

doi: 10.7690/bgzd.2024.02.016

基于极度梯度提升模型的火炮身管寿命预测

邬书豪, 邵鹏志, 孟英谦, 彭 龙, 李胜昌

(中国兵器工业计算机应用技术研究所网络信息体系论证与研发部, 北京 100089)

摘要: 为提高火炮身管寿命预测的精度, 将身管内径磨损量作为寿命预测指标, 提出基于极度梯度提升(XGBoost)模型的火炮身管寿命预测算法。以火炮弹射数为输入, 身管内径磨损量为输出, 通过集成多个弱学习器反复训练来拟合前一个弱学习器预测值与实际值之间的残差, 从而生成强学习器, 并通过在损失函数后加入正则化项及采用剪枝技术降低模型过拟合的风险。基于某型火炮实测数据进行验证, 结果表明: 该模型不仅有效解决了火炮弹射量与身管内径磨损量之间的映射关系, 且相比支持向量机、BP神经网络、灰色模型等现有算法显著提升了身管寿命预测精度。

关键词: 火炮身管; 寿命预测; 极度梯度提升; 身管内径磨损

中图分类号: TJ38 **文献标志码:** A

Life Prediction of Gun Barrel Based on Extreme Gradient Boosting Model

Wu Shuhao, Shao Pengzhi, Meng Yingqian, Peng Long, Li Shengchang

(Demonstration and Research Department of Network Information System, Institute of Computer Application Technology, China North Industries Group Corporation Limited, Beijing 100089, China)

Abstract: In order to improve the accuracy of barrel life prediction, a barrel life prediction algorithm based on extreme gradient boost (XGBoost) model was proposed by taking the wear of barrel inner diameter as the life prediction index. Taking the number of artillery shells as the input and the barrel inner diameter wear as the output, the strong learner was generated by integrating multiple weak learners to fit the residual between the predicted value and the actual value of the previous weak learner, and the risk of model overfitting was reduced by adding a regularization term after the loss function and using pruning technology. The model is verified based on the measured data of a certain type of artillery, and the results show that the model not only effectively solves the mapping relationship between the artillery ejection quantity and the barrel inner diameter wear, but also significantly improves the barrel life prediction accuracy compared with the existing algorithms such as support vector machine, BP neural network and gray model.

Keywords: gun barrel; life prediction; extreme gradient boosting; wear of barrel inner diameter

0 引言

目前, 我国各类火炮性能已比较优越, 然而火炮的寿命与以美国为代表的发达国家相比仍有一定差距。身管是火炮的重要部件, 身管损坏达到一定程度则火炮无法投入使用; 因此, 身管寿命在一定程度上等同于火炮的使用寿命。各国学者从不同的角度对火炮身管寿命预测展开了研究。

文献[1-6]指出影响火炮身管烧蚀磨损寿命的主要因素包括膛内火药气体及弹丸对内膛表面金属产生的化学侵蚀、机械磨损以及高温烧蚀等; 文献[7]通过对烧蚀机理进行分析, 基于身管内表面融化冲刷导致身管径向扩大这一假设, 应用半无限大物体假设以及内表面熔化层理论模型, 得出了身管内壁熔化层厚度的定量计算方式。

文献[8]构建了灰色线性回归组合模型, 该组合

模型既具备灰色模型时序指数变化趋势又具备线性回归模型线性变化趋势, 针对某型火炮实际数据进行验证, 结果表明组合模型相比传统灰色模型有效提升了火炮身管寿命预测精度; 文献[9]构建出基于非等间隔灰色模型和BP神经网络的组合预测模型, 在灰色有效基础上神经网络非线性映射能力, 有效提升了身管磨损预测准确度。

文献[10]提出了基于支持向量机的身管剩余寿命预测模型, 通过将非线性问题转化成线性问题进行求解, 并通过对照某型坦克炮射击试验数据证明了其准确性。

文献[11-14]提出使用BP神经网络, 基于其卓越的非线性问题解决能力和泛化性能, 对坦克炮身管剩余寿命进行预测。试验结果表明, 基于BP神经网络构建的身管寿命预测模型相比灰色模型精度

