

Exploration of Deep Learning Technology in Remaining Oil Prediction of Y Oilfield

Qing Wang^{1,2} Airong Li^{1*} Jiawei Ren³ Zhenzhou Li³ Ning Yin³

1. School of Earth Science and Engineering, Xi'an Shiyou University, Xi'an, Shaanxi, 710065, China

2. Geological Research Center of Geophysical Prospecting Co., Ltd., CNPC, Zhuozhou, Heibei, 072750, China

3. Bureau of Geophysical Prospecting Co., Ltd. CNPC, Zhuozhou, Heibei, 072750, China

Abstract

With a large number of oil fields from the exploration stage into the development stage, the demand for fine reservoir description has become increasingly prominent. Residual oil distribution is related to the preparation of development plan, so residual oil prediction technology has become one of the important technical means of reservoir development. The commonly used residual oil prediction method has the shortcomings of multi-attribute coupling and cannot guarantee the accuracy. Deep learning neural network algorithm can establish nonlinear mapping relationship between data through data training, and then obtain unknown data through data learning. Therefore, this paper carried out the exploration of deep learning technology in remaining oil prediction. By using the information of seismic well sideways in 1991 and 2011 and the water saturation curve of drilling during seismic acquisition, and through the deep learning neural network model, the nonlinear mapping relationship between seismic data and water saturation information was established to realize the input of seismic data volume and the output of water saturation volume, and then the remaining oil plane prediction diagram of Y oilfield in 2011.

Keywords

deep learning; neural network; remaining oil prediction

深度学习技术在 Y 油田剩余油预测中的探索

王青^{1,2} 李爱荣^{1*} 任嘉伟³ 李振周³ 尹宁³

1. 西安石油大学地球科学与工程学院, 中国·陕西 西安 710065

2. 东方地球物理公司研究院地质研究中心, 中国·河北 涿州 072750

3. 东方地球物理公司研究院, 中国·河北 涿州 072750

摘要

随着大量油田由勘探阶段向开发阶段转移,对油藏精细描述的需求日益突出。剩余油分布关系到开发方案的编制,因此剩余油预测技术成为油藏开发的重要手段之一。当前常用的剩余油预测方法存在多属性耦合、精度无法保证的缺点,深度学习神经网络算法,可以通过数据训练建立数据之间的非线性映射关系,再通过数据学习获得未知数据。因此,论文开展了深度学习技术在剩余油预测中的探索,利用1991年和2011年地震井旁道信息和地震采集时钻井的含水饱和度曲线,通过深度学习神经网络模型,建立地震数据和含水饱和度信息之间的非线性映射关系,实现地震数据体输入以及含水饱和度体的输出,进而刻画出Y油田2011年的剩余油平面预测图。

关键词

深度学习;神经网络;剩余油预测

1 背景介绍

随着大量油田由勘探阶段进入开发阶段,对油藏精细描述的需求日益突出。为了实现油田油气产能的跨越,要

【作者简介】王青(1988-),女,中国河北人,本科,工程师,从事地震资料解释研究。

【通讯作者】李爱荣(1976-),女,中国河北人,副教授,从事油气田地质与开发研究。

求老油田产量稳中有升。当前作为“压舱石”地位的开发油气田,是塔里木油田黑油产能建设的重要组成部分,特别需要精细描述出剩余油的分布格局,为油气高效开发做出强有力的支撑。但在经历三十余年的持续开发后,塔里木盆地大部分老油气藏已处于开发中后期阶段,高含水、低采出、稳产难的特点愈发明显,井间生产动态矛盾日益突出,剩余油气呈“整体高度分散、局部相对富集”的状态。传统的地质和物探技术已逐渐不能满足刻画复杂剩余油气的需求,老油气藏增储上产迫在眉睫,亟需开展专项攻关

研究,为老油气藏深度挖潜提供重要技术手段,为油藏下一步精细开发提供技术支撑。

为了实现研究区的剩余油有效预测,研究人员对当前剩余油预测技术进行了调研和针对性分析^[1]。①频率域属性分析技术:根据水层和油气层对地震波能量吸收衰减在频率域造成的差异,直接识别流体性质,如碳烃检测技术、流体活性等。频率域属性技术受子波的调谐作用影响严重,而且属于定性预测,精度较低^[2]。②叠前反演技术:根据叠前道集AVO特征,提取敏感性参数,预测地下储层及流体性质。但是在研究区内,深埋储层地震反射角度小,密度项已经难以满足叠前反演孔隙度有效预测的适用条件,同时地震资料品质不够高,流体敏感参数受噪声影响严重,表现出抗噪性差、不稳定的缺陷,叠前反演结果不确定性较高^[3]。③时移地震技术(4D地震):通过在同一工区不同时间点重复采集三维地震数据,将重复地震数据相减,再根据数据差异性预测剩余油气分布。时移地震技术对地震数据采集与处理要求较高且成本较大,同时如果两次采集参数差异较大,时移地震的方法也难以有效地准确刻画剩余油分布。

