

DOI:10.19651/j.cnki.emt.2105763

一种基于深度学习的数据无损压缩方法 及在测井大规模数据存储中的应用

陈建华¹ 高虎² 苏治俭¹ 樊举¹

(1. 中国石油集团测井有限公司长庆分公司 西安 710201; 2. 中国石油集团测井有限公司辽河分公司 盘锦 124000)

摘要: 为解决海量测井数据归档存储场景中出现的存储硬件和数据库存储容量限制等问题,提出了一种基于深度学习的数据无损压缩方法。采用循环神经网络 RNN 作为概率预测器,输出数据流的条件概率分布,结合当前字节值,使用自适应算术编码器对数据流进行压缩;解压过程中,使用保存的 RNN 网络权重和算术解码器,对数据流进行解压。所提方法较传统无损压缩方法,在一维测井数据的实际压缩测试中压缩率平均提升约 23%,在二维阵列测井数据上,平均提升约 21%。同时,结合数据无损压缩方法,提出一种基于多维特征索引查询树结构的测井大型存储数据库的构建方法,在多条件组合查询时,较传统数据库查询方法检索效率平均提升约 45%。结果表明,所提方法可有效减少测井数据的存储空间,降低数据的检索时间,为大规模测井数据的存储和利用提供了技术基础,节约数据归档的硬件成本和人力成本。

关键词: 测井数据归档;无损压缩;循环神经网络

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 510.4030

A data lossless compression method based on deep learning and application in storing of large well logging data

Chen Jianhua¹ Gao Hu² Su Zhijian¹ Fan Ju¹

(1. Changqing Branch of CNPC Logging Co., Ltd., Xi'an 710201, China;

2. Liaohe Branch of CNPC Logging Co., Ltd., Panjin 124000, China)

Abstract: To solve the problems of storing hardware and volume of database limitation in the archiving and storing scenario of massive well logging data, a lossless data compression method based on deep learning is proposed in this paper. Data stream is compressed by adaptive arithmetic encoder combining current byte with outputted conditional probability distribution of data stream by recurrent neural network RNN as probability predictor. Data stream is decompressed by saved weights of RNN and arithmetic decoder. Compared with traditional lossless compression methods, compression ratio of one dimensional log data is improved by about 23% averagely and that of two dimensional array log data is improved by about 21% averagely in actual compression test. At the same time, a large scale well logging data storing database constructing method based on multi dimensional featuring indexes querying tree structure is proposed combined with lossless compression method in this paper whose querying efficiency is improved by about 45% compared with traditional database querying method under the multi conditions combining query. Results show that storing space of logging data is decreased effectively with lower data querying time by the method in this paper which provides technical base for storing and utilization of large volume logging data and saves hardware cost and labor cost of data archiving.

Keywords: well logging data archiving; lossless compression; recurrent neural network

0 引言

测井数据是测井油服公司的地球物理勘探成果,也是

每口井对钻遇地质层位的岩石物理属性的真实反映,具有极其重要的保存价值。如 SL 测井公司历年来为 SL 油田各采油厂和外部市场甲方约 4 万口井提供了裸眼井、套管

收稿日期:2021-01-29

• 87 •

井和生产井测井作业服务,其采集的海量数据不仅是老井复查工作的前提,还构成了测井精细评价的数据基础。因此,使用大型数据库对测井数据进行归档和管理已成为各油服公司和各种测井解释一体化软件平台的通用做法^[1-2]。但随着将来测井作业井次的累积,测井数据量一直呈现上升的趋势,会不可避免地遇到存储硬件容量的瓶颈以及数据库软件存储大小的限制,这已成为各油服公司迫切需要解决的问题。

因此,采用数据压缩算法,降低测井数据的存储大小是减少数据存储硬件投入成本和增加测井存储数据库容量的有效方式,而无损压缩是保证解压后数据不失真的必要条件。目前,主流的数据库无损数据压缩方法是基于字典模型的 LZ 系列算法^[3-4],但这类算法主要针对数值变化微弱的平缓数据流,而对于变化剧烈的高分辨率测井数据,压缩率较低。文献[5]提出一种基于 BWT 变换和 PPM 算法的阵列声波数据无损压缩存储方法,但该方法只针对声波列数据,不具有方法的通用性。

