

# 基于极限梯度提升的完美匹配单层智能算法实现航空瞬变电磁问题高效吸收\*

冯乃星<sup>1)2)</sup> 王欢<sup>1)2)</sup> 朱子贤<sup>1)2)</sup> 董纯志<sup>1)2)</sup>  
李宏杨<sup>1)2)</sup> 张玉贤<sup>1)2)†</sup> 杨利霞<sup>1)2)</sup> 黄志祥<sup>1)2)‡</sup>

1) (安徽大学电子信息工程学院, 合肥 230601)

2) (安徽大学, 智能计算与信号处理教育部重点实验室, 合肥 230601)

(2023年10月29日收到; 2023年12月13日收到修改稿)

对于航空瞬变电磁的低频探地问题, 除了精度和效率需要考虑, 深地探测问题的复杂度也不容忽视, 特别是对于低频复杂问题存在异常体与背景间的多尺度效应. 为了模拟开域问题, 有限厚度区域的完全匹配层被用于截断计算域, 然而这也无形中增大了整个模型, 造成计算复杂度增加. 鉴于此, 提出了一种新的基于极限梯度提升 (extreme gradient boosting, XGB) 的完美匹配单层模型, 并将该模型集成到时域有限差分求解器中, 以进一步提高时域有限差分仿真的性能. 所提出的基于 XGB 的完美匹配单层模型通过特征注意力集成学习方法可以获得更高的精度, 同时占用更少的内存、消耗更少的时间. 此外, 由于该模型依托于传统机器学习模型, 因此它在模型训练的稳定性和轻量级方面具有显著的优势. 最后, 通过对航空瞬变电磁应用进行三维数值模拟, 验证了该方法的有效性和稳定性. 该模型不仅在精度、效率和问题复杂性方面具有优势, 而且还可以成功地集成到时域有限差分求解器中, 解决低频航空瞬变电磁问题.

**关键词:** 极限梯度提升, 完美匹配单层, 机器学习, 时域有限差分

**PACS:** 52.25.Os, 92.60.Ta, 47.11.Bc, 87.85.dq

**DOI:** 10.7498/aps.73.20231724

## 1 引言

基于极低频激发源的航空瞬变电磁 (airborne transient electromagnetics, ATEMs) 问题<sup>[1-3]</sup>可以用时域有限差分 (finite-difference time-domain, FDTD) 方法<sup>[4-11]</sup>来解决, 这是应用最广泛的先进数值方法之一. 目前, 显式和隐式的 FDTD 方法分别被用于处理 ATEM 问题, 而这两种方法本身面临着不同的挑战. 对于显式方法, 主要存在两大挑战: 1) 低频地下探测问题需要非常高的空间采样密度, 这样就需要大量的时间步长; 2) 准确、高

效地求解电磁波与开放区域内的极损介质相互作用需要通过吸收边界条件 (absorbing boundary condition, ABC<sup>[12-15]</sup>) 来截断物理区域. 对于隐式方法, 受色散误差、分割误差、近似误差和非对称效应<sup>[16-19]</sup>的影响, 会衍生出严重的计算精度误差问题; 此外, 稀疏矩阵的求逆计算也是不可避免的. 无论是显式方法, 还是隐式方法, 都有其各自要面对的难题, 而本文就是针对前两种方法面对的挑战, 通过引入新的方法或技术, 使得无论在精度、效率还是仿真问题复杂度上都能够取得好的性能.

近年来, 随着人工智能 (artificial intelligence, AI) 的蓬勃发展, 基于机器学习 (machine learning,

\* 国家自然科学基金 (批准号: 62271001) 和安徽省自然科学基金 (批准号: 2308085Y39, 2022AH030014) 资助的课题.

† 通信作者. E-mail: yxzhang\_tute@126.com

‡ 通信作者. E-mail: zxhuang@ahu.edu.cn

ML) 的实现<sup>[20]</sup> 被广泛应用于许多不同的工程和科学问题上. ML 能够从具有相同模式的训练数据中提取潜在的映射规律, 从而能够预测并产生一个新的输出. 因其自适应、非线性建模和数据驱动等特性, ML 可以移植到多种应用中, 如基于超材料的逆设计<sup>[21,22]</sup>、超表面成像仪<sup>[23]</sup>、可编程光子电路<sup>[24]</sup>、深度学习皮肤传感器<sup>[25]</sup>、一种可基于石墨烯在吸收和透射间快速静电调制的频选反射器<sup>[26]</sup>、基于层状石墨烯光子结构的优化单向角度不敏感超宽带吸收器<sup>[27]</sup> 等.

最近, 基于 ML 的完美匹配层 (perfectly matched layer, PML) 分裂场方案的双曲正切基函数 (hyperbolic tangent basis function, HTBF)<sup>[26]</sup> 模型被用于取代传统的有限厚度的 ABC 区域, 规避了根据当前和之前步骤中的局部和邻近场来获取局部场的整个模拟过程中的圆形计算处理. 这充分证明, ML 技术可以被应用到数值方法中, 以避免在 ABC 区域内的重复过程.

随后, 为了进一步有效地削弱强隐失波, 并在更大程度上节省计算机资源, 开发了基于深度可微森林 (deep differentiable forest, DDF) 的完美匹配单层 (perfectly matched monolayer, PMM) 模型和基于非分裂场的复频率偏移 (complex-frequency-shifted, CFS) CFS-PML 方案用于二维电磁问题模拟<sup>[27]</sup>. 通过仿真结果验证, 基于 DDF 的 PMM 不仅可以取代传统的 PML, 而且具有较高计算精度并可以成功集成到 FDTD 的计算过程中.

