

# 综合复杂性特征和剂量学评估指标提高剂量验证结果预测模型的性能

申璐瑶<sup>1</sup>, 魏强林<sup>1</sup>, 张俊俊<sup>2</sup>, 宾石珍<sup>2</sup>, 刘义保<sup>1</sup>

1. 东华理工大学核科学与工程学院, 江西 南昌 330013; 2. 中南大学湘雅三医院肿瘤科, 湖南 长沙 410013

**【摘要】目的:**构建随机森林模型预测调强计划剂量验证结果,研究综合复杂性特征和剂量学评估指标提高模型性能的可行性。**方法:**选取269例IMRT计划,共2 558个射野,采用电子射野影像系统进行剂量验证, $\gamma$ 通过率(2%/2 mm标准)阈值为95%,将剂量验证结果分为“通过”和“不通过”。提取计划的剂量学评估指标和射野的复杂性特征,分别构建剂量模型(基于剂量学评估指标)、计划模型(基于计划复杂性特征)和混合模型(综合剂量学评估指标和计划复杂性特征)。计算AUC值、特异性和敏感性评估模型性能。**结果:**剂量模型、计划模型和混合模型的AUC值分别为0.68、0.80和0.82,混合模型优于其他两个模型。混合模型的特异性和敏感性为0.70和0.79,均高于其他两个模型。剂量模型、计划模型和混合模型达到最佳性能所需的样本量分别为1 200、900和700。**结论:**剂量学评估指标与计划复杂性特征综合,可以提高模型的预测性能,同时在一定程度上弥补样本数量的不足,为预测剂量验证结果的机器学习模型性能的改善提供参考。

**【关键词】**机器学习;剂量验证;计划复杂性特征;剂量学评估指标;随机森林

**【中图分类号】**R318;R811.1

**【文献标志码】**A

**【文章编号】**1005-202X(2022)04-0409-06

## Comprehensive index combining plan complexity characteristics and dosimetric evaluation indicators to improve model performance for predicting the results of dose verification

SHEN Luyao<sup>1</sup>, WEI Qianglin<sup>1</sup>, ZHANG Junjun<sup>2</sup>, BIN Shizhen<sup>2</sup>, LIU Yibao<sup>1</sup>

1. School of Nuclear Science and Engineering, East China University of Technology, Nanchang 330013, China; 2. Department of Oncology, the Third Xiangya Hospital of Central South University, Changsha 410013, China

**Abstract: Objective** To develop a random forest model for predicting the results of intensity-modulated radiotherapy (IMRT) plan dose verification, and to study the feasibility of improving model performance by integrating plan complexity characteristics and dosimetric evaluation indicators. **Methods** Electronic portal imaging device was used for the dose verification of 269 IMRT plans with a total of 2 558 fields. The threshold of gamma passing rate (2%/2 mm criterion) was 95%, and there were only two possible outcomes in dose verification, namely pass and fail. The dosimetric evaluation indicators of plans and the complexity characteristics of the radiation fields were extracted for constructing the dose model (based on dosimetric evaluation indicators), planning model (based on plan complexity characteristics) and the hybrid model (comprehensively considering dosimetric evaluation indicators and plan complexity characteristics). The performances of the prediction models were evaluated by AUC, specificity and sensitivity. **Results** The AUC of the dose model, the planning model and the hybrid model were 0.68, 0.80 and 0.82, respectively, and the hybrid model had the highest AUC. The specificity and sensitivity of the hybrid model were 0.70 and 0.79, both higher than those of the other two models. The number of samples required for the optimal performance of the dose model the planning model and hybrid model were 1 200, 900 and 700, respectively. **Conclusion** Comprehensively considering dosimetric evaluation indicators and plan complexity characteristics can improve the prediction performance of the model, and at the same time make up for the lack of sample size to a certain extent, providing a reference for improvement of the performance of machine learning model for predicting the results of dose verification.

