

基于大数据的页岩气产能预测

祝元宠, 咸玉席, 李清宇, 卢德唐

中国科学技术大学石油天然气研究中心 安徽合肥 230026

通讯作者: Email: dtlu@ustc.edu.cn

项目支持: 国家科技重大专项“致密油气藏多尺度介质复杂结构井数值试井分析方法及应用研究”(2017ZX05009005-002)、中石油-中科院重大战略合作项目“页岩气钻完井井壁稳定与开发工程技术研究”(2015A-4812)、中国科学院战略先导科技专项“页岩气勘探开发基础理论与关键技术”(XDB10030402)

引用: 祝元宠, 咸玉席, 李清宇, 等. 基于大数据的页岩气产能预测[J]. 油气井测试, 2019, 28(1): 1-6.

Cite: ZHU Yuanchong, XIAN Yuxi, LI Qingyu, et al. Shale gas productivity forecast based on big data [J]. Well Testing, 2019, 28(1): 1-6.

摘要 参数拟合的传统页岩气井产能预测方法存在一定的局限性, 引入基于支持向量机的非参数大数据分析方法进行页岩气井产能预测研究。根据生产数据记录以及井底压力随生产过程的变化规律, 建立 e-SVR 支持向量回归模型, 对长宁页岩气某区块实际生产数据分别进行了单井和多井的训练及预测检验, 其中单井回归检验的相关度系数达到 0.958 556, 体现了该方法优秀的回归能力; 多井学习模型在前 95 d 区间内对单井数据的预测也达到了接近单井回归的效果, 体现了该方法在密集数据区间内较好的预测能力, 为页岩气产能预测提供了新的思路。

关键词 页岩气; 产能预测; 大数据; 非参数拟合; 支持向量机; 长宁气田

中图分类号: TE353 文献标识码: A DOI: 10.19680/j.cnki.1004-4388.2019.01.001

Shale gas productivity forecast based on big data

ZHU Yuanchong, XIAN Yuxi, LI Qingyu, LU Detang

Research Center of Petroleum, University of Science and Technology of China, Hefei, Anhui 230026, China

Abstract: The traditional productivity forecast method of shale gas well based on parameter matching has some limitations. This paper introduced a non-parametric big data analysis method based on support vector machine (SVM). According to the recorded production data and the change law of bottomhole pressure with the production process, the e-SVR (support vector regression) model was established, and it was tested by single-well and multi-well training and forecasting based on actual production data of a block of Changning shale gas field. The correlation coefficient of single-well regression test reaches 0.958 556, which reflects the excellent regression performance of this method. The forecasting of the multi-well learning model based on single well data in the first 95 d interval is close to the effect of the single-well regression model, which reflects the better forecasting performance of the method in the dense data interval. The proposed method provides a new idea for forecasting shale gas productivity.

Keywords: shale gas; productivity forecast; big data; non-parametric matching; support vector machine (SVM); Changning shale gas field

页岩气井的产能预测, 一般是对现有的生产数据进行回归分析拟合, 再采用回归得到的方程进行产能预测。传统的回归方法是基于物质平衡条件和三个理想假设, 即: 一口垂直井、地层边界封闭、流动达到边界流阶段。该领域内最早由 Arps 在 1945 年提出了递减曲线分析方法^[1]。此方法以简单形式的数学函数拟合产量变化曲线, 其函数曲线分为指数型、双曲型和调和型三种形式。

Arps 方法适用于稳态井底流动, 可以解释数据的单调变化, 但不适用于复杂井底流动, 也无法解

释数据的非单调变化。1980 年, Fetkovich 将此方法与试井分析中的不稳定流动公式结合, 将 Arps 方法扩展至不稳定流动阶段^[2]。1985 年 Carter 在 Fetkovich 方法的基础上引入了 λ 因子以表征气体的可压缩性^[3], 将 Fetkovich 方法拓展至气井数据分析。1993 年 Blasingame 引入了物质平衡函数, 考虑了气体的高压物性参数和黏度的变化, 并引入拟压力和拟时间的概念以线性化气体渗流方程^[4]。