收稿日期: 2023-10-18; 修回日期: 2023-11-15

第一作者: 邬书豪(1996—), 男, 湖北人, 硕士。

更高，但计算更加复杂，同时对数据量的要求也更高。

火炮身管寿命终止机理涉及高温高压、化学侵蚀、机械磨损等诸多方面，十分复杂。基于烧蚀机理构建的理论模型预测准确率较低，无法满足部队实际使用需求；基于小样本火炮退化数据，采用机器学习方法可有效地对火炮身管寿命进行预测，但其对模型的鲁棒性和泛化性要求较高。极度梯度提升 (XGBoost) 模型基于回归决策树 (classification regression decision tree, CART) 迭代拟合残差提高了预测准确率，已在工业上得到广泛应用，其计算准确率和运算效率要高于部分传统统计学习模型^[15]；因此，笔者采用 XGBoost 模型对火炮身管寿命进行预测。

1 CART 构建

针对火炮退化数据小样本、非间隔、非线性等问题，通过构建 CART 模型解决^[16]。CART 是典型的二叉树结构，通过将火炮弹射数取值划分成若干部分，使得每一部分对应一个身管内径磨损量，如图 1 所示。图中： X 为数据特征， c 为输出结果。对于火炮弹射量，按照特征将其归到某个单元，得到对应的身管内径磨损值。




图 1 CART 的基本架构

给定火炮试验训练数据集：

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}。 \quad (1)$$

式中： x 为火炮弹射量； y 为对应的身管内径磨损值； n 为火炮试验训练数据量。

对火炮弹射数取值的划分基于贪婪原则，每次划分逐一列举当前数据集中火炮弹射数的所有取值，依据平方误差最小化准则选择使得身管内径磨损预测值与实际值误差最小的点为切分点。假设对训练集中火炮弹射数为 s ，作为切分点，则对身管

内径磨损的预测可划分为 2 个区域：

$$R_1(s) = \{x | x \leq s\}； \quad (2)$$

$$R_2(s) = \{x | x > s\}。 \quad (3)$$

划分后 2 个区域平方误差和表达式为：

$$\text{error} = \sum_{x_i \in R_1(s)} (y_i - c_1)^2 + \sum_{x_i \in R_2(s)} (y_i - c_2)^2。 \quad (4)$$

式中：

$$c_1 = \frac{1}{n_1} \sum_{x_i \in R_1(s)} y_i； \quad (5)$$

$$c_2 = \frac{1}{n_2} \sum_{x_i \in R_2(s)} y_i。 \quad (6)$$

由此对式(4)进行求解得到最优的火炮弹射数切分点 s 后，将火炮弹射数输入分割成 2 个区间，然后对 2 个区间重复上述划分过程，直到满足设定的阈值。最终构建形成了一棵身管内径磨损回归决策树。

2 火炮身管寿命预测模型的构建

2.1 基于 XGBoost 的火炮身管寿命预测模型

XGBoost 是多棵 CART 的集成结果，通过不断构建新的身管内径磨损回归决策拟合前一棵树预测值与实际值之间的残差来提升精度，并将损失函数用二阶泰勒展开提升训练效率；同时，将树的复杂度加入目标函数中以避免出现过拟合现象。

假设火炮预计弹射数与身管内径磨损量的数学关系式为：

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in \mathcal{F} \quad (i=1, 2, \dots, n)； \quad (7)$$

$$F = \{f(x) = w_{q(x)}\}； \quad (8)$$

$$q: R \rightarrow \{1, 2, \dots, T\}, w \in R^T。 \quad (9)$$

式中： \hat{y} 为对应身管内径磨损的预测值； F 为决策树结构集合； K 为决策树个数； q 为样本映射到叶子节点的树结构； T 为叶子节点数； w 为叶节点的实数分数。

基于目标函数 (objective function, Obj) 最小化的原则求解得到使得模型达到最优状态时的模型参数。为保证预测模型无限逼近实际值的同时规避过拟合风险，在目标函数中加入模型复杂度因素，目标函数可写为：

$$\text{Obj} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{i=1}^K \Omega(f_k)。 \quad (10)$$

式中： $\sum_{i=1}^n l(y_i, \hat{y}_i)$ 为误差函数项； $\sum_{i=1}^K \Omega(f_k)$ 模型复杂度函数项。