**Keywords:** machine learning; dose verification; plan complexity characteristic; dosimetric evaluation indicator; random forest

**【收稿日期】**2021-12-05

**【基金项目】**国家重点研发计划(2017YFF0106503);湖南省自然科学基金青年基金(2020JJ5874)

**【作者简介】**申璐瑶,硕士研究生,研究方向:医学物理,E-mail: 1208494653@qq.com

**【通信作者】**刘义保,博士,教授,研究方向:核技术应用,E-mail: ybliu@ecut.edu.cn;宾石珍,硕士,主管技师,研究方向:放射治疗技术,E-mail: shi-zhenbin@csu.edu.cn

## 前言

近年来,机器学习由于其高效性和可预测性逐步成为研究热点,并开始应用于调强放射治疗(Intensity-Modulated Radiotherapy, IMRT)剂量验证结果的预测<sup>[1-3]</sup>。计划复杂性描述计划的复杂性调制程度,对剂量验证结果有一定的影响<sup>[4]</sup>,因此有研究将计划复杂性作为特征建立机器学习模型来预测剂量验证结果<sup>[5]</sup>。随机森林算法<sup>[6]</sup>是一种经典,高度灵活且稳定的机器学习算法,可用于构建机器学习模型预测剂量验证结果,预测效果良好<sup>[7-8]</sup>。但仍不能满足临床应用要求,预测精度亟待进一步提高。研究表明,增加与预测指标相关的特征可提高模型预测精度<sup>[9]</sup>。剂量学评估指标在ICRU第83号报告<sup>[10]</sup>中被定义为评价靶区剂量分布的定量特征,主要有适形度指数,梯度指数和均匀性指数,在临床上用来评估放疗计划质量<sup>[11]</sup>。计划质量的优劣在一定程度上反映了计划的复杂性,所以剂量学评估指标作为评估IMRT计划复杂性的指标具有潜在价值,增加剂量学评估指标可能会提高机器学习模型的预测精度。综合计划复杂性特征和剂量学评估指标对提高机器学习模型预测性能的研究有待进一步开展。

本研究利用随机森林算法分别建立基于复杂性特征、剂量学评估指标和综合指标的预测模型,对IMRT计划剂量验证的结果进行预测,评估3种模型的预测能力,为提高机器学习模型预测能力提供参考。

## 1 材料与方法

### 1.1 计划病例选取

回顾性选取2020年5月~2021年5月在中南大学湘雅三医院放疗中心接受IMRT治疗的肿瘤患者269例,其中乳腺癌患者31例、宫颈癌患者53例、食管癌患者31例、脑胶质瘤患者34例、肺癌患者32例、鼻咽癌患者50例、直肠癌患者38例、共2558个射野。所有IMRT计划均使用Varian公司Eclipse 11.0治疗计划系统进行设计,采用6 MV X射线,计算网格为2 mm,剂量率400 MU/min或600 MU/min,并在Varian公司Unique加速器上执行。

### 1.2 剂量验证

本研究使用的剂量验证设备是电子射野影像系统(Electronic Portal Imaging Device, EPID)非晶硅平板探测器,有效探测面积(40×30) cm<sup>2</sup>,分辨率0.392 mm/pixel。每次剂量验证前进行探测器阵列的绝对剂量校准、本底和泛野校准。利用Eclipse配置的Portal dosimetry软件对EPID采集的实际剂量分布与计划系统计算的剂量

分布进行比较,并采用2%/2 mm的 $\gamma$ 标准<sup>[12]</sup>和最大剂量10%的阈值进行 $\gamma$ 分析。 $\gamma$ 通过率阈值为95%<sup>[13]</sup>,即 $\gamma$ 通过率大于95%时,放射治疗计划剂量验证结果表示“通过”,否则为“不通过”。

### 1.3 特征参数提取

对于每一个IMRT计划,从计划系统中提取其剂量体积直方图(Dose Volume Histogram, DVH)文件和每一个射野的多叶准直器(Multi-Leaf Collimator, MLC)文件,采用Matlab编程提取数据,并计算计划复杂性特征和剂量学评估指标,将其作为特征参数。计划复杂性主要描述一个射野强度分布变化的频率和幅度<sup>[14]</sup>,包含多个量化方法和相应指标。涉及IMRT计划复杂性的参数通常包括射野不规则度、射野调制、子野联合面积、小野评分、平均不对称距离、调制复杂度分数、叶片序列变化、射野面积变化、边缘度量、子野平均跳数、平均子野面积、子野面积变异系数、射野总跳数、子野数、铅门最大位置、子野平均面积与铅门定义面积之比等<sup>[15-19]</sup>。涉及剂量学特征的参数,包括适形度指数、均匀性指数和梯度指数。此外,还有靶区体积,病灶部位和剂量率,总共27个特征,具体缩写与释义如表1所示。

