

# 基于改进SqueezeNet的油气管道泄漏检测算法

王 健<sup>1</sup>, 徐迎斌<sup>1</sup>, 黄传富<sup>1</sup>, 何婷婷<sup>2</sup>, 柏俊杰<sup>1\*</sup>

<sup>1</sup>重庆科技大学电气工程学院, 重庆

<sup>2</sup>重庆科创职业学院智能制造学院, 重庆

收稿日期: 2024年6月9日; 录用日期: 2024年6月29日; 发布日期: 2024年7月11日

## 摘 要

我国石油和天然气的运输方式主要是依靠管道进行运输, 根据浴盆曲线, 目前我国现存的运输管道处于事故高发期, 近些年来全国各地油气管道泄漏事故频发。近些年, 如何实时高效检测油气管道泄漏成为了研究热点。本文探索一种改进的基于SqueezeNet神经网络的轻量化模型检测算法, 通过将SqueezeNet网络中的Fire模块中的扩展层更换为Ghost模块, 再引入SE注意力机制形成G-S-SqueezeNet网络。在实验中对管道泄漏的音频数据集进行预处理并转化为梅尔倒谱进行训练, 并进行验证。结果表明在模型缩小的情况下, 其鲁棒性和准确性明显改善, 准确率相比未改进的网络提升了1.58%, 模型大小降低了4 MB, 检测速度提升了1.1 s。

## 关键词

油气管道泄漏, SqueezeNet, Ghost, SE注意力机制

# Oil and Gas Pipeline Leak Detection Technology Based on Improved SqueezeNet

Jian Wang<sup>1</sup>, Yingbin Xu<sup>1</sup>, Chuanfu Huang<sup>1</sup>, Tingting He<sup>2</sup>, Junjie Bai<sup>1\*</sup>

<sup>1</sup>School of Electrical Engineering, Chongqing University of Science and Technology, Chongqing

<sup>2</sup>School of Intelligent Manufacturing, Chongqing Creation Vocational College, Chongqing

Received: Jun. 9<sup>th</sup>, 2024; accepted: Jun. 29<sup>th</sup>, 2024; published: Jul. 11<sup>th</sup>, 2024

## Abstract

The transportation mode of oil and natural gas in our country mainly relies on pipelines for transportation. According to the bathtub curve, the existing transportation pipelines in our country are in the period of high occurrence of accidents. In recent years, oil and gas pipeline leakage accidents occur frequently across the country. In recent years, how to detect oil and gas pipeline

\*通讯作者。

文章引用: 王健, 徐迎斌, 黄传富, 何婷婷, 柏俊杰. 基于改进 SqueezeNet 的油气管道泄漏检测算法[J]. 图像与信号处理, 2024, 13(3): 271-280. DOI: 10.12677/jisp.2024.133023

leakage in real time and efficiently has become a research hotspot. In this paper, we explore an improved lightweight model detection algorithm based on the SqueezeNet neural network, by replacing the extension layer in the Fire module in the SqueezeNet network with Ghost module, and then introducing the SE attention mechanism to form a G-S-SqueezeNet network. In the experiment, the audio data set of pipeline leakage is preprocessed and transformed into MEL cepstrum for training and verification. The results show that when the model is reduced, its robustness and accuracy are significantly improved, the accuracy is increased by 1.58%, the model size is reduced by 4 MB, and the detection speed is increased by 1.1 seconds compared with the unimproved network.

## Keywords

Oil and Gas Pipelines, SqueezeNet, Ghost, SE Attention Mechanisms

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

当前我国对于石油和天然气的主要运输手段仍是管道运输。其优点在于运输的成本低、运输途中对物料的消耗少、可控性强。据国家能源局统计,在 2021 年底,全球通入使用的管道里程约 202 万公里,2022 年底,全球计划或即将建造的管道约为 16.6 万公里。而我国在 2022 年底,共管道里程约为 18 万公里。按照双碳目标的要求下,预计到 2035 年,我国将新增管道总里程约 6.5 万公里。但随着管道运输的大规模使用,其安全性受到了人们的广泛重视。由于管道所处的环境比较复杂,有些埋藏在地下或者海洋中,随着时间的推移,管道会因为遭受到环境的侵蚀、自身老化、人为破坏的问题出现泄漏事故。近些年来国内外各地不时有石油天然气泄漏导致的重大事故,给当地造成了不可估量的经济损失以及难以修复的环境污染[1]。