目前,深度学习因其自主性的特征学习功能,已成为自然语言理解、语音识别、计算机视觉和图像处理等领域的研究热点。其中,卷积神经网络、循环神经网络和多层稀疏自动编码器已应用于图像压缩编码^[6-9]、智能电表数据压缩^[9]和高通量基因组数据无损压缩^[10]。作为一种具备学习任意复杂映射并形成广泛适用近似函数能力的神经网络模型,循环神经网络 RNN^[11-12]可以极其有效地预测序列中下一个字符,表现出优异的预测性能。因此,本文采用基于预测的无损压缩原理,构建循环神经网络模型作为序列数据的条件概率预测器,经过大量样本训练后,保存神经网络模型权值。在压缩过程中,载入保存的神经网络模型权值,计算数据流中字符的概率分布,自适应算术编码器根据该分布和当前要编码的字符,更新字符的概率区间并编码输出。解码时,自适应算术编码器根据神经网络模型输出的概率分布输出解压后的字符序列。通过在 SL 油田实际井的一维常规数据和二维阵列数据上的压缩结果,以及与传统压缩方法 LZW 和算术编码的比对,验证本文压缩方法在数据压缩率提升方面的有效性。为提升压缩数据的利用效率,结合数据压缩方法,本文将每口井压缩后数据写入数据库,并结合测井时间(年)、区块名称、数据类型(常规、固井、电成像、核磁和阵列声波等)、井号以及数据写入时随机分配的唯一 ID 等特征索引,构建多维索引数据查询树。通过与传统数据查询方法的比对,验证本文数据查询策略在提升数据查询检索效率方面的有效性。本文方法的研究可应用于油服公司大规模测井数据的归档和存储,在减少数据存储软硬件设备投入成本的基础上,提升数据库使用效率和公司的数据管理水平。

