



(12) 发明专利

(10) 授权公告号 CN 115906591 B

(45) 授权公告日 2023. 08. 08

(21) 申请号 202310015813.7

(22) 申请日 2023.01.06

(65) 同一申请的已公布的文献号

申请公布号 CN 115906591 A

(43) 申请公布日 2023.04.04

(73) 专利权人 中国石油大学(华东)

地址 266580 山东省青岛市黄岛区长江西路66号

(72) 发明人 赵捍军 师俊峰 王才 张凯

樊灵 吴金炼

(74) 专利代理机构 青岛智地领创专利代理有限

公司 37252

专利代理师 陈海滨

(51) Int. Cl.

G06F 30/23 (2020.01)

(56) 对比文件

CN 113011089 A, 2021.06.22

CN 115374938 A, 2022.11.22

EP 3675061 A1, 2020.07.01

审查员 崔思鹏

权利要求书2页 说明书7页 附图3页

(54) 发明名称

一种基于XGBoost网络的油井动液面计算方法

(57) 摘要

本发明公开了一种基于XGBoost网络的油井动液面计算方法,属于石油工程技术领域,具体包括以下步骤:收集油田区块中油井的历史数据,首先对数据进行相关性分析,然后进行数据预处理,获取最终得到XGBoost网络模型的输入、输出数据;构建XGBoost网络模型,并进行模型训练;利用测试集数据检查模型的泛化能力;基于训练完成的XGBoost网络模型,进行动液面的实时监测计算。本发明具有计算速度快,经济成本低,表征精度高,无需考虑地质静态参数等优点;同时此模型可以计算该油田区块油井的动液面深度,无需经过大量、耗时的计算,节省了大量时间,提高了油田工作效率,可满足油田实际工程要求。

步骤 1、收集油田区块中油井的历史数据,对历史数据进行相关性分析和预处理,得到 XGBoost 网络模型的输入、输出数据;

步骤 2、构建 XGBoost 网络模型, 并进行模型训练;

步骤 3、利用测试集数据检查模型的泛化能力;

步骤 4、基于训练完成的 XGBoost 网络模型, 进行动液面的实时监测计算。

1. 一种基于XGBoost网络的油井动液面计算方法,其特征在于,包括以下步骤:

步骤1、收集油田区块中油井的历史数据,对历史数据进行相关性分析和预处理,得到XGBoost网络模型的输入、输出数据;

步骤2、构建XGBoost网络模型,并进行模型训练;

步骤3、利用测试集数据检查模型的泛化能力;

步骤4、基于训练完成的XGBoost网络模型,进行动液面的实时监测计算;

所述步骤1的具体过程如下:

步骤1.1、采集待分析油田区块中油井的历史数据进行相关性分析,历史数据包括油井生产变量数据和动液面深度数据;

采用皮尔森系数对油井生产变量数据和动液面深度数据进行相关性分析,具体公式为:

$$\rho_{A,B} = \frac{\text{cov}(A,B)}{\sigma_A \sigma_B} \quad (1)$$

其中,cov(A,B)为油井生产变量数据中的某一参数变量A和该参数变量对应的动液面变量B的协方差矩阵, σ_A 为变量A的方差, σ_B 为变量B的方差;

选定与动液面相关性高的前n个油井生产参数变量,作为XGBoost网络模型的输入,记作 $X = \{x_1, x_2, x_3, x_4, x_5, \dots, x_n\}$;将不同工作制度下油井的动液面深度,作为XGBoost网络模型的理想输出,记作 $Y = \{y\}$;

步骤1.2、对于收集到的输入集合X,以及输出集合Y所构成的初始数据样本进行归一化处理,使数值映射到[0,1]之间,转换函数如下:

$$X^* = (X - X_{\min}) / (X - X_{\max}) \quad (2)$$

$$Y^* = (Y - Y_{\min}) / (Y - Y_{\max}) \quad (3)$$

式中, X_{\min} 和 X_{\max} 分别表示输入集合X中的最小值和最大值; Y_{\min} 和 Y_{\max} 分别表示输出集合Y中的最小值和最大值; X^* 和 Y^* 为X和Y归一化后的值,作为机器学习的标准样本集;

所述步骤2的具体过程如下:

