Leur méthode permet d'améliorer l'estimation de la courbure, et donc permet de détecter des objets coloniques en plus des polypes comme les haustrations (il s'agit des plis de la paroi du côlon).



FIGURE 1.15 – Illustration de la méthode de Zhu et al. [ZFL10]

- Kang et al. [KD03] (figure 1.16) ont mis au point un système permettant de traiter les images endoscopiques en temps réel. Cette méthode a été développée dans le but de proposer un système rapide pour le traitement des images. Les images endoscopiques sont ainsi capturées et envoyées directement à des modules MATLAB. Ces modules permettent d’améliorer le contraste pour la détection, de segmenter l’image grâce à un filtre de détection de contours (Canny), puis pour finir, d’identifier les structures détectées. Cette identification est obtenue en comparant les paramètres détectés avec ceux caractéristiques d’un polype (pixel, segment, couleur, forme...). Cependant, aucune information sur les performances de cette méthode n’est donnée, si ce n’est qu’elle opère en temps réel.

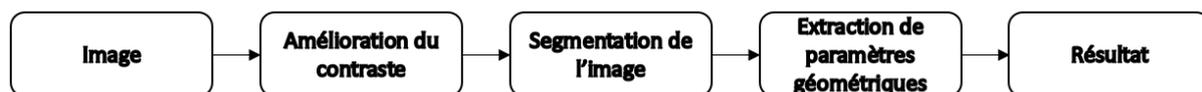
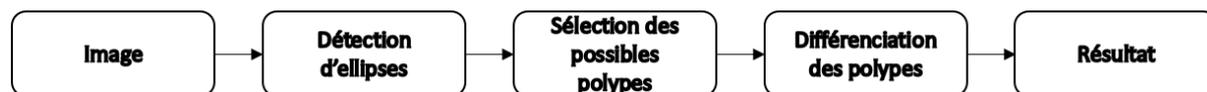


FIGURE 1.16 – Illustration de la méthode de Kang et al. [KD03]

- Hwang et al. [HOT<sup>+</sup>07] (figure 1.17) ont développé une méthode de détection des polypes basée sur la forme. La forme recherchée par Hwang et al. est celle d’une ellipse et se consacrent donc principalement à la détection d’ellipse dans les images endoscopiques. Pour y parvenir, ils segmentent l’image en plusieurs régions. Ils utilisent alors un algorithme de ligne de partage des eaux contrôlé par un marqueur pour la segmentation des polypes. Puis en utilisant les bordures des régions segmentées, ils génèrent l’ellipse correspondante. Enfin, pour sélectionner la zone correspondante à un polype parmi les zones détectées, plusieurs filtrages sont effectués (un filtrage par courbure et par direction de courbe, un filtrage par distance à une bordure, et un filtrage par intensité de pixel). Cette méthode obtient de bons résultats en terme de détection, mais au niveau du temps de calcul, elle n’est capable que de fonctionner à 15 images par secondes. La figure 1.18 montre des résultats de la détection.

FIGURE 1.17 – Illustration de la méthode de Hwang et al. [HOT<sup>+</sup>07]

- Tajbakhsh et al. [TGL16] (figure 1.19) proposent un moyen permettant de faire la détection automatique des polypes en coloscopie en utilisant les informations de formes et de contexte. L’information de contexte permet de réduire les structures

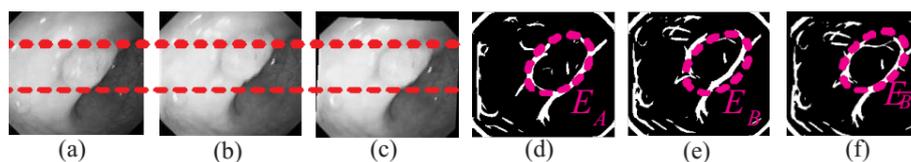


FIGURE 1.18 – Résultat de la méthode de Hwang et al. [HOT<sup>+</sup>07], (a) image en cours, (b) image suivante, (c) image précédente, (d) carte binaire de (a), (e) carte binaire de (b), (f) carte binaire de (c), avec la localisation du polype

ne contenant pas de polypes afin de localiser de manière fiable les polypes. Pour y arriver, ils obtiennent une carte brute des contours, puis ils retirent les contours des zones sans polypes, et finissent par localiser le polype grâce à des scores de probabilités sur la carte des contours. Cette méthode permet ainsi d’obtenir un taux de détection de 88% des polypes sur des images issues de coloscopies. La figure 1.20 représente des bonnes détections de polypes dans des images de coloscopies

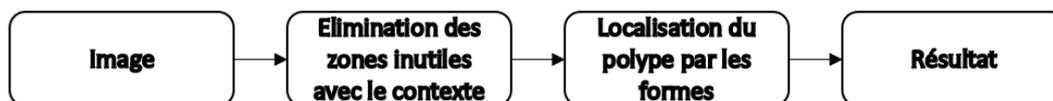


FIGURE 1.19 – Illustration de la méthode de Tajbakhsh et al. [TGL16]