1 数据流编码、解码机制

1.1 RNN 概率预测器模型

本文采用两层多输入和多输出的门控循环单元(gated

recurrent unit,GRU)作为 RNN 模型,防止梯度弥散以及对序列中较远字符的依赖减弱等问题。神经网络模型架构如图 1 所示。

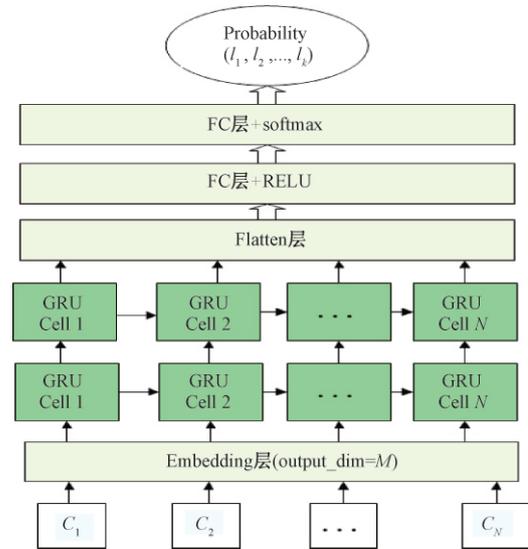


图 1 RNN 概率预测器模型

在输入层,加入 Embedding 层,将输入字符根据单层神经网络和字符在字典中的位置映射到 M 维向量空间,表征该字符在 M 个维度上的得分,使相互独立的输入字符串向量变成了有内在联系的关系向量,可以用来发现输入字符串向量之间的深层关系。这种关系在网络模型训练的反向传播过程中,在一直更新,因此能在多次 epoch 后,使得这个关系变成相对成熟,可以正确表达各个输入字符串之间的相互关系,其训练出来的向量可以更好的适应数据压缩任务。每层 GRU 单元的个数为输入字符序列长度 N 。在时刻 t ,每个 GRU 单元输出为 $(1, M)$ 维向量, M 为 GRU 单元的输出维度。在第 2 层 GRU,每个 GRU 都产生输出,形成 $(1, N, M)$ 维向量,此时加入 Flatten 层,将 $(1, N, M)$ 维向量进行串接,形成 $(1, N \times M)$ 维向量,后接两个激活函数分别为 RELU 和 softmax 的全连接层 FC,其中最上面的全连接层的神经元个数为整个压缩数据流中的字符种类数 K ,这样模型可以输出所有类别字符的概率分布,用于下一步的自适应算术编码。

GRU 作为一种扩展的带有门控循环单元的 RNN 网络单元结构^[13-14],使用了更新门(update gate)与重置门(reset gate),目的是在保留长期序列信息的同时,解决标准 RNN 中出现的梯度弥散问题。更新门将当前输入字符信息与前一个 GRU 单元输出信息分别进行线性变换后相加,并通过 Sigmoid 激活函数,将输出变换到 $0 \sim 1$ 之间,帮助模型决定上一步的记忆信息和当前输入字符信息需要继续传递的信息量。同样,重置门将当前输入字符信息与前一个 GRU 单元输出信息分别进行线性变换后相加,送入 Sigmoid 函数,决定需要保留和遗忘的信息。在当前记忆

内容的计算时,使用重置门,以门控的形式,确定前一个GRU单元的输出中要保留和遗忘的元素。最后使用更新门,将前一个GRU单元的输出保留到最终记忆的信息与当前记忆内容保留至最终记忆的信息相加,即为当前GRU单元最终的输出内容。

1.2 概率预测器模型的训练

RNN 概率预测器模型的目的是在给定在字符表 S 上的字符序列 $C^L = \{C_1, C_2, \dots, C_L\}$ 的情况下,基于前 N 个观察到的字符,估计第 $N+1$ 个字符 C_r 的条件概率分布 $\hat{P}(C_r | C_{r-1}, \dots, C_{r-N})$ 。因此,本文首先从训练数据文件中读入字符流,重新整理为一维字符向量,通过 stride 方式,将一维向量分解为 $(R, N+1)$ 维的重叠分段矩阵,如图 2 所示。

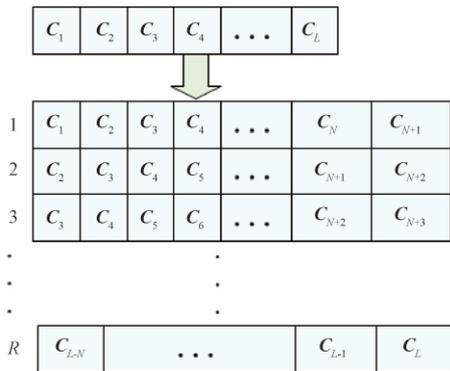


图 2 训练数据转换示意图

截取 $(R, N+1)$ 维重叠分段矩阵中前 N 列的数据作为训练样本,即训练样本数为 R , 每个训练样本维数为 N 。在实际训练过程中,将训练样本打乱,分为多个 Batch,有助于网络模型的收敛,其中每个 Batch 的大小为 128,超参数 N 取 64。网络模型的期望输出为 $(R, N+1)$ 维重叠分段矩阵的第 $N+1$ 列形成的向量 $\{C_{N+1}, C_{N+2}, \dots, C_L\}$ 采用独热编码 OneHotEncoder 生成的由 0 和 1 组成的二进制序列组。向量 $\{C_{N+1}, C_{N+2}, \dots, C_L\}$ 中有多少种状态(即字符的种类数),独热编码的二进制序列就有多少比特,并且二进制序列对应位置取 1,其他位置为 0。向量 $\{C_{N+1}, C_{N+2}, \dots, C_L\}$ 几乎遍历整个输入数据流,其字符种类数,即为字符表 S 中的字符数,这样二进制序列每一比特对应网络模型最上部全连接层的神经元输出。如对于训练样本 $\{C_1, C_2, \dots, C_N\}$,其期望输出为字符 C_{N+1} 的独热编码 $1000\dots 0$,即 C_{N+1} 对应的神经元输出为 1,可看作条件概率,而此时其他神经元输出为 0。而字符 C_{N+2} 如果与 C_{N+1} 相同,则独热编码一致,如果不同,独热编码为 $0100\dots 0$,其他字符类推。由于本文网络模型基于向量空间度量进行优化,因此使用独热编码,将字符离散输出的取值扩展到欧氏空间,某个字符值对应欧氏空间的某个点,使损失函数的度量更加合理。本文的网络模型训练采用 Adam 算法^[15]作为优化器,采用多分类交叉熵损失函数,epoch 数目设置为 20。在每个 epoch,如果损失函数较之前有下降,则 Adam 算法更新网络模型参数。