步骤2.1、搭建XGBoost网络模型,由n个输入变量、1个输出变量构成XGBoost网络模型,分别由向量表示为: $[x_1, x_2, x_3, x_4, x_5, \dots, x_n]$, $[y]$;

步骤2.2、进行训练集与测试集的划分,根据步骤1得到的输入样本集 X^* 和输出样本集 Y^* ,以8:2的比例将样本集划分为训练集 $X^*_{\text{train}}, Y^*_{\text{train}}$ 和测试集 $X^*_{\text{test}}, Y^*_{\text{test}}$;

步骤2.3、XGBoost网络的定义如下:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (4)$$

其中, \hat{y}_i 为最终预测结果, x_i 为样本特征, $f_k(x_i)$ 为F中的一个函数,F为分类决策树所有可能的集合;K为树的个数,k为树的序号;

XGBoost的目标函数由训练损失项和正则化项两部分组成,表示为:

$$\text{obj}(\theta) = L(\theta) + \Omega(\theta) \quad (5)$$

其中, $obj(\theta)$ 为XGBoost的目标函数, θ 为模型参数, $L(\theta)$ 为训练损失项, $\Omega(\theta)$ 为正则化项;

优化后的目标函数表示为:

$$obj(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (6)$$

其中, n 为预测值的总数, $L(y_i, \hat{y}_i)$ 为第 i 个预测值的训练损失值, $\Omega(f_k)$ 为 f_k 的正则化值; XGBoost通过学习 f_k , 找到最优的 f_k , 构建出一个最佳的XGBoost网络模型, 使训练损失与正则化达到最优;

所述步骤3的具体过程如下:

基于步骤2中构建完成的XGBoost网络模型, 根据相对平均误差的计算公式(7), 分别计算训练集数据 X_{train}^* , Y_{train}^* 和测试集数据 X_{test}^* , Y_{test}^* 在模型上的相对平均误差,

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_{true}(i) - Y_{pred}(i)}{Y_{true}(i)} \right| \quad (7)$$

其中, $Y_{true}(i)$ 为真实值; $Y_{pred}(i)$ 为预测值;

当测试集误差小于训练集误差时, 说明网络模型具有很好的泛化能力, 输出网络模型; 当测试集误差略大于训练集误差时, 说明网络具有较好的泛化能力, 输出网络模型; 当测试集误差远大于训练集误差时, 说明模型可能发生了过拟合, 返回步骤2, 重新进行模型训练。

2. 根据权利要求1所述基于XGBoost网络的油井动液面计算方法, 其特征在于, 所述步骤4的具体过程如下: 导出步骤3训练完成的XGBoost网络模型应用到油井现场动液面的监测中, 实时获取油田中油井的生产数据, 并将其输入模型中进行实时监测, 计算得出该油井的动液面深度。

一种基于XGBoost网络的油井动液面计算方法

技术领域

[0001] 本发明属于石油工程技术领域，具体涉及一种基于XGBoost网络的油井动液面计算方法。

背景技术

[0002] 油井开采的最终目标是实现产量和综合效率的最大化，而制约实现这一目标的根本因素是地层的供液能力。油井的动液面是反映地层供液能力的一个重要指标，是油田确定合理沉没度、制定合理工作制度的重要依据。

[0003] 常规的确定油井动液面的工程方法，往往需要消耗大量的时间成本，并且对于油田专家经验有着很高的依赖性，难以进行推广。因此，如何利用油田大数据，通过机器学习的方法进行油井的动液面深度的准确快速确定，对于油井开采具有重要意义。

发明内容

[0004] 为了解决上述问题，本发明提出了一种基于XGBoost网络的油井动液面计算方法，提高动液面深度计算的准确度，加快计算速度。

[0005] 本发明的技术方案如下：

[0006] 一种基于XGBoost网络的油井动液面计算方法，包括以下步骤：

[0007] 步骤1、收集油田区块中油井的历史数据，对历史数据进行相关性分析和预处理，得到XGBoost网络模型的输入、输出数据；

[0008] 步骤2、构建XGBoost网络模型，并进行模型训练；

[0009] 步骤3、利用测试集数据检查模型的泛化能力；

[0010] 步骤4、基于训练完成的XGBoost网络模型，进行动液面的实时监测计算。

[0011] 进一步地，步骤1的具体过程如下：

[0012] 步骤1.1、采集待分析油田区块中油井的历史数据进行相关性分析，历史数据包括油井生产变量数据和动液面深度数据；

[0013] 采用皮尔森系数对油井生产变量数据和动液面深度数据进行相关性分析，具体公式为：

$$[0014] \quad \rho_{A,B} = \frac{\text{cov}(A,B)}{\sigma_A \sigma_B} \quad (1)$$