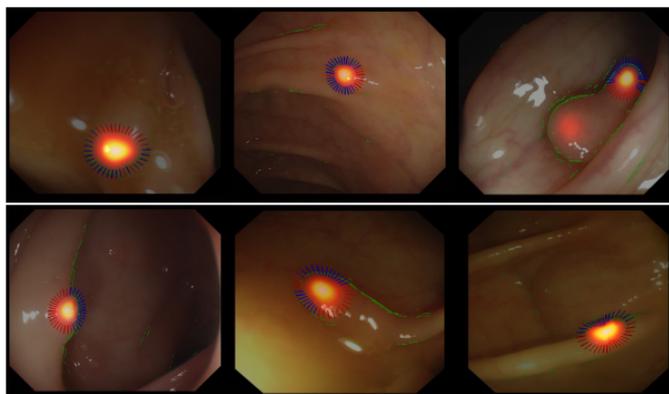


FIGURE 1.20 – Résultat de la méthode de Tajbakhsh et al. [TGL16]

- Sevo et al. [ŠAB<sup>+</sup>16] (figure 1.21) proposent de détecter les inflammations dans les vidéos d’examen coloscopiques en se basant sur la densité de bord. Ceci est basé sur une analyse de la texture. Une texture caractéristique d’un tissu enflammé est alors utilisée pour distinguer les tissus inflammatoires des tissus sains, en créant un filtre adapté. De plus, une version améliorée de cette méthode permet aussi d’éliminer les vaisseaux sanguins. Les résultats de cette méthode montrent que les régions inflammatoires peuvent être détectées en temps réel avec une précision supérieure à 84%.

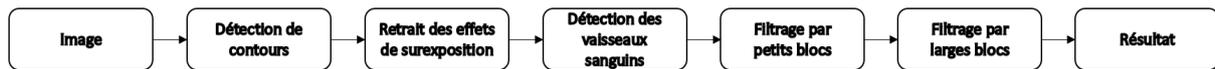


FIGURE 1.21 – Illustration de la méthode de Sevo et al. [ŠAB+16]

### Les méthodes basées sur de l'apprentissage profond

La seconde famille de méthodes est celle des méthodes basées sur l'apprentissage profond. Elle se consacre aux méthodes qui n'utilisent que l'apprentissage machine profond dans leur chaîne de traitement afin d'effectuer la détection. Dans la littérature, de nombreuses méthodes sont proposées, en voici ici les plus représentatives :

- Park et al. [PS16] (figure 1.22) proposent de détecter les polypes colorectaux en utilisant un réseau de neurones convolutif. Ils ont appliqué un modèle d'image propre pour extraire les caractéristiques représentant des polypes, des tissus normaux, et bien d'autres structures à partir de vidéos d'examens. La classification a été effectuée en utilisant un modèle de champ aléatoire conditionnel. Puis, ils remplacent les descripteurs de caractéristiques d'image propre avec des fonctionnalités d'un réseau de neurones convolutif. L'utilisation du réseau de neurones montre une plus grande robustesse concernant la prise de vue autour du polype. De plus, ils obtiennent de bons résultats en terme de sensibilité et de spécificité (plus de 85%). La figure 1.23 montre le résultat d'une détection sur une image.

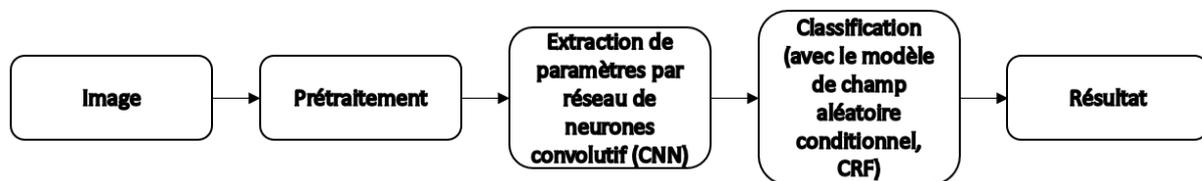


FIGURE 1.22 – Illustration de la méthode de Park et al. [PS16]

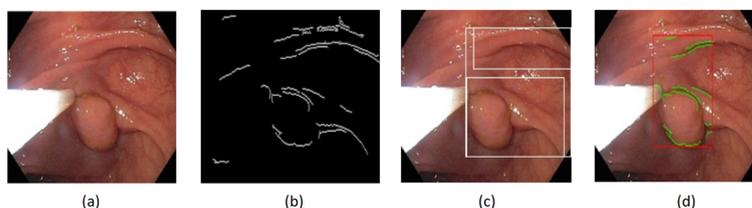


FIGURE 1.23 – Résultat de la méthode de Park et al. [PS16], (a) image de vidéo, (b) détection des contours, (c) projection de fenêtres, (d) résultat de la classification CRF

- Ribeiro et al. [RUH16] (figure 1.24), eux aussi, utilisent les réseaux de neurones convolutifs pour effectuer la classification des polypes colorectaux. Pour y parvenir, ils se basent sur l'extraction de paramètres de texture de l'image afin d'en effectuer la classification. Afin de rendre la classification d'autant plus efficace, ils décident d'utiliser non pas les images normales pour effectuer l'apprentissage, mais

des patches afin d'augmenter la quantité de données pour apprendre. Leur méthode permet d'atteindre une précision de 90% concernant la classification des polypes.