由于本文的压缩、解压策略存储网络模型权值作为压缩表示的一部分,且训练的模型只用于在训练数据上的预测,因此为防止实际应用中网络模型出现在训练数据上的过拟合,本文没有在训练过程中使用交叉验证。网络模型训练后,将网络权值保存为文件,用于后续的压缩和解压。

1.3 自适应算术编码

算术编码是在给定每个符号概率估计的情况下,对数据流进行压缩的熵编码技术。算术编码维护在 $[0, 1]$ 区间内的一个概率范围,每一个符号流唯一决定了一个概率范围。这一范围直接依赖下一个字符的条件概率分布,能够随着字符的序列输入进行计算。最终,该范围被编码为比特流,形成压缩后的数据。解码在给定概率估计的情况下,执行编码的逆操作。

由符号概率估计方式的不同,算术编码分为固定模式算术编码和自适应算术编码。在固定模式下,信源符号的概率需要预先统计计算,并且编码过程中符号概率保持不变,而自适应算术编码,根据编码时符号出现的频繁程度动态修改信源符号的概率。固定模式需要遍历整个符号流,统计每个符号全局概率,而算术编码符合概率匹配原则:出现概率较大的符号压缩为较短的码字,出现概率较小的符号取较长码字,可能某个符号在整个符号流中全局概率较小,但在符号流某一位置集中分布,此时采用自适应编码,由于符号出现的概率随着符号输入不断变化,输入相同符号数越多,该符号的概率被更新的越大,则该符号压缩后的码字要明显小于固定模式编码。因此,采用编码过程中动态估计字符概率的自适应算术编码不仅在压缩算法时效上优势明显,而且压缩率也优于固定模式编码。自适应算术编码的压缩率与符号概率预测的准确程度密切相关,本文采用的基于 GRU 单元的概率预测模型,能够较准确的预测符号概率,保证压缩编码效率。

1.4 压缩和解压策略

如图 3 和 4 所示为本文的压缩和解压策略。在压缩策略中,对于初始的 N 个字符,选择均匀先验概率分布,采用自适应算术编码器进行编码压缩,接着将这 N 个字符输入已经加载训练好的网络模型权值的 RNN 概率预测器,得到每个字符的概率分布,自适应算术编码器根据该概率分布和第 $N+1$ 个字符值,更新原有的字符概率分布和累积频率,得到每个字符新的概率区间。重复这一过程,最后锁定字符 C_L 的概率区间,得到编码后的数据流。解压过程与压缩过程对称,为压缩的逆过程。自适应算术编码器首先使用均匀先验概率分布解码出前 N 个字符,再由 RNN 概率预测器得到的字符概率分布,解码出后续字符。这里,算术解码器每次也需要对字符概率分布进行更新,得到新的字符概率区间,根据压缩数据流表示的实数落入的概率区间,解码出概率区间对应的字符。在解压过程中,RNN 概率预测器同样使用了训练好的网络模型权值,能够产生与压缩过程相同的概率估计。