针对变井底压力的油气井, Agarwal-Gardner 提出了压力变化的流量瞬时分析, 并在 Blasingame 方

法的基础上引入了新的基于井控面积的无量纲时间定义,还针对导流能力有限的水力压裂井进行了数据分析扩展^[5]。

近年来,国内的研究人员也针对油气田产能分析问题做了很多研究。如:肖阳等讨论了不关井试井分析在桑南西生产动态分析中的应用^[6]。梅显旺等在2016年对致密油水平井多级压裂后的产能影响因素进行了分析^[7]。同年,汪益宁等讨论了生产数据分析在哈拉哈塘油田储层评价中的应用^[8]。

目前,世界上较为优秀的生产数据分析软件Topaze和中国科大渗流研究室的ProTA软件都可以通过对生产历史数据的拟合来进行产能预测。其中ProTA重新定义了拟压力,求解拟压力渗流方程得到其解析解,再结合传统数据分析方法,得到无量纲压力及其导数图版^[9]。

然而,在一些非常规油气井,比如致密井、页岩气井等的开采过程中,因为对复杂地质条件认识不足、对油气流动机理研究不足,目前采用的“解析解+传统数据分析”的方法存在一定的局限性。例如页岩气存在吸附、扩散及滑脱等现象,流动方程形式复杂,加之水平井多段压裂使得难以得到解析解。即使存在解析解或者采用数值解计算,在反演时依然存在多解性问题。因此,考虑引入非参数统计方法对天然气田的产量进行预测。

随着近年来人工智能技术的发展,基于大数据的非参数统计机器学习方法已经成为各个领域研究的热点。如2007年,方瑞明将支持向量分类机应用于电气工程领域的电机故障诊断和非参数建模中,并在电网短期负荷预测中使用了支持向量回归机^[10]。2015年,刘敬等进行了基于单分类支持向量机和主动学习的网络异常检测研究^[11]。

相较于其它机器学习方法,支持向量机不依赖于庞大的数据量,可以在小样本的情况下准确提取样本的非线性变化规律,预测性能较好,在科研和工程应用中被广泛使用。

近年来,在国内石油天然气领域,对支持向量机方法的应用有如下研究进展:

2006年,薛磊等提出了一种基于支持向量回归的多层原油分层产能贡献预测模型^[12]。2007年,李卓等探讨了支持向量机在油田系统建模中的应用^[13]。2008年,石广仁指出了支持向量机在裂缝预测及含气性评价应用中的优越性^[14]。2015年,

汪旭颖进行了基于支持向量回归机的油田异常井预警模型研究^[15]。2016年,赵小龙提出了基于支持向量机的深层地应力预测模型^[16]。

以上研究基本集中于对油井或油层的分类定性判断和产量的历史拟合,并没有涉及产能预测。而相对来说,产能预测对油气田生产更为重要。因此,本文将尝试在页岩气产能预测中引入支持向量回归方法,建立e-SVR支持向量回归模型,并进行实际案例的试算。

1 统计机器学习与支持向量机方法

统计机器学习,是指在“同类数据具有一定的统计规律”的基本前提下,通过构建概率统计模型,对数据进行分析 and 预测的一门学科^[17]。

支持向量机(Support Vector Machine,简称SVM)是20世纪90年代中期在统计学习理论的基础上发展起来的一种新方法。它与传统的人工神经网络不同,不是基于“经验风险最小化原理”,而是基于“结构风险最小化原理”,具有理论完备、适应性强、泛化性能好等优点。

支持向量机理论最早起源于对统计分类问题的讨论中。对于统计分类,传统的思路一般是:寻求一个分类边界,使得这个分类边界可以在统计意义上把“所有”统计样本分离的最好。这样的思路基于“大数定理”,也就是说需要较大的样本数量来支撑。其目的则是“经验风险最小”,即学习出的分类模型应尽量匹配既有的所有样本。

但是Vapnik等认为,统计样本中对分类起作用的样本只应该局限于紧贴在分类界面两侧的一部分样本,而不是传统意义上的“所有样本”。所以,基于这个假设,若要使得一个基于统计样本的分类模型具有较好的适应性和泛化预测能力,那么就不应该拘泥于精确描述既有样本的形态,而是应该着重考虑其分类边界。由此,Vapnik在1963年首次提出了“支持向量”的概念,奠定了支持向量机的理论基础^[18]。

