

递变能量 X 射线高动态融合图像的 灰度表征算法研究*

陈平^{1)2)†} 阴晓刚¹⁾ 潘晋孝¹⁾ 韩焱¹⁾

1)(中北大学, 信息探测与处理山西省重点实验室, 电子测试技术国家重点实验室, 仪器科学与动态测试教育部重点实验室, 太原 030051)

2)(中国科学院自动化研究所, 中国科学院分子影像重点实验, 北京 100190)

(2014年4月3日收到; 2014年7月13日收到修改稿)

递变能量 X 射线成像, 通过获取并融合图像序列实现动态范围扩展, 完整再现了检测对象的结构信息. 但是在融合过程中往往是以质量优化为目的, 忽略了与实际高动态成像的灰度映射正确性, 从而不能保证图像信息与实际物体信息的物理匹配性. 因此, 本文提出了递变能量 X 射线高动态融合图像的灰度表征算法. 该算法首先以标钢质准楔形试块为对象, 将不同电压下的融合图像作为输入数据, 直接采集高动态成像图像作为输出数据, 利用神经网络方法构建递变能量成像的灰度表征模型. 同时针对不同于训练对象的材料, 对灰度表征模型进行修正, 实现了不同材质的灰度正确表征, 进而实现了低动态图像序列融合图像的正确表征. 以 12 和 16 bit 成像系统进行实验, 结果表明, 利用 12 bit 探测器通过变电压采集图像序列, 经图像融合、灰度映射及灰度校正, 达到了 16 bit 探测器的成像效果, 且满足灰度对应关系, 有效拓展了成像器件的动态范围.

关键词: 递变能量, 高动态, 灰度表征, 神经网络

PACS: 87.59.-e, 41.50.+h, 85.60.Gz

DOI: 10.7498/aps.63.208703

1 引言

X 射线无损检测技术在工业领域有广泛的应用^[1,2], 在航空、航天、国防工业等领域中, 常遇到结构复杂、材料多组元化、各部分厚度差异大的构件. 对这类构件进行 X 检测时, 常规固定单一电压成像模式无法同时对整个工件曝光成像, 图像中出现过度曝光和不足曝光共存现象, 图像结构信息缺失严重, 影响射线图像质量和检测灵敏度. 对此, 提出了递变能量 X 射线 DR 成像技术^[3,4]. 该技术依据检测对象的厚度变化范围, 由低电压到高电压递变, 获取递变能量图像序列, 然后对图像序列融合, 获取涵盖工件完整结构信息的高动态图像. 如基于电压-灰度-厚度模型的图像序列融合方法, 该方

法需要通过大量的标定实验获取电压-灰度-厚度模型, 同时由于 X 射线的多谱性以及物理衰减过程的复杂性, 由模型获得权系数往往需要进一步修正^[5]. 为了解决这一问题, 人们又提出了基于主成分分析和基于小波变换的图像序列融合方法^[6,7], 这两种方法可实现图像序列加权系数的自适应获取, 但其灰度的物理对应性无法得到有效表征. 对此本文主要针对递变能量融合方法及物理表征开展研究.

对于融合结果的物理表征, 理论上需要从物理角度对 X 射线物理成像过程以及平板探测器的内部转换过程进行建模, 分析灰度值与射线能量之间的非线性关系. 但是由于 X 射线具有的多谱特性、散射特性、射线硬化特性以及平板探测器光子转化效率等方面的影响^[8,9], 很难建立准确的物理模型.

* 国家自然科学基金(批准号: 61227003, 61171179, 61301259)、山西省自然科学基金(批准号: 2012021011-2)、高等学校博士学科点专项科研基金(批准号: 20121420110006)、山西省回国留学人员科研资助项目(批准号: 2013-083)和山西省高等学校优秀创新团队支持计划资助的课题.

† 通讯作者. E-mail: pc0912@163.com

虽然高动态图像可以正确地表征物理信息,但是由于高动态成像设备价格昂贵,因此,为了扩展低动态成像设备的使用范围,如何将低动态融合图像正确地对应到高动态图像的研究就十分有必要.