XGBoost 模型的本质是在保证原有模型不变的基础上，加入新的决策函数到模型中，使得目标函数尽可能的趋近于 0，具体函数构建过程为：

$$\hat{y}_i^{(0)} = 0; \quad (11)$$

$$\hat{y}_i^{(1)} = \hat{y}_i^{(0)} + f_1(x_i); \quad (12)$$

$$\hat{y}_i^{(2)} = \hat{y}_i^{(1)} + f_2(x_i); \quad (13)$$

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i). \quad (14)$$

式中： $\hat{y}_i^{(t)}$ 为第 t 次模型的预测值； $f_t(x_i)$ 为第 t 次加入的新函数。此时目标函数可表示为：

$$\text{Obj}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t). \quad (15)$$

为求出使得目标函数最低时的参数值，将原始目标函数通过二阶泰勒展开进行变形，得到近似目标函数：

$$\text{Obj}^{(t)} \approx \sum_{i=1}^n \left[l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + h_i f_t^2(x_i)/2 \right] + \Omega(f_t). \quad (16)$$

式中： g_i 为损失函数 l 关于 $\hat{y}_i^{(t-1)}$ 的一阶偏导数； h_i 为损失函数 l 关于 $\hat{y}_i^{(t-1)}$ 的二阶偏导数。

由于 $t-1$ 棵树的结构已经确定，因此可去掉常数项，近似目标函数可表示为：

$$\text{Obj}^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + h_i f_t^2(x_i)/2 \right] + \Omega(f_t). \quad (17)$$

其中决策树的复杂项可表示为：

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2. \quad (18)$$

式中： γT 为 L_1 正则项； w_j^2 为 L_2 正则项。

则近似目标函数可表示为：

$$\text{Obj}^{(t)} \approx \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T. \quad (19)$$

式中： $\sum_{i \in I_j} g_i$ 为叶子结点 j 对属于结点 j 的所有样本的一阶偏导数累加之和，为常量，记作 G_j ； $\sum_{i \in I_j} h_i$ 为叶子结点 j 对属于结点 j 的所有样本的二阶偏导数累加之和，为常量，记作 H_j 。

对该目标函数进行求导，得到决策树每个叶子

结点的权重 w_j^* 以及最优目标函数值：

$$w_j^* = -G_j / (H_j + \lambda); \quad (20)$$

$$\text{Obj} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T. \quad (21)$$

通过反复递归调用上述身管内径磨损回归决策树的构建过程，得到大量回归决策树模型，并依据目标函数寻找求解最优的树结构，将其集合到已有的决策模型中，最终生成拟合效果最佳的火炮身管寿命预测模型。

2.2 基于信息增益 (Gain) 的模型剪枝

为保证基于 XGBoost 构建的决策树不会一直分裂下去，导致模型出现过拟合的情况，基于对 Gain 模型进行剪枝。

对于当前节点及对应数据集，分裂前损失为：

$$-\frac{1}{2} \frac{G^2}{H + \lambda} + \gamma. \quad (22)$$

按某一分裂点分裂成左右子树的损失和为分裂后损失：

$$-\frac{1}{2} \frac{G_L^2}{H_L + \lambda} - \frac{1}{2} \frac{G_R^2}{H_R + \lambda} + 2\gamma. \quad (23)$$

定义信息增益为分裂前损失减去分裂后损失。

Gain 可表示为：

$$\text{Gain} = \frac{1}{2} \left(\frac{G_L}{H_L + \lambda} + \frac{G_R}{H_R + \lambda} - \frac{G}{H + \lambda} \right) - \gamma. \quad (24)$$

若 Gain 为正，并且值越大，则表示分裂前损失越大于分裂后损失，越值得分裂，相反则越不值得分裂。遍历当前所有叶子节点，选择 Gain 最大时的分裂点。当 Gain < 0 时，停止分裂。同时，设置树的最大深度、叶子结点最小样本数等超参数来限制决策树的复杂度。

2.3 算法流程

基于 XGBoost 的火炮身管寿命预测算法流程如下：

- 1) 基于火炮退化数据，初始化每个弹射量对应的火炮身管内径磨损预测值。
- 2) 根据式(10)定义目标函数。
- 3) 根据式(19)化解目标函数。
- 4) 计算目标函数对于每个样本预测值的导数。
- 5) 根据式(20)和(24)构建一棵新的决策树。
- 6) 将刚生成的决策树集成到之前构建的决策树群中计算内径磨损值。