近些年研究者对于油气管道泄漏的问题做出了很多研究,早期因为技术发展不足,主要采用人工巡检的方法,这种方法一方面人工成本高,另一方面无法做到实时检测,只能定期巡检。统计检测法[2] [3]是由 Zhang 提出的一种基于测量数据统计分析的管道泄漏检测方法,该方法是通关传感器获取管道两端的流速和压力后,再计算泄漏的概率,原理是使用最小二乘法进行定位泄漏位置。但是该方法对硬件的资源要求过高。声波检测法[4]是在管道两端安装传感器检测声波,通过泄漏时音波的变化进行检测,但是该方法对处理管道运行的噪声要求较高。

近些年深度学习的兴起为检测管道泄漏带来了新的技术,大批学者开始对此进行研究,许[5]等人对 RNN 网络进行研究并加以改进用以检测管道泄漏,但是深度学习的方法涉及到的模型均比较庞大,需要高算力的平台。罗[6]使用鲸鱼优化算法进行石油管道泄漏检测技术的研究,建立了一种切应力修正的石油管道泄漏模型,并用特征线法求解,进行泄漏处定位,但是该方法存在的问题在于实时性较差,存在 4~9 秒的误差,无法满足工程需求。潘[7]针对电厂中存在的油液泄漏的现象进行研究,提出了一种图像检测法,该方法通过将 CBMA 注意力机制融入 YOLOv5,并采用 Focal EIoU Loss 作为损失函数,提高了算法的鲁棒性,并在后续工作中做出了预警系统,但是该研究所检测的泄漏类型较少,而且对于现场环境复杂无法提取有效图像未能提出解决方案。刘[8]针对神经网络存在的问题提出了一种动态深度可分离的卷积神经网络来检测管道泄漏,该方法一定程度上解决了神经网络目前所存在的参数量过大,实时性不强的问题,但是该方法只能对泄漏数据进行无监督的机器学习,并未探索对未知泄漏类型的识别能力。

根据已经发生的事故,管道泄漏时间具有突发性和时间不可控性。现有的油气管道泄漏检测技术大多使用大模型进行训练和预测,使其只能借助高算力平台,并不适合移植到嵌入式设备做到软硬件相结合检测。近几年学者对于算法的研究已经从开始的复杂算法转变为研究如何将算法轻量化,本文将从近些年研究轻量化模型的角度入手,选择 SqueezeNet 神经网络作为研究基础,并用 Ghost 模块替换模型中 Fire 模块中的扩展层,并引入 SE 注意力机制来提高准确度。使其在不损失精度的前提下模型更小,更适合移植到嵌入式设备,解决算法模型参数和准确性不能兼顾的问题。

## 2. SqueezeNet 神经网络

CNN 卷积神经网络对比传统算法,在机器视觉等领域在精度上有较大的提升,但是 CNN 卷积神经网络依赖于平台的算力,模型的计算量和参数量都较大,这就是难以将算法与嵌入式设备融合的原因。目前较为主流的轻量化模型有 MobileNet, ShuffleNet, EfficientNet, AlexNet 等[9]。而 SqueezeNet 是由 han [10]所提出的一种轻量化的 CNN 模型。对比 AlexNet 模型,其能够在保持性能的前提下参数比 AlexNet 减少 50 x。对比于其他网络, SqueezeNet 具有三个独到的优势:

1、SqueezeNet 将卷积神经网络的部分  $3 \times 3$  的卷积核开创性的替换为  $1 \times 1$  的卷积核,以达到更少的计算参数。

2、将卷积层替换为由挤压层和扩展层组合而成的 fire 模块结构:首先,输入特征通过 squeeze 层,其中包含  $1 \times 1$  卷积核,以减少特征通道数。然后,经过扩展层,其中包含  $1 \times 1$  卷积核和  $3 \times 3$  卷积核,以增加特征的复杂性和丰富度。最后,将  $1 \times 1$  卷积核和  $3 \times 3$  卷积核的输出特征拼接在一起,以形成 fire 模块的输出。此结构有效减少了整个网络的参数量。