由于神经网络模型具有实现从输入到输出的任意非线性映射^[10,11],而无须明确输入与输出之间的函数关系的特点,在X射线图像处理领域有很广泛的应用. Lee等^[12]提出基于神经网络的变电压材质分解的方法,通过仿真模拟得到变能量图像; Torbati等^[13]利用神经网络进行射线图像分割. 同时根据Funahaski等^[14]的理论,三层前馈神经网络可以对任意非线性映射进行拟合. 因此,本文采用神经网络方法,以标准楔形试块为对象,构建低动态融合图像和直接高动态成像的灰度映射模型,实现递变能量融合图像的灰度正确表征.

2 变能量成像与图像融合

2.1 变能量图像采集

递变电压成像所获取的是检测对象厚度由薄到厚的局部有效的图像序列,为了能够获取结构信息完整的投影图像,需要经图像序列融合,实现信息重组及动态范围扩展,满足复杂异形工件正常成像的高动态范围需求.

本文采用钢质楔形标准块(如图1所示),对楔形块由低电压到高电压进行照射. 采集条件为: 450 kV工业X射线源,射线源与平板探测器之间的距离为80 cm,低动态采集设备为12位PaxScan2520探测器,采集电压为75—110 kV之间,间隔为5 kV(如图2所示).




图1 楔形块尺寸模型




图2 不同电压下的低动态图像 (a) 75 kV; (b) 85 kV; (c) 95 kV; (d) 105 kV; (e) 110 kV

2.2 图像融合

为了保证工件结构信息的完整性,一般所采用的电压步进间隔较小,如此相邻图像间必然存在重叠区域,实验过程中采用5 kV间隔. 记相邻电压下图像 X_i 和 X_{i+1} 的有效区域的重叠部分为 Ω_i . 而在实际成像过程中,单一电压下同一区域的透照灰度理论上应该一致. 对此,可依据相邻图像间重叠区域灰度一致性的特性,通过加权融合将各电压下图像乘以不同的系数变换到同一电压下,然后求平均. 定义 X_i 和 X_{i+1} 之间的距离为

$$d(X_i, X_{i+1}) = \sqrt{\sum_{j \in \Omega_i} (a_i x_{ij} - a_{i+1} x_{i+1,j})^2}, \quad (1)$$

可用 $d(X_i, X_{i+1})$ 衡量 X_i 和 X_{i+1} 在 Ω_i 内的灰度一致性, $d(X_i, X_{i+1})$ 越小,其一致性越高.

融合图像记为 X ,融合过程中对图像 X_i 所做的线性变换为 $a_i X_i$,则

$$X = \frac{1}{n} (a_1 X_1 + a_2 X_2 + \dots + a_n X_n). \quad (2)$$

依据(1)式,选择的 a_i 应使变换后各图像间的总距离最小,即图像序列整体在重叠区域内的灰度一致性最好. 由此可得(3)^[14]的目标优化模型:

$$\begin{aligned} \min & \quad g(a_1, a_2, \dots, a_n) \\ & = \sum_{i=1}^{n-1} \sum_{j \in \Omega_i} (a_i x_{ij} - a_{i+1} x_{i+1,j})^2. \end{aligned} \quad (3)$$

递变能量图像序列融合是通过灰度变换将低电压的图像以不同的权系数加权到最高电压对应的射线图像中. 为此,对于(3)式,可令 $a_n = 1$,再通过优化求解得 a_1, a_2, \dots, a_{n-1} 值,并由(2)式计算得融合图像,如图3所示.

为了便于比较分析,在相同的条件下,直接获取110 kV下楔形块的高动态图像(图4)进行对比分析,其中高动态采集设备为16位PerkinElmer探测器.选取融合图像与高动态图像中一系列灰度值,比较灰度曲线如图5所示.



图3 (网刊彩色)融合图像



图4 (网刊彩色)高动态图像




图5 (网刊彩色)融合图像与高动态图像灰度曲线比较

通过灰度曲线比较分析可以得出,融合图像与直接高动态图像的灰度曲线在较薄区域上灰度变化曲率不一致,无法经平移重合.由此可见,低动态图像序列融合图像相对于直接高动态图像存在一定的灰度差异性,从而导致工件的物理特征无法得到正确表征.