7) 如满足阈值要求, 停止计算, 得到最优的火炮身管寿命预测模型; 如不满足要求, 则返回 2), 创建新的决策树。

3 火炮身管寿命预测实例

火炮在完成一定射击发数后, 其身管不同位置的烧蚀磨损不同, 距离火炮身管发射起始部越近, 烧蚀磨损越为严重。此外, 多门火炮数据比一门火炮全生命周期数据更能反映身管寿命变化规律。笔者将同种型号火炮身管的起始部位的内径磨损作为研究对象, 根据多根同型号火炮身管全生命周期内不同弹射数下得到的磨损量数据如表 1 所示。

表 1 某型火炮射弹数 n 与磨损量 Δd 数据 mm

n	Δd	n	Δd
0	0	390	2.87
5	0.18	460	3.58
17	0.48	500	3.72
65	0.71	624	4.86
100	1.02	709	5.21
195	1.66	800	5.58
300	2.51	953	6.05
325	2.64	1 003	6.21

从上表中可以看出, 火炮弹射量与身管磨损量之间的关系不明显, 且数据样本较少, 火炮弹射数非等间隔分布。基于前 624 发射弹试验数据, 分别建立支持向量回归机(support vector regression, SVR)模型、灰色(GM(1, 1))模型、BP 神经网络以及基于 XGBoost 的火炮身管寿命预测模型, 对 709~1 003 发弹射数的预测结果进行验证。

实际磨损量与预测磨损量的均方根误差 (root mean square error, RMSE) 作为误差评判标准, 即

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (25)$$

分别对不同模型拟合效果、预测效果以及模型整体误差进行对比分析, 如图 2—4 所示。

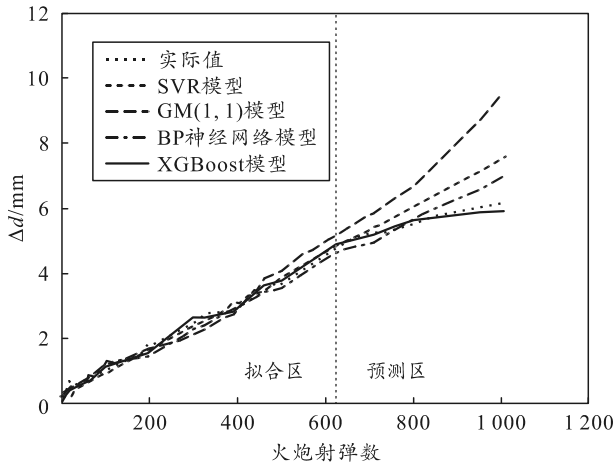


图 2 不同模型拟合预测效果




图 3 不同模型的相对误差

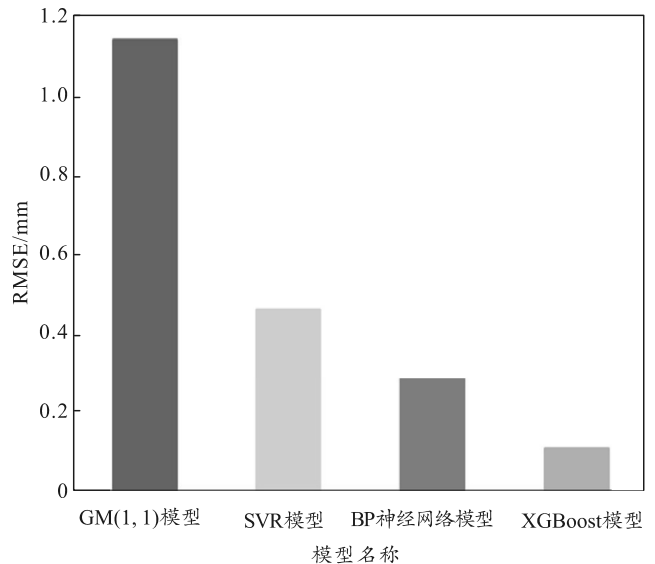


图 4 不同模型的均方根误差

从图中可以看出, GM(1, 1)模型误差最大, 其次是 SVR 模型和 BP 神经网络模型, 而笔者构建的极度梯度提升模型预测准确度最高。这是因为: GM(1, 1)模型偏向于分析时效性较强的数据, 而身管烧蚀磨损变化过程是中长期的过程, 导致使用 GM(1, 1)模型进行预测会有较大误差; SVR 和 BP 神经网络模型则出现了过拟合的情况, 导致模型在拟合区域精度较高, 而在预测区域误差较大; XGBoost 模型通过集成多颗决策树并对树进行剪枝, 在保证模型具有足够拟合精度的基础上, 有效提升了模型泛化性。