[0015] 其中， $\text{cov}(A,B)$ 为油井生产变量数据中的某一参数变量A和该参数变量对应的动液面变量B的协方差矩阵， σ_A 为变量A的方差， σ_B 为变量B的方差；

[0016] 选定与动液面相关性高的前n个油井生产参数变量，作为XGBoost网络模型的输入，记作 $X = \{x_1, x_2, x_3, x_4, x_5, \dots, x_n\}$ ；将不同工作制度下油井的动液面深度，作为XGBoost网络模型的理想输出，记作 $Y = \{y\}$ ；

[0017] 步骤1.2、对于收集到的输入集合X，以及输出集合Y所构成的初始数据样本进行归

一化处理,使数值映射到[0,1]之间,转换函数如下:

$$[0018] \quad X^* = (X - X_{min}) / (X - X_{max}) \quad (2)$$

$$[0019] \quad Y^* = (Y - Y_{min}) / (Y - Y_{max}) \quad (3)$$

[0020] 式中, X_{min} 和 X_{max} 分别表示输入集合X中的最小值和最大值; Y_{min} 和 Y_{max} 分别表示输出集合Y中的最小值和最大值; X^* 和 Y^* 为X和Y归一化后的值,作为机器学习的标准样本集。

[0021] 进一步地,步骤2的具体过程如下:

[0022] 步骤2.1、搭建XGBoost网络模型,由n个输入变量、1个输出变量构成XGBoost网络模型,分别由向量表示为: $[x_1, x_2, x_3, x_4, x_5, \dots, x_n]$, $[y]$;

[0023] 步骤2.2、进行训练集与测试集的划分,根据步骤1得到的输入样本集 X^* 和输出样本集 Y^* ,以8:2的比例将样本集划分为训练集 X^*_{train} , Y^*_{train} 和测试集 X^*_{test} , Y^*_{test} ;

[0024] 步骤2.3、XGBoost网络的定义如下:

$$[0025] \quad \hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (4)$$

[0026] 其中, \hat{y}_i 为最终预测结果, x_i 为样本特征, $f_k(x_i)$ 为 F 中的一个函数, F 为分类决策树所有可能的集合; K 为树的个数, k 为树的序号;

[0027] XGBoost的目标函数由训练损失项和正则化项两部分组成,表示为:

$$[0028] \quad obj(\theta) = L(\theta) + \Omega(\theta) \quad (5)$$

[0029] 其中, $obj(\theta)$ 为XGBoost的目标函数, θ 为模型参数, $L(\theta)$ 为训练损失项, $\Omega(\theta)$ 为正则化项;

[0030] 优化后的目标函数表示为:

$$[0031] \quad obj(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (6)$$

[0032] 其中, n 为预测值的总数, $L(y_i, \hat{y}_i)$ 为第 i 个预测值的训练损失值, $\Omega(f_k)$ 为 f_k 的正则化值; XGBoost通过学习 f_k , 找到最优的 f_k , 构建出一个最佳的XGBoost网络模型,使训练损失与正则化达到最优。

[0033] 进一步地,步骤3的具体过程如下:

[0034] 基于步骤2中构建完成的XGBoost网络模型,根据相对平均误差的计算公式(7),分别计算训练集数据 X^*_{train} , Y^*_{train} 和测试集数据 X^*_{test} , Y^*_{test} 在模型上的相对平均误差,

$$[0035] \quad MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_{true}(i) - Y_{pred}(i)}{Y_{true}(i)} \right| \quad (7)$$

[0036] 其中, $Y_{true}(i)$ 为真实值; $Y_{pred}(i)$ 为预测值;