3、将池化操作延后,保留了更大的特征图,从而保留了更多的特征信息。图 1 显示了 fire 模块的结构。




Figure 1. Structure of the fire module

图 1. Fire 模块的结构

SqueezeNet 的核心策略是利用  $1 \times 1$  卷积模块对特征图进行降维处理,如图 1 所示。这种操作能有效地减少  $3 \times 3$  卷积层的输入通道数,从而降低训练参数量、缩小模型尺寸,并提高训练速度。

图 2 展示了 SqueezeNet 的网络结构,其输入图像首先通过一个独立的卷积层进行处理,然后特征被逐步引入八个 fire 模块。在每个 fire 模块中,卷积核数量都逐渐增加。此外,在 conv1、fire4、fire8 和 conv10 层之后, SqueezeNet 都会进行步幅为 2 的最大池化操作。

SqueezeNet 是为满足边缘计算中有限资源和高计算速度而提出的压缩网络,在不大幅度降低模型精度的前提下,提高了运算速度,然而经过实践验证,该网络也存在以下缺点:

1、信息缺失。由于 SqueezeNet 采用了较小的参数量和模型大小,因此可能会导致信息损失,特别是在处理复杂数据集时,可能会影响模型的性能。

2、实时性。SqueezeNet 的提出旨在将其应用于嵌入式环境,而在这种环境中,实时性是一个重要的

挑战。虽然 SqueezeNet 采用了较为轻量的 18 层结构来减少网络的参数数量，但更深层的结构也会降低网络的并行性，从而可能影响网络的实时性。

3、适用范围限制：尽管 SqueezeNet 在移动端设备上具有一定的优势，但在一些对模型精度要求较高的场景下，可能会受到限制，例如在需要进行精细的图像分类或物体检测时。




Figure 2. Structure of SqueezeNet

图 2. SqueezeNet 的网络结构

### 3. 改进的 SqueezeNet 神经网络




Figure 3. G-S-SqueezeNet network

图 3. G-S-SqueezeNet 网络

针对以上传统 SqueezeNet 网络的缺点,本文拟探索一种将 SqueezeNet 网络中 Fire 模块中的扩展层更换为 Ghost 模块,同时在新模块的结束后,添加 SE 注意力机制的新型网络。这样做的目的是使改进过的网络更加轻量化,并不会因为模型大小的减少而降低精度。更加符合解决目前部署到资源有限的嵌入式设备的难题。在不改变其大体网络结构的情况下,首先将 Fire 模块中的 expand 层替换成 Ghostnet 的 Ghost 模块。随后在新模块后插入 SE 注意力机制,用以提高识别的准确率。改进后的 SqueezeNet 网络命名为 G-S-SqueezeNet 网络,其结构图如图 3 所示。

### 3.1. Ghost 模块

华为诺亚方舟实验室在 2020 年提出了一种轻量级神经网络架构 - GhostNet [11], 其主要特点在于在保持高精度的前提下,成功减少了网络的参数量和计个全新的 Ghost 模块,目标是通过廉价的操作生成更多的特征映射。对于一组原始的特征图,开发者应用一系列线性变换,以很小的代价生成许多能从原始特征发掘所需信息的“幻影”特征图(Ghost feature maps) [12]。它能够通过成本低廉的操作  $\phi_1$  生成更多的特征映射。GhostNet 还采用了自适应模型推理(Adaptive Model Inference)的方法,通过在测试时自适应地调整模型的宽度和深度,以进一步减少模型的计算量,同时保持模型的精度。




Figure 4. Traditional conv  
图 4. 普通卷积




Figure 5. Ghost module  
图 5. Ghost 模块

Ghost 模块的实现分为两个部分: 1、首先通过普通的卷积计算来得到通道比较少的特征映射。2、再对普通卷积计算得到的特征进行廉价简单的操作来获得更多的特征映射。将两个部分的特征连接到一起

组成一个新的特征输出。通过这两个操作得到与普通卷积相同数量的特征图。为了提升效率, Ghost 模块中的初始卷积采用的是点卷积。Ghost 的优点在于可以在神经网络中即插即用, GhostNet 的组成实质上就是堆叠 Ghost 模块来生成的。图 4 为普通卷积的示意图, 图 5 为 Ghost 模块的示意图。