假设统计样本 i 具有多维特征值 \mathbf{x}_i ,全体样本的特征向量构成一个特征向量空间,那么样本的分类边界便可以描述为若干边界特征向量 \mathbf{x}_s 的线性组合 \mathbf{x} ,它满足特征向量空间的超平面方程:

$$\mathbf{w}^T \mathbf{x} + \mathbf{b} = 0 \quad (1)$$

这种构成分类边界的特征向量 \mathbf{x}_s 就被称为支持向量。

再构造一个分类函数 $f(\mathbf{x})$, 即

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + \mathbf{b} \quad (2)$$

经过简单的几何计算可知,若假设特征向量到分类超平面的函数间隔为 ± 1 , 而其它向量到分类超平面的函数间隔大于 1, 则支持向量和分类超平面之间的几何间隔为:

$$\gamma_s = \frac{\pm 1}{\|\mathbf{w}\|} \quad (3)$$

因此,求解最优超平面即可化归为求解一个极小值问题,并且其约束条件为:

$$|\mathbf{w}^T \mathbf{x}_i + \mathbf{b}| \geq 1 \quad i = 1, 2, \dots, n \quad (4)$$

由此,原本的分类函数值的不同,即所谓的函数间隔,被转变成了向量空间中的几何间隔。而原本的最优分类问题,则变成了几何间隔的最大化的问题,“经验风险”被成功转化成了“结构风险”。

一般来说,为求解上述约束极值问题,应构造拉格朗日函数 $L(\mathbf{w}, \mathbf{b}, \alpha)$, 利用拉格朗日对偶和 KKT 条件转化为一个二次规划问题 $W(\alpha)$ 。

为使得这个方法具有一般适用性,以处理错误样本和线性不可分样本集,可分别引入松弛变量 ξ 以及核函数方法。

引入松弛变量 ξ_i , 其几何意义为表征样本点反向偏离支持向量平面的程度。因此, (4) 式变为:

$$|\mathbf{w}^T \mathbf{x}_i + \mathbf{b}| + \xi_i \geq 1 \quad i = 1, 2, \dots, n \quad (5)$$

而引入核函数则使得 $W(\alpha)$ 内表征特征向量 \mathbf{x}_i 和 \mathbf{x}_j 的相似度的内积项 $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ 变为核函数 $K(\mathbf{x}_i, \mathbf{x}_j)$, 将特征向量映射到高维空间,从而寻求在高维空间进行线性分类的可能性。

2 基于支持向量的回归分析

针对天然气田的产量分析需求,考虑在支持向量机的理论上进行回归分析。以“ ε -支持向量回归机”(e-SVR)为例,首先引入合页损失函数(Hinge Loss),以取代传统分析中的均方差损失函数,即

$$\text{err}(\mathbf{x}_i) = \begin{cases} 0 & |y_i - f(\mathbf{x}_i)| \leq \varepsilon \\ |y_i - f(\mathbf{x}_i)| - \varepsilon & |y_i - f(\mathbf{x}_i)| > \varepsilon \end{cases} \quad (6)$$

其中, ε 被称为允许误差上限。均方差对应的目标函数为

$$\begin{aligned} \theta &= \min \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s.t. } & |y_i - (\mathbf{w}^T \mathbf{x} + \mathbf{b})| \leq \varepsilon \end{aligned} \quad (7)$$

考虑绝对值正负号,依次引入正负方向的两个松弛变量 ξ_i, η_i , 以及惩罚系数 C , 易知拉格朗日函数的最终形式为

$$\begin{aligned} L(\mathbf{w}, \mathbf{b}, \alpha, \beta, \mu, \nu) &= \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \eta_i) + \\ &\sum_{i=1}^n \alpha_i (y_i - \mathbf{w}^T \mathbf{x}_i - \mathbf{b} - \varepsilon - \xi_i) + \\ &\sum_{i=1}^n \beta_i (-y_i + \mathbf{w}^T \mathbf{x}_i + \mathbf{b} - \varepsilon - \eta_i) - \\ &\sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \nu_i \eta_i \end{aligned} \quad (8)$$

其中拉格朗日系数为

$$\alpha_i \geq 0, \beta_i \geq 0$$

$$\mu_i \geq 0, \nu_i \geq 0$$

其对偶问题最终形式为

$$\begin{aligned} W(\alpha, \beta) &= \min_{\alpha_i \geq 0, \beta_i \geq 0} \left[\sum_{i=1}^n (\varepsilon - y_i) \alpha_i + (\varepsilon + y_i) \beta_i + \right. \\ &\left. \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \beta_i)(\alpha_j - \beta_j) y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right] \end{aligned} \quad (9)$$