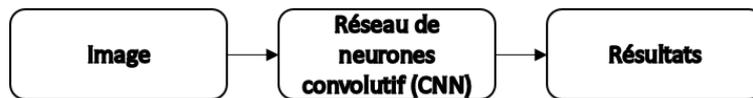


FIGURE 1.24 – Illustration de la méthode de Ribeiro et al. [RUH16]

### Les méthodes hybrides

Puis pour finir, il existe les méthodes hybrides, ces méthodes combinent principalement différents paramètres (texture, forme, contexte...) pour détecter des régions d'intérêt avec de l'apprentissage machine afin de discriminer ces régions d'intérêt et de trouver la pathologie recherchée. Voici quelques unes des méthodes les plus représentatives qui existent à ce jour :

- Iwahori et al. [ISH<sup>+</sup>13] (figure 1.25) proposent une technique de détection des polypes en utilisant un filtre Hessian et les techniques d'apprentissage machine. Dans leur technique, le filtre Hessian est utilisé pour détecter les régions dans les images qui auraient une forme de "blob" (la forme de certains polypes). Puis une extraction des paramètres de couleurs et de contours s'en suit pour ces régions. Finalement, une machine à vecteurs de support (SVM, Support Vector Machine) est utilisée sur ces paramètres pour déterminer les possibles régions contenant un polype. Cette méthode permet d'obtenir une grande précision expérimentalement. La figure 1.26 montre le résultat de cette méthode sur une image.



FIGURE 1.25 – Illustration de la méthode d'Iwahori et al. [ISH<sup>+</sup>13]

- Silva et al. [SHR<sup>+</sup>14] (figure 1.27) ont développé une méthode permettant de détecter les polypes dans les images de capsules endoscopiques en combinant l'extraction de paramètres géométriques dans l'image et l'apprentissage machine. La détection des formes permet de créer des régions d'intérêt dans l'image. Ainsi, des paramètres de textures sont alors générés à partir de ces régions et une comparaison de ces paramètres par rapport à des résultats issus de l'apprentissage machine permet de déterminer s'il s'agit d'un polype ou non. Les résultats montrent de bons résultats en terme de sensibilité et de spécificité.

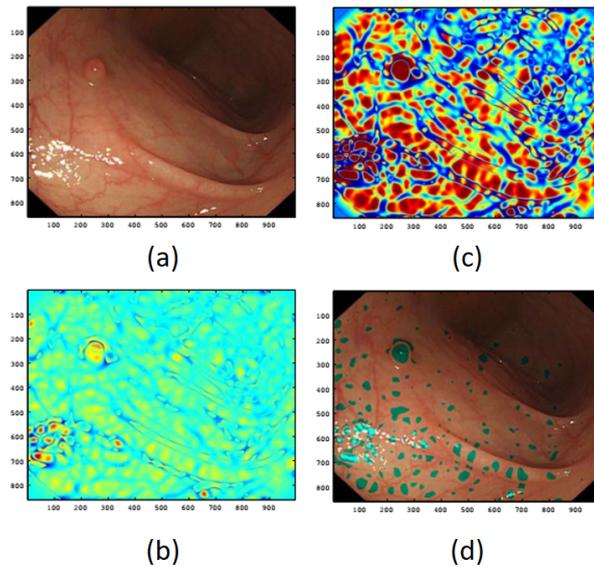


FIGURE 1.26 – Résultat de la méthode d’Iwahori et al. [ISH<sup>+</sup>13], (a) image originale, (b) image améliorée, (c) image segmentée, (d) régions candidates

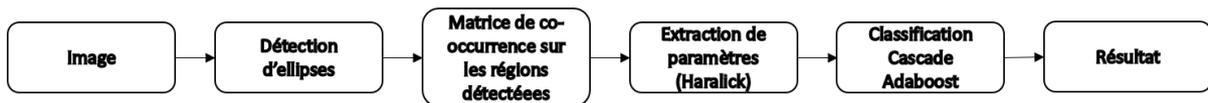


FIGURE 1.27 – Illustration de la méthode de Silva et al. [SHR<sup>+</sup>14]

