

DOI:10.3969/j.issn.1003-5060.2023.12.020

基于卷积神经网络的压裂停泵数据滤波方法

徐 靛, 李道伦, 查文舒

(合肥工业大学 数学学院, 安徽 合肥 230601)

摘 要:水力压裂停泵时,由于水击效应的影响,井口处压力会产生波动,此时测量得到的压力数据不能反映真实的渗流情况,不利于试井解释,需要对压裂停泵后的压力数据进行数据滤波。针对该问题,文章提出一种基于卷积神经网络的滤波方法:基于方差思想,构造可表征数据离散程度的损失函数,用以约束滤波后数据的离散程度;基于停泵压力数据的物理特征,给出可保留停泵压力最高点的损失函数表征方法;在此基础上,构造一个 9 层的卷积神经网络模型,使得神经网络能够合理完成数据滤波。对于水平井多段压裂停泵压力数据的样本,只需进行 1 次合适的参数调整,同一网络框架可以完成对以上不同段压力数据的处理,且实验效果好;以均值和相对误差为参照标准,对比滤波前后的压力数据,滤波后的数据与原始数据相比,离散程度变化较小,且与原有数据相比仍能保持较小的相对误差,基本稳定在 0.2% 左右。该滤波方法为压裂效果评价提供了可靠数据,具有广阔的应用前景。

关键词:数据滤波;神经网络;自定义损失函数;一维卷积;水击效应;水力压裂

中图分类号:TP181

文献标志码:A

文章编号:1003-5060(2023)12-1717-05

A filtering method of fracturing pump-stop data based on convolutional neural network

XU Liang, LI Daolun, ZHA Wenshu

(School of Mathematics, Hefei University of Technology, Hefei 230009, China)

Abstract: With the hydraulic fracturing pump stop, the pressure at the wellhead will fluctuate due to the water hammer effect. At this time, the measured pressure data cannot reflect the real seepage situation, which is not conducive to well test interpretation. Therefore, it is necessary to filter the pressure data after the fracturing pump stop. Aiming at this phenomenon, this paper proposes a convolutional neural network-based filtering method. Based on the idea of variance, a loss function is constructed to characterize the dispersion of the data to constrain the dispersion of the filtered data; based on the physical characteristics of the stopping pressure data, a loss function characterization method is given to retain the highest point of the stopping pressure. Based on this, a nine-layer convolutional neural network model is constructed to enable the neural network to reasonably complete the data filtering. For the pressure data samples of multi-stage fracturing in horizontal wells, only one appropriate parameter adjustment is needed, and the same network framework can complete the processing of the above pressure data of different stages, and the experimental effect is good. Taking the mean value and relative error as the reference standard, and comparing the pressure data before and after filtering, it is found that compared with the original data, the dispersion degree of the filtered data has less variation, and the relative error can still be kept at about 0.2%. This filtering method provides reliable data for fracturing effect evaluation and has a broad application prospect.

收稿日期:2022-04-10;修回日期:2022-05-19

基金项目:国家自然科学基金资助项目(12172115)

作者简介:徐 靛(1997—),女,安徽六安人,合肥工业大学硕士生;

李道伦(1972—),男,安徽合肥人,博士,合肥工业大学教授,博士生导师;

查文舒(1982—),男,安徽池州人,博士,合肥工业大学副教授,硕士生导师。

Key words: data filtering; neural network; custom loss function; one-dimensional convolution; water hammer effect; hydraulic fracturing

0 引言

水力压裂,即在地面用电泵机向井筒注入大量压裂液,使液体在井底形成高压,并将地层压开,扩大地层与井筒的接触面积,提高油气的渗流速度起到增产的方法^[1-2]。在低渗油气、致密油气、页岩油气开发过程中,为获得较高的经济产能,需要对地层进行大规模体积压裂^[3-7]。

停泵关井的瞬间,压裂液流量骤降为 0,压力会在极短时间内下跌,油管内的非恒定有压管流流体流速在某个时间点将会发生突变。流体速度前后不一致使流体在管内压缩,但流体的流动方向与原先仍保持一致,并在惯性力的作用下以波动的形式继续向井底流动,这种波动在触底后反弹。在此阶段,压力的具体变化为停泵短期内呈现大幅波动起伏变化,并伴有周期性特征^[8-9],但随着时间推移逐渐减弱,最终趋于平缓,这种现象被称作水击效应^[10]。

