

Mise en œuvre et expérimentations

Dans ce chapitre, nous présentons les différents tests que nous avons mis en place pour évaluer la performance et la précision de :

- notre algorithme d'apprentissage incrémental parallèle ;
- nos algorithmes d'évaluation de dépôt de dose.

La première partie de ce chapitre a pour rôle de présenter nos résultats pour les réseaux de neurones. Nous débutons par l'illustration des performances de notre algorithme incrémental en réalisant un comparatif avec d'autres algorithmes d'apprentissage. La suite de cette section présente l'influence des différents paramètres liés à l'apprentissage incrémental parallèle.

La deuxième partie de ce chapitre présente quant à elle, les performances de notre algorithme d'évaluation de dépôt de dose. Afin de montrer la précision générale de nos travaux, nous mettons en valeur, par un test spécifique, chacune des solutions apportées.

5.1 Évaluation de l'algorithme d'apprentissage

L'objectif de cette partie est de détailler les caractéristiques de notre algorithme d'apprentissage. Dans une première partie nous établissons une comparaison entre deux algorithmes classiques d'apprentissage pour la réalisation de perceptrons multicouches : l'algorithme d'apprentissage en cascade et l'algorithme de construction incrémentale proposé par Dunkin et al. La seconde partie porte sur une étude des performances de ces algorithmes dans le domaine applicatif de la radiothérapie externe. Enfin la dernière partie de cette section détaille l'influence des différents paramètres sur le déroulement et les performances de l'apprentissage incrémental en parallèle.

5.1.1 Étude de l'algorithme d'apprentissage incrémental

Test sur une fonction classique

La première fonction utilisée pour comparer notre algorithme d'apprentissage est une fonction classique qui est régulièrement utilisée dans la littérature. Cette fonction, présentée à la figure 5.1, est de la forme suivante :

$$f(x, y) = (\exp(\cos(4 * (x + y))))/2 \quad (5.1)$$

Pour évaluer la qualité de l'apprentissage, nous avons présenté au réseau de neurones différents ensembles de tailles différentes. L'objectif est de voir l'influence de la taille de l'ensemble des données sur la qualité de l'apprentissage. Nous avons donc réalisé dix apprentissages à l'aide d'ensembles contenant respectivement 20, 30, 40, 50, 60, 70, 80, 90, 100 et 125 points distribués sur l'intervalle $[0, 1]^2$. Ces points sont pour la majorité d'entre eux uniformément distribués sur le domaine d'apprentissage (en utilisant la racine carrée du nombre de points), le reste étant placé aléatoirement. Pour chaque test, le seuil d'apprentissage est fixé à une précision de 1.10^{-4} .

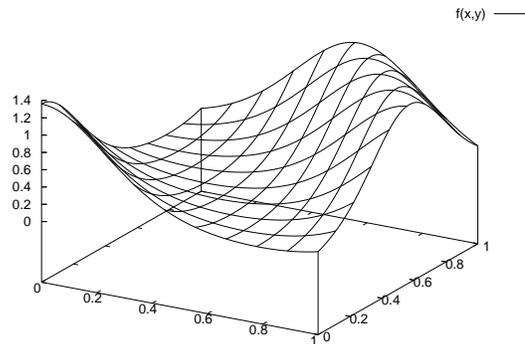


FIG. 5.1 – Présentation de la fonction classique utilisée pour l'apprentissage

Ensuite, sur tous les réseaux entraînés, nous avons calculé la racine carrée de l'erreur (TSE ¹) sur un ensemble de 25 points choisis aléatoirement sur le domaine de la fonction approchée. L'objectif de ce test est de vérifier la propriété de généralisation du réseau de neurones. Les résultats sont donnés dans la figure 5.2 dans laquelle la TSE est tracée en fonction de la taille de l'ensemble de données pour chaque méthode d'apprentissage. Ces résultats représentent une moyenne de 10 apprentissages successifs pour chaque algorithme. Il est possible de voir que l'algorithme de Dunkin ainsi que celui que nous avons proposé présentent le même comportement. Les deux sont nettement plus performants que l'algorithme d'apprentissage en cascade. Toutefois, le comportement de notre algorithme est légèrement plus oscillant que celui proposé par Dunkin, tout en conservant la

¹Total Squared Error

même décroissance générale, ce qui est le plus important, puisque notre algorithme doit être utilisé avec des ensembles de données de grandes tailles.

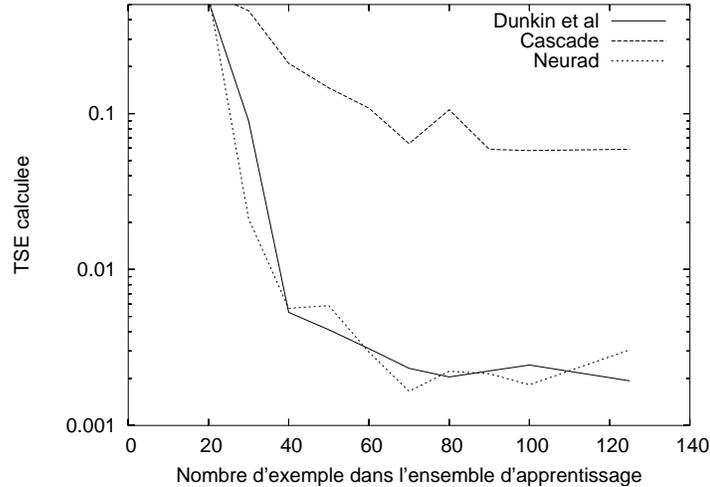


FIG. 5.2 – TSE en fonction de la taille d'apprentissage

Application à la radiothérapie

Toujours dans le but de présenter les avantages de notre algorithme, cette section présente une comparaison entre l'algorithme de Dunkin et le nôtre en se basant sur un apprentissage lié à notre domaine d'application : la radiothérapie externe.

Ce comparatif est construit en se basant sur un ensemble d'apprentissage provenant du résultat d'une irradiation d'un volume se situant dans l'alignement de la tête d'irradiation, schématisé dans la figure 5.3 (gauche). La structure de données utilisée pour représenter le domaine d'apprentissage est une grille de discrétisation à deux dimensions, permettant d'enregistrer la valeur de la dose déposée à chaque position discrète. Un exemple de courbe de distribution de dose est donné à la figure 5.3 (droite) pour une irradiation d'un volume entièrement composé d'eau. De tels résultats peuvent être obtenus soit directement par des mesures physiques, soit à l'aide d'un simulateur. Ceux-ci ont été établis à l'aide du simulateur BeamNrc [7] basé sur les techniques de Monte Carlo.