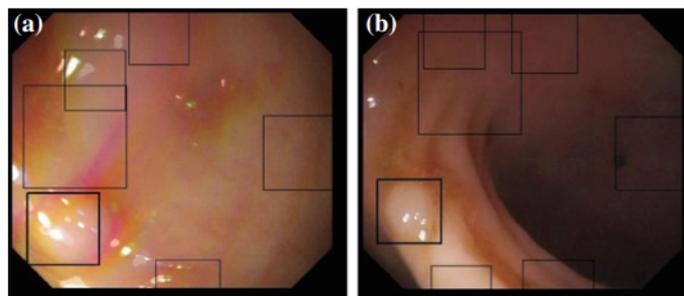
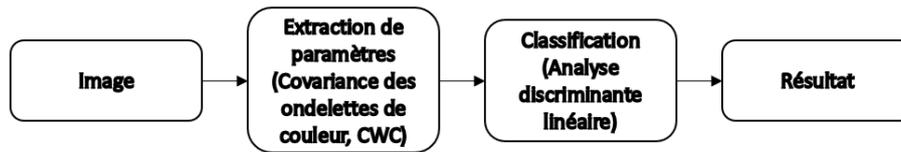
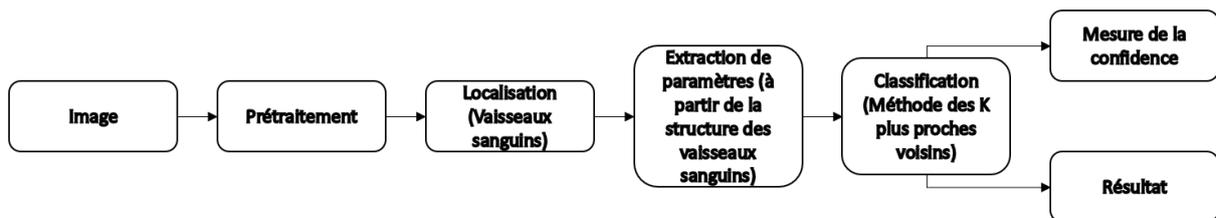


FIGURE 1.28 – Résultat de la méthode de Silva et al. [SHR<sup>+</sup>14], les rectangles noirs sont toutes les zones détectées, les rectangles noirs plus épais sont les zones classées comme possible polype

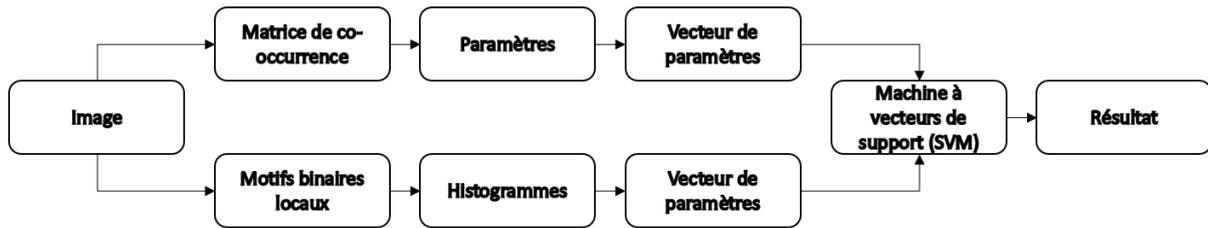
- Karkanis et al. [KIM<sup>+</sup>03] (figure 1.29) ont mis au point un outil d’aide à la détection dans les vidéos utilisant les caractéristiques des ondelettes de couleur. Ces caractéristiques sont basées sur la mesure des textures du second ordre de la covariance. Cet outil est basé sur une analyse discriminante linéaire (LDA, Linear Discriminant Analysis), méthode comparable aux méthodes d’apprentissages supervisées, afin de caractériser les différentes régions d’une image afin de détecter le polype. Cet outil propose de bons résultats en terme de spécificité et sensibilité.
- Gross et al. [GSB<sup>+</sup>09] (figure 1.30) ont développé une méthode effectuant la classifi-

FIGURE 1.29 – Illustration de la méthode de Karkanis et al. [KIM<sup>+</sup>03]

cation des polypes en se basant sur des paramètres extraits des vaisseaux sanguins. Ils proposent alors un moyen permettant de faire la différence entre un polype hyperplasique et un polype adénomateux. Pour y parvenir, une classification est effectuée sur l'extraction des paramètres relatant la structure des vaisseaux sanguins. Ils combinent la longueur de ces vaisseaux, leur périmètre moyen et la valeur de l'intensité moyen (en niveaux de gris) de ces vaisseaux. Puis en comparant les résultats de leur méthode par rapport aux LBP (Local Binary Pattern, motif binaire local en français), ils montrent que leur solution est capable de bien classer les polypes dans 90% des cas.