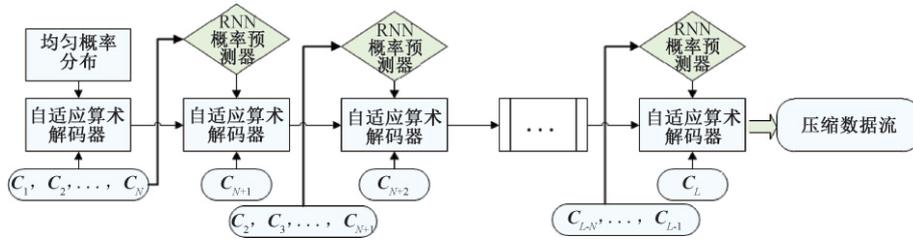


图 3 压缩策略

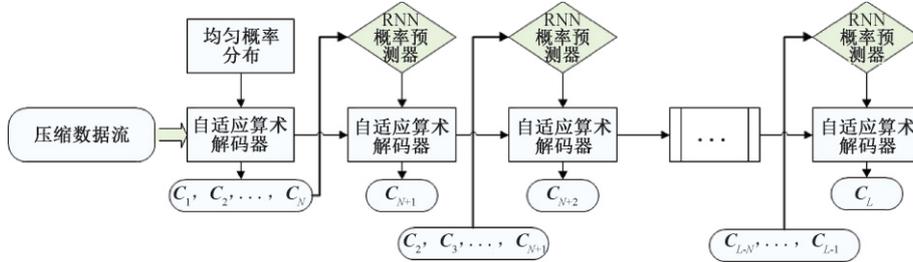


图 4 解压策略

2 大型测井数据库构建

面向测井大规模数据存储这一应用场景,将多口井的实际测井数据根据本文压缩方法进行压缩编码后,存储入 SQLServer 大型关系型数据库,并在写入时,加入该井对应的测井时间(年)、区块名称、数据类型(常规、固井、电成像、核磁和阵列声波等)、井号以及数据写入时随机分配的唯一 ID 等索引字段,形成的大型数据表单如图 5 所示。其中, ID 值为算法产生的全局唯一标识符 GUID,是一种二进制长度为 128 位的数字标识符,形式如“EC8209E0-4E31-41E2-AF20-A989723984D3”,表单中“数据”字段值为压缩后的二进制比特流,这样每一个压缩后数据对应一个唯一的 ID 标识。为提升数据的查询检索效率,综合所

有索引字段,构建多维索引数据查询树,如图 6 所示。查询树结构自顶向下包含根节点、时间检索层、区块检索层、数据类型检索层和井号检索层。

ID	测井时间	区块	类型	井号	数据
ID1	2009	DX	常规	X23-1	二进制Bit流
ID2	2010	DX	核磁	X23-1	二进制Bit流
...
ID35	2011	GDAO	常规	CB213	二进制Bit流
ID36	2011	GDAO	电成像	CB213	二进制Bit流
...
ID101	2013	MIAN	常规	L69	二进制Bit流
ID102	2014	MIAN	固井	L69	二进制Bit流
...

图 5 测井数据存储大型表单

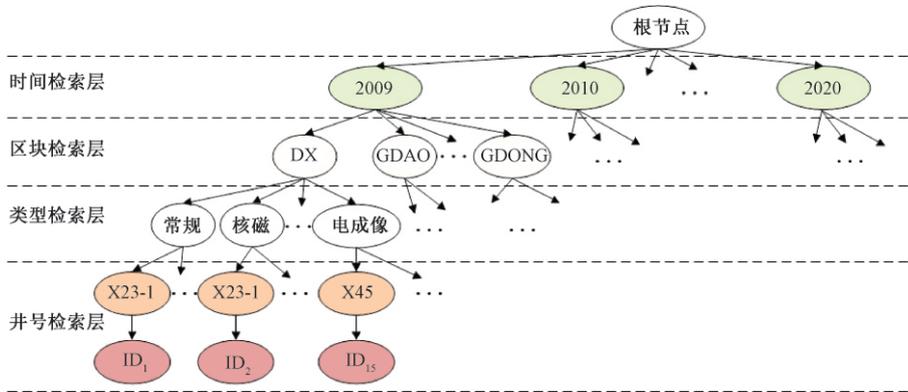


图 6 多维索引数据查询树结构

图 6 中其他时间节点的子节点构建如“2009”时间节点,同样“GDAO”等区块子节点如同“DX”子节点向下构建,而类型子节点对应各井号子节点,每个井号子节点与其唯一的 ID 节点连接。在用户进行数据检索时,如果同