井口压力变化特征可反映水力压裂的效果,对压裂停泵后的数据进行参数反演,不仅可以得到反映地层信息的重要参数,还可以在开采前通过压裂效果评价控制施工的成本^[11-13]。由于水击效应等多种因素的干扰,井口采集的压力数据夹杂着大量噪声,不能直接用以压裂效果评价,需要对水击压力进行滤波。

数据去噪有小波去噪、巴特沃斯低通滤波器、FIR 低通滤波器和数据平滑处理去噪等方法。传统的信号滤波最常见的处理方法是小波去噪^[14-16]。首先通过小波基作小波变换将数据进行小波分解;其次挑选一个合适的阈值函数筛选和处理需要保留的小波分解系数,得到估计小波分解系数;最后通过逆变换完成信号的重构,完成数据滤波^[17-19]。而其他去噪方法则是通过一些算法将信号里的噪声除去,进而提升振动曲线光滑度,但是这些滤波方法的处理过程比较繁琐,对水击压力波去噪效果差,且传统的信号处理方法对于非平稳性的信号不适用^[20]。

深度学习属于机器学习的一个新研究领域,通过构建含有多个隐藏层的网络模型,学习大规模数据,获取样本中的内在规律。近年来,深度学习作为一门新兴且强大的信息处理工具,在试井解释上有出色的应用。文献^[21-23]利用卷积神

经网络进行径向复合油藏自动试井解释;文献^[24-25]利用深度学习进行数字岩心重建;文献^[26-28]利用深度学习完成渗流力学方程的求解。以深度学习为核心的人工智能正在油气开发领域掀起新的研究热潮。

卷积神经网络在 20 世纪 80 年代被提出,是一种不断发展的前馈型神经网络,也是当下最流行的深层神经网络之一;它可以从大规模数据中学习细节特征,并对特征进行组合,提升其泛化能力。基于深度学习,本文提出一种基于一维卷积神经网络的滤波方法,该网络框架可适用于水平井多段的压裂停泵压力数据,且去噪效果良好。

1 停泵压力数据与卷积神经网络概述

1.1 水力压裂停泵压力数据

通常的停泵压力数据如图 1 所示。




图 1 停泵压裂压力数据(原始噪声数据)

从图 1 可以得到以下特征信息:

1) 噪声主要集中在总体数据前 20% 局部范围内,使得曲线形态上下振荡较为明显,呈锯齿状;而后 80% 数据中夹杂的噪声较少,曲线形态无明显激烈震荡。

2) 由于受水击效应的影响,前 20% 的压力数据离散程度大,振荡剧烈且压力变化明显,呈现周期性波动特征,伴随着时间的推移,振幅逐渐减小,整个压力曲线总体上呈下降的趋势。

1.2 一维卷积神经网络

一维卷积一般用来处理序列数据,且只对数据的宽度进行卷积,对高度不卷积。卷积层一般含有多个卷积核,卷积核中的单个元素都由 1 个权值构成,卷积核通过对各维的序列数据做一维卷积运算,提取该层的特征信息^[29],而卷积层的功能是提取整个输入数据的特征。本文中一维卷积核计算原理如图 2 所示,其中, $y_1 = x_1k_1 + x_2k_2 + y_3k_3$ 。




图 2 一维卷积核计算原理

本文中的卷积神经网络有 9 层,由输入层、7 个卷积层和 Flatten 层构成。输入层将压力数据 x_1, x_2, \dots, x_n 作为输入数据,其中: n 表示数据的样本点数; x_i 表示在第 i 时刻的压力数据;卷积层将卷积核以窗口方式滑动处理数据,提取数据的特征值形成特征向量;Flatten 层将上一层得到的全部特征向量整合成列向量。

1.3 一维卷积神经网络的优化

为使网络结构进一步优化,网络能够合理滤波,基于方差思想并保留停泵压力最高值特征,构造了可表征数据离散程度的损失函数。设输出数据为 $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$,且对输出值每连续 5 个点做一次方差,并用方差的均值进一步约束数据的离散程度,减少数据的浮动。方差公式为 $D(X) = E(X^2) - E^2(X)$,对应方差均值为:

$$L(\hat{y}_i) = \frac{1}{n-4} \sum_{i=1}^{n-4} \sum_{j=i}^{i+4} \left[\frac{\hat{y}_i^2}{5} - \left(\frac{\hat{y}_i}{5} \right)^2 \right]_j \quad (1)$$