继上述二维 EM 问题, 将本算法应用于三维微带传输线问题的求解可进一步验证 ML 方法的通用性、准确性与高效性. 因此, 选择可以利用可区分的注意机制来访问外部内存库中数据/程序的神经图灵机 (neural turing machine, NTM) 模型合并到基于 DDT<sup>[28]</sup> 的 FDTD 求解器中来提高计算效率. 所提出的基于 DDT 的 NTM 模型对三维微带传输线可获得约 95% 的高精度.

然而, 在提出的基于 DDT 的 NTM 模型<sup>[28]</sup> 中, 只考虑了单极 CFS-PML 方案, 因此它在吸收低频传播波方面的效果远不如基于单极拉伸坐标的 PML (stretched-coordinate based PML, SC-PML) 方案, 特别是对于三维低频 ATEM 应用. 为了克服上述有/无 CFS 方案的局限性, 提出了一些多极 PML<sup>[29-31]</sup> 可以明显衰弱强低频传播和隐失波. 此外, 双极 PML (two-pole PML, TP-PML) 被

验证是一种更好的选择<sup>[32]</sup>, 与多极 PMLs (multipole PML, MP-PML) ( $n > 2$ ) 相比, 它不仅需要更少的 CPU 时间和内存, 而且保持了几乎相同的吸收精度.

本文主要关注进一步提高低频 ATEM 问题的算法精度和降低问题复杂度, 因此考虑了基于  $Z$  变换技术的 TP-PML 方案对开放区域问题进行建模. 为了实现更高的预测精度和进一步降低问题的复杂度, 本文提出了一种高效、准确的基于极限梯度提升 (extreme gradient boosting, XGB) 的 PMM 模型来取代传统的有限厚度 PML. 所提出的基于 XGB 的 PMM 模型通过特征注意的集成学习方法, 可以获得更高的精度, 同时实现更少的内存和 CPU 时间消耗. 此外, 基于传统 ML 模型的特点, 该模型在模型训练的稳定性 and 模型轻量级方面具有显著的优势. 这种方法在这里被称为基于 XGB 的 PMM 模型. 在这项工作中, 该方案不仅对三维低频 ATEM 问题具有较高的精度和效率, 而且可以集成到 FDTD 求解器中, 并与一般差分方法兼容性.

全文的研究流程框架安排如下, 第 1 节为全文的引言, 介绍关于深地探测低频问题建模求解过程中, 显/隐式数值算法在求解过程中所面临的挑战, 并通过引入当前机器学习技术克服相关的困难, 从而引出本文的工作要点; 其次, 第 2 节是对基于机器学习的完全匹配层吸收边界条件模型算法的提出、训练、预测及优化进行阐述; 第 3 节则是通过相关的深地探测问题去验证所提出算法模型的有效性 and 准确性, 用于测试所提出模型算法的稳定性和精度是否达标; 最后, 对全文工作的总结.

## 2 基于 XGB 的完美匹配单层模型

自从由 Berenger<sup>[33]</sup> 提出了完全匹配层吸收边界条件以来, 各种完全匹配层实现算法已经用于截断时域有限差分网格. 拉伸坐标完全匹配层<sup>[34]</sup> 是将麦克斯韦方程组中的两个旋度方程映射到复数拉伸坐标空间, 其优点是在完全匹配层的角和棱上的实现非常简单. 与最初 Berenger 的完全匹配层一样, 拉伸坐标完全匹配层对隐失波的吸收无效<sup>[34]</sup>. 随后, 复频率偏移完全匹配层<sup>[35]</sup> 的出现备受关注, 这是由于复频率偏移完全匹配层能够更有效地衰减低频隐失波以及减少电磁相互作用过程中后期

的反射<sup>[36]</sup>, 其实现是通过简单地将复平面的极点从实轴移动到负虚半平面上实现的. 在文献<sup>[36]</sup>中, 基于拉伸坐标完全匹配层公式和卷积定理提出的卷积完全匹配层能够有效地实现复频率偏移完全匹配层. 然而, 复频率偏移完全匹配层对低频行波的吸收效果较差<sup>[37-39]</sup>. 因此, 为了可以同时吸收行波和隐失波, 双极 PML 被提出并证实其具备同时吸收二者的性能. 在本文中, 所采用的就是双极 PML 吸收边界条件进行区域截断并收集数据集, 用于后期神经网络模型的训练.

PML ABC 通常被用来截断计算区域, 从而得到一个开放域. 一般来说, 使用的是有限厚度层, 比如 8 层、10 层或更多层, 这将导致额外的资源消耗, 扩大了问题的复杂性. PML 最优参数 (如  $\alpha$ ,  $\kappa$  和  $\sigma$  等) 的选择主要凭借经验以获得满意的吸收精度, 因此在试错时会耗费大量时间成本. 为了克服这些问题, 提出了基于 XGB 的 PMM 模型, 从而取代传统的 PML 方案进行计算区域的截断.

在第 1 节中已经讨论过, 基于 XGB 的 PMM 模型在模型训练稳定性和模型轻量级方面具有明显的优势, 其训练过程, 如图 1 所示.

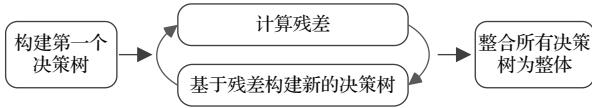


图 1 XGB 的训练过程

Fig. 1. Training process of XGB.