L'ensemble d'apprentissage utilisé pour réaliser notre comparaison est donc composé de deux courbes distinctes de dépôt de doses ; la première étant le résultat d'une irradiation d'un volume d'eau, la seconde étant le résultat de la même irradiation mais cette fois-ci pour un volume composé de titane². Cet ensemble d'apprentissage est représenté à la figure 5.4. On peut voir que les principales différences entre ces deux courbes se situent sur l'inclinaison de la pente de la courbe en profondeur et également sur la valeur du point maximum pris par chacune des courbes. Cet ensemble est constitué de 40 000 points au total (20 000 points par courbes) uniformément distribués sur le domaine d'apprentissage.

²le choix du titane a été fait car cette matière est couramment utilisée lors de la réalisation de prothèses de hanche

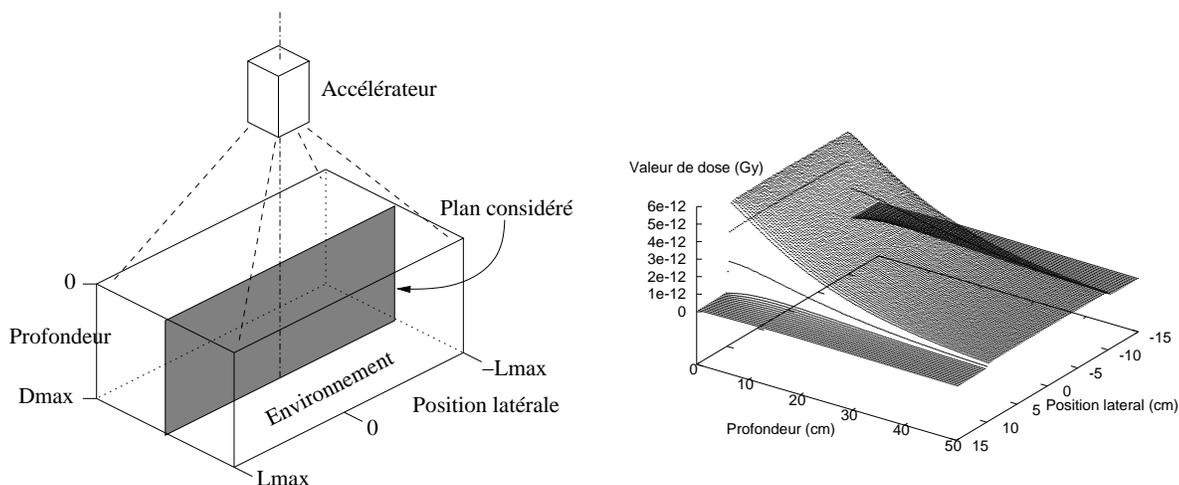


FIG. 5.3 – Localisation de la zone d'intérêt (gauche). Distribution de doses pour un milieu homogène d'eau (droite)

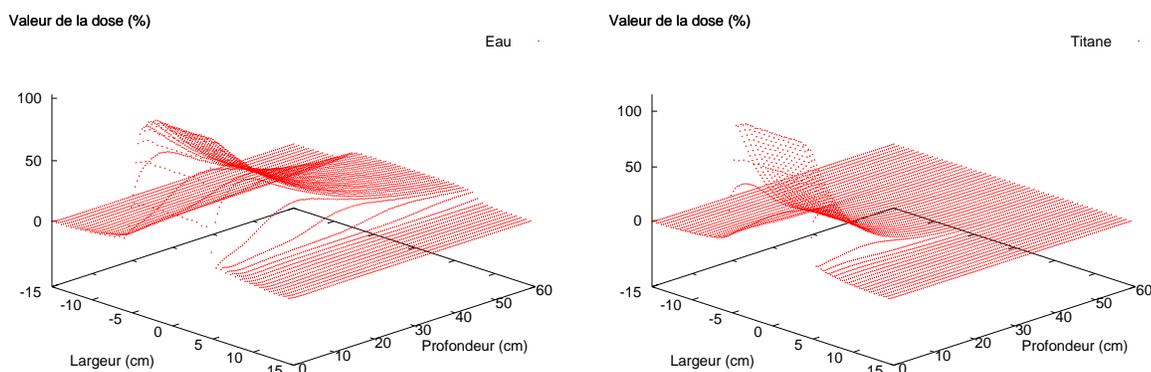


FIG. 5.4 – L'ensemble d'apprentissage composé de deux courbes de distributions de doses.

Les résultats de l'algorithme de Dunkin et ceux de notre algorithme sont présentés dans le tableau 5.1. Les résultats de l'algorithme en cascade ne sont pas présentés car celui-ci nécessite un temps avant convergence beaucoup plus important que les deux autres. De plus, au vu de son comportement lors du test précédent, il ne semble pas qu'il puisse obtenir de bons résultats. C'est pourquoi nous ne réalisons une comparaison qu'entre les deux autres algorithmes d'apprentissage.

Il peut être remarqué que le temps d'apprentissage ainsi que la taille finale de notre architecture est plus important que pour l'algorithme de Dunkin. L'augmentation du temps d'apprentissage vient en réalité du fait que dans notre algorithme, tous les poids des différents neurones peuvent être modifiés à chaque pas d'apprentissage. Cette méthode implique un nombre plus important de calculs par pas d'apprentissage, et donc, un temps d'apprentissage plus important. Concernant la taille du réseau de neurones, notre algorithme ne semble pas être optimal. Toutefois, il est relativement difficile d'interpréter de

	Dunkin et al	notre algorithme	Comparatif
Temps d'apprentissage	17h54s	19h13	+1h19
Neurones cachées	37	50	+13
Déviations (%)	0,66	0,032	négligeable
Écart min (%)	$2,7e - 4$	$1,3e - 5$	/ 20
Écart max (%)	429,9	179,9	/ 2,4
Écart moyen(%)	4,03	1,38	/ 2,92

TAB. 5.1 – Comparatif sur les résultats des deux algorithmes d'apprentissage appliqués à la radiothérapie

tels résultats alors que l'architecture du réseau est directement en lien avec la précision globale du réseau. Ainsi, si l'algorithme de Dunkin atteignait la même précision finale que le nôtre, il est sûr que son architecture serait un avantage par rapport à notre algorithme, mais dans ce cas, notre défaut d'architecture est comblé par notre performance concernant la précision d'apprentissage.