[0037] 当测试集误差小于训练集误差时,说明网络模型具有很好的泛化能力,输出网络模型;当测试集误差略大于训练集误差时,说明网络具有较好的泛化能力,输出网络模型;当测试集误差远大于训练集误差时,说明模型可能发生了过拟合,返回步骤2,重新进行模型训练。

[0038] 进一步地,步骤4的具体过程如下:导出步骤3训练完成的XGBoost网络模型应用到油井现场动液面的监测中,实时获取油田中油井的生产数据,并将其输入模型中进行实时监测,计算得出该油井的动液面深度。

[0039] 本发明所带来的有益技术效果:

[0040] 基于XGBoost网络的动液面计算方法简洁实用,与传统的动液面测定方法相比,具有计算速度快,经济成本低,表征精度高,无需考虑地质静态参数等优点,为油田确定合理沉没度、制定合理工作制度提供了依据,对油井生产提供了重要的指导意义;同时通过XGBoost网络模型能够计算该区块其他油井的动液面深度,为油井动液面的计算提供了便利,节省了大量时间,提高了油田工作效率,能够满足实际应用要求。

附图说明

[0041] 图1为本发明基于XGBoost网络的油井动液面计算方法的流程图;

[0042] 图2为本发明中实际动液面与XGBoost网络模型计算所得动液面的对比图,展示的是前250个动液面数据可视化结果;

[0043] 图3为本发明中实际动液面与XGBoost网络模型计算所得动液面的对比图,展示的是后239个动液面数据可视化结果;

[0044] 图4为本发明中计算结果误差的统计柱状图。

具体实施方式

[0045] 下面结合附图以及具体实施方式对本发明作进一步详细说明:

[0046] 本发明提出了一种基于XGBoost网络的油井动液面计算方法,在XGBoost网络的训练过程中,通过相关性的大小反映不同变量之间的重要程度,从而将各个变量与油井动液面联系起来,进行动液面深度的确定。首先收集油田现场某区块中各个油井的数据,先对变量进行相关性分析,之后对数据进行归一化处理,得到XGBoost网络模型所需的输入、输出数据;利用得到的训练集进行XGBoost网络模型的搭建;基于训练完成的XGBoost网络模型,用测试集进行误差分析,检验模型的泛化能力;最后利用训练好的模型实时监测计算该区块其他油井动液面。

[0047] 一种基于XGBoost网络的油井动液面计算方法,简要流程如附图1所示,具体包括以下步骤:

[0048] 步骤1.1、采集待分析油田区块中油井的历史数据进行相关性分析,历史数据包括油井生产变量数据和动液面深度数据;

[0049] 采用皮尔森系数对油井生产变量数据和动液面深度数据进行相关性分析,具体公式为:

$$[0050] \quad \rho_{A,B} = \frac{\text{cov}(A,B)}{\sigma_A \sigma_B} \quad (1)$$

[0051] 其中, $\text{cov}(A,B)$ 为油井生产变量数据中的某一参数变量A和该参数变量对应的动液面变量B的协方差矩阵, σ_A 为变量A的方差, σ_B 为变量B的方差。

[0052] 选定与动液面相关性高的前n个油井生产参数变量,作为XGBoost网络模型的输入,记作 $X = \{x_1, x_2, x_3, x_4, x_5, \dots, x_n\}$;将不同工作制度下油井的动液面深度,作为XGBoost网

络模型的理想输出,记作 $Y=\{y\}$ 。

[0053] 步骤1.2、对于收集到的输入集合 X ,以及输出集合 Y 所构成的初始数据样本进行归一化处理,使数值映射到 $[0,1]$ 之间,转换函数如下:

$$[0054] \quad X^* = (X - X_{min}) / (X - X_{max}) \quad (2)$$

$$[0055] \quad Y^* = (Y - Y_{min}) / (Y - Y_{max}) \quad (3)$$

[0056] 式中, X_{min} 和 X_{max} 分别表示输入集合 X 中的最小值和最大值; Y_{min} 和 Y_{max} 分别表示输出集合 Y 中的最小值和最大值; X^* 和 Y^* 为 X 和 Y 归一化后的值,分别作为机器学习的标准输入样本集和输出样本集。

[0057] 步骤2、构建XGBoost网络模型,并进行模型训练,具体步骤如下:

[0058] 步骤2.1、搭建XGBoost网络模型,由 n 个输入变量、1个输出变量构成XGBoost网络模型,分别由向量表示为: $[x_1, x_2, x_3, x_4, x_5, \dots, x_n]$, $[y]$;

[0059] 步骤2.2、进行训练集与测试集的划分,根据步骤1得到的输入样本集 X^* 和输出样本集 Y^* ,以8:2的比例将样本集划分为训练集 X^*_{train} , Y^*_{train} 和测试集 X^*_{test} , Y^*_{test} ;

[0060] 步骤2.3、XGBoost网络的定义如下:

$$[0061] \quad \hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (4)$$

[0062] 其中, \hat{y}_i 为最终预测结果, x_i 为样本特征, $f_k(x_i)$ 为 F 中的一个函数, F 为分类决策树所有可能的集合; K 为树的个数, k 为树的序号。

[0063] XGBoost的目标函数由训练损失项和正则化项两部分组成,表示为:

$$[0064] \quad obj(\theta) = L(\theta) + \Omega(\theta) \quad (5)$$

[0065] 其中, $obj(\theta)$ 为XGBoost的目标函数, θ 为模型参数, $L(\theta)$ 为训练损失项, $\Omega(\theta)$ 为正则化项。

[0066] 优化后的目标函数表示为:

$$[0067] \quad obj(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (6)$$

[0068] 其中, n 为预测值的总数, $L(y_i, \hat{y}_i)$ 为第 i 个预测值的训练损失值, $\Omega(f_k)$ 为 f_k 的正则化值。

[0069] XGBoost通过学习 f_k ,找到最优的 f_k ,构建出一个最佳的XGBoost网络模型,使训练损失与正则化达到最优。

[0070] 步骤3、利用测试集数据检查模型的泛化能力,具体步骤如下:

[0071] 基于步骤2中构建完成的XGBoost网络模型,根据相对平均误差的计算公式(7),分别计算训练集数据(X^*_{train} , Y^*_{train})和测试集数据(X^*_{test} , Y^*_{test})在模型上的相对平均误差。

$$[0072] \quad MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_{true}(i) - Y_{pred}(i)}{Y_{true}(i)} \right| \quad (7)$$

[0073] 其中, $Y_{true}(i)$ 为真实值; $Y_{pred}(i)$ 为预测值;

[0074] 当测试集误差小于训练集误差时,说明网络模型具有很好的泛化能力,输出网络模型;当测试集误差略大于训练集误差时,说明网络具有较好的泛化能力,输出网络模型;当测试集误差远大于训练集误差时,说明模型可能发生了过拟合,需要返回步骤2,重新进行模型训练。

[0075] 步骤4、基于训练完成的XGBoost网络模型,进行动液面的实时监测计算,具体步骤如下:

[0076] 导出步骤3训练完成的XGBoost网络模型应用到油井现场动液面的监测中,实时获取油田中油井的生产数据,并将其输入模型中进行实时监测,计算得出该油井的动液面深度。

[0077] 为了证明本发明方法的可行性,进行了如下实验。

[0078] 本实验数据来自某油田的某区块,待研究的某区块地层有若干个油井,具有若干个不同生产制度下的数据。

[0079] 通过整理该区块油井的历史生产数据共获得有效数据集2445条,按照一定比例(训练集:测试集=8:2)将数据集随机划分为训练集与测试集,其中训练集数据1956条,测试集数据489条。部分数据如表1所示。