综合上述,剩余油预测技术虽然多样,但总结归纳起来,都是基于一个数学模型,将地震数据转换为流体敏感参数。同时受地震数据影响和非线性算法的限制,求解往往难度大,并且精度难以保证,因此需要一种新的方法,实现研究区的剩余油有效预测。

人工智能深度学习算法让计算机结合大数据优势自主建立最优模型进行求解,具有一定可行性。

2 主要方法及探索应用

为了降低求解难度,提升剩余油预测精度,本次研究结合工区实际背景,提出了深度学习预测剩余油的方法。深度学习是机器学习的一种,而机器学习是实现人工智能的必经路径。深度学习的概念源于神经网络的研究,含多个隐藏层的多层感知器就是一种深度学习结构。深度学习通过组合低层特征形成更加抽象的高层表示属性类别或特征,以发现数据的分布式特征表示。

区别于传统的浅层学习,深度学习的优势在于其强调了模型结构的深度,通常有5层、6层,甚至10多层的隐层节点。同时,有效并且针对性的样本集建立,也进一步明确了特征学习的重要性。也就是说,通过逐层特征变换,将样本在原空间的特征表示变换到一个新特征空间,从而使分类或预测更容易。与人工规则构造特征的方法相比,利用大数据来学习特征,更能够刻画数据丰富的内在信息,具有一定的可行性^[4]。

2.1 深度学习原理

深度学习技术是神经网络模型和机器学习算法的结合,让计算机结合大数据优势自主建立最优模型进行求解的过程^[5]。

神经网络的基本单元是神经元模型(图1左)在神经元模型中,神经元接收到来自n个其他神经元传递过来的输入信号,这些输入信号通过带权重的连接进行传递,神经元接收到的总输入值将与神经元的阈值进行比较,然后通过激活函数处理以产生神经元的输出。

把许多个这样的神经元按一定的层次结构连接起来,就得到了神经网络。根据数据在神经网络模型中的传播方向可以将其划分为前向网络和反馈网络^[6]。在前向网络中,数据只从输入层传播到输出层,而反馈网络还存在数据从输出层到输入层的反向传播。深度学习神经网络模型在基础模型中加入了多层隐含层,并且能够根据计算目标对象和精度需求调整隐含层的层数和节点数,实现输入数据和输出数据的复杂非线性映射关系建立(图1右)。




图1 神经元模型与单隐含层神经网络模型

根据数据的传播方向,可以划分为:信号的前向传播和误差的反向传播,即计算实际输出时按从输入到输出的方向进行,而权重和阈值的修正从输出到输入的方向进行。以包含一层隐含层的神经网络模型为例,输入信号 x_i 、权重 w_{ji} 、阈值 a_j 和 b_k 、激活函数 f 以及输出信号 y_k 在信号的前向传播过程中:

隐含层第j个节点的输入 p_j :

$$p_j = \sum_{i=1}^I w_{ji} x_i - a_j \quad (1)$$

隐含层第j个节点的输出 q_j :

$$q_j = f(p_j) = f\left(\sum_{i=1}^I w_{ji} x_i - a_j\right) \quad (2)$$

输出层第k个节点的输入 r_k :

$$r_k = \sum_{j=1}^J w_{kj} q_j - b_k = \sum_{j=1}^J w_{kj} f\left(\sum_{i=1}^I w_{ji} x_i - a_j\right) - b_k \quad (3)$$

输出层第k个节点的输出 s_k :

$$s_k = g(r_k) = g\left(\sum_{j=1}^J w_{kj} f\left(\sum_{i=1}^I w_{ji} x_i - a_j\right) - b_k\right) \quad (4)$$

误差的反向传播,首先由输出层开始逐层计算各层神经元的输出误差,然后根据误差调节各层的权重和阈值,使修改后网络的最终输出能接近期望值。常用的优化算法有最速下降法和共轭梯度法。

对单一样本 p ,理论输出为 T_k ,实际输出为 y_k 的二次型误差准则函数 E_p :

$$E_p = \frac{1}{2} \sum_{k=1}^K (T_k^p - y_k^p)^2 \quad (5)$$

P 个训练样本的总误差准则函数 E:

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{k=1}^K (T_k^p - y_k^p)^2 \quad (6)$$

不同优化方法对权重和阈值的修正是不一样的,以步长为 η 的最速下降法为例:

输出层权重修正量:

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} = \eta \sum_{p=1}^P \sum_{k=1}^K (T_k^p - y_k^p) \cdot g'(r_k) \cdot y_k \quad (7)$$

输出层阈值修正量:

$$\Delta b_k = -\eta \frac{\partial E}{\partial b_k} = \eta \sum_{p=1}^P \sum_{k=1}^K (T_k^p - y_k^p) \cdot g'(r_k) \quad (8)$$

隐含层权重修正量:

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} = \eta \sum_{p=1}^P \sum_{k=1}^K (T_k^p - y_k^p) \cdot g'(r_k) \cdot w_{kj} \cdot f'(p_j) \cdot x_i \quad (9)$$

隐含层阈值修正量:

$$\Delta a_j = -\eta \frac{\partial E}{\partial a_j} = \eta \sum_{p=1}^P \sum_{k=1}^K (T_k^p - y_k^p) \cdot g'(r_k) \cdot w_{kj} \cdot f'(p_j) \quad (10)$$

数据训练是已知输入数据和期望值,通过信号的前向传播和误差的反向传播交替进行,不断修正神经网络模型的权重和阈值,最终获得输出数据与期望值相符的神经网络模型。数据学习则是将输入数据带入训练获得的神经网络模型中,计算得到的输出结果为学习结果。

2.2 深度学习剩余油预测效果

本次研究区选择塔里木盆地 Y 油田,位于塔北隆起西部,其周缘多个构造带均获得油气,是一个重要的富油气区带,石炭系东河砂岩段为其最终重要的储集层,以海相碎屑岩沉积为主,储层厚度纵向在 260~300m,整体表现为弱非均质特征,原始油层厚度再 120~160m,该油田发现得较早,是中国第一个海相砂岩油田,也是当时埋藏最深(5700~5800 m)的高产油田。在 1990 年发现之后,在 2001 年已全面进入开发,目前该油田正处于二次开发阶段。同时,研究区在 1991 年和 2011 年分别进行了两次三维地震采集工作,资料齐全。

本次研究的主要研究路线为,利用 1991 年和 2011 年地震井旁道信息和地震采集时钻井的含水饱和度曲线,通过深度学习神经网络模型,建立地震数据和含水饱和度信息之间的非线性映射关系,最终实现地震数据体输入以及含水饱和度和体的输出,进而实现研究区 2011 年份剩余油平面的预测(图 2)。




图 2 深度学习剩余油预测研究路线示意图

通过针对性的井旁地震道与年份井含水饱和度曲线的深度学习,得到了研究区 2011 年剩余油预测结果平面(图 3)。从深度学习计算结果的平面图上分析,暖色地区代表该油藏 2011 年剩余油相对富集区域,位于油藏东北部以及南部 Y1-4-7 井附近,冷色地区代表该油藏 2011 年油水置换程度较大,含水率较高区域,主要位于油藏西南部。为了进一步验证结果的可靠性,研究人员统计了 Y 油藏 2011 年 3 月的 31 口井的日生产平均数据(地震数据为 2011 年 3 月进行采集的),并与平面结果进行泡泡图叠合显示,其中单井泡泡图的大小代表着产液量的多少,产液量越多,泡泡图越大;泡泡图中红色的部分代表产油量,蓝色的部分代表产水量,产油量相较产水量越多,则其相应的占比也越高。