En analysant les résultats, on peut voir que notre algorithme a une plus grande performance sur l'ensemble des critères. Même si l'erreur moyenne est le critère le plus avantageux pour notre algorithme, il est aussi intéressant de remarquer que la valeur de biais, ainsi que les valeurs minimales et maximales des erreurs sont à notre avantage. Ceci est très important car le critère seul de l'erreur moyenne n'est pas suffisant pour garantir une bonne approximation de fonction. C'est pourquoi, nous pouvons dire que notre algorithme produit actuellement un très bon réseau pour l'approximation de fonctions. Ce point est confirmé par l'aspect global des courbes obtenues avec chacun des réseaux résultants. Ces courbes sont présentées dans la figure 5.5 et on peut voir que la courbe issue du réseau "Dunkin" présente des oscillations non désirées à sa surface et que celles-ci ne sont pas présentes sur la courbe issue de notre réseau.

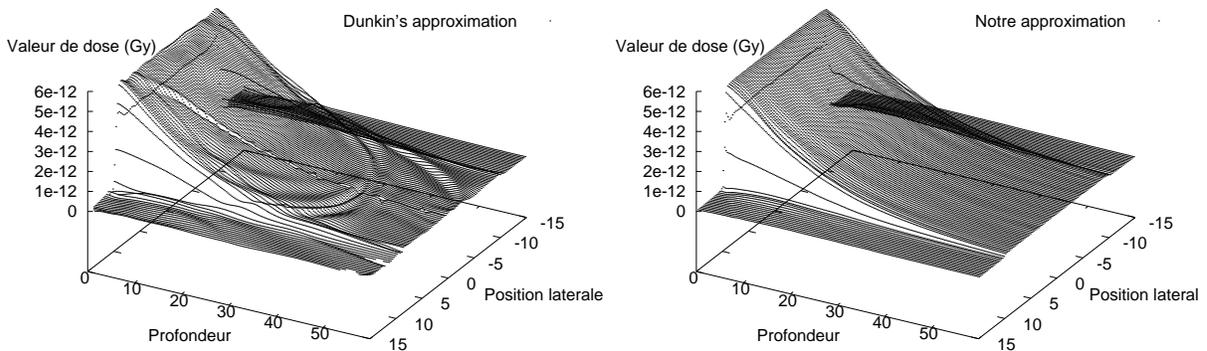


FIG. 5.5 – Approximation à l'aide du réseau "Dunkin" (gauche). Approximation à l'aide de notre algorithme (droite).

5.1.2 Étude de la version parallélisée

Influence du taux de recouvrement

Ce premier test porte sur l'étude de l'impact du recouvrement sur la précision d'apprentissage. Pour valider ce test nous avons utilisé un domaine d'apprentissage ne contenant qu'une seule courbe de dépôt de doses. Tout l'intérêt est de montrer l'influence de ce paramètre sur la gestion des zones limites entre les sous-réseaux de neurones. Nous avons donc utilisé une configuration de décomposition en trois parties pour les dimensions propres au positionnement latéral et en profondeur.

Taux recouvrement (%)	0	5	7	10	50
Écart (%)	2,86	2,38	2,37	2,37	2,45
Déviations (%)	2,28	1,86	1,82	1,83	1,85

TAB. 5.2 – Influence du taux de recouvrement sur la précision d'apprentissage

Les résultats de ce premier test sont présentés dans le tableau 5.2. Ce tableau représente l'écart obtenu sur l'étude d'un milieu homogène composé d'eau entre les données de référence et celle calculées à l'aide du réseau de neurones. Comme il est possible de le voir, l'augmentation du taux de recouvrement permet d'améliorer dans un premier temps l'écart du réseau de neurones. Mais, cette amélioration de la gestion des interfaces entre milieux est ensuite atténuée par l'augmentation importante des domaines d'apprentissage. Le fait d'augmenter la taille du domaine d'apprentissage, augmente en proportion équivalente le degré de complexité de ce domaine. Ce premier test permet donc de montrer que la mise en place du recouvrement est indispensable afin de garantir les performances de notre algorithme d'apprentissage. Il est toutefois important de noter que le choix du taux de recouvrement ne peut être fait sans une étude de performance préalable.

Influence de la décomposition du domaine d'apprentissage

Pour réaliser cette série d'apprentissages, nous avons utilisé un ensemble de données obtenu à l'aide du simulateur BeamNrc s'appuyant sur les techniques de Monte Carlo. Le jeu de données représente les résultats d'irradiation d'une cuve d'eau en utilisant trois valeurs différentes (98, 100 et 102 cm) pour la distance entre la source et la surface d'entrée dans le milieu. Cet ensemble est donc composé de cinq paramètres d'entrée (trois pour le positionnement du point, la densité, et la distance de la cuve à la source) et d'un paramètre de sortie, la valeur de l'énergie déposée. Il est composé de 1 500 000 points.

Tout l'intérêt de ce test est de montrer que la parallélisation de l'apprentissage ne réduit pas la précision globale, et que, de plus, elle apporte un gain important sur la durée d'apprentissage. Les résultats de ce test sont disponibles dans le tableau 5.3. Ce tableau montre l'évolution des performances de notre algorithme parallèle d'apprentissage en fonction de la décomposition du domaine d'apprentissage. Cette décomposition porte uniquement sur les paramètres d'entrée correspondant au positionnement spatial.