### 3.2. SE 注意力机制

通道注意力机制专注于各个通道, 因为在特征提取过程中, 数据通常经过下采样, 导致图像的长宽维度减小, 而通道数增加。在众多通道中, 包含多种类型的信息, 有些与特征高度相关, 而有些则不相关甚至无用。通道注意力机制的目标是探索这些通道, 并加权它们的重要性, 以突出对特征提取有帮助的通道, 减少无用的通道[13]。

本本采用 SENet (Squeeze-and-Excitation Networks) 模块, 该模块利用注意力机制捕捉每个通道内部的关联性, 并结合压缩和激励操作, 目的在于让模型能够自主学习各个通道特征的不同重要程度, 其结构如图 6 所示。




Figure 6. SE attention mechanism

图 6. SE 注意力机制

在输入 SE 注意力机制之前(左侧橙色 C2), 特征图的每个通道的重要程度都是一样的, 通过 SENet 之后(右侧彩图 C2), 不同颜色代表不同的权重, 使每个特征通道的重要性变得有差异, 使神经网络重点关注某些权重值大的通道。

实际情况中特征图的不同通道所占的重要性程度一定是存在差异的, 而一般的卷积池化模型却不会对这种存在差异的通道进行分类操作, SE 的出现解决了这种问题, 他的结构由两个操作, 压缩(Squeeze)操作和激励(Excitation)操作所构成, 首先压缩操作是通过在特征图层上执行全局平均池化操作完成的, 完成这步操作之后会获得当前特征图的全局压缩特征量[14], 其本质是在空间维度上进行压缩, 结果是将  $h \times w \times c$  的特征维度转化为  $1 \times 1 \times c$  的特征维度, 转化得到的特征维度在一定范围内具有全局性的感受野, 而且其输入输出的通道数目是相同的, 其具体公式如下所示:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W_{i=1,j=1}} u_c(i, j), z \in R^c \quad (1)$$

其中  $c \in \{1, 2, \dots, C\}$  为通道维度序号。

激励操作通过两层全连接的 bottleneck 结构得到特征图中每个通道的权值, 下层网络的输入就是激励操作后并经过加权输出的特征图, 其公式如下所示

$$s = F_{ex}(z, W) = \sigma(W_2 \text{ReLU}(W_{1z})) \quad (2)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\text{ReLU}(x) = \max(0, x) \quad (4)$$

其中  $W_1 R^{c \times c}$  表示第一个全连接层权重矩阵,  $W_2 R^{c \times c}$  表示第二个全连接层权重矩阵, 降维系数为  $r$ , 使用 **ReLU** 作为激活函数, 之后将学习到的各通道的激活值应用 **sigmoid** 函数激活后与在  $U$  上的原始特征相乘, 具体公式如下:

$$\tilde{x}_c = F_{scale}(u_s, s_c) = s_c \cdot u_c \quad (5)$$

### 3.3. G-S-Fire 模块

传统神经网络中标准卷积核的参数个数  $N$  为:

$$N = S \times S \times Q \times W \quad (6)$$

其中  $S$  为卷积核大小,  $Q$  为输入通道数量,  $W$  为输出通道数量。

在这里设标准 SqueezeNet 网络中的 Fire 模块的参数为  $N_s$ , 挤压层和扩展层的输出通道数分别为  $W_s$  和  $W_e$ , 其表达式可以表示为:

$$N_s = Q \times W_s \times W_s \times \frac{W_e}{2} + S \times S \times W_s \times \frac{W_e}{2} \quad (7)$$

设通过将挤压层更换为 Ghost 模块后新模块的参数为  $N_g$ , 表达式可以表示为:

$$N_g = Q \times W_s + S \times S \times W_s \times \frac{W_e}{2} + S \times S \times \frac{W_e}{2} \quad (8)$$

在本实验中, 将卷积核的大小选定  $1 \times 1$ , 则表达式可以表示为:

$$N_g = Q \times W_s + W_s \times \frac{W_e}{2} + \frac{W_e}{2} \quad (9)$$

通过式(7)与式(9)相对比, 可以看到与传统的 SqueezeNet 网络原 Fire 模块相比, 本文提出的新模块共减少了  $(S \times S \times W_s - 1) \times \frac{W_e}{2}$  的参数数量。