条件为

$$\begin{aligned} \sum_{i=1}^n (\alpha_i - \beta_i) &= 0 \\ 0 &\leq \alpha_i \leq C \\ 0 &\leq \beta_i \leq C \end{aligned} \quad (10)$$

此处也可以引入适当的核函数 $K(\mathbf{x}_i, \mathbf{x}_j)$, 替换上式中的内积项 $\mathbf{x}_i^T \mathbf{x}_j$ 。

由此可见,这个最终问题 $W(\alpha, \beta)$ 是一个稀疏的凸二次规划问题,可以利用 John C. Platt 提出的一种启发式算法——“序列最小优化(Sequential Minimal Optimization)”算法(下称 SMO 算法)来进行迭代求解。

3 长宁气田某区块产量预测实例

长宁气田某区块 6 口井分别于 2014-2015 年间完成体积压裂,并开始生产。其数据记录完备,产量较高,故将其用作训练和测试的基准数据。其生产数据记录主要有:生产日期、生产时长、油管压力、套管压力、气体产量、液体产量和返排率。

这是一组水力压裂的页岩气井,如果按照传统方法建模,则需要连续性方程中考虑吸附气。而压裂的裂缝中又存在压力梯度,气体扩散效应明显,并且需要考虑微纳尺度下气体分子滑移效应的边界条件。在气井开采过程中,井底压力变化也会因为压敏效应导致渗透率的变化。

如果按照非参数模型的思路,鉴于这些井所处区块相同,可以假设它们具有相似的物理模型,而这个模型无需显式的表达在模型内,只需要考虑影响预测指标(如井底压力或者产量)的所有因素,并进行归纳即可。

本算例中,取油管压力为井底压力。若记录缺失,则采用套管压力值;若两者全部未能记录,则当日的生产数据将被排除。另外,考虑到每日产量跳跃幅度较大,所以采用累计总产量以增强数据的连续性。

基于油气田生产的一般物理模型可知,随着油气井的持续开采,其井底压力会逐渐降低。而关井后,开采中断,其压力会回升。故若训练用的数据集仅仅局限于一口井,则只需考虑生产的相对日期和开关井操作即可。

因此,一条有效的生产数据记录分以下几项:井底压力、气体总产量、液体总产量、连续关井日期(连续开井则为负数)和相对日期(总天数)。其中井底压力作为模型预测的对比指标,后四项则作为特征向量。

本算例利用统计学习领域常用的 libsvm 开源计算库(包含 SMO 迭代算法)进行计算,采用常用的 RBF 核函数替换内积项,最后用 matplotlib 作图进行对比。其中 RBF 核函数(也称高斯径向基核函数)的表达形式为:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma |\mathbf{x}_i - \mathbf{x}_j|^2) \quad (11)$$

综上所述,本算例的基本计算流程为:

(1)提取原始生产记录中的数据,分别输出为指定格式的学习数据集和测试数据集。

(2)对算例数据进行归一化(针对 RBF 核函数的特性进行优化)。

(3)使用 Libsvm 库训练学习数据集,生成模型,并使用测试数据集进行测试,最后作图对比数据。

3.1 单井回归模型

首先尝试用一口井的生产数据进行学习,预测其未来的生产数据变化规律。以 1 号井为例,将井底压力设置为应变变量,并将气体总产量、液体总产量、连续关井天数和总天数定义为一组特征向量。学习 1 号井的所有有效生产数据,得到“模型一”,然后代入 1 号井的所有特征变量进行预测,将预测图线和实际进行对比,如图 1 所示。




图 1 1号井回归模型(e-SVR 模型一)
Fig.1 Regression model of Well #1 (Model 1)

按均方差最小进行优化搜索后,其学习参数为:“-s 3 -c 16 -g 2 -p 0.025”,其中“-s 3”表示采用 e-SVR 支持向量回归机模型,c、g、p 对应于 e-SVR 模型中的惩罚系数 C、RBF 核函数((11)式)中的 γ ,以及合页损失函数((6)式)中的 ε 。

根据程序计算,“模型一”的学习及拟合检验结果为:输入数据 735 组,找出支持向量 720 个,其中边界支持向量(拉格朗日系数达到惩罚边界值 C) 703 个,均方误差(MSE)为 4.208,相关度系数达到 0.959。