La configuration de l'apprentissage utilisée pour réaliser cette série de test privilégie la vitesse d'apprentissage à la précision finale. Cette configuration se traduit en favorisant

Discrétisation	1×1×1	2×1×2	2×2×2	3×1×3	3×2×3	3×3×3
Erreur moy ($\times 10^{-4}$)	6,20	1,57	1,0	1,63	1,0	1,01
Erreur min ($\times 10^{-5}$)	62	9,99	9,99	9,99	9,99	9,99
Erreur Max ($\times 10^{-4}$)	6,20	2,3	1,01	4,97	1,01	1,23
Temps min	4h34	4h06	0h54	1h11	0h04	0h03
Temps max	4h34	8h10	3h25	5h59	3h47	1h42
Taux Convergence(%)	0	25	33	62	66	92

TAB. 5.3 – Influence de la décomposition de domaine sur l'apprentissage

l'ajout de nouveaux neurones sur la couche cachée en diminuant la période sur laquelle la performance de l'apprentissage est étudiée. Le taux de recouvrement choisi pour ce test correspond à celui présentant les meilleurs résultats au test précédent, c'est à dire 7 %.

La première série d'indicateurs étudiés porte sur l'erreur finale obtenue par les différents sous-réseaux. Il est possible de voir que la décomposition de l'ensemble des différentes entrées permet de faciliter la convergence globale du processus d'apprentissage, et que dès que le domaine d'apprentissage est découpé sur l'ensemble de ses dimensions, l'apprentissage converge au niveau global, c'est à dire que l'erreur obtenue correspond à l'erreur souhaitée. Le taux de convergence sur chacun des sous-réseaux s'améliore aussi en conséquence pour atteindre un taux supérieur à 90% lorsque chacune des dimensions est décomposée en 3. Le taux de convergence correspond au nombre de sous-réseaux ayant convergé par rapport au nombre total de sous-réseaux composant le réseau global.

La seconde partie des paramètres étudiés porte sur le temps nécessaire à l'apprentissage d'un sous-réseau. Du fait de la grande taille de l'ensemble d'apprentissage, les premiers essais utilisant des ensembles de grande taille ont des taux de convergence faibles. De fait le premier test ayant un temps relativement faible ne correspond pas à l'obtention d'un réseau correctement entraîné. Il est à noter que comme les différents apprentissages sont réalisés en parallèle, le temps maximum nécessaire pour réaliser un entraînement correspond au temps global d'apprentissage. Ces résultats montrent donc bien que la discrétisation permet de réduire de manière importante le temps d'apprentissage.

Influence de la décomposition sur la réactivité du réseau

Le dernier test de cette version parallélisée est de montrer l'influence de la parallélisation sur le temps de réponse du réseau de neurones. Pour montrer cette influence nous avons testé la différence de temps de réponse des réseaux sur le même domaine d'apprentissage. Les points testés sont uniformément répartis sur l'ensemble du domaine applicatif.

Pour évaluer cette influence, nous avons construit une série de réseaux de neurones couvrant un important intervalle de parallélisation, de 1 à 5 découpages sur les dimensions \vec{x} et \vec{z} . À l'aide de ces réseaux, nous avons effectué trente évaluations successives dans un milieu homogène d'eau de dimension $100 \times 1 \times 200$. La seule différence entre ces différentes exécutions porte sur le niveau de décomposition du domaine d'apprentissage, c'est à dire

sur le nombre de sous-réseaux composant le méta-réseau complet. Ce nombre de sous-réseaux varie de 1, lorsqu'il n'y a aucune décomposition du domaine, à 25, quand les axes, \vec{x} et \vec{z} sont découpés en 5 parties.

y : x	1	2	3	4	5
1	2,53	2,5	2,53	2,53	2,53
2	2,53	2,5	2,53	2,53	2,53
3	2,53	2,53	2,53	2,53	2,53
4	2,53	2,57	2,53	2,57	2,57
5	2,53	2,57	2,53	2,53	2,6

TAB. 5.4 – Influence de la décomposition du domaine d'apprentissage sur la vitesse d'évaluation (temps en secondes)

Comme il est possible de le voir dans le tableau 5.4 présentant le temps d'évaluation d'un milieu homogène en fonction du nombre de sous-réseaux, ce paramètre n'est pas réellement influant sur le temps de réaction du réseau de neurones. Quel que soit le nombre de sous-réseaux, le temps d'évaluation reste constant aux alentours de 2,5 secondes. Ce peu d'influence s'explique par la grande efficacité du mécanisme mis en place pour le choix du réseau, et aussi, par le fait que le temps nécessaire à l'évaluation du choix du sous-réseau est négligeable devant le calcul du résultat du sous-réseau.

5.2 Évaluation des algorithmes de reconstruction de doses

Cette partie a pour objectif de montrer les performances de notre algorithme d'évaluation des doses. La première partie de cette évaluation a été réalisée dans la section précédente quand nous avons montré les capacités d'apprentissage de notre réseau de neurones appliqué à la radiothérapie externe. Pour réaliser cette évaluation, nous avons utilisé notre algorithme d'évaluation des doses. Vu que le milieu étudié est homogène, seule la partie concernant le positionnement des différents voxels a été validée, il reste donc dans cette partie à présenter les résultats concernant l'évaluation de chacune des deux situations caractéristiques que sont la gestion des interfaces longitudinales et celle des interfaces latérales.