而停泵压力的最高点往往是真值,代表压裂最后一刻的压力,也是停泵瞬间的压力,需保留,为此必须约束 x_1 与 \hat{y}_1 的关系。融合方差约束条件,保留停泵压力最高点数值特征,并结合均方误差自定义损失函数如下:

$$L_{\text{custom}}(x_i, \hat{y}_i) = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{y}_i)^2 + 100L(\hat{y}_i) + 0.01 |x_1 - \hat{y}_1| \quad (2)$$

2 基于卷积神经网络的滤波方法

2.1 卷积神经网络模型的搭建

在数据滤波问题上,假设原始压力数据为 $X(t)$,噪声数据为 N ,含噪压力数据为 $Y(t)$,其中 X, Y 都是关于时间 t 的函数,三者之间的关系为:

$$Y(t) = X(t) + N \quad (3)$$

本文提出的压裂停泵压力数据滤波方法是含噪数据 Y 中滤除噪声 N ,从而恢复原始不含噪数据 X 。本文的实验思路是将原始压力数据 X 和滤波后压力数据 Y 分别作为神经网络的输入和输出数据,使用卷积核提取数据的特征值,通过误差反向传播调整其中的权值和参数,使目的函数

最小化,使得网络能够完成合理的数据滤波,滤除噪声数据 N ,可得滤波后的数据 \tilde{X} 。滤波数据与原始数据之间的关系为 $\tilde{X} \approx X = Y - N$ 。

2.2 算法流程

使用神经网络处理数据前,需要对数据集做一些预处理,比如数据清洗、数值缩放等,这些工作可以提高神经网络的训练效率。基于卷积神经网络的滤波流程如下:

1) 数据收集与预处理。在使用神经网络前对数据做预处理,有利于神经网络的训练效率。本文使用 Min-Max 归一化将数据映射到 $0 \sim 1$ 范围内,方便数据的处理,且不改变数据的分布状态。此外,Min-Max 归一化方法可以减少神经网络训练的计算时间,加快梯度下降,进而提升模型的收敛速度。归一化公式为:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

其中: x 为归一化前的含噪压力数据; x^* 为经过归一化处理的含噪压力数据; x_{\min}, x_{\max} 分别为归一化处理前的数据中的最小值和最大值。

在原始数据集上选取实验所需的时间和压力数据段,将处理后的整个时间和压力数据分别作为网络的输入和输出,并对二者做归一化处理,使网络在计算过程中能减少收敛所需的时间。

2) 实验数据拟合。利用自定义损失函数,融合方差约束条件并保留停泵压力最高点特征,在网络训练过程中最小化目标函数,对预测值与输入值之间进行合理约束,使滤波后的压力数据的离散程度尽可能小,输出滤波后的数据。

3) 数据评估。数据评估在数据处理开发和利用过程中扮演着不可或缺的角色,有助于选择数据的最佳模型和评估模型处理数据的性能,也是评估研究是否达到预期目标的主要依据和判断标准。

在预测值和真实值比较问题上,常用的误差计算方法有绝对误差和相对误差,计算公式分别为:

$$A_e = |y_i - \hat{y}_i| \quad (5)$$

$$R_e = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6)$$

其中: y_i 为真实值,即压裂停泵压力的原始数据; \hat{y}_i 为滤波后的压力数据。

停泵压力数据滤波效果优劣主要依靠专业人员的分析,缺乏绝对性的判断标准;用绝对误差对比滤波前后的数据,微小的数据变化可能导致结

果差别很大,评价不够合理;因此本文从数据滤波前后的离散程度和分布角度出发,使用相对误差的均值作为评估标准,具体表达式为:

$$R_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

3 实际案例研究

本文选择同一水平井 3 个不同时间段的压裂停泵压力数据作为实验数据,验证本文方法的有效性。使用卷积神经网络滤波之后的效果如图 3 ~ 图 5 所示。由图 3 ~ 图 5 可知:噪声主要集中在整体数据的前 20% 区间内,造成数据的曲线形态在短期内上下振荡;后 80% 数据受噪声的影响较小,整个压力曲线总体上呈下降趋势。