现在, 对相关的表达式和符号作详细推导, 以便能够清晰、正确地描述模型的细节. 本文有  $N$  个样本, 其数据集表示为  $X = \{x_1, x_2, \dots, x_N\}$ , 对应的目标值定义为  $Y = \{y_1, y_2, \dots, y_N\}$ . 根据不同的增强模式, XGB 模型可以学习  $K$  个决策树, 这些决策树的装配表示为  $\{T_1, T_2, \dots, T_N\}$ , 从而训练一个新的决策树并将其添加到模型中以减少迭代训练过程中的损失值, 如下所示:

$$\hat{Y} = \hat{y}_1 + \hat{y}_2 + \dots + \hat{y}_N = \sum_{i=1}^K T_i(x), \quad (1)$$

其中  $\hat{y}$  是模型的预测值, 同时也是所有决策树预测值的累加, 这意味着模型的训练可以视为多次对单个决策树的训练.

对于在算法流程图中构建单个决策树的构建过程, 只关注以下表达式:

$$L = \sum_{i=1}^a (y_i^A - c_1)^2 + \sum_{i=1}^b (y_i^B - c_2)^2, \quad (2)$$

$$c = \arg \min_c \sum_{i=1}^n (y_i - c)^2. \quad (3)$$

$Y_A, Y_B$  是通过将数据预测值以大小排序并随机取值将样品分为小于随机值和大于随机值的两部分:

$$Y_A = \{y_1^A, y_2^A, \dots, y_a^A\}, \quad Y_B = \{y_1^B, y_2^B, \dots, y_b^B\}.$$

(2) 式的具体作用是指导决策树单个节点对数据集的划分取值, 它在 (2) 式划分叶节点的具体方法是多次取不同数据预测值的中间值将数据集划分为不同的两组并用  $c_1, c_2$  作为两组数据的预测值, 可以根据实际情况选择损失函数 Loss, 预测值  $c_1$  和  $c_2$  可以通过求解 (3) 式得到最优的结果. 通过多次将数据一分为二, 二分为四将构成类似树状结构, 而  $c_1$  和  $c_2$  也将被计算的越来越精确, 因为数据的规模越来越小, 达到最小的一两个数据为一组时, 几乎没有误差.

上述介绍决策树构建的简单流程, 接下来将确定 XGB 的目标函数来规定算法整体公式: 已知训练数据集  $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ , 损失函数  $l(y_i, \hat{y}_i)$ , 正则化项  $\Omega(f_k)$ , 则构造整体目标函数为

$$L(\theta) = \sum_i l(y_i, \hat{y}_i) + \sum_k \Omega(f_k),$$

其中  $i$  是第  $i$  个样本,  $k$  是第  $k$  棵树.  $\hat{y}_i$  是第  $i$  个样本的预测值:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) = \hat{y}_i^{(k-1)} + f_k(x_i).$$

XGB 的损失函数  $l(y_i, \hat{y}_i)$  在计算中采用二阶泰勒展开:

$$f(x) \approx f(x_0) + f'(x_0)(x - x_0) + \frac{f''(x_0)}{2}(x - x_0)^2.$$

将上式代入目标函数并记一阶导数为  $g$ , 二阶导数为  $h$ , 得到最终结果为

$$L = \sum_{i=1}^n \left[ l(y_i, \hat{y}_i^{k-1}) + g_i f_k(x_i) + \frac{1}{2} h_i f_k^2(x_i) \right] + \sum_k \Omega(f_k),$$

其中  $l(y_i, \hat{y}_i^{k-1})$  是前一棵树构造时的损失函数, 作为常数项可以略去, 得到目标函数为

$$L = \sum_{i=1}^n \left[ g_i f_k(x_i) + \frac{1}{2} h_i f_k^2(x_i) \right] + \sum_k \Omega(f_k).$$

正则化项由两个部分构成, 叶子节点数量  $T$  与叶子节点权重向量  $\omega$ , 公式如下:

$$\sum_k \Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2.$$

以此方式约束叶子节点的数量和权重范围.

在单棵树的分裂过程中, 定义如下两个参数:

$$G_j = \sum g_i,$$

$$H_j = \sum h_i.$$

代入目标函数后化简得到

$$L = \sum_{j=1}^T \left[ G_j x_j + \frac{1}{2} (H_j + \lambda) x_j^2 \right] + \gamma T.$$

而针对叶子节点划分方式的最优计算则求解如下函数的最优解:

$$f(x) = Gx + \frac{1}{2} (H + \lambda)x.$$

在  $w_j = -\frac{G_j}{H_j + \lambda}$  时, 取得最小值  $\min f(w_j) = -\frac{1}{2} \frac{G_j^2}{H_j + \lambda}$ . 最终目标值求解为

$$\min O = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T,$$

其中  $\lambda$  和  $\gamma$  为超参数, 用于约束模型的复杂度和深度.

增强的迭代方法表明, 在下次迭代启动之前需要前一次迭代的残差, 残差将作为下一个决策树的训练集用于训练下一个决策树, 并直接与基础模型相加来直接降低模型的偏差, 因此, XGB 模型选择负梯度近似残差, 如下式所示:

$$F_{i+1}(x) = F_i(x) + T_i(x), \quad (4)$$

$$m_i = \frac{\partial L(y_i, F(x_i))}{\partial F(x_i)}. \quad (5)$$

(4) 式显示了残差的计算方法, 在每个单个决策树构建完成后, 首先根据 (4) 式将单个决策树整合到整个模型中, 然后用 (5) 式计算新的残差以获得新的残差数据  $M = \{m_1, m_2, \dots, m_N\}$ .

这些残差数据与样本数据集  $X = \{x_1, x_2, \dots, x_N\}$  一一对应. 除了第 1 个决策树是基于  $X$  和  $Y$  之间的对应关系所构造之外, 后续的决策树都是基

于  $X$  和  $M$  之间的对应关系构造的.

在传统的开域问题的 FDTD 模拟中, 有限的 PML 层 (如 8 或 10 层) 通常用于终止物理域, 这导致模拟过程需要大量的 CPU 时间和内存来处理吸收边界. 为了解决这两个问题, 本文将重点介绍用基于 XGB 的 PML 模型来开发和实现 FDTD 域的终止.