### 1.4 模型训练

采用R语言实现基于随机森林算法构建的机器学习模型,对剂量验证结果进行预测。随机森林算法在构建每棵决策树时,随机有放回地抽取一部分样本,剩余样本称为袋外数据,可以用来评估随机森林内部<sup>[20]</sup>。因此,模型训练时不需要进行交叉验证来获得无偏估计<sup>[21]</sup>。按照7:3的比例将数据集划分为训练集(1766个射野)和测试集(756个射野)。本研究中机器学习模型预测结果为二分类,“通过”表示“阴性”,“不通过”表示“阳性”。剂量学评估指标、复杂性指标和综合指标作为模型输入,分别构建剂量模型、计划模型和混合模型。并通过调整ntree值和mtry值对模型进行优化,其中ntree为随机森林所包含的决策树数目,mtry为节点中用于二叉树的变量个数。

### 1.5 模型评估方法

受试者工作特征曲线(Receiver Operating Characteristic Curve, ROC)下面积(Area Under the Curve, AUC)是用来评估模型分类预测效果的综合指标<sup>[22]</sup>。通过计算AUC值、特异性和敏感性对模型进行评估。

### 1.6 统计学方法

采用SPSS 26.0对数据进行统计分析,Spearman相关系数用于评估每个特征和剂量验证 $\gamma$ 通过率的关联度。 $P<0.05$ 为差异有统计学意义。

表 1 机器学习预测中使用的特征  
Table 1 Features used in machine learning prediction

序号	中文释义	英文释义	英文缩写
1	射野总跳数	Monitor unit	MU
2	射野总子野数	Number of segments	NS
3	子野平均跳数	Mean MU per control point	MUCP
4	子野平均面积	Mean aperture area	MAA
5~7	平均小野评分	Mean of Small aperture score	SAS5, SAS10, SAS20
8~10	最大小野评分	Max of fraction of aperture smaller	MSAS5, MSAS10, MSAS20
11	子野面积变异系数	Coefficient of variation of segments area	CVA
12	叶片序列变化	Leaf sequence variability	LSV
13	射野面积变化	Aperture area variability	AVV
14	调制复杂度评分	Modulation complexity score	MCS
15	平均不对称距离	Mean asymmetry distance	MAD
16	射野不规则度	Beam irregularity	BI
17	射野调制	Beam modulation	BM
18	子野面积与铅门定义面积之比	MAA over the area defined by jaws	AAJA
19	铅门的最大位置	Maximum of x-y jaw positions	MAXJ
20	边缘度量	Edge Metric	EM
21	子野联合面积	Union area of aperture	UAA
22	靶区体积	Volumes of the PTV	Vptv
23	适形度指数	Conformity index	CI
24	均匀性指数	Homogeneity index	HI
25	梯度指数	Gradient index	GI
26	剂量率	Dose rate	DR
27	病灶部位	Disease site	DS

2 结果

2.1 模型性能评估

调整ntree值和mtry值对模型进行优化,使模型性能达到最佳。对于剂量模型、计划模型和混合模型,ntree值分别为20、425和265,mtry值分别为2、4和5。用测试集评估模型的预测能力,根据预测结果绘制ROC曲线(图1),并计算AUC值、特异性和敏感性(表2)。混合模型的AUC值最高,为0.82,预测能力最强,计划模型的AUC值为0.80,而剂量模型的AUC值只有0.68,预测能力一般。混合模型的敏感性和特异性为0.79和0.70,均高于其他两个模型。

2.2 特征重要性评估

为更好地揭示各特征对剂量验证 $\gamma$ 通过率的影响程度,对所有的特征进行重要性排序(图2),其中最重要的前12个特征为:NS、BI、MU、SAS5、MSAS5、CVA、MCS、MAXJ、LSV、UAA、EM、AVV。同时,对特征和剂量验证 $\gamma$ 通过率进行Spearman相关性分析,结果显示,27个特征总体上与剂量验证 $\gamma$ 通过率呈弱相关,其




图1 每个模型在测试集上的ROC曲线  
Figure 1 ROC curve for each model on the test set

中21个特征具有统计学意义( $P<0.05$ ),11个特征与剂量验证 $\gamma$ 通过率的相关系数的绝对值大于0.20。相关系数绝对值 $>0.30$ 的特征有NS、MU和BI,和重要性排序前三位的特征一致。NS的相关系数最大,为-0.40( $P<0.001$ ),呈中等程度关联,MU和BI的相