图 3 数据 1 的滤波前后结果




图 4 数据 2 的滤波前后结果




图 5 数据 3 的滤波前后结果

使用卷积神经网络对压力数据进行滤波后,由图 3 滤波后的压力曲线可知:滤波后的数据起始点能够与停泵压力最高点齐平,并穿过含噪高的数据震荡区域,且滤波后的数据离散程度明显变小;滤波后的压力曲线依旧保持先下降最终趋于平缓的趋势,说明这种卷积神经网络滤波方法能够在保持原有数据总体趋势不变的情况下,对

压力数据曲线形态尽可能达到最大平滑。

图 4 和图 5 反映的滤波效果与图 3 一致,说明该模型可适用于同一水平井多段压裂停泵压力数据的样本。综上所述,本文搭建的卷积神经网络对压裂停泵压力数据有很好的滤波效果。

压裂停泵压力数据滤波前后的数据对比结果见表 1 所列。从表 1 可以看出:滤波前后前 20% 压力数据和总体压力数据的均值非常接近,说明滤波实验前后卷积神经网络能够较好地保证数据的离散程度和分布程度;以原始压裂停泵压力数据作为参照,对比滤波前后压力数据的相对误差,实验计算出的相对误差范围较小,数值基本上稳定在小数点后 2 ~ 3 位,进一步表明卷积神经网络滤波后,数据依旧保持很高的可信度,从而证明卷积神经网络滤波的可行性。

表 1 压裂停泵压力滤波前后数据均值对比

序号	前 20% 噪声	前 20% 滤波	所有 噪声	所有 滤波	相对 误差 / %
1	30.690	30.835	28.260	28.292	0.2
2	35.035	35.301	32.095	32.159	0.2
3	41.841	42.052	38.020	38.055	0.2

综上所述,以均值和相对误差为参照标准,对比滤波前后的压力数据,滤波后的数据与原始数据相比,离散程度变化较小,且与原始数据相比仍能保持较小的相对误差,基本稳定在 0.2% 左右;滤波前后数据最高点相齐平,保留了停泵瞬间压力的物理特征,说明该滤波方法为压裂效果评价提供了可靠数据;滤波后的压力数据很好地保留了关井压力数据的瞬态特征,说明该方法是有效的。正确性的检验还需要井口、井底压力数据,完成正确性的检验可进一步改进与完善滤波方法。

4 结 论

本文提出了一种基于卷积神经网络的压裂停泵数据滤波方法,使用 7 个卷积层提取含噪声压力数据的特征信息,基于方差思想,保留停泵压力最高点数值特征,构造可表征数据离散程度的损失函数,用以约束输出数据的离散程度,使得神经网络能够合理滤波。

实验过程首先对油田相关数据进行预处理,将原始压力数据 X 和滤波后压力数据 Y 分别作为神经网络的输入和输出,利用卷积核提取数据特征,使用自定义损失函数约束两者之间的关系,油田相关数据滤波取得较好效果,能很好地去除停

泵压力数据噪音;实际案例研究验证了该方法的可行性与有效性,能有效减少试井解释工作人员的工作负荷,有广阔的应用前景。

[参 考 文 献]

