

# 水封洞库Q分值围岩分级深度学习优化

刘珠兰<sup>1</sup>, 韩立亮<sup>2</sup>, 孙 健<sup>2</sup>

<sup>1</sup>青岛理工大学理学院, 山东 青岛

<sup>2</sup>中石油华东设计院有限公司, 山东 青岛

收稿日期: 2023年3月15日; 录用日期: 2023年4月16日; 发布日期: 2023年4月24日

## 摘 要

水封洞库现场实地调研发现Q值法受施工人员、环境、设备等因素影响较大, 分级工作流于形式, 论文利用图像处理手段对其进行优化提高分级结果准确性。首先, 对水封洞库现场地质素描围岩分级结果整理, 将围岩等级和岩体发育程度分别划分为四梯度, 节理面强度和赋存条件分别划分为三梯度; 然后, 将采集到的围岩图像批量裁剪与筛选, 并借用数据增强技术完成现场图像分类数据构建; 最后将训练集和验证集输入到分类网络(EfficientNet\_B3)中进行训练, 训练结束后再对模型进行验证。

## 关键词

Q值法, 卷积神经网络, 地下水封洞库, 图像处理技术

# Deep Learning Optimization of Q-Value Method of Water-Sealed Cave Library

Zhulan Liu<sup>1</sup>, Liliang Han<sup>2</sup>, Jian Sun<sup>2</sup>

<sup>1</sup>College of Science, Qingdao University of Technology, Qingdao Shandong

<sup>2</sup>CNPC East China Design Institute Co., Ltd., Qingdao Shandong

Received: Mar. 15<sup>th</sup>, 2023; accepted: Apr. 16<sup>th</sup>, 2023; published: Apr. 24<sup>th</sup>, 2023

## Abstract

The field investigation of the water-sealed cave warehouse found that the Q-value method was greatly affected by the construction personnel, environment, equipment and other factors, and the grading workflow was in form. The paper used image processing to optimize it to improve the accuracy of the grading results. Firstly, the grading results of the surrounding rock of the geological sketch at the site of the water-sealed cave reservoir were sorted out, and the surrounding rock grade and rock mass development degree were divided into four gradients, and the joint surface

strength and occurrence conditions were divided into three gradients. Then, the collected surrounding rock images are clipped and screened in batches, and the data enhancement technology is used to complete the construction of on-site image classification data. Finally, the training set and validation set are input to the classification network (EfficientNet\_B3) for training, and the model is verified after training.

## Keywords

Q-Value Method, CNN, Underground Oil Storage in Rock Caverns, Image Processing Technology

Copyright © 2023 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

地下水封洞库利用地下水天然埋藏条件将石油及其产品封存于地下超大洞室内，具有存储量大、坚固耐用、安全性能高和占地面积小等多种优势，得到国际社会广泛认同。研究水封洞库施工地质条件对于其安全施工以及后期正常生产使用具有重要意义。目前地下洞库岩体判定方式众多， $Q$  值法[1]由于提出较早，在国内外工程应用中得到广泛实践并改进[2]-[7]。肖春华[5]将该围岩分级应用于汕头地下洞库(LPG)工程中，并分析了其局限性与优势；Xu [6]等人将其应用于某地下洞室群开挖建设中，判定工程岩体强度；史永跃[7]等人应用超声波钻孔成像技术为手段，利用考虑膨胀性因素的  $Q$  值法分析地下油库蚀变岩的工程特性。虽然  $Q$  值法被不断改进优化，但是通过水封洞库现场实地考察发现： $Q$  值围岩分级参数采用表格打分制，不同地质工程人员对危险界定不同，打分界限也不同，导致分级结果波动性大。