FIGURE 1.30 – Illustration de la méthode de Gross et al. [GSB<sup>+</sup>09]

- Ameling et al. [AWP<sup>+</sup>09] (figure 1.31), proposent une méthode de détection des polypes basée sur la texture. Analyser la texture passe par l'extraction de paramètres dédiés, en l'occurrence ici les paramètres d'Haralick issus de la matrice de cooccurrence en niveaux de gris (GLCM, Grey Level Cooccurrence Matrix) et les motifs binaires locaux (LBP, Local Binary Pattern). Et pour venir suppléer l'extraction de ces paramètres et ainsi détecter les polypes, les auteurs utilisent des machines à vecteurs de support (SVM). Un modèle de polype est ainsi obtenu à partir de données d'entraînement. Les résultats obtenus montrent principalement que l'analyse de la texture des images permettent d'obtenir de bonnes détections des polypes.
- Bae et al. [BY15] (figure 1.32) ont mis au point une méthode permettant de détecter les polypes en utilisant l'apprentissage déséquilibré et l'apprentissage discriminatif. Ils se sont proposés d'utiliser l'apprentissage déséquilibré en raison du déséquilibre qu'il existe dans les bases de données de polypes (entre zones positives et zones négatives). Afin d'y parvenir, dans leur processus d'apprentissage, ils créent des classificateurs faibles avec des jeux de données rééquilibrés par échantillonnage ascendant/descendant, et de générer un classificateur fort en combinant les faibles. Puis pour améliorer la discrimination entre polype et non polype, ils proposent une méthode d'apprentissage d'analyse des moindres carrés partielle. Les résultats

FIGURE 1.31 – Illustration de la méthode d’Ameling et al. [AWP<sup>+</sup>09]

montrent alors de nettes améliorations par rapport aux détecteurs classiques. La figure 1.33 montre des résultats de détections.

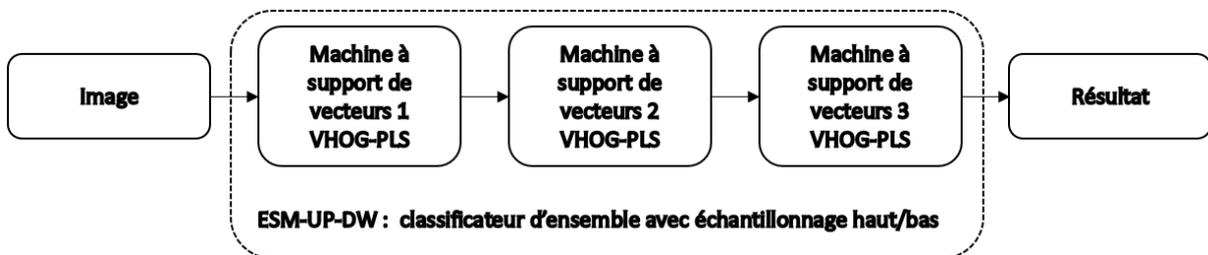


FIGURE 1.32 – Illustration de la méthode de Bae et al. [BY15]

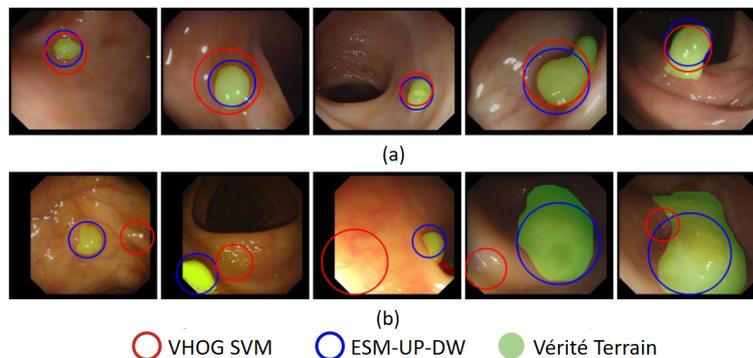


FIGURE 1.33 – Résultat de la méthode de Bae et al. [BY15], (a) cas de bonnes détections, (b) cas de mauvaises détections

Le tableau 1.1 permet de comparer les performances des différentes méthodes proposées ici. Ce tableau a pour but de montrer qu’il n’existe pas à ce jour de méthode unique pour mesurer les performances d’une approche permettant d’aider à la détection des polypes. On peut ainsi constater des informations complètement disparates. Premièrement, les données (images) utilisées pour tester les méthodes sont totalement différentes, on ne peut alors pas vraiment se rendre compte des performances d’une méthode par rapport à une autre. Deuxièmement, les métriques utilisées pour mesurer ces performances sont tout aussi différentes, il peut être alors difficile de juger si telle ou telle méthode est meilleure par rapport à une autre. Par ailleurs, aucune de ces méthodes n’a, aujourd’hui, été trans-

férée en routine clinique.

Ainsi, à la vue des résultats proposés, et afin de détecter les polypes colorectaux, il peut être intéressant de proposer une méthode se plaçant dans la famille des méthodes hybrides afin de tirer parti des avantages de l'extraction des paramètres de l'image combinée à une étape d'apprentissage machine afin de réduire le nombre de fausses détections et ainsi obtenir une méthode performante. Mais plus encore, la contrainte temps réel doit être présente dans la méthode que l'on souhaite proposer. En effet, dans l'optique de proposer un outil de détection des polypes colorectaux qui soit facilement intégrable et permettant d'assister le médecin durant l'examen et non pas à posteriori (chose qui induit un second examen si le médecin s'aperçoit qu'il a raté un polype), on se doit de proposer un outil fonctionnant sans perturber la routine clinique.