时输入时间、区块和类型查询条件,则在查询树上,从对应的时间节点开始向下搜索,找到对应的区块子节点,返回对应的类型子节点包含的所有井号和其 ID 值,在把井号呈现给用户的同时,根据 ID 值在数据存储表单中检索出

对应的压缩数据文件,解压后提供给用户。如果用户单独输入井号进行查询,则在查询树的井号检索层,直接搜索对应的井号子节点,此时在查询树中向上回溯,在为用户提供井号对应的数据的同时,可以将该井的数据类型、所在区块和测井时间等丰富的信息呈现给用户,便于测井数据的综合利用。其他单独的查询条件的处理与此类似。多维索引数据查询树的构建为大型测井数据库提供了一种高效且相关信息丰富的检索查询方式。

3 实验结果与分析

3.1 压缩算法实验对比

测井数据的类型依据测井仪器类型的不同,分为一维常规数据和二维阵列数据(包括固井、电成像、核磁和阵列声波),其中一维数据量明显少于二维阵列数据量。在实际应用中,为使压缩算法更具有针对性,分别使用一维常规数据、固井数据、电成像数据、核磁数据和阵列声波数据组成各自的训练样本集,训练各自的RNN概率预测器,在进行数据压缩时,依据数据类型,选择对应的RNN概率预测器。为保证算法的鲁棒性,收集不同区块的多口井数据,构建训练样本集,如表1所示。

表1 训练样本集说明

数据类型	训练样本井数	训练样本集大小/MB
一维常规	100	502
固井	50	843
电成像	12	1 554
核磁	12	1 255
阵列声波	12	1 378

一维常规测井数据是每口井必须采集的,按照测量井段的不同,每口井的数据量从1~10 M不等,一维数据是实际应用场景中压缩算法主要针对的数据类型,因此在构建样本集时,尽可能多的选择训练样本井数。固井数据主

要是二维声波数据,即在每个深度点上包含一条512个时间采样点的声波全波列,其数值连续变化,规律性较强,因此可以降低固井数据训练样本集选择的井数,不会对RNN模型的性能造成太大的影响。电成像、核磁和阵列声波属于特殊测井项目,只在重点井中的重要井段施工,不是每口井的必测项目,所以历史测量井次较少,而且每井次的测量井段长度基本在200~800 m,但是单次测量数据量很大,特别是电成像测井,深度采样间隔为0.1 in,纵向分辨率最高,如B440井的电成像测量井段约为600 m,其数据量达到229 MB。RNN模型训练时,在keras深度学习架构和GPU硬件设备的支持下,由cuDNN神经网络模型库,实现并行加速,训练时间减少了约7倍。

表2所示为5口井的实测一维常规数据的压缩率对比结果。从表2中可以看出,针对不同原始大小的5口井数据,基于字典模型的LZW算法压缩率最低,这是由LZW算法的固定码长和字典存储的限制导致的^[16]。算术编码是一种信息保持型编码,虽然算法较为复杂,但无需像LZW算法传送编码字典,因此压缩率有了明显提升,而RNN网络模型方法将自适应算术编码和RNN概率预测模型结合在一起,比固定模式的算术编码压缩率更高,平均提升了约23%。对比5口井的原始数据大小,可以发现LZW算法的压缩率随着数据量的增加而有所提升,这是由于数据文件中重复字符串的增多,使得字典中对应字符串编码缩短导致的。而L885和Z13两口井的原始数据大小相差不大,但Z13井LZW算法的压缩率明显增大,压缩率达到18.54%,远高于在其他实验数据上的LWZ算法压缩率;经该实验数据研究发现,Z13井的测量井段大部分为泥岩层段,自然电位、自然伽马等一维常规曲线在深度上的起伏较小,使得LZW算法在Z14井数据上构造的编码字典大幅度减小,进一步导致压缩率大幅度增加。同样,在Z13井变化平缓的原始一维数据上,算术编码和RNN网络模型方法的压缩率相对于其他实验数据也有了明显提升。