5.2.1 Évaluation qualitative

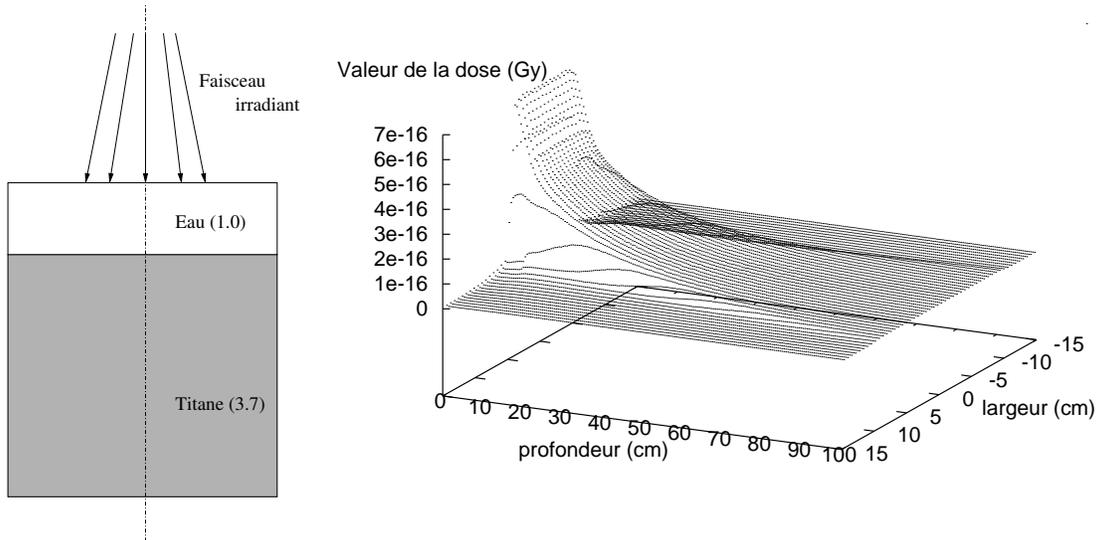


FIG. 5.6 – Étude de l'algorithme de gestion des interfaces en profondeur

Trois cas présentant l'ensemble des hétérogénéités existantes sont testés. Ces trois différents milieux sont composés d'eau et de titane. L'eau, possédant une densité de 1, est choisie car c'est l'élément majoritaire entrant dans la composition du corps humain. Le titane est choisi, comme il a déjà été mentionné, car il entre dans la composition de prothèses humaines. De plus, l'intérêt de choisir ces deux matières et qu'elles présentent une grande différence de densité ce qui amplifie les changements de valeur de doses aux interfaces, et représente un cas des plus complexes dans la mise au point de notre algorithme d'évaluation de doses.

Environnement testé	déviaton (%)	Ecart (%)
Milieu homogène d'eau	0,02	0,76
Interface en profondeur	-1,46	1,85
Interface latérale	-0,15	1,48
Milieu complexe	1,32	2,87

TAB. 5.5 – Déviaton et écart de notre algorithme en pourcent par rapport aux courbes de référence

Le premier environnement contient uniquement une interface longitudinale comme il est présenté dans la figure 5.6. Le milieu est donc composé d'une première partie en eau, suivie pour le reste du milieu de titane. Dans une voie analogue, le second environnement étudié est composé de deux matières juxtaposées dans l'axe du faisceau irradiant. Ce second milieu permet d'évaluer notre algorithme dans une situation d'interface latérale. Finalement, le troisième milieu étudié est plus complexe que les deux précédents car il a pour objectif de nous permettre l'évaluation de la combinaison des deux types d'interfaces. Ce dernier milieu, présenté à la figure 5.7, correspond à l'évaluation d'une irradiation d'une cuve d'eau où est plongé un cylindre de titane (voir le résultat à la figure 5.8).

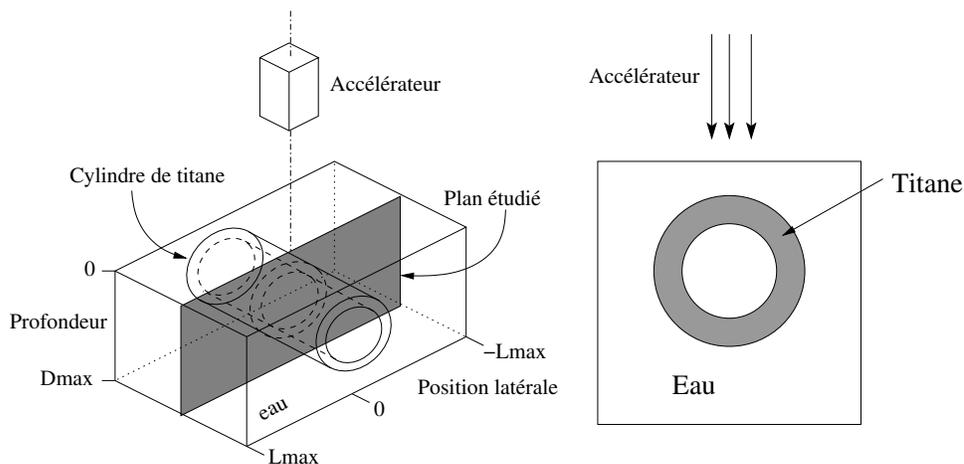


FIG. 5.7 – Étude d'un milieu complexe, un cylindre de titane, plongé dans une cuve d'eau

Les résultats qualitatifs de nos tests sont présentés dans le tableau 5.5. Pour chacun des tests, nous avons évalué la valeur de biais, cette valeur correspond à la moyenne de la déviaton entre les valeurs données par notre algorithme et celles issues de simulation Monte Carlo. Pour la seconde valeur, nous avons utilisé les mêmes valeurs de référence pour calculer l'écart. Cette valeur d'écart renseigne sur la précision globale de notre algorithme. Ces valeurs d'erreur sont calculées sur la zone représentative du faisceau, correspondant aux zones se trouvant sous l'influence directe du rayon.

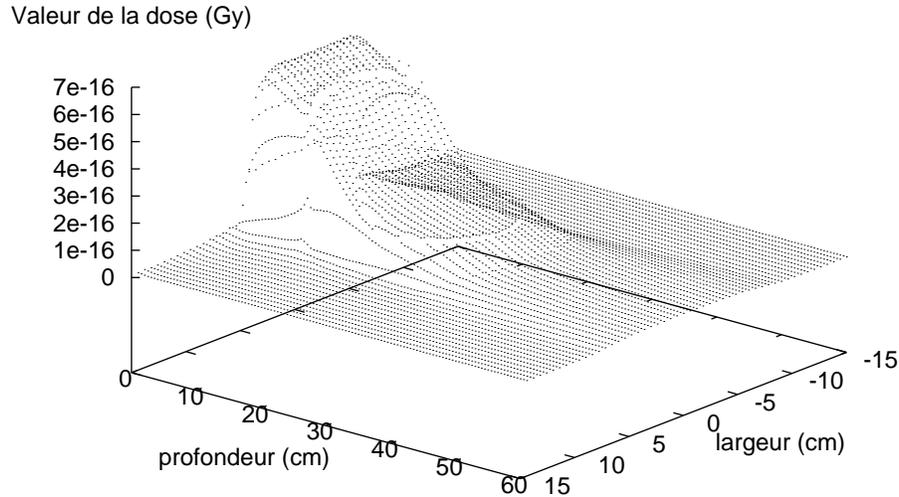


FIG. 5.8 – Résultat de l'irradiation du cylindre

Il peut être remarqué que les réseaux utilisés pour cette évaluation ont une très grande précision et une valeur de biais négligeable. L'écart moyen sur le milieu homogène d'eau est inférieur à un pourcent. Les résultats pour les évaluations des autres milieux montrent que nous obtenons un écart toujours inférieur à trois pourcents. Nous rappelons que l'écart maximum toléré dans le domaine médical pour ce type d'application est de l'ordre de cinq pourcents.