Un autre objectif apparait ici. En effet, comme il n'existe pas d'uniformité dans le protocole de mesures des performances, il serait intéressant de proposer des métriques de référence qui permettraient de mieux rendre compte des performances des outils proposés, sur des bases de données ouvertes, clairement identifiées.

Auteurs	Méthode	Données	Performances	Temps de calcul
Tajbakhsh et al. [TGL16]	AH	CVC-ColonDB	Sensibilité : 88%	2.6 s/image
Sevo et al. [ŠAB <sup>+</sup> 16]	AH	3 vidéos (6375 images)	Exactitude > 84%	13 ms/image
Bernal et al. [BSFE <sup>+</sup> 15]	AH	CVC-ClinicDB (612 images)	Exactitude : 70.26%	X
Zhu et al. [ZFL10]	AH	52 sets d'images	Sensibilité : 100%, 3.5 fausses détections par set	X
Kang et al. [KD03]	AH	X	X	1 image/s
Hwang et al. [HOT <sup>+</sup> 07]	AH	8621 images	Rappel : 96%, Précision : 84%	15 images/s
Park et al. [PS16]	AP	35 vidéos	Sensibilité : 86%, Spécificité : 85%	X
Ribeiro et al. [RUH16]	AP	100 images	Sensibilité : 95.16%, Spécificité : 74.19%	X
Ameling et al. [AWP <sup>+</sup> 09]	HY	4 heures de vidéo	Aire sous la courbe : 0.95	X
Silva et al. [SHR <sup>+</sup> 14]	HY	500 images	Sensibilité : 91%, Spécificité : 95%	37.5ms/image
Bae et al. [BY15]	HY	CVC-ColonDB + 1263 images	Rappel > 90%	0.6375 s/image
Iwahori et al. [ISH <sup>+</sup> 13]	HY	128 images	Exactitude : 96.8%, Spécificité : 98.2%, Sensibilité : 95.4%	X
Gross et al. [GSB <sup>+</sup> 09]	HY	102 images	Rappel : 90%	X
Karkanis et al. [KIM <sup>+</sup> 03]	HY	1200 images (20 images/vidéos)	Spécificité : 97%, Sensibilité : 90%	1.6 minute/vidéo

TABLE 1.1 – Tableau comparatif du panel exhaustif des méthodes existantes pour la détection des polypes colorectaux (AH = Ad-Hoc, AP = Apprentissage Profond, HY = HYbride)

## 1.2 Apprentissage machine orienté Boosting

L'apprentissage machine est donc une étape incontournable afin de mettre au point un outil pour effectuer la détection des polypes en coloscopie. Parmi toutes les méthodes d'apprentissage machine existantes, le boosting et quelques unes de ses variantes n'ont été que peu utilisées mais sont pourtant très prometteuses. En effet, le boosting est un bon compromis en termes de performances de détection, de temps de calcul et de capacité à être embarqué.

### 1.2.1 Boosting

Le boosting repose sur la combinaison de classificateurs [Sch90] [Fre95]. Il fonctionne par itérations successives, en partant de classificateurs faibles afin de construire un classificateur fort. On appelle souvent un apprenant faible un algorithme qui permet de construire un classificateur fort, dont les performances de classifications sont légèrement supérieures au hasard. Le classificateur final obtenu est une combinaison linéaire des classificateurs faibles précédents. Les exemples qui sont mal classés sont alors boostés afin d'avoir plus de poids dans la classification et donc plus d'importance par rapport à l'apprenant faible au prochain tour d'apprentissage, afin de pallier le manque.

Il existe de nombreuses méthodes de boosting, et parmi elles, la méthode de boosting adaptatif, communément appelé Adaboost. C'est grâce à cette méthode d'apprentissage que l'on va mettre au point notre outil afin d'en améliorer les performances et en particulier, la précision, tout en conservant un temps de traitement compatible avec la contrainte vidéo.

### 1.2.2 Adaboost

D'après [VJ01], l'algorithme d'apprentissage Adaboost est utilisé afin d'augmenter les performances de classification d'un algorithme d'apprentissage simple (on peut prendre l'exemple d'augmenter les performance d'un simple perceptron). Ceci est obtenu en combinant un ensemble de fonctions de classification faible afin de former un classificateur plus fort. Dans le langage du boosting, un algorithme d'apprentissage faible est appelé faible apprenant.

L'apprenant est appelé faible parce que personne ne s'attend à ce que la meilleure fonction de classification classe correctement les données d'apprentissage (c'est-à-dire pour un problème donné, le meilleur perceptron ne peut que classer les données de formation correctement que dans 51% des cas). Pour que l'apprenant faible soit stimulé, il est appelé à résoudre une séquence de problèmes d'apprentissage. Après le premier cycle d'apprentissage, les exemples sont redéfinis pour souligner ceux qui ont été mal classés par le classificateur faible précédent. Le classificateur final, dans notre exemple, prend la forme d'un perceptron construit comme une combinaison linéaire pondérée de classificateurs faibles suivie d'un seuil.