本节构建了一个基于多个决策树和注意机制的 XGB 模型, 如表 1 所列. 一般来说, XGB 是一个集成学习方法, 通过迭代来训练决策树和注意样本与之前的模型预测误差, 在整个仿真期间, 根据当前及前一时间步内的局部和邻近场所取得的局部场的循环计算过程可以避免. 在前面的介绍中, 已经详细说明了 XGB 的具体逻辑, 其中损失函数的选择和一些关键的超参数是至关重要的. 结果表明, 当单个决策树的最大深度为 10, 最小样本的分割数为 8, 单个采样比为 90% 并采用均方误差作为损失函数时, 模型的性能更加理想.

表 1 基于 XGB 的 ABC 模型算法

Table 1. XGB-based ABC algorithms.

**算法** 基于 XGB 的 ABC 模型

**输入**

训练集、验证集、测试集

**初始化**

初始化第一颗决策树  $T_1$ , 并基于目标函数最小来计算决策树权重:

$$\min O = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T,$$

$$w_j = -\frac{G_j}{H_j + \lambda}$$

初始化总模型并将第一棵树加入  $F_1(x) = T_1$

初始化残差变量空间  $M$

**循环**

计算总模型残差:

$$L = \sum_{j=1}^T \left[ G_j x_j + \frac{1}{2} (H_j + \lambda) x_j^2 \right] + \gamma T$$

基于残差数据构建新的决策树  $T_i$ :

$$\min O = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T,$$

$$w_j = -\frac{G_j}{H_j + \lambda}$$

更新总模型:

$$F_{i+1}(x) = F_i(x) + T_i(x)$$

在验证集中测试模型

**停止** 收敛或达到预设迭代次数

为了进一步验证所提出的基于 XGB 的 ABC 模型, 进行了数值计算. 如图 2 所示, 三维模型的几何形状分别由空气、岩石和矿体组成. 该矿体是一个深度为 536 m, 宽度为 536 m, 高度为 536 m 的立方体, 且其中心位于 (2010 m, 2010 m, 670 m), 其电导率为 4 S/m, 岩石的电导率为 0.005 S/m. 空间用的均匀网格在三个方向均为 67 m 离散化. 仿真是在 4020 m × 4020 m × 1876 m 的区域下完成的.




图 2 三维 ATEM 问题的几何模型  
Fig. 2. Geometry of 3D ATEM Problem.

本文采用的样本量共为 295200 组, 每次采样包括 15 个元素, 分别是  $ex\_it1, ex\_it2, ex\_it3, ex\_it4, ey\_it1, ey\_it2, ey\_it3, ey\_it4, hz\_it1, hz\_it2, hz\_it3, hz\_it4, ex\_ot, ey\_ot, hz\_ot$ . 这些数据被用于学习一个新模型, 用于预测电场与磁场的数值. 每组所耗时 332.06 s, 共耗时近 27.23 h. 文中使用了 295200 个样本作为训练数据, 训练集的样本量为 20 万, 验证集和测试集的样本量为 47600 个. 该模型大约需要 81.3 s 来训练 60 次迭代, 而预测 295200 测试集样本只需要 0.298 s. 虽然模型在训练过程中只能进行连续训练, 但在推理阶段也可以并行执行, 以显著提高速度. 该模型的内存使用量为 4.08 MB.

在初始模型的设计中, 我们的目的是设计一系列的实验来确定模型的三个重要的超参数, 包括树的最大深度, 叶片的最小样本分裂数, 以及单个样本的采样率. 如图 3 所示, 实验结果表明, 更深的树状结构可以更好地学习数据之间的潜在相关性, 因此, 我们选择的最大深度为 8. 为了确保模型具有更强的泛化能力, 在这里选择了 90% 的单样本采样率.

用上述的超参数对所提出模型进行训练, 然后

应用该模型来预测样本的  $E_x, E_y$  和  $H_z$ . 通过预测值与真实值之间的相对误差  $e$  来衡量精度  $A$ , 如下式所示:

$$e = \frac{\sqrt{\sum_{i=1}^n |t_i^2 - \hat{t}_i^2|}}{\sqrt{\sum_{i=1}^n t_i^2}}, A = 1.0 - e. \quad (6)$$




图 3 训练过程的精度 (a) 树深度; (b) 叶片的最小样本分割数; (c) 单个样本的抽样比

Fig. 3. Accuracies of training process: (a) Tree depth; (b) minimum number of sample splits for the leaves; (c) sampling ratio for a single sample.

从图 4 可以看到, 以 (6) 式计算的指标作为参考, 所提模型的  $E_x, E_y, H_z$  的精度分别为 97.6%,

98.7%, 98%. XGB 模型长期以来广泛应用于各个领域,但在数值分布稳定均匀的数值模拟领域仍占有一席之地.在未来,还可以通过 XGB 的特定调试来实现更高的精度和效率.




图 4 训练过程中  $E_x$ ,  $E_y$ ,  $H_z$  的相对误差  
Fig. 4. Relative errors of  $E_x$ ,  $E_y$ , and  $H_z$  during the training process.

### 3 数值实例及讨论

为了验证所提出的基于 XGB 模型的准确率和效率,考虑了两种不同源的更复杂的 ATEM 问题,分别为案例 A——接地线源;案例 B——机载磁偶极子源.图 5 中的“案例 A 和案例 B”代表本节中的两个不同的例子.案例 A 中,接地线源  $J_x$  被置于岩石上方,案例 B 中,磁点偶极子源  $M_x$  位于空气中.