从图 1 中可以看出,e-SVR 模型具有非参数统计学习方法的一般特性,即针对一段较窄的数据集(一口井,每天只有 1 个数据点),可以迅速收敛,与实际图线吻合度较好。而且,从 400~700 d 的数据来看,其对数据的抖动不敏感,体现了结构风险最小化的特点。

3.2 多井学习模型

既然已经假设这些同一区块的井具有相似的物理模型,那么通过学习一部分井的生产数据形成的模型就可以用于预测另一口井的生产数据。但此时,学习的数据集在特征向量空间内充分展开,状态空间充分膨胀:如果测试数据介于学习数据集内部,则类似于一次多维度内插值,其结果相对稳定;如果测试数据远离已有学习区间,则需要进行外推。

一般而言,非参数统计学习方法的外推预测较为困难。对于支持向量机模型来说,分类或回归超平面可能因为过拟合而严重畸变,导致外推的时候出现巨大误差。

以本算例为例,1 号井开采时间最长,2~6 号井没有那么长的数据记录,所以以 2~6 号井的生产数据进行学习,得到“模型二”,再代入 1 号井的特征

变量进行预测检验,则会出现较大的误差。具体如图 2 所示。




图 2 以 2~6 号井为训练集对 1 号井进行预测检验 (e-SVR 模型二)

Fig.2 Forecast test for Well #1, with Wells #2-#6 as the training set (Model II)

按均方差最小进行优化搜索后,模型二的学习参数为:“-s 3 -c 32 -g 1 -p 0.05”,输入数据 2 948 组,找出支持向量 2 685 组,其中边界支持向量 2 639 组,其回归均方差达到 50.138,而回归相关性系数仅为 0.804。

对比两个模型的数据可以看出,它们的支持向量占比都非常高,而且其中边界支持向量比例也都很高,也就是说过拟合风险都很大。而从图中可以看出,最早约 100 d 的图线吻合度依然良好,但是随后的图线出现了大范围的偏移。再结合较大的回归均方差和较低的回归相关性系数,可以认为过拟合确实发生,并影响了最终的预测结果。但是,放大两个模型的前 95 d 的图线可以发现(图 3、图 4),两个模型对这段时间的预测基本一致。




图 3 1 号井回归模型 (模型一,前 95 d)

Fig.3 Regression model of Well #1 (Model I, first 95 d)




图 4 以 2~6 号井为训练集对 1 号井进行预测检验 (模型二,前 95 d)

Fig.4 Forecast test for Well #1, with Wells #2-#6 as the training set (Model II, first 95 d)

通过图 3 和图 4 的对比不难看出,只要数据足够密集(各井的前 100 d 的数据都齐备),通过学习多井数据来预测同一区块的另一口井的压力曲线是可行的。

4 结论

本文介绍了基于支持向量机的非参数统计学习方法,并应用到页岩气田产能预测中。对长宁页岩气田某区块 6 口井的数据进行了单井回归和多井预测单井压力曲线的检验。其中单井回归拟合较好,体现了支持向量回归的特点;而多井训练预测单井则只在数据密集区间取得了较好的效果。

考虑到这 6 口井虽然在同一个区块,但是在生产时间上有一定的先后顺序。所以,也可以尝试增加时间参数用来表征区块开采的先后顺序,或者也可以用全区块总产量等表达区块总的开采程度,来体现先开采的井对后来的影响。由此,支持向量机学习的特征向量空间将继续扩大,对学习样本数量的需求也将随之放大。考虑到一个区块上的油井数量有限,应针对性的提出更大规模机器学习的算法和优化手段。

致谢:感谢中国科学技术大学石油天然气研究中心同意本文发表;感谢李道伦老师、查文舒老师等人在论文选题、研究过程和论文修改上提出的宝贵建议。

参考文献

[1] ARPS J J. Analysis of decline curves [J]. Transactions of the AIME, 1945, 160(1): 228-247.
 [2] FETKOVICH M J. Decline curve analysis using type curves [J]. Journal of Petroleum Technology, 1980, 32(6): 1065-1077.