[0080] 表1 某区块油井的历史数据

泵径	泵深	泵效	套压	油压	含水率	冲程	冲次	上行电流	下行电流	电流比	理论上载荷	理论下载荷	日产液量	日产油量	实测动液面
57	1052	39.1	0.55	0.46	97.2	4.2	5	65	60	92.31	55.54	38.03	30.03	0.84	570.9
57	1040	59.8	0.55	0.34	97.5	4.2	4	47	45	95.74	47.42	25.15	36.74	0.92	995.2
57	962	42.5	0.51	0.67	92.6	3	4	50	48	96	44.53	24.41	18.51	1.37	914.7
44	963	37.7	0.46	0.65	98.5	2.5	6	34	33	97.06	34.69	24.15	12.34	0.19	881.3
70	993	55.8	0.64	0.72	98.9	4	5	67	46	68.66	70.69	39.92	61.7	0.68	233.9
57	832	31.9	0.6	0.54	96.9	3	6	41	58	70.69	43.77	27.12	20.78	0.64	347.2
...
70	813	71.9	0.44	0.39	96.1	6	5	89	85	95.51	52.93	26.51	118.66	4.63	580.1
70	1102	44.2	0.13	0.45	90.4	3	7	70	65	92.86	69.91	35.16	50.6	4.86	912.6
70	923	98.8	0.68	0.42	97.6	6	4	86	79	91.86	60.46	30.24	130.81	3.14	661.2
44	995	48.5	0.78	0.65	98.4	5	5	53	48	90.57	35.83	24.94	26.48	0.42	833.3
83	888	21.9	0.86	0.75	97.3	4.2	5	58	57	98.28	71.42	28.99	35.66	0.96	642.9

[0082] 采用公式(1)的皮尔森系数公式对数据进行相关性分析,得到实测动液面与其他参数的相关系数如表2所示,可以看出其他油田参数与实测动液面具有一定的相关性,可用于动液面的预测。

[0083] 表2 实测动液面与其他油田参数的相关系数

实测动液面		
	泵径	-0.30
	泵深	0.55
	泵效	-0.30
	套压	-0.16
	油压	-0.04
	含水率	-0.29
	冲程	-0.15
[0084]	冲次	-0.15
	上行电流	0.00
	下行电流	-0.03
	电流比	0.02
	理论上载荷	-0.07
	理论下载荷	0.06
	日产液量	-0.34
	日产油量	-0.11
	实测动液面	1.00

[0085] 同时采用公式(2)和公式(3)对数据进行归一化处理。其中,输入变量为:泵径(m)、泵深(m)、泵效(%)、套压(MPa)、油压(MPa)、含水率(%)、冲程(m)、冲次、上行电流(A)、下行电流(A)、电流比、理论上载荷(MPa)、理论下载荷(MPa)、日产液量(m³/s)、日产油量(m³/s),输出变量:实测动液面(m)。并将训练集输入模型中,训练模型,得到XGBoost网络的动液面计算模型;将测试集输入训练好的模型中,利用公式(7)分别计算它们的MRE,结果如表3所示。

[0086] 表3 训练集与测试集的MRE

MRE (%)		
[0087]	训练集	3.56
	测试集	1.92

[0088] 由表3可以看出,测试集的误差小于训练集误差,说明网络具有很好的泛化能力,可以利用该训练好的XGBoost网络的动液面计算模型进行动液面的实时监测计算。

[0089] 计算所得的动液面与实测动液面的误差,如表4所示(因为数据量大,表4只展示了其中部分数据);绘制它们的对比图进行可视化分析,如附图2和附图3所示。结合表4和附图2、附图3可看出,该模型计算出来的动液面深度与实际动液面深度相差无几,大部分动液面数据相差在5m以下,符合油田现场的要求。

[0090] 表4 部分实测动液面与计算动液面对比及误差

	实测动液面(m)	计算动液面(m)	误差 (%)
	570.9	572.3	1.51
	995.2	996.7	0.15
	914.7	913.5	0.13
	881.3	887.1	0.66
	233.9	240.6	2.86
[0091]	347.2	350.2	0.86

	580.1	578.6	0.26
	912.6	920.8	0.90
	661.2	665.4	0.64
	833.3	850.3	2.04
	642.9	644.9	0.31

[0092] 对其误差进行可视化处理,结果如附图4所示,其中每个柱状图上方的两个数字分别表示油井数量(单位:口)和所占比例,比如323/66.05%表示“<1%”的误差范围内油井数量为323口,占总比例的66.05%;138/28.22%表示“1%-5%”的误差范围内油井数量为138口,占总比例的28.22%;10/2.04%表示“5%-10%”的误差范围内油井数量为10口,占总比例的2.04%;11/2.25%表示“10%-20%”的误差范围内油井数量为11口,占总比例的2.25%;5/1.02%表示“20%-50%”的误差范围内油井数量为5口,占总比例的1.02%;2/0.41%表示“>50%”的误差范围内油井数量为2口,占总比例的0.41%。从附图4可看出,约66%的油井动液面误差小于1%,接近于0%;油井动液面误差范围在5%内的比例高达94%;因此该模型计算所得的动液面误差小,满足油田工程要求。