通过上述操作, 成功将 Fire 模块进行了减重操作, 为了平衡其精度, 在这里引入 SE 注意力机制来优化我们改进的模块。

第二步, 将 SE (Squeeze-and-Excitation) 模块嵌入到前文 Ghost 替换过 Fire 模块中扩展层的整体新模块中, 其生成注意力特征的过程如下: 经过改进的 Fire 模块层的特征矩阵会经过 SE 模块, 将一个通道上的空间特征编码为一个全局特征, 采用全局平均池化输出该层  $\gamma$  个特征图的数值分布情况, 如下所示:

$$K_\gamma = X(m_c) \quad (10)$$

其中,  $m_c$  表示第  $c$  个通道的特征,  $X()$  表示全局平均池化。

采用

$$s = \sigma(g(K_\gamma, Y)) \quad (11)$$

**sigmoid** 形式的门机制让网络学习各个通道间的非线性关系。其中  $Y$  是网络的权重, 函数  $g()$  是池化函数, 是 **sigmoid** 函数。为了降低模型复杂度以及提高泛化能力, 采用包含两个全连接的瓶颈(bottleneck)结构将特征降维, 降维系数  $r$  是超参数, 本文将  $r$  设为 12, 然后用 **ReLU** 函数激活, 最后将学习到的各个通道的激活值乘以原始特征得到最终的注意力特征图

$$L = s \otimes m_c \quad (12)$$

加入 SE 结构的注意力机制可以让模型更加关注信息量最大的通道特征, 抑制那些不重要的通道特征。

通过上述两个步骤后所得到的模块 G-S-Fire 如图 7 所示：



**Figure 7.** G-S-Fire module  
**图 7.** G-S-Fire 模块

#### 4. 实验过程以及结果分析

本次实验环境为百度飞桨所提供的云服务器。实验数据集为本人在学校所采集的管道正常运行和泄漏时的音频文件。其中正常运行数据集共有 964 份，泄漏数据集有 978 份，共计 1942 份。其中 216 份作为测试集，1726 份作为训练集。

每份数据集的音频长度均为 4 秒。其实验步骤如下：1、将采集的音频数据集进行分类，分为泄漏和正常运行的声音数据集。2、将音频数据进行预处理，并转换为梅尔倒谱图，进行后续的实验。3、将数据进行分类，正常运行的标签设为 0，泄漏的标签设为 1，便于实验的验证。4、将数据分别在未经改进的 SqueezeNet 网络和改进过后的 SqueezeNet 网络进行训练和测试。

本文通过对网络的准确率、检测速度、模型大小、召回率四个指标来对比两个网络性能的差别，同时还对比了使用  $1 \times 1$  卷积核和  $3 \times 3$  卷积核之间的差别，可以从表 1 看出使用  $1 \times 1$  卷积核的 G-S-SqueezeNet 网络的准确率相比未改进的网络准确率提升了 1.58%，模型大小比未改进的网络降低了 4 MB。而使用  $3 \times 3$  卷积核的情况下，精确度和为改进的网络相差不大，但模型大小反而更大。故选择  $1 \times 1$  的卷积核作为 G-S-SqueezeNet 网络的卷积核作为卷积核，同时本文还选取了经典的 CNN 网络进行横向对比，结果表面经过改进的网络效果最佳。

**Table 1.** Accuracy and model size comparison  
**表 1.** 准确率及模型大小对比

|                                 | 准确率           | 模型大小/MB   |
|---------------------------------|---------------|-----------|
| SqueezeNet                      | 97.13%        | 16        |
| G-S-SqueezeNet ( $1 \times 1$ ) | <b>98.61%</b> | <b>12</b> |
| G-S-SqueezeNet ( $3 \times 3$ ) | 97.45%        | 21        |
| VGG-16                          | 87.63%        | 541       |
| ResNet                          | 91.34%        | 207       |