L'algorithme décrit dans le tableau 1 sert à sélectionner les classificateurs clés faibles à partir de l'ensemble des classificateurs faibles possibles. Pour que le processus AdaBoost soit assez efficace, l'ensemble de classificateurs faibles peut être fortement grand

- 
1. On considère les images d'apprentissage  $(x_1, y_1), \dots, (x_n, y_n)$  où  $y_i = 0$  pour les exemples négatifs (respectivement 1 pour les exemples positifs)
  2. On initialise les poids  $w_{1,i} = \frac{1}{2m}$  pour  $y_i = 0$  (respectivement  $w_{1,i} = \frac{1}{2l}$  pour  $y_i = 1$ ) avec  $m$  et  $l$  les nombres d'images négatives et positives
  3. Pour  $t = 1, \dots, T$  :
    - On normalise les poids  $w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$
    - On choisit le plus faible classificateur grâce à l'erreur basée sur le poids :

$$\epsilon_t = \min_{f,p,\theta} \sum_i w_i |h(x_i, f, p, \theta) - y_i|$$

où  $h(x_i, f, p, \theta)$  correspond à un classificateur faible avec un paramètre ( $f$ ), un seuil ( $\theta$ ) et une polarité ( $p$ ) qui indique la direction de l'inégalité

- On définit  $h_t(x) = h(x, f_t, p_t, \theta_t)$  où  $f_t, p_t$ , et  $\theta_t$  sont les "minimizers" de  $\epsilon_t$
- On met à jour les poids :

$$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i}$$

où  $e_i = 0$  si l'exemple  $x_i$  est classé correctement,  $e_i = 1$  sinon, et  $\beta_t = \frac{\epsilon_t}{1-\epsilon_t}$

4. Le classificateur fort final est :

$$C(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{sinon} \end{cases}$$

où  $\alpha_t = \log\left(\frac{1}{\beta_t}\right)$

---

TABLE 1.2 – Algorithme de boosting.  $T$  hypothèses sont faites en utilisant chaque paramètre. L'hypothèse finale est une combinaison linéaire pondérée des  $T$  hypothèses où les poids sont inversement proportionnels à l'erreur d'apprentissage

### 1.2.3 Cascade Adaboost

D'après [VJ04], l'algorithme utilisant une cascade de classificateurs permet de réaliser de meilleures détections tout en réduisant le temps de calcul. L'essentiel dans cet algorithme est qu'il utilise des classificateurs plus efficaces qui rejettent une bonne partie des sous-fenêtres négatives tout en détectant la quasi totalité des zones positives dès les premiers étages de la cascade. Les classificateurs plus simples sont utilisés pour rejeter la majorité des sous-fenêtres avant que des classificateurs plus complexes ne soient appelés à obtenir des faibles taux de faux positifs.

Les étages de la cascade sont construits en entraînant des classificateurs avec l'apprentissage Adaboost.

La forme globale du processus de détection est celui d'un arbre de décision, qui est appelé "cascade" (voir figure 1.34) [Quinlan, 1986]. Un résultat positif du premier classificateur engage l'évaluation à travers le second classificateur qui a été aussi ajusté afin d'avoir un fort taux de détection. Un résultat positif du second classificateur va engager l'évaluation à travers le troisième classificateur, et ainsi de suite. Cependant, un résultat négatif à la sortie de n'importe lequel des classificateurs va entraîner le retrait immédiat de la cascade de la sous-fenêtre traitée. La structure de la cascade reflète donc le fait que parmi n'importe quelle image, une majorité de sous-fenêtres sont négatives. La cascade tente de rejeter autant d'éléments négatifs que possible et en le faisant le plus tôt possible dans les étages de la cascade. Bien qu'une instance positive déclenche l'évaluation de chaque classificateur dans la cascade, il s'agit d'un événement extrêmement rare. Plus comme les arbres de décisions, les classificateurs suivants sont entraînés en utilisant les exemples qui ont réussi à passer à travers les étages précédents. Il en découle alors que le second classificateur fait face à une tâche plus difficile que le premier classificateur. L'exemple qui arrive à passer le premier étage est théoriquement plus compliqué à déterminer que des exemples typiques.

En pratique, un framework simple est utilisé pour construire un classificateur à la fois efficace et efficient. L'utilisateur doit sélectionner le taux maximum acceptable de fausses alarmes par étage et le taux minimum de détection acceptable par étage. Chaque étage de la cascade est entraînée en utilisant la technique Adaboost dont le nombre de paramètres utilisés augmente tant que les taux cibles de fausses alarmes et de détection acceptable sont atteints pour l'étage en cours d'apprentissage. Ces taux sont déterminés en testant le détecteur courant sur un set de données de validation. Si le taux global de fausses détections n'est toujours pas atteint, alors un nouvel étage est ajouté à la cascade. Le set de données d'exemples négatifs pour entraîner les étages suivants est obtenu en collectant toutes les fausses détections en testant le détecteur courant sur un set d'image qui ne contient aucune instance des choses à détecter. Ce framework est disponible dans le tableau 1.3. L'application la plus connue de ce framework est la détection des visages dans les images, qui est illustré par la figure 1.35.