针对岩体分级参数受主观因素影响操作空间大的问题，一些学者将图像处理技术应用于工程中，以提炼与围岩分级有关的参数[8]-[16]。冷彪[8]利用图像分割技术给出掌子面典型情况的分割结果，提取了围岩部分地质组成信息。李汪石[9]利用卷积神经网络识别围岩的节理、裂隙、破碎程度、粗糙程度、光滑程度、泥石混合和涌水等分布式特征。Dongho Kang [10]、Ankang Ji [11]和 Amir Rezaie [12]均提出了基于卷积神经网络算法的裂纹检测方法，朱鑫[13]采用 SVM 建立了识别模型，将隧道结构面裂缝区与非裂缝区进行分类。查焕奕[14]以公路隧道掌子面图像为基础，利用深度学习 ResNet 模型，结合云计算在 Matlab 软件上通过 C++语言实现隧道围岩自动分级。柳厚祥[15]通过深度卷积神经网络模型和岩体裂隙图像智能解译方法提取隧道掌子面图片中的围岩一些特征参数。李赤谋[16]等人依托某隧道，采用图像处理技术，结合围岩单轴抗压强度等特性，实现基于岩体完整性和强度特征的掌子面围岩结构面特征识别和围岩级别快速评价。

虽然许多学者在围岩分级方法和基于机器视觉的围岩分级系统研究中取得一定成果，但是适用于地下水封洞库工程的围岩分级研究较少。本文以某地下水封洞库围岩图像为基础，利用深度卷积神经网络模型，通过 python 语言实现隧道围岩自动分级。削弱洞室开挖所揭示的裸露岩石面地质信息受施工人员，环境，设备等因素影响，避免  $Q$  值围岩分级参数有很大操作空间，使得该项工作流于形式。

## 2. 理论基础

### 2.1. 现场围岩分级方法

$Q$  值法节理指标包括节理组数、节理粗糙度、节理蚀变度及节理水折系数，具体计算见式(1)。 $Q$  值

取值范围为 0.001~1000，将岩体分为了五个级别，两者具体对应见表 1。

$$Q = \left( \frac{RQD}{J_n} \right) \times \left( \frac{J_r}{J_a} \right) \times \left( \frac{J_w}{SRF} \right) \tag{1}$$

式中： $RQD$ ——岩石质量指标； $J_n$ ——节理组数； $J_r$ ——节理粗糙度系数； $J_a$ ——节理面蚀变程度或充填情况； $J_w$ ——节理水折系数； $SRF$ ——应力折减系数。 $RQD$  和  $J_n$  主要判断围岩节理发育程度， $J_n$  和  $J_a$  主要分析节理面强度条件， $J_w$  和  $SRF$  主要对岩体赋存条件进行描述。

**Table 1.**  $Q$  value method of rock mass quality index


**表 1.** 岩体质量指标  $Q$  值分类

$Q$ 值	>40	10~40	1~10	0.1~1.0	<0.1
围岩类别	I	II	III	IV	V

## 2.2. 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)区别于人工神经网络，是一种前馈神经网络。它主要由卷积层(convolutional layer)、池化层(pooling layer)和全连接层组成，在图像处理领域表现非常出色。主要模块介绍如下：


卷积层：卷积运算的目的就是提取输入图像的不同特征，第一层卷积层可能只能提取一些低级的特征边缘、线条和角等层级，更多层的网络能从低级特征中迭代提取更复杂的特征(图 1)。



**Figure 1.** Convolutional layer

**图 1.** 卷积层

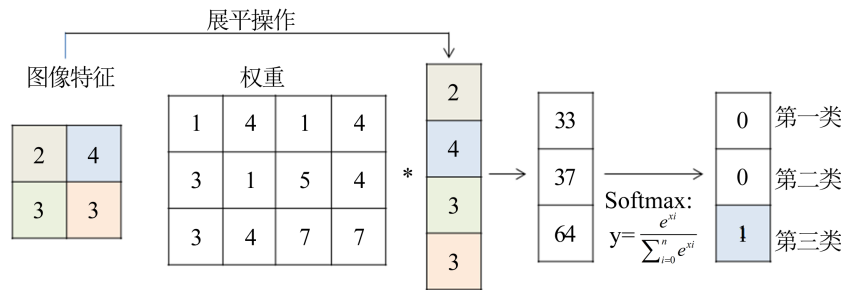
池化层：池化层主要对卷积层之后的数据进行压缩，降低维度，减少参数量，避免过拟合现象的发生。主要是通过计算点像素与周围像素进行统计聚类，缩减特征图尺寸，常用的池化操作主要包括平均池化和最大池化。此外，池化核大小一般与其步距相一致(图 2)。