5.2.2 Évaluation quantitative

Environnement testé	Temps (en s)
Milieu homogène d'eau	2,0 s
Interface en profondeur	12 s
Interface latérale	1,8 s
Milieu complexe	47 s

TAB. 5.6 – Évaluation quantitative de l'algorithme d'évaluation des doses sur différents milieux.

Comme il a déjà été mentionné, le calcul des courbes de doses à l'aide des méthodes de Monte Carlo prend un temps très important, généralement de l'ordre de la journée. L'algorithme d'évaluation de dose est développé en C++ standard. L'évaluation de cet algorithme est réalisée sur une simple machine de travail de type Pentium IV 3.6 GZ avec 1Go de Ram utilisant le système d'exploitation Linux. Le temps moyen pour calculer une

courbe de rendement en deux dimensions est de l'ordre de 2s pour les milieux homogènes et de 47s maximum pour le milieu complexe.

L'ensemble des résultats est disponible dans le tableau précédent. On peut voir dans ce tableau que le temps nécessaire à réaliser l'évaluation d'un milieu ne présentant qu'une interface latérale est très inférieur à l'évaluation d'un milieu possédant une interface en profondeur. Ceci s'explique par le fait que les interfaces latérales ne sont pas encore gérées par notre algorithme. Enfin, on peut dire que même pour le type de milieu le plus complexe que nous avons testé, les temps de calcul restent très courts.

Conclusions et Perspectives

Conclusion

Les travaux présentés dans ce mémoire concernent les réalisations que j'ai effectuées au cours de ma thèse. Ce travail a porté dans un premier temps sur la mise au point d'algorithmes d'apprentissage de réseaux de neurones utilisés en tant qu'interpolateurs de fonction dans le domaine applicatif qu'est la radiothérapie externe. L'objectif de cet algorithme est de pouvoir apprendre l'ensemble des courbes de rendement issues d'irradiations de milieux homogènes, obtenues à l'aide d'un simulateur basé sur la technique de Monte Carlo. Dans un second temps, l'objectif applicatif de ma thèse portant sur l'élaboration d'un code de calcul permettant l'évaluation des doses déposées, nous avons mis au point des algorithmes permettant cette évaluation dans tous les milieux, hétérogènes comme homogènes, en se basant sur les résultats fournis par les réseaux de neurones précédemment entraînés.

Dans la première partie de ce mémoire, nous avons réalisé un état de l'art sur les techniques utilisées en radiothérapie externe puis sur les différents algorithmes utilisés dans le domaine des réseaux de neurones.

La radiothérapie externe permet le traitement de cancer par le biais d'irradiations successives. Un des grands enjeux de ce domaine de recherche est d'optimiser la réalisation de la planification de traitement. Le but est d'améliorer ainsi la qualité des soins fournis aux patients. Une part importante de ces recherches concerne la mise au point de codes de calcul permettant l'évaluation de la dose déposée lors d'une irradiation avec la plus grande précision possible. Il existe actuellement plusieurs méthodes permettant d'évaluer ce dépôt de doses. Ces méthodes peuvent soit reposer sur des mesures a posteriori, soit sur des solutions analytiques ou encore sur des calculs statistiques tels que les méthodes de Monte Carlo. Ces dernières méthodes sont celles qui offrent la meilleure précision. Toutefois, leur important temps de calcul les rend inutilisables pour un emploi en clinique quotidien. C'est pourquoi, les systèmes de planification de traitement font appel à des méthodes analytiques en incorporant dans certains cas, des codes pré-évalués de Monte Carlo dédiés à la gestion de cas spécifiques. Les résultats de ces solutions restent souvent perfectibles, et peuvent même parfois être erronés pour des cas très particuliers tels que la présence de prothèses.

Dans la seconde partie de cet état de l'art, nous avons présenté les différentes techniques mises en œuvre pour les réseaux de neurones. Ceux-ci peuvent être utilisés de manière performante en tant qu'interpolateurs de fonctions. La plupart de ces interpolateurs basés sur les réseaux de neurones utilisent une architecture de type perceptron

multicouches ainsi qu'un algorithme d'apprentissage de type rétropropagation du gradient. Plusieurs optimisations de ces techniques classiques existent. Suite à une série de tests permettant la comparaison de ces optimisations, nous avons sélectionné les deux plus performantes pour notre domaine applicatif; il s'agit de l'architecture HPU et de l'algorithme d'apprentissage RPROP. Le dernier thème abordé de cet état de l'art porte sur une analyse de nos besoins en parallélisation en vue de choisir une plate-forme spécialisée dans la programmation parallèle. Après une étude des besoins liés à notre application, le choix de la plate-forme s'est orienté vers la mise en œuvre LAM/MPI. Cette plate-forme supporte nos demandes en fonctionnalité de communication et de tolérances aux pannes.

La seconde partie de ce mémoire porte sur les contributions que nous avons apportées à ces domaines de recherche. La première part de notre travail a consisté en la réalisation d'un nouvel algorithme d'apprentissage incrémental, alors que la seconde, a porté sur la réalisation d'algorithmes performants permettant l'évaluation des doses déposées lors d'une irradiation. L'objectif de ce travail est de mettre au point un nouveau code de calcul permettant, à l'aide de réseaux de neurones entraînés sur des données représentant le résultat d'irradiations de milieux homogènes, d'atteindre la précision des méthodes de Monte Carlo avec de bonnes performances sans nécessiter une forte puissance de calcul.