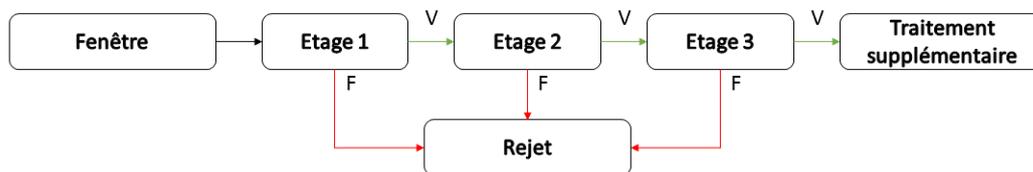


FIGURE 1.34 – Illustration du principe de détection Cascade Adaboost

### 1.3 Conclusion

On a pu voir dans cette partie les moyens mis en place (matériels ou logiciels) permettant d'aider le médecin dans l'amélioration de ses capacités à mieux détecter les polypes

- 
1. L'utilisateur choisit des valeurs pour  $f$  (Le taux maximum acceptable de fausses alarmes par étage) et  $d$  (le taux minimum de détection acceptable par étage)
  2. L'utilisateur choisit aussi le taux cible de fausses détections total  $F_{target}$
  3.  $P$  = set d'exemples positifs
  4.  $N$  = set d'exemples négatifs
  5.  $F_0 = 1.0$ ,  $D_0 = 1.0$
  6.  $i = 0$
  7. Tant que  $F_i > F_{target}$ 
    - $i \leftarrow i + 1$
    - $n_i = 0$ ,  $F_i = F_{i-1}$
    - Tant que  $F_i > f \times F_{i-1}$ 
      - $n_i \leftarrow n_i + 1$
      - On utilise  $P$  et  $N$  pour entrainer un classificateur avec  $n_i$  paramètres en utilisant l'Adaboost
      - On évolue le classificateur cascade actuel avec un set de validation pour déterminer  $F_i$  et  $D_i$
      - On baisse le seuil pour le  $i^{\text{ème}}$  classificateur tant que le classificateur cascade actuel a un taux de détection d'au moins  $d \times D_{i-1}$  (qui affecte aussi  $F_i$ )
    - $N \leftarrow \emptyset$
    - Si  $F_i > F_{target}$  alors on évalue le détecteur cascade actuel sur un set d'images négatives et en mettant toutes les fausses détections dans le set  $N$
- 

TABLE 1.3 – Framework d'apprentissage Cascade Adaboost pour obtenir un détecteur cascade

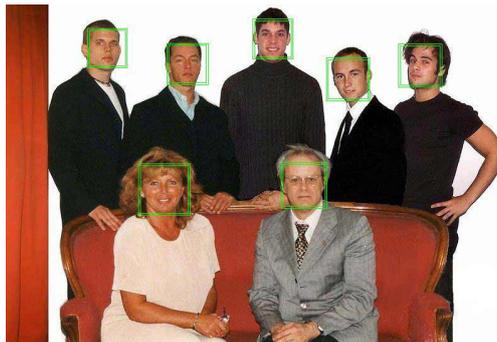


FIGURE 1.35 – Illustration du résultat de la détection Cascade Adaboost (Source : OpenCV Docs)

lors d'un examen de coloscopie. Malgré les solutions matérielles proposées, on a pu s'apercevoir que la coloscopie classique reste l'examen de référence et que peu, voire aucune, de ces optimisations ne sont utilisées actuellement en routine clinique. Cela a donc donné naissance à de nouveaux outils d'aide à la détection assistée par ordinateur, qui ont pour

but de s'adapter à la coloscopie classique. C'est donc pour cela qu'il peut être intéressant de proposer un tel outil qui sera susceptible d'intéresser les médecins s'il propose des performances acceptables tout en ne modifiant pas le déroulé de l'examen (on pourrait ici parlé d'une méthode user friendly).

Si on souhaite mettre au point un outil permettant d'aider les médecins à réduire le taux de polypes manqués, il faut alors proposer un système d'aide à la détection assistée par ordinateur, car il s'agit d'un outil que les praticiens pourront utiliser plus facilement dans le cadre de l'examen. De plus, parmi les 3 familles de méthodes, seule la famille des méthodes hybrides est la plus adaptée. En effet, cette famille propose de bonnes performances de détection associées à des temps de calcul pouvant s'approcher du temps réel. Cela répond en effet à plusieurs contraintes que l'on s'est fixées, qui sont l'aspect temps réel et les bonnes performances de détection.

Par la suite, il est proposé de mettre au point des méthodes hybrides qui vont permettre de détecter les polypes dans les images issues de coloscopies. L'utilisation de l'apprentissage machine, et précisément l'utilisation de la méthode de Viola et Jones, méthode dont les performances en termes de temps de calcul sont plus qu'intéressantes, va être plus qu'incontournable dans la mise au point de notre outil.