3 基于神经网络的X射线图像物理表征模型

3.1 理论分析

为了逼真地反映直接高动态成像特性,修正图5所显示的灰度差异性,需要研究高、低动态成像系统的多谱物理特性及光电转换效应,并构建灰度变换模型:

$$G_{\text{high dynamic}} = H(G_{\text{fusion}}), \quad (4)$$

其中 H 为递变能量X射线成像系统的非线性传递函数, $G_{\text{high dynamic}}$ 为直接高动态成像图像, G_{fusion} 为低动态图像序列融合图像.(4)式中的传递函数 H 与X射线的多谱特性、散射特性和射线硬化特性以及平板探测器的光子转化效率等因素有关,其物理过程极其复杂,难以用数学表达式准确表示.然而人工神经网络具有能以任意精度逼近任何单值连续数函数的优点,因此以标准试块的低动态融合图像为输入,以直接高动态成像为输出,经三层前馈神经网络模型训练,构建灰度变换映射模型.

3.2 基于神经网络的融合图像灰度表征模型

神经网络结构包含输入层、中间隐含层和输出层,如图6所示.

设 x_j^1 为第一个隐含层第 j 个神经元的输出, x_k^2 为第二个隐含层中第 k 个神经元的输出,则输出 y_1, y_2 与输入 x_1, x_2 的关系为

$$\begin{cases} x_j^1 = f\left(\sum_{i=1}^2 \omega_{ij}^1 x_i - \theta_j^1\right) & (j = 1, 2, \dots, n_1), \\ x_k^2 = f\left(\sum_{j=1}^{n_1} \omega_{jk}^2 x_j^1 - \theta_k^2\right) & (k = 1, 2, \dots, n_2), \\ y_m = f\left(\sum_{k=1}^{n_2} \omega_{km}^3 x_k^2 - \theta_m^3\right) & (m = 1, 2), \end{cases} \quad (5)$$

式中 $f(\cdot)$ 为激活函数; n_1, n_2 为第一、第二隐含层神经元数; ω_{ij}^1 为输入层第 i 输入到第一隐含层第 j 个神经元的连接权值; ω_{jk}^2 为第一隐含层第 j 个神经元输出到第二隐含层第 k 个神经元的连接权值; ω_{km}^3 为第二隐含层第 k 个神经元输出到输出层第 m 个输出的连接权值; θ_j^1, θ_k^2 和 θ_m^3 为相应的神经元

阈值. 神经网络训练就是通过不断修正权值和阈值, 最后达到输出结果与期望输出相一致的过程.




图6 神经网络结构图

将融合图像作为输入, 高动态图像作为相应输出, 随机选取30组输入数据作为测试样本, 将剩下的数据作为神经网络模型的训练数据. 为了使神经网络具有较好的收敛特性, 学习函数采用动量及自适应梯度递减函数. 激活函数 $f(\cdot)$ 定义为

$$f(x) = \frac{2}{1 + e^{-2x}} - 1. \quad (6)$$

对于该模型, 以图1标准楔形试块的低动态融合图像为输入, 以直接高动态成像为输出, 训练得到递变能量成像的灰度映射模型, 如图7和8所示.




图7 (网刊彩色) 预测值与实验输出值




图8 (网刊彩色) 输出图像灰度曲线与高动态图像对比

从图7和8来看, 经神经网络训练的灰度映射

模型得到的输出图像与高动态图像的灰度误差在1%之内, 真实地表征了输入与输出间的非线性关系.

3.3 灰度修正模型

由于射线能量与衰减系数之间存在非线性关系, 而且不同材质之间的多谱衰减特性也成非线性, 因此3.2节中所构建的基于神经网络的灰度映射表征模型仅适用于与训练对象材质一样的工件. 当工件材料与训练对象材料不同时, 为了得到正确的灰度表征图像, 需要依据质量衰减系数的多谱特性, 对映射结果进一步修正.

在低能量下正常成像的区域, 设低动态采集板上 d_1 厚度的测试工件的灰度值与 d_2 厚度的模型材料的灰度值是相同的, 测试工件的衰减系数为 μ_1 , 模型材料的衰减系数为 μ_2 . 则由Beer定律 $I = I_0 e^{-\mu d}$, 可知 $\mu_1 d_1 = \mu_2 d_2$. 即在低能量下 d_1 厚度的测试工件等效于 d_2 厚度的模型材料. 那么该区域在高能量下, 测试工件的衰减系数变为 μ'_1 , 模型材料的衰减系数变为 μ'_2 .