**Figure 2.** Pooling layer

**图 2.** 池化层


全连接层：全连接层主要对图像进行分类。一般面对多分类问题时，将全连接层与 softmax 函数联系，完成最终分类结果输出(图 3)。



**Figure 3.** Full connection layer and activation function  
**图 3.** 全连接层和激活函数

**2.2.1. 深度学习分类网络 ResNet**

残差神经网络(ResNet) [17]由何凯明等人在 2015 年提出,该网络在 2015 年的 ILSVRC 中取得了冠军,是卷积神经网络发展的里程碑。算法针对梯度爆炸和梯度消失问题,引入了残差网络结构(图 4),增加了深层网络训练准确性。



**Figure 4.** Residual structure  
**图 4.** 残差结构[17]

ResNet 网络首先对输出图像进行卷积计算,然后再用四个残差模块依次计算,最后进行全连接  $n-1$  ( $n$  表示数据集类别数)个浮点数上,经过归一化后形成  $n$  个类别各自的概率,具体网络结构组成见表 2。本文采用 ResNet-34 和 ResNet-50 作为数据模型。

**Table 2.** The composition of the ResNet network  
**表 2.** ResNet 网络组成

	ResNet-34		ResNet-50
结构	组成	结构	组成
卷积层	$7 \times 7$ 卷积核, 64 通道, 步长 2 $3 \times 3$ 最大池化, 步长 2	卷积层	$7 \times 7$ 卷积核, 64 通道, 步长 2 $3 \times 3$ 最大池化, 步长 2
Layer_1	$\begin{bmatrix} 3 \times 3 \text{Conv}, 64\text{-d} \\ 3 \times 3 \text{Conv}, 64\text{-d} \end{bmatrix} \times 3$	Layer_1	$\begin{bmatrix} 1 \times 1 \text{Conv}, 64\text{-d} \\ 3 \times 3 \text{Conv}, 64\text{-d} \\ 1 \times 1 \text{Conv}, 256\text{-d} \end{bmatrix} \times 3$
Layer_2	$\begin{bmatrix} 3 \times 3 \text{Conv}, 128\text{-d} \\ 3 \times 3 \text{Conv}, 128\text{-d} \end{bmatrix} \times 3$	Layer_2	$\begin{bmatrix} 1 \times 1 \text{Conv}, 128\text{-d} \\ 3 \times 3 \text{Conv}, 128\text{-d} \\ 1 \times 1 \text{Conv}, 512\text{-d} \end{bmatrix} \times 4$
Layer_3	$\begin{bmatrix} 3 \times 3 \text{Conv}, 256\text{-d} \\ 3 \times 3 \text{Conv}, 256\text{-d} \end{bmatrix} \times 3$	Layer_3	$\begin{bmatrix} 1 \times 1 \text{Conv}, 256\text{-d} \\ 3 \times 3 \text{Conv}, 256\text{-d} \\ 1 \times 1 \text{Conv}, 1024\text{-d} \end{bmatrix} \times 6$

Continued

Layer_4	$\begin{bmatrix} 3 \times 3 \text{Conv}, 512-d \\ 3 \times 3 \text{Conv}, 512-d \end{bmatrix} \times 3$	Layer_4	$\begin{bmatrix} 1 \times 1 \text{Conv}, 512-d \\ 3 \times 3 \text{Conv}, 512-d \\ 1 \times 1 \text{Conv}, 2048-d \end{bmatrix} \times 3$
输出层	平均池化层, 1000 维全连接, softmax, 归一化	输出层	平均池化层, 1000 维全连接, softmax, 归一化

### 2.2.2. 分类网络 EfficientNet

EfficientNet 网络[18]同时采用三种方式提升网络性能：增加网络宽度即增加卷积核的个数提升性能；增加网络深度即使用更多的层结构来提升网络的性能；增加输入图像的分辨率提升网络性能。本文使用 EfficientNet\_B3，网络详细结构见表 3。

Table 3. The composition of the EfficientNet\_B3 network

表 3. EfficientNet\_B3 网络结构

步骤	卷积操作	输入图片大小	卷积核个数	层数
1	Conv3 × 3		40	1
2	MBCConv1, k3 × 3		24	2
3	MBCConv6, k3 × 3		32	3
4	MBCConv6, k5 × 5		48	3
5	MBCConv6, k3 × 3	300 × 300	96	5
6	MBCConv6, k5 × 5		136	5
7	MBCConv6, k5 × 5		232	6
8	MBCConv6, k3 × 3		384	2
9	Conv1 × 1 & Pooling & FC		1536	1