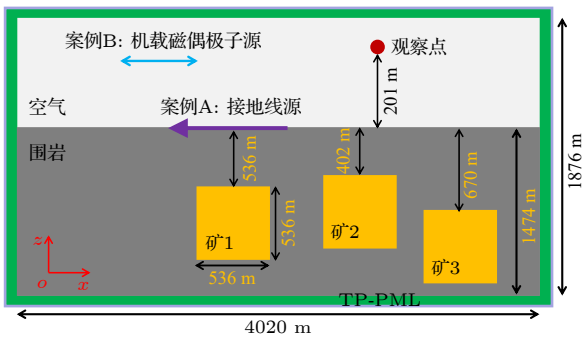


图 5 三维 ATEM 问题的几何模型  
Fig. 5. Geometry of 3D ATEM problems.

从图 5 可以看到,信号源是由重复频率为 25 Hz 的双极方波脉冲所激发产生.图 6 展示了一个周期(即 0.04 s)的脉冲波形.

#### 案例 A 地面上的线源和目标

案例 A 中进行模拟的水平电流线源  $J_x$  位于地

表上,这是典型的大地航空瞬变电磁,如图 5 中的“案例 A”所示.线源  $J_x$  从 (1943 m, 2010 m, 1474 m) 到 (2077 m, 2010 m, 1474 m),其几何外观分别由空气、岩石和矿石组成,如图 5 所示.每个矿山都是深度为 536 m、宽度为 536 m、高度为 536 m 的立方体,其电导率  $\sigma_{\text{ore}}$  为 4 S/m,岩石的电导率为  $\sigma_{\text{rock}}$  为 0.005 S/m.整个空间用  $\Delta x = \Delta y = \Delta z = 67$  m 的均匀网格离散化.物理域的深度为 4020 m、宽度为 4020 m、高度为 1876 m.




图 6 双极方波脉冲,持续时间为 0.04 s,上升时间为 0.0025 s,下降时间为 0.0125 s

Fig. 6. Bipolar square wave pulse with duration of 0.04 s, rise time 0.0025 s, and fall time 0.0025 s.

如图 5 所示,为了使结构复杂,在岩石层中嵌入了 3 个矿体,以验证所提出的基于 XGB 的模型的鲁棒性和有效性.接下来,用五种方法对案例 A 进行分析,这些方法包括具有 10 层 PML 截断的传统 FDTD 方法,具有 5 层 CFS-PML 截断的隐式 FDTD 方法,内嵌复频率因子的深度可微森林完全匹配单层模型,内嵌复频率因子的深度决策神经网络图灵机模型,及内嵌双极因子的梯度增强决策树完全匹配单层模型.

如图 7(a) 所示,在窗口的水平轴上设置时间长度为 0.16 s 以观察接收机所在位置的二次磁场(即矿体目标的总场  $H_z$  减去无矿石的主场  $H_{z0}$ ) 的稳定性.从图 7(a) 和表 2 可以看出,所提出的基于 XGB 的 PMM 模型不仅比基于 DDF 的 PMM 模型和基于 DDT 的 NTM 模型有着更高的精度,而且计算效率比传统的隐式 FDTD 方法更快.此外,在基于 XGB 的 PMM 模型中,只考虑了单层 PML,从而降低了问题的复杂性.

为了保证吸收性能可以满足工程问题的要求,进行了相对反射误差与时间关系的研究.从图 7(b)

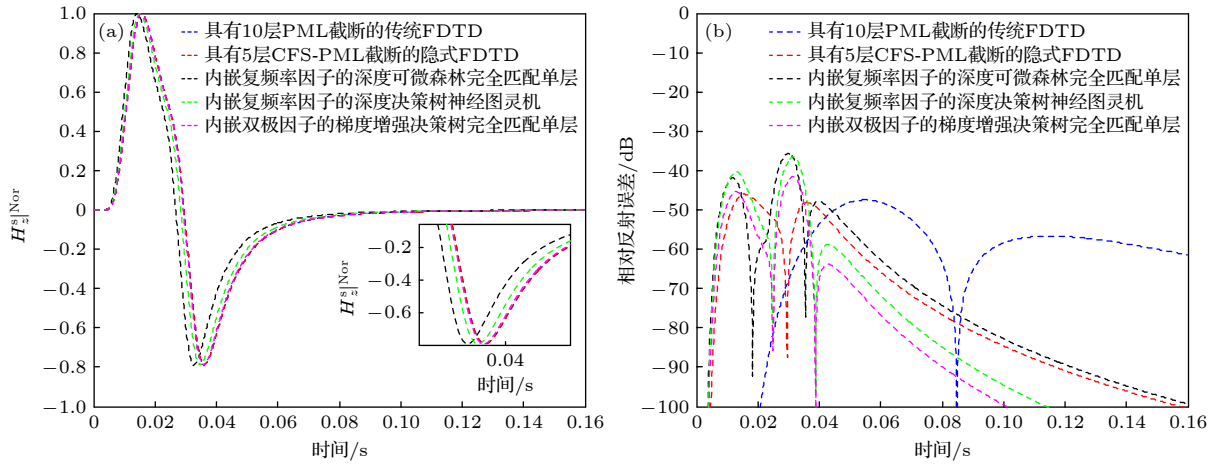


图 7 对于案例 A, 利用五种不同方法所取得的二次磁场 (a) 时间轴上二次场数值解与预测解对比; (b) 相对反射误差计算  
 Fig. 7. Secondary  $H_z$  achieved by five different methods for case A: (a) Comparison of secondary  $H_z$  field between numerical methods and machine learning methods; (b) computation of relative reflection errors.

表 2 以 0.04 s 为周期的计算时间

Table 2. Computational time for 0.04 s as a period.