表 2 3 个模型的性能评估

Table 2 Performance evaluation of the 3 models

指标	剂量模型	计划模型	混合模型
AUC	0.68	0.80	0.82
敏感性	0.64	0.74	0.79
特异性	0.61	0.69	0.70

关系数分别为-0.33( $P<0.001$ )和-0.31( $P<0.001$ ),呈弱关联,3个特征和剂量验证 $\gamma$ 通过率的关系如图3所示。此外,为了评估这3个指标单独识别剂量验证“不通过”的计划的作用,对这3个指标分别进行ROC分析并绘制ROC曲线(图4),NS、MU和BI的AUC值分别为0.69、0.66和0.64,3个特征的相关统计指标见表3。




图3 3个特征与 $\gamma$ 通过率的关系图

Figure 3 Relationships between the 3 features and gamma passing rate




图4 3个特征的ROC曲线

Figure 4 ROC curve of the 3 features

2.3 样本数量的影响

样本量的大小直接影响模型训练的效果,为了评估3种模型达到最佳性能所需要的样本量,改变训练样本的数量来训练模型。分别随机选取原始样本量的5%,10%,15%, $\cdots$ ,100%,3种模型各构建20组模型,计算AUC值并绘制学习曲线,如图5所示。3




图2 特征重要性排序

Figure 2 Ranking the importance of features

表3 3个特征的相关系数、AUC值、特异性和敏感性的比较

Table 3 Comparison of the correlation coefficient, AUC, specificity and sensitivity of the 3 features

特征	相关系数	AUC	阈值	敏感性	特异性
NS	-0.40	0.69	165.50	0.59	0.74
MU	-0.33	0.66	176.25	0.59	0.68
BI	-0.31	0.64	8 433.35	0.51	0.77

种模型的AUC值都随样本量的增加而增加,当训练的样本数超过一定值后,AUC值达到上限,模型的性能将不会进一步改善。剂量模型的样本量达到1 200时,AUC值达到上限(0.68);计划模型的样本量达到900时,AUC值达到上限(0.80);混合模型的样本量达到700时,AUC值达到上限(0.82)。

3 讨论

在机器学习中,特征的选取和数量直接影响模型的预测能力,其和数据一起决定了机器学习的性能上限。增加与预测指标相关性较高的特征在一定






图5 AUC值与用于训练模型的样本数量之间的关系  
Figure 5 Relationship between AUC and the number of samples used for model training

程度上可以提高模型的预测性能<sup>[9]</sup>。目前,大部分预测调强计划剂量验证结果的研究都是基于计划复杂性特征<sup>[5]</sup>。Li等<sup>[8]</sup>的研究证明基于计划复杂性特征建立的随机森林模型具有较高的敏感性。Hirashima等<sup>[23]</sup>证明计划复杂性特征与剂量组学特征相结合,可以提高模型的预测性能。但是,其剂量组学特征无法直接提供剂量验证不通过的原因。本研究综合计划复杂性特征和剂量学评估指标,建立基于随机森林算法的机器学习模型,预测剂量验证结果“通过”或“不通过”,采用的剂量学评估指标能在计划系统中直接计算得到,可以直观地分析剂量验证不通过的原因。研究结果显示,对于剂量模型,AUC值为0.68,模型的性能一般,与其他两个模型的差别较大,这可能是由于构建模型所使用的特征较少。对于计划模型,AUC值为0.8,优于Hirashima等<sup>[23]</sup>的结果(AUC=0.73)。而综合复杂性特征和剂量学评估指标构建的混合模型,AUC值达到0.82,均高于单独的剂量模型和计划模型,与Hirashima等<sup>[23]</sup>的结果一致。Li等<sup>[8]</sup>的结果显示,敏感性对于剂量验证结果预测模型性能的评估也很重要。在本研究中,与其他模型相比,混合模型表现出更高的敏感性。进一步说明,综合计划复杂性特征和剂量学评估指标对提高预测模型的性能有积极的作用。在特征的重要性排序中,NS的重要性评分最高,其次是BI和MU。在Spearman相关性分析中,NS的相关系数最大,为-0.40,MU和BI的相关系数分别为-0.33和-0.31,均呈负相关。为了进一步分析这些特征辅助计划设计的可行性,对剂量验证结果影响最大的3个特征进行ROC分析,结果与重要性分析和Spearman相关性分析结果一致,NS的AUC值最大,为0.69,MU和BI分别为0.66和0.64。王凯等<sup>[24]</sup>的研究表明子野数较少时通过率较高,迟子锋等<sup>[25]</sup>的研究也显示MU和子野数会影响剂量验证结果。