在油气管道泄漏的研究中，检测泄漏的响应时间也是及其重要的指标，表 2 表示了 G-S-SqueezeNet 网络和为改进的 SqueezeNet 网络对于泄漏样本的响应速度。可以看到使用  $1 \times 1$  卷积核的 G-S-SqueezeNet 网络的响应速度比传统的网络快了 1.1 秒。其召回率指标对比未改进的提升了 0.83%。

**Table 2.** Response speed comparison  
**表 2.** 响应速度对比

|                                 | 检测速度/s     | 召回率           |
|---------------------------------|------------|---------------|
| SqueezeNet                      | 2.4        | 98.51%        |
| G-S-SqueezeNet ( $1 \times 1$ ) | <b>1.3</b> | <b>99.34%</b> |

图 8 为 G-S-SqueezeNet 网络在测试集上的表现，在训练轮次达到 80 轮后逐渐趋于收敛，最终准确率达到 98.61%。




Figure 8. Accuracy curve  
图 8. 准确率曲线

最终进行验证，将储存的正常管道泄漏的音频输入进行检测，其结果如图 9 所示。

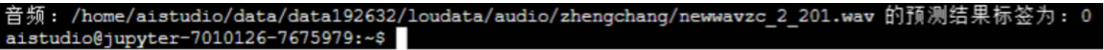


Figure 9. Leakage detection  
图 9. 泄漏检测

## 5. 总结

本文所作的工作主要是针对于传统的 SqueezeNet 网络的一些不足之处做出了改进，主要工作有两点：1、使用 GhostNet 网络中的 Ghost 模块替换 SqueezeNet 网络中最关键的 Fire 层中的扩展层。达到了减少模型参数数量的目的。2、在 Fire 层后插入了 SE 注意力机制模块，使其精度更高。经实验验证，取得了不错的效果，改进后的 G-S-SqueezeNet 网络在模型大小上有了缩减，同时在测试集上的表现整体优于未改进的网络。

## 基金项目

重庆科技大学研究生创新项目，项目号“YKJCX2220405”。

## 参考文献

- [1] 李子彬, 孙益星. 油气管道泄漏安全对策措施研究[J]. 现代职业安全, 2023(9): 35-37.
- [2] Zhang, J. (2018) Statistical Leak Detection in Gas and Liquid Pipelines. *Pipes and Pipelines International*, **38**, 26-29.
- [3] Zhang, J. (2021) Designing a Cost-Effective and Reliable Pipeline Leak Detection System. *Pipes and Pipelines International*, **42**, 20-26.
- [4] 王显宇. 声纹识别技术在气体管道泄漏监测 RTU 中的应用[D]: [硕士学位论文]. 北京: 北京化工大学, 2011.
- [5] 许庆言. 基于深度学习的长输油气管道泄漏检测方法研究[J]. 智能城市, 2023, 9(6): 15-17.
- [6] 罗威. 基于鲸鱼优化算法的石油管道泄漏检测技术研究与应用[D]: [硕士学位论文]. 昆明: 昆明理工大学, 2023.

- [7] 潘俊臻. 电厂管道泄漏检测与异常识别预警系统开发[D]: [硕士学位论文]. 上海: 上海电力大学, 2023.
- [8] 刘源. 基于 1DCNN 的天然气管道泄漏孔径实时识别[D]: [硕士学位论文]. 大庆: 东北石油大学, 2023.
- [9] 杨海娟. 基于轻量级神经网络的苹果叶片病害识别[D]: [硕士学位论文]. 马鞍山: 安徽工业大学, 2021.
- [10] Iandola, F.N., Han, S., Moskewicz, M.W., *et al.* (2016) SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and < 0.5 MB Model Size.
- [11] Han, K., Wang, Y., Tian, Q., *et al.* (2020) GhostNet: More Features from Cheap Operations. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 14-19 June 2020, 1580-1588.  
<https://doi.org/10.1109/CVPR42600.2020.00165>
- [12] Hu, J., Shen, L., Albanie, S., *et al.* (2017) Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **32**, 1-4.
- [13] 代丽, 倪光亮. 基于注意力机制与残差网络的玉米病害识别[J]. 计算机时代, 2023(8): 84-88.
- [14] 卢禹冰. 深度学习注意力机制设计与应用研究[D]: [硕士学位论文]. 兰州: 兰州理工大学, 2023.