不同实现方法	CPU 所耗时间/s
具有 10 层 PML 截断的传统 FDTD 方法	9711.21
具有 5 层 CFS-PML 截断的隐式 FDTD 方法	342.06
内嵌复频率因子的深度可微森林完全匹配单层模型	115.21
内嵌复频率因子的深度决策树神经图灵机模型	114.51
内嵌双极因子的梯度增强决策树完全匹配单层模型	112.33

可以看到, 具有 10 层 PML 截断的传统 FDTD 方法, 具有 5 层 CFS-PML 截断的隐式 FDTD 方法, 内嵌复频率因子的深度可微森林完全匹配单层模型, 内嵌复频率因子的深度决策树神经图灵机模型, 及内嵌双极因子的梯度增强决策树完全匹配单层模的最大相对误差分别为  $-47.49$  dB,  $-46.02$  dB,  $-35.68$  dB,  $-36.59$  dB 和  $-41.59$  dB. 最后, 结果表明, 与基于 DDF 的 PMM 模型和基于 DDT 的 NTM 模型相比, 所提出的基于 XGB 的 PMM 模型达到了工程应用的要求 (低于  $-40$  dB).

从案例 A 可以得出如下结论: 1) 所提出模型可以实现良好吸收精度类似于传统 FDTD 方法和隐式 FDTD 方法; 2) 所提出模型仅采用单层 PML, 可以大大降低问题的复杂度; 3) 所提出模型与传统的 FDTD 方法和隐式 FDTD 方法在二次磁场  $H_z$  上可以得到良好的一致性; 4) 所提出模型的计算时间比其他方法少, 尤其是传统的 FDTD 方法; 5) 所提出模型能获得更好的数值精度和吸

收精度.

### 案例 B 机载磁偶极子源和目标

为了进一步验证所提出模型的鲁棒性, 对案例 B 也进行了研究. 如图 5 所示, 案例 B 的配置与案例 A 的配置相同. 磁点偶极子源  $M_x$  位于表面上方, 由一个重复频率为 25 Hz 的双极方波脉冲激发.

由图 8(a) 可知, 所提出的基于 XGB 的 PMM 模型不仅与传统的 FDTD 方法和隐式 FDTD 方法有很好的 consistency, 而且在数值精度方面优于其他机器学习方法, 这与案例 A 相似. 此外, 通过对相对反射误差与时间关系的研究来观察这些方法的吸收精度. 如图 8(b) 所示, 所提出的基于 XGB 的模型的最大相对误差与传统的 FDTD 方法和隐式 FDTD 方法相似, 这些方法可以满足电磁工程问题中对吸收精度要求的最低标准.

为了保证吸收性能可以满足工程问题的要求, 进行了相对反射误差与时间关系的研究. 从图 8(b) 可以看到, 具有 10 层 PML 截断的传统 FDTD 方法, 具有 5 层 CFS-PML 截断的隐式 FDTD 方法, 内嵌复频率因子的深度可微森林完全匹配单层模型, 内嵌复频率因子的深度决策树神经图灵机模型, 及内嵌双极因子的梯度增强决策树完全匹配单层模的最大相对误差分别为  $-47.26$  dB,  $-47.02$  dB,  $-35.29$  dB,  $-36.98$  dB 和  $-41.98$  dB. 最终结果表明, 与基于 DDF 的 PMM 模型和基于 DDT 的 NTM 模型相比, 所提出的基于 XGB 的 PMM 模型符合工程应用的要求 (低于  $-40$  dB).

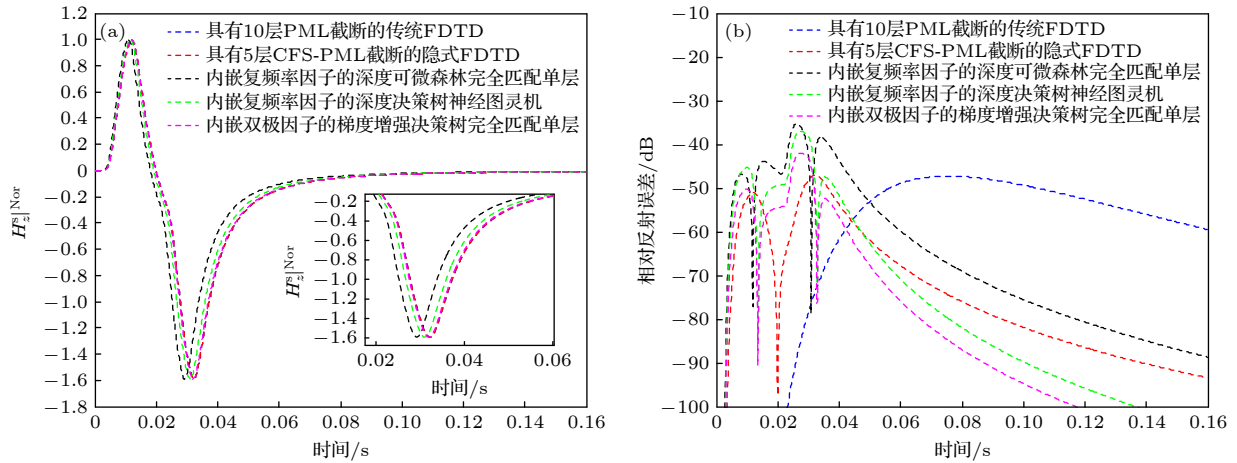


图 8 对于案例 B, 利用五种不同方法所取得的二次磁场 (a) 时间轴上二次场数值解与预测解对比; (b) 相对反射误差计算  
Fig. 8. Secondary  $H_z$  achieved by five different methods for case B: (a) Comparison of secondary  $H_z$  field between numerical methods and machine learning methods; (b) computation of relative reflection errors.