L'algorithme d'apprentissage incrémental, que nous proposons, est construit sur une architecture de type HPU en utilisant l'algorithme d'apprentissage RPROP. En utilisant la combinaison de ces optimisations et en ajoutant à l'algorithme ainsi obtenu la possibilité d'optimiser le nombre de neurones disponibles sur la couche cachée en l'augmentant progressivement au cours de l'apprentissage, nous obtenons un algorithme d'apprentissage d'une grande performance pour les réseaux de neurones utilisés en interpolateur de fonction. Mais, même avec un tel algorithme, le passage à l'échelle semble difficile. C'est pourquoi nous avons mis en place une version parallèle de ce précédent algorithme. Cette parallélisation est réalisée en effectuant une décomposition du domaine d'apprentissage et en développant une application sur le modèle maître-esclave. Ensuite, pour répondre aux difficultés rencontrées lors du déploiement de cet algorithme, nous avons mis en œuvre une série de mécanismes permettant de répondre aux pannes des machines exécutantes, ou même, du processus général d'apprentissage.

Nos contributions portent ensuite sur les algorithmes d'évaluation des doses. L'objectif est de construire un algorithme en se basant sur les réseaux de neurones précédemment entraînés sur des résultats d'irradiation en milieux homogènes. Pour les concevoir, nous nous sommes basés sur le principe de continuité de la dose en tout point du milieu ainsi que sur une fine observation du comportement de la courbe de dépôt de dose aux interfaces entre milieux. L'algorithme global est en fait construit à base de plusieurs algorithmes spécifiquement développés pour résoudre chaque problème indépendamment. Le premier algorithme réalisé permet de prendre en charge l'hétérogénéité du milieu. Il s'agit donc de pouvoir retrouver lors de l'évaluation de dose d'un milieu, la position virtuelle correspondant à un niveau de dose dans un milieu de densité différente, en ayant pour seul repère de positionnement, la direction entre la source d'irradiation et le point recherché. Le second algorithme proposé permet quand à lui d'estimer la valeur de dose déposée dans

un volume alors que celui-ci n'est pas directement sous le champ du faisceau irradiant. Malgré nos recherches, nous n'avons pas été à même d'implémenter un algorithme pour la gestion des interfaces latérales. Nous avons toutefois proposé un ensemble de solutions permettant d'évaluer l'irradiation d'un milieu avec une grande précision, quel que soit le type d'hétérogénéité qui le compose [6].

Enfin, nous présentons une évaluation complète de l'ensemble de nos solutions. La première partie de cette évaluation présente donc les avantages de notre algorithme d'apprentissage en réalisant une comparaison avec d'autres algorithmes mettant en place une construction incrémentale. Suite à cette évaluation, nous présentons une série de tests permettant de voir l'influence de chacun des paramètres mis en place pour la gestion de la parallélisation de notre algorithme.

Ce chapitre se clôt par le détail des performances de notre algorithme d'évaluation de la dose déposée lors d'une irradiation. Les tests réalisés permettent d'estimer la performance de nos algorithmes sur chacune des conditions caractéristiques qui peuvent être rencontrées lors de l'évaluation d'un milieu d'une irradiation dans un milieu donné.

Perspectives

Les travaux réalisés au cours de cette thèse ouvrent plusieurs perspectives de recherche. En effet, même si ces travaux se concluent par l'obtention d'une application permettant pleinement d'évaluer les doses déposées lors d'une irradiation dans tous milieux, et ce, avec une précision suffisante, il reste encore plusieurs points d'étude intéressants. Certains sont facultatifs mais permettraient d'améliorer encore les parties déjà développées et d'autres sont essentiels à l'aboutissement du projet global actuel d'optimisation de la planification du traitement des cellules cancéreuses.

Algorithme d'apprentissage incrémental

Un point important que je n'ai pas encore pu mettre en place est l'ajout de connaissances à un réseau neuronal déjà entraîné. Dans mon contexte de travail et même avec parallélisation, il est fréquent qu'un apprentissage dure plusieurs jours. Les réseaux devant être utilisés dans des conditions évoluant au cours du temps, il est très intéressant de pouvoir leur ajouter des connaissances complémentaires, comme des doses d'irradiation obtenues dans un contexte (distance, densité du milieu homogène,...) encore non appris. Cet axe de recherche qui est la suite logique de mes travaux, rejoint une des grandes problématiques actuelles dans le domaine des réseaux neuronaux.

Utilisation des réseaux de neurones pour la gestion des interfaces entre milieux

L'utilisation des réseaux de neurones a été limitée dans notre approche actuelle à l'évaluation des doses dans les sous-parties homogènes d'un milieu hétérogène. Cependant, la gestion des interfaces entre milieux, c'est-à-dire le comportement des dépôts de doses au voisinage des changements de matières du milieu irradié, pourrait être améliorée par la mise au point de réseaux spécifiquement entraînés. En effet, le comportement physique du dépôt de doses autour des changements de matières est encore mal modélisé aujourd'hui. Il est donc actuellement retranscrit de manière approchée dans l'algorithmique de calcul des doses. Par rapport à notre objectif d'évaluation des doses, il serait donc très intéressant de s'abstraire de la connaissance précise du phénomène physique en utilisant une approche complètement neuronale faisant intervenir un second réseau spécifiquement entraîné sur ces changements de matières.

Extension de l'algorithme parallèle d'apprentissage aux grilles distribuées

L'algorithme parallèle de construction et d'apprentissage du réseau neuronal, utilisé pour l'évaluation des doses, est actuellement opérationnel sur des grappes locales de calcul. Étant donné les grands volumes de données à traiter et de calculs à effectuer pour réaliser cet apprentissage, les temps d'apprentissage restent relativement élevés même en utilisant des grilles locales assez importantes. Il paraît donc utile à terme d'étendre l'algorithme existant pour qu'il puisse fonctionner efficacement sur de grandes grilles réparties sur différents sites géographiques.

Optimisation de la décomposition du domaine d'apprentissage

Actuellement la décomposition du domaine d'apprentissage est uniquement réalisée en prenant en compte la taille du domaine d'apprentissage affecté à chaque sous-réseau. Hors, comme il est possible de voir dans nos différents résultats, les temps d'apprentissage que nous pouvons obtenir pour chacun des différents sous-réseaux n'est pas homogène. En vue d'harmoniser le temps d'apprentissage pour chacun des sous-réseaux, il peut être intéressant de ne plus réaliser la décomposition du domaine uniquement en fonction de la taille des données d'apprentissage mais plutôt en fonction de leur complexité.