- [3] CARTER R D. Type curves for finite radial and linear gas-flow systems: constant-terminal-pressure case [J]. Society of Petroleum Engineers Journal, 1985, 25(5): 719-728.
- [4] PALACIO J C, BLASINGAME T A. Decline curve analysis using type curves-analysis of gas well production data [J]. SPE 25909, 1993.
- [5] AGARWAL R G, GARDNER D C, KLEINSTEIBER S W, et al. Analyzing well production data using combined type curve and decline curve analysis concepts [C]. SPE 49222, 1998.
- [6] 肖阳, 江同文, 冯积累, 等. 不关井试井分析在桑南西生产动态分析中的应用[J]. 油气井测试, 2012, 21(1): 19-21.
XIAO Yang, JIANG Tongwen, FENG Jilei, et al. Application of well test analysis without closing well for production performance in the Sangnan Oilfield [J]. Well Testing, 2012, 21(1): 19-21.
- [7] 梅显旺, 罗梅, 马威奇, 等. 致密油水平井多级压裂后产能影响因素分析[J]. 油气井测试, 2016, 25(4): 29-32.
MEI Xianwang, LUO Mei, MA Weiqi, et al. Analysis of influencing factors on productivity after multistage fracturing to tight oil of horizontal well [J]. Well Testing, 2016, 25(4): 29-32.
- [8] 汪益宁, 李洪, 肖伟, 等. 生产数据分析在哈拉哈塘油田储层评价中的应用[J]. 钻采工艺, 2016, 39(6): 46-49.
WANG Yining, LI Hong, XIAO Wei, et al. Application of production data analysis in carbonate reservoir evaluation at Halahatang Oilfield [J]. Drilling & Production Technology, 2016, 39(6): 46-49.
- [9] LI Q, LI P, PANG W, et al. A new method for production data analysis in shale gas reservoirs [J]. Journal of Natural Gas Science and Engineering, 2018, 56: 368-383.
- [10] 方瑞明. 支持向量机理论及其应用分析[M]. 北京: 中国电力出版社, 2007: 66-92, 131-159.
- [11] 刘敬, 谷利泽, 钮心忻, 等. 基于单分类支持向量机和主动学习的网络异常检测研究[J]. 通信学报, 2015, 36(11): 136-146.
LIU Jing, GU Lize, NIU Xinqi, et al. Research on network anomaly detection based on one-class SVM and active learning [J]. Journal on Communications, 2015, 36(11): 136-146.
- [12] 薛磊, 吴炜, 杨晓敏, 等. 一种基于支持向量回归的多层原油分层产能贡献预测模型[J]. 石油化工高等学校学报, 2006, 19(4): 88-92.
XUE Lei, WU Wei, YANG Xiaomin, et al. A forecasting model of productivity contribution in single zone of multiple-zone production based on support vector regression [J]. Journal of Petrochemical Universities, 2006, 19(4): 88-92.
- [13] 李卓, 柴滨景, 胡继东. 支持向量机在油田系统建模中的应用[J]. 现代电子技术, 2007, 30(1): 162-164.
LI Zhuo, CHAI Binjing, HU Jidong. A novel approach to model in oilfield based on support vector machine [J]. Modern Electronics Technique, 2007, 30(1): 162-164.
- [14] 石广仁. 支持向量机在裂缝预测及含气性评价应用中的优越性[J]. 石油勘探与开发, 2008, 35(5): 588-594.
SHI Guangren. Superiorities of support vector machine in fracture prediction and gassiness evaluation [J]. Petroleum Exploration and Development, 2008, 35(5): 588-594.
- [15] 汪旭颖. 基于支持向量回归机的油田异常井预警模型研究[D]. 大庆: 东北石油大学, 2015.
WANG Xuying. Research on early warning model of oilfield abnormal wells based on support vector regression [D]. Daqing: Northeast Petroleum University, 2015.
- [16] 赵小龙. 基于支持向量机的深层地应力预测模型[J]. 特种油气藏, 2016, 23(1): 139-141.
ZHAO Xiaolong. SVM deep geo-stress prediction model [J]. Special Oil & Gas Reservoirs, 2016, 23(1): 139-141.
- [17] 李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012: 95-134.
- [18] Vapnik V. The nature of statistical learning theory [M]. Springer Science & Business Media, 2013: 133-140.

编辑 王军

第一作者简介: 祝元宪, 男, 1988年出生, 中国科学技术大学近代力学系在读硕士研究生, 主要研究方向为致密油气藏试井及产能预测。电话: 158567984326; Email: redsky@mail.ustc.edu.cn。通信地址: 安徽省合肥市中国科学技术大学西区力四楼 616, 邮政编码: 230026。