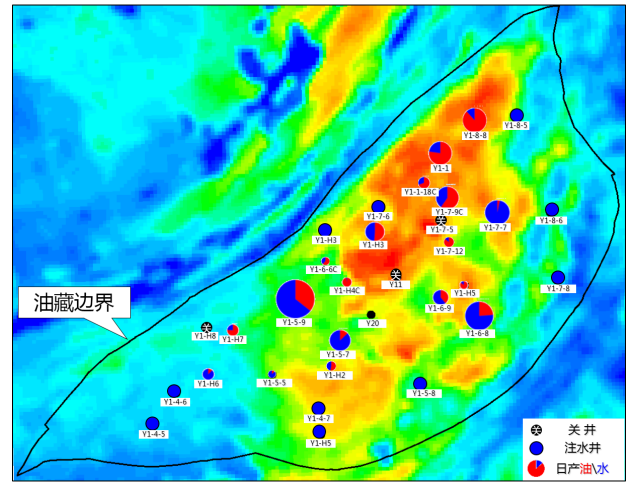


图 3 2011 年 Y 油田东河砂岩油藏含水饱和度平面叠合并 2011 年 3 月日生产数据

从生产结果上看,剔除掉两口关停井(Y1-7-5 井、Y11 井),两口未投产井(Y20 井、Y1-H8 井)以及外围的 10 口注水井,其余井均为生产井,并且产液量较大的井基本均位于工区中北部,也就是暖色地区,剩余油相对富集区域,在暖色较深地区,Y1-H3 井、Y1-7-9C 井、Y1-1 井、Y1-8-8 井含水率均相对较低,在 50% 以下,同时产油量相对较高,为该油藏生产的主力井;在深暖色向蓝色过渡的地区,虽然有些井产液量也很大,但产油量较低,含水率较高,工区北东地区的 Y1-7-7 井正位于暖色边界油水过渡带地区,含水率接近 95%。在 Y1-7-7 井南部的 Y1-6-8 井,位于油藏的边部,认为受边水影响,含水率较高,在深度学习预测结果平

面图上,该井也正位于绿色剩余油相对较少区域。在工区的中部两口井,从当时的日生产数据上分析,Y1-5-9井与Y1-5-7井两口井含水率都非常高,产油量相对较少,在深度学习预测结果平面图上,位于暖色地区的西部,剩余油相对较少地区。

在油藏的外围,根据开发方案设计,部署了10口注水井,在东北部和东南部,5口注水井均位于冷色地区,在工区的中北部地区,两口注水井Y1-H3井、Y1-7-6井随位于暖色地区,但从平面图上可以清晰看出存在向冷色带过渡变化的特征,同时Y1-7-6井局部位置处冷色带明显向暖色带延伸的细节,也展示了水驱的特征。在深度学习结果的工区的中南部,存在大面积暖色区域,在该区域的南部存在两口注水井Y1-4-7井和Y1-H5井,该两口井注水时间相对较短,为2010年新部署的注水井,所以在平面图上存在一定不吻合的现象。

通过结合生产数据,综合分析深度学习计算的平面结果,发现生产井基本位于图中的暖色地区,注水井位于冷色地区或者暖色向冷色的过渡区域,吻合度高,反映出了Y油田在2011年时的剩余油分布格局,同时结合注水井的信息,在水驱特征的局部细节上也有很好的反映。

3 结论

通过对深度学习技术在Y油田剩余油的预测探索研究,取得了较好的效果,在方法探索和分析过程中得到以下两点认识:

①通过设计建立适量的神经元计算节点和多层运算层次结构,选择合适的输入层和输出层,通过网络的学习和调优,建立起从输入到输出的函数关系,虽然不能100%找到输入与输出的函数关系,但是可以尽可能地逼近现实的关联

关系。同时,采用动态神经网络模型,可以细化目标的类别差异,克服由于岩性不同以及迭代收敛上的缺陷,有效提高深度学习结果的精度,并节省了计算时间。

②深度学习的方法已成为当前人工智能领域的重要实现手段,通过本次在地球物理领域剩余油预测的应用,可以有效规避深埋储层地震发射角度小,密度项难以适用的叠前反演问题,同时其较当前常见的剩余油预测方法,其自主建立最优模型,大数据分析的优势,更有助于提高了剩余油分布预测的精度。

参考文献

- [1] 杜睿,杨小川,韩耀祖,等.动静态结合在复杂断块油藏剩余油表征中的应用[C]//2021油气田勘探与开发国际会议论文集(下册),2021:463-469.
- [2] Li Airong, Qiang Qian, Yin Shuai, et al. Numerical simulation of remaining oil distribution in tight sandstone reservoirs: a case study of the upper Triassic Yanchang formation in the Ordos Basin, China[J]. Arabian Journal of Geosciences, 2021,14(1):73-74.
- [3] Xu SY, White RE. A new velocity model for clay-sand mixtures[J]. Geophysical Prospecting,1995,43(1):91-118.
- [4] 尹宁,李爱荣,王青,等.优势频率条件下无监督模式断裂识别技术的应用[C]//2020油气田勘探与开发国际会议论文集,2020:1909-1918.
- [5] 尹宝才,王文通,王立春.深度学习研究综述[J].北京工业大学学报,2015,41(1):48-59.
- [6] 李策,陈海霞,汉语,等.深度学习算法中卷积神经网络的概念综述[J].电子测试,2018(23):61-62.