表2 一维实测常规数据压缩率对比结果

井号	原始大小/ kB	LZW		算术编码		RNN网络模型	
		压缩大小/kB	压缩率/%	压缩大小/kB	压缩率/%	压缩大小/kB	压缩率/%
W152-X14	4 032	3 774	6.39	3 209	20.42	2 237	44.51
L176	8 634	7 976	7.62	6 704	22.35	4 758	44.89
L885	1 586	1 486	6.28	1 179	25.68	812	48.78
Z13	1 478	1 203	18.54	950	35.71	626	57.65
C7-P4	10 453	9 467	9.43	8 139	22.14	5 638	46.06

表3所示为5口井的实测二维阵列数据的压缩率对比结果。表中原始数据大小为各自数据类型5口井的实测数据量之和。整体来看,在二维阵列数据上,3种压缩算法的性能较一维常规数据都有所下降。但对于变化规律性较强的声波全

波列固井数据来说,3种算法的压缩率基本保持不变,并略有提升,而阵列声波数据在一个深度点上包含24条声波全波列,因此其压缩率仅次于固井数据。对于数据变化比较剧烈的电成像数据,3种算法的压缩率相比其他类型数据是最低

的。RNN 网络模型方法在四种类型的二维阵列数据上,相比 固定模式的算术编码,压缩率平均提升 20.5%。

表 3 二维实测阵列数据压缩率对比结果

数据类型	原始大小/ MB	LZW		算术编码		RNN 网络模型	
		压缩大小/MB	压缩率/%	压缩大小/MB	压缩率/%	压缩大小/MB	压缩率/%
固井	82.3	73.7	10.41	63.0	23.47	43.3	45.32
电成像	651.0	617.5	5.14	522.3	19.76	397.5	38.94
核磁	518.0	491.0	5.23	411.4	20.57	308.3	40.48
阵列声波	576.0	538.3	6.54	451.0	21.71	331.0	42.52

3.2 大型数据库检索实验对比

实验在 CPU 主频 3.2 GHz,内存 8 G 的 HP 工作站上,比较本文的多维索引数据查询树与传统的 SQL 查询方式的检索效率,实验数据为如图 5 格式的包含 8 000 条记录的大型数据表单。查询输入分为多条件组合和单条件。实验结果如表 4 所示。

表 4 查询检索效率对比结果

查询输入条件	SQL 检索耗时/s	查询树检索耗时/s
时间+区块+类型	1.875	1.031
时间+区块	1.347	0.781
区块+类型	1.453	0.857
井号	0.918	1.212

表 4 中列出了实际应用中常用的查询输入条件。传统的 SQL 查询模式取出数据表单中的每一条记录,将索引字段值与输入的查询条件逐一比对,如果两者相符,则将该记录放入缓存,待表单中的所有记录都比对完毕,输出缓存中的查询结果。因此,查询输入条件越多,SQL 检索耗时越长。表 4 的实验结果也说明了这一点,而查询检索树在多条件查询时,根据查询树上的高层子节点进行向下的局部搜索,相比于 SQL 的全局查询方式,限定并缩小了后续条件的检索范围,因此查询检索效率平均提升了约 45%。在“井号”单条件查询时,查询树在井号检索层进行全局搜索,得到相应井号的子节点,再根据每个井号子节点对应的 ID 值,在数据表单中使用 SQL 方式查询得到压缩数据,相比于直接的“井号”条件 SQL 查询,多出了井号检索层的搜索耗时,因此查询树的耗时有所增加。