在重要性分析中,剂量学评估指标对剂量验证结果的影响整体上比复杂性特征弱,其中HI的影响最大,其次是GI。本研究在计划设计时,使用动态调强技术形成多个小子野,子野的衔接会带来剂量偏差。剂量分布不均匀和剂量梯度较大时会产生更多以及更小的子野,而更狭窄的子野会带来更大的偏差<sup>[15]</sup>。因此在放疗计划设计阶段,需要在更好的剂量分布和剂量精确性中做出权衡。

训练模型的样本数量直接影响模型的预测能力。在本研究中对于模型达到稳定预测性能所需的样本量,剂量模型为1200个,计划模型为900个,混合模型为700个,而Lam等<sup>[7]</sup>的模型需要1000个样本。此外,混合模型达到最佳性能所需的样本量最少,说明增加有效的特征可以降低建模所需的样本量。在数据量不够充足的情况下,可以适当增加有效的特征以提高模型的预测性能。

此外,本研究有一定的局限性,建模使用的数据来自同一台加速器,加速器的性能也会影响剂量验证结果,所以模型在其他机器上的预测效果不稳定。在未来的研究中,可以选取不同加速器的计划并增加与加速器性能有关的特征建立模型,进一步提高模型预测精度和泛化性能。

综上所述,基于计划复杂性特征和综合指标的模型均能较好地对剂量验证结果进行预测,增加剂量学评估指标并与计划复杂性特征综合,可以提高机器学习模型的预测性能,同时在一定程度上弥补样本数量的不足。此外,计划复杂性特征中NS对剂量验证结果影响最大,虽然剂量学评估指标对剂量验证结果的影响整体上低于计划复杂性特征,但是HI对剂量验证亦显示出了较大的影响,这些指标均有助于分析剂量验证结果“不通过”的原因。这些指标的结合,为剂量验证结果预测模型性能的改善和特征的选择提供有效的参考。

【参考文献】

[1] VALDES G, SCHEUERMANN R, HUNG C Y, et al. A mathematical framework for virtual IMRT QA using machine learning[J]. Med Phys, 2016, 43(7): 4323-4334.

[2] VALDES G, CHAN M F, LIM S B, et al. IMRT QA using machine learning: a multi-institutional validation[J]. J Appl Clin Med Phys, 2017, 18(5): 279-284.

[3] TOMORI S, KADOYA N, TAKAYAMA Y, et al. A deep learning-based prediction model for gamma evaluation in patient-specific quality assurance[J]. Med Phys, 2018, 45(9): 4055-4065.

[4] CHIAVASSA S, BESSIERES I, EDOUARD M, et al. Complexity metrics for IMRT and VMAT plans: a review of current literature and applications[J]. Br J Radiol, 2019, 92(1102): 20190270.

[5] CHAN M F, WITZTUM A, VALDES G. Integration of AI and machine learning in radiotherapy QA[J]. Front Artif Intell, 2020, 3: 577620.

[6] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.