## 4 结 论

本文提出了一种基于 XGB 模型可替代 PMM 方法来解决极低频 ATEM 地下探测问题. XGB 技术可以获得较高的精度和效率, 最终数值结果表明, 所提出的 PMM 模型不仅能在数值和吸收的准确率上与传统的 FDTD 方法和隐式 FDTD 方法达到较好的一致性, 而且在很大程度上降低了问题的复杂度, 从而节省了更多的计算资源. 此外, 由于将基于  $Z$  变换方法的 TP-PML 方案纳入基于 XGB 的 PMM 模型中, 使得系统的求解精度得到了进一步的提高. 鉴于此, 可以看到, 所提出的模型可以成功地集成到 FDTD 求解器中来解决 ATEM 问题的建模.

## 参考文献

- [1] Liu H, Zhao X, Yu Y, Qiu S, Ji Y 2023 *IEEE Trans. Geosci. Remote Sens.* **61** 2002114
- [2] Feng N, Zhang Y, Sun Q, Zhu J, Joines W, Liu Q 2018 *IEEE Trans. Antennas Propag.* **66** 2967
- [3] Qi Y Z, Huang L, Zhang J G, Fang G Y 2013 *Acta Phys. Sin.* **62** 234201 [齐有政, 黄玲, 张建国, 方广有 2013 物理学报 **62** 234201]
- [4] Chen J, Li J, Liu Q 2017 *IEEE Trans. Antennas Propag.* **65** 1896
- [5] Mou C H, Chen J, Fan K H, Lu Y 2022 *Acta Phys. Sin.* **71** 184101 [牟春晖, 陈娟, 范凯航, 鲁艺 2022 物理学报 **71** 184101]
- [6] Xie G D, Hou G L, Niu K K, Feng N X, Fang M, Li Y S, Huang Z X 2023 *Acta Phys. Sin.* **72** 150201 [谢国大, 侯桂林, 牛凯坤, 冯乃星, 方明, 李迎松, 黄志祥 2023 物理学报 **72** 150201]
- [7] Chen J 2018 *J. Comput. Phys.* **363** 256
- [8] Wang F, Wei B, Li L Q 2014 *Acta Phys. Sin.* **63** 104101 [王
- [9] Wang J, Yin W 2013 *IEEE Trans. Antennas Propag.* **61** 299
- [10] Zhu X M, Ren X C, Guo L X 2014 *Acta Phys. Sin.* **63** 054101 [朱小敏, 任新成, 郭立新 2014 物理学报 **63** 054101]
- [11] Zhang Y, Feng N, Wang L, Guan Z, Liu Q 2020 *IEEE Trans. Antennas Propag.* **68** 366
- [12] Zhan Q, Zhuang M, Sun Q, Ren Q, Ren Y, Mao Y, Liu Q 2017 *IEEE Trans. Geosci. Remote Sens.* **55** 5577
- [13] Fang Y, Xi X, Wu J, Liu J, Pu Y 2016 *IEEE Trans. Microwave Theory Tech.* **64** 1957
- [14] Fang Y, Xi X, Liu J, Pu Y, Zhao Y, Luo R 2018 *IEEE Trans. Antennas Propag.* **66** 6209
- [15] Feng N, Yue Y, Liu Q 2015 *IEEE Trans. Microwave Theory Tech.* **63** 877
- [16] Chen J, Wang J 2009 *IEEE Trans. Antennas Propag.* **57** 3375
- [17] Yang S, Chen Z, Yu Y, Yin W 2012 *IEEE Trans. Antennas Propag.* **60** 1995
- [18] Feng N, Zhang Y, Tian X, Zhu J, Joines W, Wang G 2019 *IEEE Trans. Microwave Theory Tech.* **67** 3260
- [19] Feng N, Zhang Y, Wang G 2022 *IEEE Trans. Microwave Theory Tech.* **70** 1026
- [20] Bishop C 2006 *Pattern Recognition and Machine Learning* (Springer) pp1-674
- [21] Cai Y, Huang Y, Feng N, Huang Z 2023 *IEEE Trans. Microwave Theory Tech.* **71** 3284
- [22] Feng N, Chen Y, Hong B, Huang Z 2023 *IEEE Trans. Microwave Theory Tech.* **71** 3294
- [23] Li L, Ruan H, Liu C, Li Y, Shuang Y, Alù A, Qiu C, Cui T 2019 *Nat. Commun.* **10** 1082
- [24] Pérez-López D, López A, DasMahapatra P, Capmany J 2020 *Nat. Commun.* **11** 6359
- [25] Kim K, Ha I, Kim M, Choi J, Won P, Jo S, Ko S 2020 *Nat. Commun.* **11** 2149
- [26] Tang Z, Li S, Xu J, Zhang H 2023 *Opt. Lett.* **48** 4416
- [27] Tang Z, Xu J, Wang S, Zhang H 2023 *Diamond Relat. Mater.* **137** 110091
- [28] Yao H, Jiang L 2019 *IEEE Antennas Wirel. Propag. Lett.* **18** 192
- [29] Feng N X, Chen Y S, Zhang Y X, Tong M S, Zeng Q S, Wang G P 2021 *IEEE Microwave Wirel. Compon. Lett.* **31** 541
- [30] Chen Y, Zhang Y, Wang H, Feng N, Yang L, Huang Z 2023