[0093] 当然,上述说明并非是对本发明的限制,本发明也并不仅限于上述举例,本技术领域的技术人员在本发明的实质范围内所做出的变化、改型、添加或替换,也应属于本发明的保护范围。

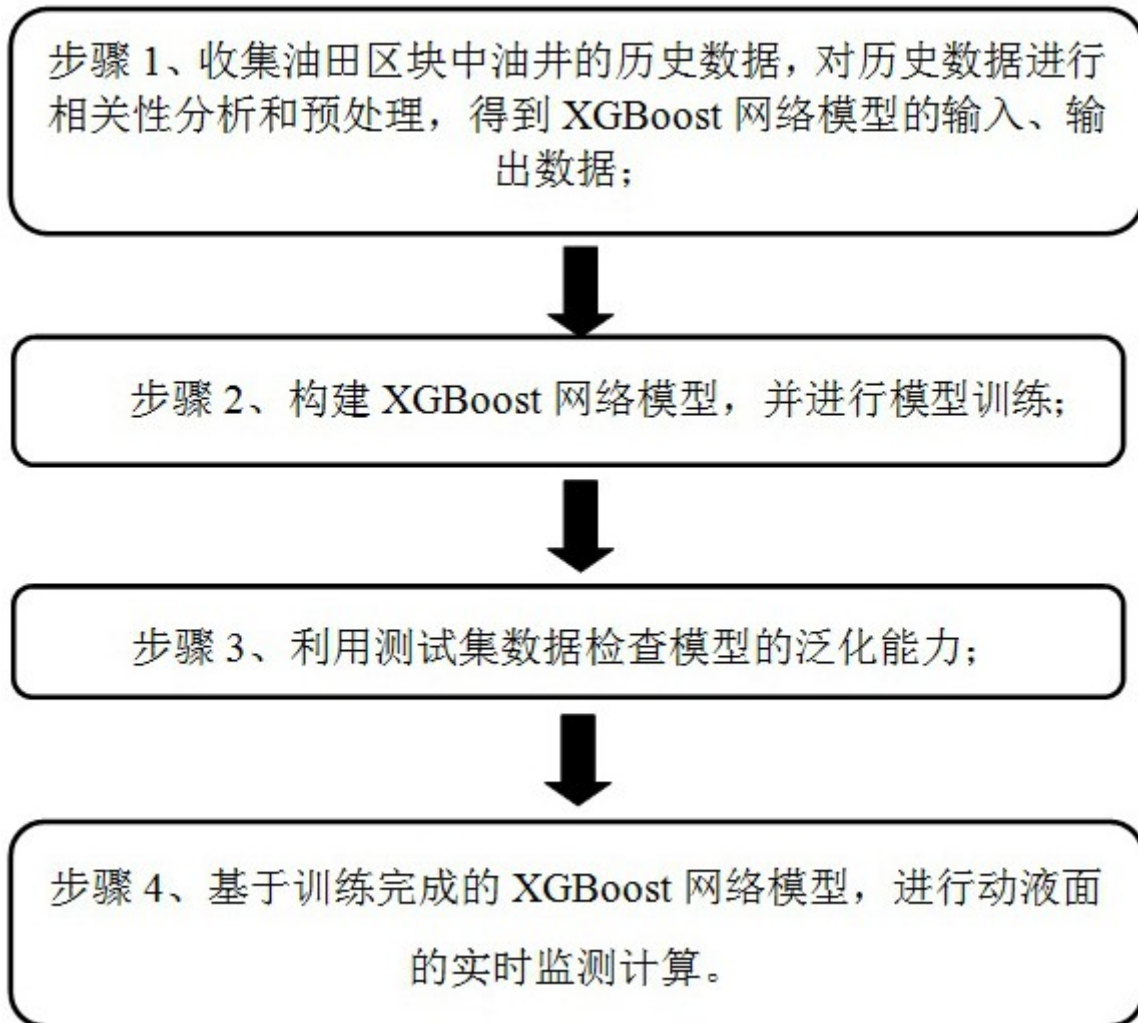


图1




图2




图3




图4