Conception et développement du processus d'optimisation de la planification de traitement

Enfin, la dernière pierre à apporter à l'édifice est, bien entendu, le processus d'optimisation de la planification du traitement des tumeurs cancéreuses. Cette étape est réalisée en maximisant la dose prescrite à la tumeur tout en minimisant l'irradiation des zones sensibles. Actuellement, les systèmes existants privilégient le temps de calcul total par rapport à la précision finale en minimisant le nombre de simulations effectuées. En utilisant les solutions que nous avons proposées pour évaluer les courbes de doses déposées, il est possible d'accroître de manière significative le nombre de simulations permettant une vérification plus précise des choix de traitements proposés et ainsi, d'améliorer de manière importante la planification de traitement.

Bibliographie

- [1] Lam/mpi parallel computing. electronic. <http://www.lam-mpi.org/>.
- [2] Open mpi :open source high performance computing. electronic. <http://www.open-mpi.org/>.
- [3] Anders Ahnesjo and Maria Mania Aspradakiso. Dose calculations for external photon beams in radiotherapy. *Physics in Medicine and Biology*, 1999.
- [4] Frelin Anne-Marie. *Développement du dosimap, Instrument de dosimétrie pour le contrôle de qualité en radiothérapie*. PhD thesis, Université de Caen, 2006.
- [5] Jacques Bahi, Sylvain Contassot-Vivier, Libor Makovicka, Eric Martin, and Marc Sauget. Neurad. *Agence pour la Protection des Programmes. No : IDDN.FR.001.130035.000.S.P.2006.000.10000*, 2006.
- [6] Jaques Bahi, Sylvain Contassot-Vivier, Libor Makovicka, Eric Martin, and Marc Sauget. Neural network based algorithm for radiation dose evaluation in heterogeneous environments. In *International Conference on Artificial Neural Networks, ICANN 2006*, Athens, Greece, September 2006.
- [7] BEAM-nrc. NRC of Canada. <http://www.irs.inms.nrc.ca/BEAM/beamhome.html>.
- [8] Thomas Bortfeld. Optimized planning using physical objectives and constraints. In *Seminars in Radiation Oncology*, volume 9 of 1, pages 20–34, January 1999.
- [9] E. Buffard, R. Gschwind, L. Makovicka, E. Martin, and C. Meunier C. David. Study of the impact of artificial articulations on the dose distribution under medical irradiation. In Elsevier Science, editor, *Nuclear instruments and methods in physics research*, volume 229, pages 78–84, 2005.
- [10] Y. Le Cun. A learning scheme for threshold networks. In *Cognitiva'95*, pages 599–604, Paris, France, 1985.
- [11] G. Cybenko. Approximations by superpositions of sigmoidal functions. *Mathematics of Control, Signals, and Systems*, 2 :303–314, 1989.
- [12] N. Dunkin, J. Shawe-Taylor, and P. Koiran. A new incremental learning technique. In Springer Verlag, editor, *Neural Nets Wirm Vietri-96. Proceedings of the 8th Italian Workshop on Neural Nets*, pages 112–118, 1997.
- [13] J. F. Briesmeister (Editor). Mcnp—a general monte carlo n-particle transport code. Technical Report LA-12625-M, LANL, Los Alamos, NW, 1993.

- [14] C. L. Hartmann-Siantar et al. Lnl's peregrine project. In Medical Physics Publishing, editor, *Proceedings of the XII-th Conference on the Use of Computers in Radiotherapy*, pages 19 – 22, Madison, Wisconsin, May 1997.
- [15] F. Salvat et al. Penelope, an algorithm and computer code for monte carlo simulation of electron-photon showers. University of Barcelona preprint, 1996.
- [16] S. E. Fahlman. Faster-learning variations on back-propagation : An empirical study. In Morgan-Kaufmann, editor, *Connectionist Models Summer School*, Los Altos CA, 1988.
- [17] S. E. Fahlman and C. Lebiere. The cascade-correlation learning architecture. In D. S. Touretzky, editor, *Advances in Neural Information Processing Systems*, volume 2, pages 524–532, Denver 1989, 1990. Morgan Kaufmann, San Mateo.
- [18] I. Feuvret, G. Noel, C. Nauraye, P. Garcia, and J.-J. Mazeron. Index de conformation et radiothérapie. In Elsevier, editor, *Cancer Radiothérapie*, volume 8, pages 108–119. 2004.
- [19] G. Flake. Square unit augmented, radially extended, multilayer perceptrons.
- [20] B. Fritzke. Fast learning with incremental rbf networks. *Neural Processing Letters*, 1(1) :2–5, 1994.
- [21] C.L. Giles and T. Taxwell. Learning, invariance and generalization in high-order neural networks. *Optical Neural Networks*, pages 344–350, 1994.
- [22] W. Gropp and E. Lusk. Sowing MPICH : A case study in the dissemination of a portable environment for parallel scientific computing. *The International Journal of Supercomputer Applications and High Performance Computing*, 11(2) :103–114, 1997.
- [23] Babak Hassibi and David G. Stork. Second order derivatives for network pruning : Optimal brain surgeon. In Stephen José Hanson, Jack D. Cowan, and C. Lee Giles, editors, *Advances in Neural Information Processing Systems*, volume 5, pages 164–171. Morgan Kaufmann, San Mateo, CA, 1993.
- [24] K. Hornik, M. Stinchcombe, and H. White. Multilayer feedforward networks are universal approximators. *Neural Network*, 2(5) :359–366, 1989.
- [25] C. Igel and M. Hüsken. Empirical evaluation of the improved Rprop learning algorithm. *Neurocomputing*, 50(C) :105–123, 2003.
- [26] J.Allison. Geant4 - a simulation toolkit. volume 17, April 2007.
- [27] T.D. Solberg J.J. DeMarco, I.J. Chetty. A monte carlo tutorial and the application for radiotherapy treatment planning. *Medical Dosimetry*, 27 :43–50(8), Spring 2002.
- [28] N. T. Karonis, B. Toonen, and I. Foster. MPICH-G2 : A grid-enabled implementation of the message passing interface. *J. Parallel Distrib. Comput.*, 63(5) :551–563, 2003.
- [29] I. Kawrakow. Vmc++, electron and photon monte carlo calculations optimized for radiation treatment planning. In *Advanced Monte Carlo for radiation physics, particle transport simulation, and applications*, pages 229–236, Lisbon, Portugal, 2001. Monte Carlo 2000 Conference, Springer.