- [1] 温杰雄,田伟,毕全福,等. 基于数字滤波的压裂停泵数据反演方法[J]. 中国科学技术大学学报,2018,48(5):392-399.
- [2] 温杰雄. 基于水锤和信号降噪的压裂数据分析方法研究[D]. 合肥:中国科学技术大学,2017.
- [3] ZHANG Z,LI J,ZHENG Y S,et al. Finite service life evaluation method of production casing for sour-gas wells[J]. Journal of Petroleum Science and Engineering, 2018,165:171-180.
- [4] ZHANG Z,ZHANG N Y,LIU Z W,et al. Synergistic effects of corrosion time and stress on corrosion of casing steel in H₂S/CO₂ gas wells[J]. Materials and Corrosion, 2018,69(3):386-392.
- [5] ZHANG Z,SHAO LY,LI J,et al. Environmentally assisted cracking performance research of casing for sour gas wells[J]. Journal of Petroleum Science and Engineering, 2017,158:729-738.
- [6] 张智,何雨,黄茜,等. 含硫气井完整性风险等级预测研究[J]. 中国安全科学学报,2017,27(10):155-161.
- [7] 张智,李炎军,张超,等. 高温含CO₂气井的井筒完整性设计[J]. 天然气工业,2013,33(9):79-86.
- [8] 陈林. 气井多相流水击数学模型的建立和求解[J]. 石油学报,2017,38(7):813-820.
- [9] 曾凌翔,郑云川,蒲祖凤,等. 页岩气水平井压裂改造多角度分析研究[J]. 钻采工艺,2020,43(2):72-74,5.
- [10] 张智,王嘉伟,李炎军,等. 高产气井瞬时关井对油管内流体流动的影响[J]. 石油勘探与开发,2020,47(3):600-607.
- [11] 陈劲松,曹健志,韩洪宝,等. 页岩油气井常用产量预测模型适应性分析[J]. 非常规油气,2019,6(3):48-57.
- [12] 董浩,马轮,韦乐乐,等. 页岩气藏体积压裂产能影响因素分析[J]. 非常规油气,2014,1(2):55-66.
- [13] 张忠林,申峰,徐栋哲,等. 利用压裂停泵数据的大规模体积压裂改造区域反演方法及其应用[J]. 非常规油气,2020,7(6):81-89.
- [14] 郑建国,石智,权豫西. 非平稳信号的小波包阈值去噪方法[J]. 信息技术,2007(3):16-18.
- [15] 李海东,李青. 基于阈值法的小波去噪算法研究[J]. 计算机技术与发展,2009,19(7):56-58.
- [16] 马东,杨铮,王立玲. 基于改进小波去噪算法的sEMG研究[J]. 东北师大学报(自然科学版),2019,51(3):77-81.
- [17] 张建军,贾永禄,张烈辉. 长时压力监测数据处理新方法与应用研究[J]. 西南石油大学学报(自然科学版),2010,32(2):133-137.
- [18] 谭健,贾永禄,覃芳,等. 小波理论在试井长时压力计数据分析中的应用研究[J]. 钻采工艺,2008,31(4):44-46.
- [19] 杨济源,李晓平. 小波变换在试井数据处理中的应用[J]. 钻采工艺,2009,32(5):42-44.
- [20] 江莉,尚文擎,周军妮,等. 一种用于地震信号分析的二阶挤压小波变换算法[J]. 电子与信息学报,2021,43(12):3710-3717.
- [21] 李道伦,刘旭亮,查文舒,等. 基于卷积神经网络的径向复合油藏自动试井解释方法[J]. 石油勘探与开发,2020,47(3):583-591.
- [22] LIU X L,LI D L,YANG J H,et al. Automatic well test interpretation based on convolutional neural network for infinite reservoir[J]. Journal of Petroleum Science and Engineering, 2020,195:107618.
- [23] LIU X L,ZHA W S,QI Z K,et al. Automatic reservoir model identification method based on convolutional neural network[J]. Journal of Energy Resources Technology, 2021,144(4):043002.
- [24] ZHA W S,LI X B,XING Y,et al. Reconstruction of shale image based on Wasserstein Generative Adversarial Networks with gradient penalty[J]. Advances in Geo-Energy Research, 2020,4(1):107-114.
- [25] ZHA W S,LI X B,LI D L,et al. Shale digital core image generation based on generative adversarial networks[J]. Journal of Energy Resources Technology, 2021,143(3):033003.
- [26] LI D L,SHEN L H,ZHA W S,et al. Physics-constrained deep learning for solving seepage equation[J]. Journal of Petroleum Science and Engineering, 2021,206:109046.
- [27] ZHA W S,ZHANG W,LI D L,et al. Convolution-based model-solving method for three-dimensional,unsteady, partial differential equations[J]. Neural Computation, 2022,34(2):518-540.
- [28] SHEN L H,LI D L,ZHA W S,et al. Surrogate modeling for porous flow using deep neural networks[J]. Journal of Petroleum Science and Engineering, 2022,213:110460.
- [29] 李盼池,李文杰. 基于一维卷积神经网络的岩石物理相识别[J]. 吉林大学学报(信息科学版),2022,40(1):51-63.

(责任编辑 朱晓临)