- [7] LAM D, ZHANG X, LI H, et al. Predicting gamma passing rates for portal dosimetry-based IMRT QA using machine learning[J]. Med Phys, 2019, 46(10): 4666-4675.
- [8] LI J, WANG L E, ZHANG X, et al. Machine learning for patient-specific quality assurance of VMAT: prediction and classification accuracy[J]. Int J Radiat Oncol Biol Phys, 2019, 105(4): 893-902.
- [9] 李佳奇, 张书铭, 王皓, 等. 机器学习在调强放疗质量保证中的应用研究进展[J]. 中华放射肿瘤学杂志, 2019, 28(4): 309-313.  
LI J Q, ZHANG S M, WANG H, et al. Research progress on application of machine learning in quality assurance of intensity-modulated radiotherapy[J]. Chinese Journal of Radiation Oncology, 2019, 28(4): 309-313.
- [10] HODAPP N. The ICRU report 83: prescribing, recording and reporting photon-beam intensity-modulated radiation therapy (IMRT) [J]. Strahlenther Onkol, 2012, 188(1): 97-99.
- [11] SHAW E, KLINE R, GILLIN M, et al. Radiation Therapy Oncology Group: radiosurgery quality assurance guidelines [J]. Int J Radiat Oncol Biol Phys, 1993, 27(5): 1231-1239.
- [12] LOW D A, HARMS W B, MUTIC S, et al. A technique for the quantitative evaluation of dose distributions[J]. Med Phys, 1998, 25(5): 656-661.
- [13] MIFTEN M, OLCH A, MIHAILIDIS D, et al. Tolerance limits and methodologies for IMRT measurement-based verification QA: recommendations of AAPM Task Group No.218[J]. Med Phys, 2018, 45(4): e53-e83.
- [14] MOHAN R, ARNFIELD M, TONG S, et al. The impact of fluctuations in intensity patterns on the number of monitor units and the quality and accuracy of intensity modulated radiotherapy[J]. Med Phys, 2000, 27(6): 1226-1237.
- [15] DU W L, CHO S H, ZHANG X D, et al. Quantification of beam complexity in intensity-modulated radiation therapy treatment plans [J]. Med Phys, 2014, 41(2): 021716.
- [16] CROWE S B, KAIRN T, KENNY J, et al. Treatment plan complexity metrics for predicting IMRT pre-treatment quality assurance results [J]. Australas Phys Eng Sci Med, 2014, 37(3): 475-482.
- [17] YOUNGE K C, MATUSZAK M M, MORAN J M, et al. Penalization of aperture complexity in inversely planned volumetric modulated arc therapy[J]. Med Phys, 2012, 39(11): 7160-7170.
- [18] MCNIVEN A L, SHARPE M B, PURDIE T G. A new metric for assessing IMRT modulation complexity and plan deliverability[J]. Med Phys, 2010, 37(2): 505-515.
- [19] 郭冉, 张艺宝, 李明辉, 等. 调强计划验证通过率的影响因素分析[J]. 中国医学物理学杂志, 2018, 35(10): 1117-1121.  
GUO R, ZHANG Y B, LI M H, et al. Factors affecting the passing rate of intensity-modulated radiotherapy plans [J]. Chinese Journal of Medical Physics, 2018, 35(10): 1117-1121.
- [20] MATTHEW W. Bias of the random forest out-of-bag (OOB) error for certain input parameters[J]. OPS, 2011, 1(3): 205-211.
- [21] 王可心, 包云轩, 朱承璇, 等. 随机森林回归法在冬季路面温度预报中的应用[J]. 气象, 2021, 47(1): 82-93.  
WANG K X, BAO Y X, ZHU C Y, et al. Forecasts of road surface temperature in winter based on random forests regression [J]. Meteorological Monthly, 2021, 47(1): 82-93.
- [22] 邱秋. 急性胰腺炎相关并发症人工智能预测模型建立及效能探讨的研究[D]. 重庆: 中国人民解放军陆军军医大学, 2019.  
QIU Q. Development and validation artificial intelligence predictive models for complications of acute pancreatitis [D]. Chongqing: Third Military Medical University, 2019.
- [23] HIRASHIMA H, ONO T, NAKAMURA M, et al. Improvement of prediction and classification performance for gamma passing rate by using plan complexity and dosimetrics features[J]. Radiother Oncol, 2020, 153: 250-257.
- [24] 王凯, 程惠华, 雷勇, 等. 不同子野数前列腺癌调强放射治疗剂量的验证分析[J]. 中国医疗设备, 2016, 31(6): 117-118.  
WANG K, CHENG H H, LEI Y, et al. Validation of the dose of radiation therapy for prostate cancer with different numbers of sub fields[J]. China Medical Devices, 2016, 31(6): 117-118.
- [25] 迟子锋, 刘丹, 曹彦坤, 等. IMRT计划剂量误差与射野特征参数相关性分析[J]. 中华放射医学与防护杂志, 2012, 32(3): 294-296.  
CHI Z F, LIU D, CAO Y K, et al. Pertinence analysis of intensity-modulated radiation therapy dosimetry error and parameters of beams [J]. Chinese Journal of Radiological Medicine and Protection, 2012, 32(3): 294-296.

(编辑: 薛泽玲)