构建的物理表征模型中, 将 d_1 厚度的测试工件等效为 d_2 厚度的模型材料, 输出结果为 $I_2 = I_0 e^{-\mu'_2 d_2}$, 其中, I_0 为高能量下高动态采集板的背景灰度值. 而真实灰度值为 $I_1 = I_0 e^{-\mu'_1 d_1}$, I_1 为修正后的图像, 则

$$I_1 = I_0 / \exp \left[(\ln I_0 - \ln I_2) \frac{\mu'_1 \mu_2}{\mu'_2 \mu_1} \right]. \quad (7)$$

4 实验验证

为了验证上述训练得到的灰度表征模型以及修正模型的正确性, 分别采用与训练模型材质相同的厚度为2, 4, 6 mm的阶梯块以及材质不同的厚度为4, 2 mm的阶梯块对模型进行测试验证. 实验中, 低动态采集设备为12位PaxScan2520探测器, 高动态采集设备为16位PerkinElmer探测器.

4.1 采用同种材料验证灰度表征模型

对与训练模型同材质的阶梯试块, 采用低动态成像设备采集电压为75—110 kV图像序列(间隔为5 kV, 如图9); 通过融合, 将其结果代入灰度表征模型, 得到输出图像如图10. 同时, 直接获取110 kV下阶梯块的高动态图像(图11).



图9 (网刊彩色) 钢阶梯块图像 (a) 75 kV; (b) 85 kV; (c) 95 kV; (d) 105 kV; (e) 110 kV; (f) 融合图像




图10 (网刊彩色) 输出图像




图11 (网刊彩色) 高动态图像

对比分析图10和图11中所标识的灰度曲线, 结果示于图12. 从图中可以看出, 经灰度表征映射后的图像与直接高动态成像灰度信息基本一致. 从而可说明, 检测对象材质与训练模型材质相同时, 无须经灰度校正, 可实现递变能量高动态成像的正确表征.




图12 (网刊彩色) 钢阶梯块灰度曲线比较

4.2 采用不同材料验证修正模型

对不用于训练模型材质的检测对象, 以厚度为2与4 mm的铜阶梯块为例, 使用低动态成像设备采集图像, 采集电压为90—110 kV, 间隔为5 kV, 见图13. 同样以低动态融合图像为灰度表征模型的输入, 并与110 kV下直接高动态成像进行对比分析, 结果如图14所示.




图13 (网刊彩色) 铜阶梯块图像 (a) 90 kV; (b) 110 kV; (c) 融合图像; (d) 输出图像; (e) 修正图像; (f) 16 bit 高动态图




图14 (网刊彩色) 输出图像与高动态图像灰度曲线比较




图15 (网刊彩色) 修正后图像与高动态图像灰度曲线比较

由图 14 可知, 2 mm 区域的输出灰度值要比高动态图像中 2 mm 区域的灰度值小 400 左右. 这是由于测试材质铜与模型材质不同, 在对应的能量下衰减系数不同, 从而相应时间的灰度无法正确对应. 在此基础上利用灰度修正模型进行修正, 结果如图 13(e) 所示, 对比灰度曲线如图 15 所示. 分析可知: 修正后图像的灰度曲线与高动态图像的灰度曲线相一致, 能够正确表征工件的物理信息.

5 结 论

本文针对递变能量图像融合结果与实际高动态成像结果之间的物理对应性问题, 利用神经网络方法构建了灰度映射模型, 将递变能量图像融合过程中所涉及的 X 射线能谱、衰减系数以及探测器转换特性等因素, 综合为递变能量 X 射线成像系统的非线性传递函数, 并采用三层神经网络模型进行物理过程的近似估计; 同时, 依据衰减系数随射线能量的变化规律, 构建基于材质多谱衰减特性的灰度校正模型, 将不同能量下的图像灰度校正到最高能量对应的图像灰度, 修正了灰度映射过程中训练对象和检测对象的材质差异性, 实现了低动态图像序列融合图像的正确表征. 但是对内部材质未知的复杂异形工件, 所涉及的修正模型有待进一步研究, 需通过 X 射线多谱序列估计内部材质组成, 再进行灰度映射表征.