本文的研究成果应用于 SL 测井公司的测井数据归档与管理,原有的约 8 TB 历史测井数据经过压缩后,构建约 4.1 TB 的大型数据库,节省了数据存储硬件的投资成本。同时,通过构建多维索引数据查询树,在数据管理这一日常生产任务中,历史数据提取的人工操作时间每井次平均减少了约 15 min,特别是在进行区块研究解释任务时,提取数据的井号集中在同一区块,数据管理人员通过区块和类型组合检索,得到该区块所有井数据,再手工选择解释人员需要的数据进行提取,可以避免单纯井号检索的耗时问题。

4 结 论

本文根据基于预测的数据无损压缩原理,将 RNN 概率预测器和自适应算术编码相结合,有效提升测井数据压缩率,缓解了存储硬件容量使用紧张问题,为将来减少存储硬件购置成本奠定了技术基础。通过使用大型数据库,实现大量杂乱历史测井数据的有序管理,多维索引数据查询树的构建,可提升测井数据的查询检索时效,减轻数据管理人员的工作强度,同时为老井复查和区块研究等解释任务提供与井号关联的测井时间、区块、数据类型等丰富的辨识信息。如何降低测井数据库单条件查询耗时是下一步要开展的工作。

参考文献

- [1] 李长文,余春昊,周军,等. 测井处理解释一体化软件平台的设计[J]. 测井技术, 2011, 35(4):344-348.
- [2] 李国军,余春昊,周军,等. 网格技术在统一软件测井油气评价数据库的应用[J]. 测井技术, 2011, 35(B12):674-676.
- [3] 胥胜林. 实时数据库中数据压缩算法的研究与实现[J]. 科技与企业, 2016(6):100-101.
- [4] 杨永军,徐江,舒逸,等. 实时数据库中历史数据无损压缩算法的研究[J]. 计算机与现代化, 2012, 1(6):165-168.
- [5] 邢强,张晋言. 基于 BWT 和 PPM 的 XMAC 数据无损压缩方法研究[J]. 科技创新导报, 2011(34):113-113.
- [6] 刘彦慧. 基于深度学习的图像编码方法研究[D]. 哈尔滨:哈尔滨工业大学, 2017.
- [7] 任杰. 基于深度学习的图像压缩方法研究[D]. 哈尔滨:哈尔滨工业大学, 2017.
- [8] 郭智. 高光谱图像的数据压缩与分类算法研究[D]. 西安:西安电子科技大学, 2015.
- [9] 鲁玉江. 深度学习在数据压缩中的应用研究[D]. 北京:华北电力大学, 2017.
- [10] 王荣杰. 高通量基因组数据的无损压缩方法研究[D]. 哈尔滨:哈尔滨工业大学, 2019.
- [11] 胡敏,高永,吴昊,等. 融合边缘检测和递归神经网络

- 的视频表情识别[J]. 电子测量与仪器学报, 2020, 34(7):108-116.
- [12] 谭峰,李成南,萧红,等. 基于 LSTM 循环神经网络的数控机床热误差预测方法[J]. 仪器仪表学报, 2020, 41(9):81-89.
- [13] 潘喜福,滕召胜,张甫,等. 基于肌电和肌阻抗的吞咽信号同步测量方法[J]. 仪器仪表学报, 2020,41(10):180-188.
- [14] 赵建鹏,张爱军,蔡程飞,等. 基于门控循环网络的海浪波倾角预测研究[J]. 国外电子测量技术, 2019, 38(5):96-100.
- [15] 谢佳琪,尤伟,沈长青,等. 基于改进卷积深度置信网络的轴承故障诊断研究[J]. 电子测量与仪器学报, 2020, 34(2):41-48.
- [16] 陈建华. 数据无损压缩传输方法在阵列声波测井仪中的应用[J]. 电子测量技术, 2020, 43(13):81-84.

作者简介

陈建华,硕士研究生,工程师,主要研究方向为常规测井与成像测井资料采集。

E-mail:chenjianhuacq@cnpc.com.cn