- IEEE Trans. Electromagn. Compat.* DOI: 10.1109/TEM.2023.3273724
- [31] Feng N, Li J 2013 *J. Comput. Phys.* **232** 318
- [32] Feng N, Yue Y, Zhu C, Wan L, Liu Q 2015 *J. Comput. Phys.* **285** 71
- [33] Berenger J 1994 *J. Comput. Phys.* **114** 185
- [34] Chew W, Weedon W 1994 *Microwave Opt. Technol. Lett.* **7** 599
- [35] Kuzuoglu M, Mittra R 1996 *IEEE Microwave Wirel. Compon. Lett.* **6** 447
- [36] Roden J, Gedney S 2000 *Microwave Opt. Technol. Lett.* **27** 334
- [37] Becacha E, Petropoulos P, Gedney S 2004 *IEEE Trans. Antennas Propag.* **52** 1335
- [38] Berenger J 2002 *IEEE Trans. Antennas Propag.* **50** 258
- [39] Correia D, Jin J 2006 *Microwave Opt. Technol. Lett.* **48** 2121

# Intelligent algorithm of extreme gradient boosting based perfectly matched monolayer and its efficient absorption on airborne transient electromagnetics problems\*

Feng Nai-Xing<sup>1)2)</sup> Wang Huan<sup>1)2)</sup> Zhu Zi-Xian<sup>1)2)</sup> Dong Chun-Zhi<sup>1)2)</sup>  
 Li Hong-Yang<sup>1)2)</sup> Zhang Yu-Xian<sup>1)2)†</sup> Yang Li-Xia<sup>1)2)</sup> Huang Zhi-Xiang<sup>1)2)‡</sup>

1) (School of Electronic and Engineering, Anhui University, Hefei 230601, China)

2) (Key Laboratory of Intelligent Computing and Signal Processing, Ministry of Education, Anhui University, Hefei 230601, China)

( Received 29 October 2023; revised manuscript received 13 December 2023 )

## Abstract

In addition to requiring the accuracy and computational efficiency for solving low-frequency subsurface sensing problem on the airborne transient electromagnetics (ATEMs), to the best of our knowledge, the complexity of subsurface sensing problems should also be considered in order to reduce more and more computational resources, particularly for a large-scale complicated multis-scale problem with a difference between background and targets. For simulating the open-domain, the finite-thickness perfectly matched layer is used to truncate the computational region, while the whole domain becomes larger so that the problem turns more complex. As a result, we propose a novel perfectly matched monolayer (PMM) model based on the extreme gradient boosting (XGB), which is selected and added to further improve the performance during the finite-difference time-domain (FDTD) simulation. The proposed XGB-based PMM model can achieve higher accuracy by using the ensemble learning method of feature attention, and has less memory and time consumption at the same time. Besides, this model has significant advantages in terms of model training stability and its lightweight due to the fact that it relies on the characteristics of traditional machine learning models. Finally, three-dimensional numerical simulations of ATEM problems are carried out to prove the validity and stability of the proposal. The proposed model can not only achieve advantages in numerical accuracy, efficiency and problem complexity, but also be integrated into the FDTD solver to deal with the low-frequency ATEM problems.

**Keywords:** extreme gradient boosting, perfectly matched monolayer, machine learning, finite-difference time-domain

**PACS:** 52.25.Os, 92.60.Ta, 47.11.Bc, 87.85.dq

**DOI:** 10.7498/aps.73.20231724

\* Project supported by the National Nature Science Foundation of China (Grant No. 62271001) and the Natural Science Foundation of Anhui Province, China (Grant Nos. 2308085Y39, 2022AH030014).

† Corresponding author. E-mail: [yxzhang\\_tute@126.com](mailto:yxzhang_tute@126.com)

‡ Corresponding author. E-mail: [zxhuang@ahu.edu.cn](mailto:zxhuang@ahu.edu.cn)



## 基于极限梯度提升的完美匹配单层智能算法实现航空瞬变电磁问题高效吸收

冯乃星 王欢 朱子贤 董纯志 李宏杨 张玉贤 杨利霞 黄志祥

### Intelligent algorithm of extreme gradient boosting based perfectly matched monolayer and its efficient absorption on airborne transient electromagnetics problems

Feng Nai-Xing Wang Huan Zhu Zi-Xian Dong Chun-Zhi Li Hong-Yang Zhang Yu-Xian Yang Li-Xia  
Huang Zhi-Xiang

引用信息 Citation: *Acta Physica Sinica*, 73, 065201 (2024) DOI: 10.7498/aps.73.20231724

在线阅读 View online: <https://doi.org/10.7498/aps.73.20231724>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

#### 您可能感兴趣的其他文章

##### Articles you may be interested in

基于机器学习和器件模拟对Cu(In,Ga)Se<sub>2</sub>电池中Ga含量梯度的优化分析

Optimization of Ga content gradient in Cu(In,Ga)Se<sub>2</sub> solar cells through machine learning and device simulation

物理学报. 2021, 70(23): 238802 <https://doi.org/10.7498/aps.70.20211234>

通过机器学习实现基于摩擦纳米发电机的自驱动智能传感及其应用

Self-powered sensing based on triboelectric nanogenerator through machine learning and its application

物理学报. 2022, 71(7): 078702 <https://doi.org/10.7498/aps.71.20211632>

基于波动与扩散物理系统的机器学习

Machine learning based on wave and diffusion physical systems

物理学报. 2021, 70(14): 144204 <https://doi.org/10.7498/aps.70.20210879>

机器学习辅助绝热量子算法设计

Machine learning assisted quantum adiabatic algorithm design

物理学报. 2021, 70(14): 140306 <https://doi.org/10.7498/aps.70.20210831>

基于机器学习的非线性局部Lyapunov向量集合预报订正

Machine learning based method of correcting nonlinear local Lyapunov vectors ensemble forecasting

物理学报. 2022, 71(8): 080503 <https://doi.org/10.7498/aps.71.20212260>

基于机器学习的无机磁性材料磁性基态分类与磁矩预测

Classification of magnetic ground states and prediction of magnetic moments of inorganic magnetic materials based on machine learning

物理学报. 2022, 71(6): 060202 <https://doi.org/10.7498/aps.71.20211625>