参考文献

- [1] Bi B, Li Z, Kuan S, Haina J 2013 *NDT E Int.* **58** 26
- [2] Krämer P, Weckenmann A 2010 *Measur. Sci. Technol.* **21** 1
- [3] Chen P, Han Y, Pan J X 2013 *Optik* **124** 3265
- [4] Chen P, Han Y, Pan J X 2013 *Spectrosc. Spectr. Anal.* **33** 1383 (in Chinese) [陈平, 韩焱, 潘晋孝 2013 光谱学与光谱分析 **33** 1383]
- [5] Liu B, Han Y, Pan J, Chen P 2014 *J. X Ray Sci. Technol.* **22** 241
- [6] Wei J T, Chen P, Pan J X 2013 *Chin. J. Stereol. Image Anal.* **18** 103 (in Chinese) [魏交统, 陈平, 潘晋孝 2013 中国体视学与图像分析 **18** 103]
- [7] Yang Y, Mou X Q, Luo T, Tang S J 2009 *Acta Photon. Sin.* **38** 2435 (in Chinese) [杨莹, 牟轩沁, 罗涛, 汤少杰 2009 光子学报 **38** 2435]
- [8] Fan J D, Jiang H D 2012 *Acta Phys. Sin.* **61** 218702 (in Chinese) [范家东, 江怀东 2012 物理学报 **61** 218702]
- [9] Liu L X, Du G H, Hu W, Xie H L, Xiao T Q 2007 *Acta Phys. Sin.* **56** 4556 (in Chinese) [刘丽想, 杜国浩, 胡雯, 谢红兰, 肖体乔 2007 物理学报 **56** 4556]
- [10] Wang J, Zhang H, Cheng X L 2013 *Chin. Phys. B* **22** 085201
- [11] Zhang J, Wang X W, Sun Y D 2011 *Comput. Tomography Theory Appl.* **20** 235 (in Chinese) [张健, 王学武, 孙运达 2011 CT 理论与应用研究 **20** 235]
- [12] Lee W J, Kim D S, Kang S W, Yi W J 2012 *34th Annual International Confer-Ence of the IEEE Engineering in Medicine and Biology Society California, USA, August 28–September 1, 2012* p1514
- [13] Torbati N, Ayatollahi A, Kermani A 2014 *Comput. Biol. Med.* **44** 76
- [14] Funahashi K 1989 *Neural Networks* **2** 183

Algorithm of high-dynamic fusion image gray characterization based on variable energy^{*}

Chen Ping^{1)2)†} Yin Xiao-Gang¹⁾ Pan Jin-Xiao¹⁾ Han Yan¹⁾

1) (*Key Laboratory of Instrumentation Science and Dynamic Measurement of Ministry of Education, Shanxi Key Laboratory of Signal Capturing and Processing, National Key Laboratory for Electronic Measurement Technology, North University of China, Taiyuan 030051, China*)

2) (*Key Laboratory of Molecular Imaging, Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China*)

(Received 3 April 2014; revised manuscript received 13 July 2014)

Abstract

X-ray imaging based on variable energy can expand the dynamic range of the imaging system and perfectly show the structure information of the detection objects, by acquiring and fusing the image sequences. However, the fusion method is ordinarily based on image quality optimization, and neglects the gray mapping accuracy of the actual high dynamic imaging. It cannot guarantee the physical matching between the image information and actual structure information. Therefore, in this paper we propose an X-ray image gray characterization algorithm of high dynamic fusion based on variable energy. First, take a standard wedge block as test object, and use the fusion image of low dynamic image sequences as input data. The output data are the actual high dynamic image. Then establish the X-ray imaging gray characterization model by neural network training. At the same time, because the attenuation coefficients of different heterogeneous materials are different, a modified model of physical characterization is established to achieve a correct characterization of real object. Finally, experiments by 12 bit and 16 bit imaging systems acquire the variable voltage image sequences using 12 bit detector. After image fusion, image mapping and gray level correction, the output image not only achieves the same effect of 16 bit detector, but also satisfies the gray relation. Also this method can effectively expand the dynamic range of the imaging system.

Keywords: variable energy, high dynamic, gray characterize, neural network

PACS: 87.59.-e, 41.50.+h, 85.60.Gz

DOI: 10.7498/aps.63.208703

* Project supported by the National Natural Science Foundation of China (Grant Nos. 61227003, 61171179, 61301259), the Natural Science Foundation of Shanxi Province, China (Grant No. 2012021011-2), the Specialized Research Fund for the Doctoral Program of Higher Education, China (Grant No. 20121420110006), the Shanxi Scholarship Council of China (Grant No. 2013-083), and the Top Science and Technology Innovation Teams of Higher Learning Institutions of Shanxi, China.

† Corresponding author. E-mail: pc0912@163.com