从表 1 可看出, 该型火炮磨损量在 $\Delta d=6.21$ mm 时寿命终止, 寿命终止时的实际最大弹射量为 1 003 发, 使用建立好的模型预测寿命终止时最大弹射量, 各模型预测值与相对误差如表 2 所示。

表 2 各模型预测值与相对误差

模型	预测值	相对误差/%
SVR 模型	861	14.15
GM(1,1)模型	748	25.42
BP 神经网络模型	936	6.68
XGBoost 模型	1 007	0.40

XGBoost 模型相对误差为 0.4%，远远高于其他模型。以上结果表明：XGBoost 模型不仅可以精准描述火炮弹射量与身管内径磨损量之间的关系，而且在身管寿命预测问题上，明显优于 SVR、BP 神经网络以及 GM(1, 1)模型。

4 结论

为提高火炮身管寿命预测准确度，笔者构建极度梯度提升模型来分析该问题。该预测模型不依赖大量发射试验，只需提供少量的原始试验数据便可准确预估某型火炮寿命终止时的最大射弹数；因此，模型更加健壮且符合实际作战需求。该模型的预测准确率高于灰色 GM(1,1)模型、SVR 模型和 BP 神经网络模型。基于该模型对某型火炮实测数据进行应用验证，结果表明该模型高效可信。

参考文献：

- [1] 许耀峰, 单春来, 刘朋科, 等. 火炮身管寿终机理及寿命预测方法研究综述[J]. 火炮发射与控制学报, 2020, 41(3): 89-94, 101.
- [2] 罗天放, 陈荣刚. 火炮身管寿命理论预测方法[J]. 兵工自动化, 2018, 37(6): 28-32.
- [3] 焦贵伟, 胡朝根. 火炮身管寿命评估预测[J]. 兵器装备工程学报, 2018, 39(5): 66-69, 74.
- [4] MOTES D, KEENA J, WOMACK K, et al. Thermal Analysis of High-Energy Railgun Tests[J]. IEEE Transactions on Plasma Science, 2012, 40(1): 124-130.
- [5] MYERS S H, SMITH A N. Demonstration of Combined Spray and Evaporative Cooling of an Electromagnetic Railgun[J]. IEEE Transactions on Magnetics, 2009, 45(1): 396-401.
- [6] ZOU L, YU C, FENG G, et al. Establishment of erosion model of gun steel material and study on its erosion performance[J]. Journal of Mechanical Science and Technology, 2020, 34(4): 2019-2026.
- [7] 李明涛, 崔万善, 姚哲, 等. 基于内表面熔化层理论的身管寿命预测方法[J]. 火炮发射与控制学报, 2009(2): 5-8.
- [8] 孟翔飞, 王昌明, 何博侠, 等. 基于灰色线性回归组合模型的火炮身管寿命预测[J]. 南京理工大学学报(自然科学版), 2012, 36(4): 635-638.
- [9] 易怀军, 刘宁, 张相炎, 等. 基于优化的非等间隔灰色理论和 BP 神经网络的身管磨损量预测[J]. 兵工学报, 2016, 37(12): 2220-2225.
- [10] 徐达, 武新星, 郭磊, 等. 基于最小二乘支持向量机的坦克炮身管剩余寿命预测方法[J]. 装甲兵工程学院学报, 2010, 24(1): 42-44.
- [11] 卞拥峰, 刘焕章, 王永彬, 等. 基于 BP 神经网络的坦克炮身管剩余寿命的预测分析[J]. 兵工自动化, 2009, 28(5): 34-35, 49.
- [12] 陈国利, 韩海波, 于东鹏. BP 神经网络的身管寿命预测方法[J]. 火力与指挥控制, 2008, 33(9): 146-148.
- [13] 杜中华, 孙雅娟, 薛德庆. 某型火炮身管寿命的 BP 网及多项式递推预测研究[J]. 机械, 2004, 31(1): 10-12.
- [14] 王国辉, 张宝栋, 李向荣. 基于遗传算法的 BP 神经网络火炮身管烧蚀磨损量预测[J]. 火炮发射与控制学报, 2019, 40(4): 6-10, 15.
- [15] CHEN T, GUESTRIN C. XGBoost: A Scalable Tree Boosting System[C]// The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 785-794.
- [16] LOH W Y. Classification and regression trees[J]. Wiley interdisciplinary reviews, 2011, 1(1): 14-23.