其中 MBCConv 结构主要由一个 1×1 普通卷积，一个 k×k 的 Depthwise 卷积，一个 SE 模块，一个 1×1 普通卷积，一个 Dropout 层构成，具体见图 5。第一个 1×1 卷积层有“升维作用”，其卷积核个数是输入特征矩阵的 n 倍，当 n 为 1 时，不需要该卷积层。SE 模块由一个全局平均池化和两个全连接层组成。第二个 1×1 卷积具有“降维作用”。关于 shortcut 连接，仅当输入 MBCConv 结构的特征矩阵与输出的特征矩阵 shape 相同时才存在。





Figure 5. The structure of MBCConv

图 5. MBCConv 结构

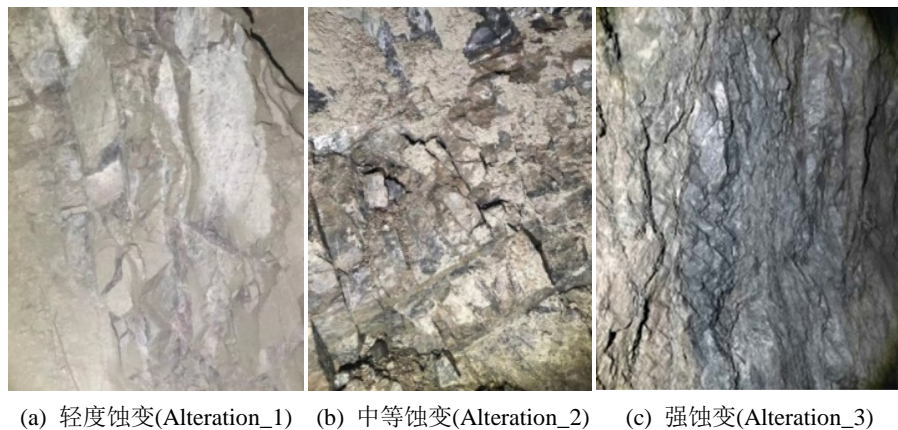
### 3. 构建现场图像分类数据

首先，将采集到的围岩图像进行批量裁剪与筛选，以消去施工机械和人员影响；其次，利用现场地质素描结果与相关地质学知识，将围岩图像分类整理；之后利用图像数据增强技术：水平翻转、增加噪声和改变亮度，扩充数据大小，为深度学习多分类网络提供合适数据集。

对水封洞库现场地质素描围岩分级结果整理, 岩体包含四个等级: II 级、III 级、IV 级和 V 级。II 类: 岩石节理较发育, 岩体较完整; III 类: 岩石节理较发育, 岩体较破碎, 节理裂隙面存在弱绿泥石蚀变; IV 类: 岩石严重节理化, 岩体破碎, 岩节理裂隙面具绿泥石蚀变。V 级: 岩石破碎, 蚀变强烈。部分分类结果见图 6。结合现场素描结果和  $Q$  分类围岩分级数据统计规律, 参考裂隙度  $K$  划分岩体破碎程度方法, 将岩体分为如下四类: 疏节理, 岩体较完整; 密节理; 非常密集节理; 压碎或糜棱化带。部分分类结果见下图 6。



**Figure 6.** Results of rock mass classification and development degree  
**图 6.** 岩体分级与岩体发育程度结果图





(d) 大水流(Water\_3) (e) 有局部小水流(Water\_2) (f) 干燥(Water\_1)

**Figure 7.** Classification result of rock mass strength and rock mass occurrence condition  
**图 7.** 岩体强度与岩体赋存条件分类结果图

节理蚀变程度和机理粗糙程度对节理面强度有很大影响。本节结合现场素描结果和  $Q$  分类围岩分级数据以及前人对岩体节理面的研究, 将该地下工程按照蚀变程度和节理面粗糙程度划分为 3 个等级: 轻度蚀变、中等蚀变和强蚀变, 部分分类结果见图 7。地下水与岩体之间的关系非常复杂, 他对岩体的影响是一个不可忽视的问题, 有无地下水对围岩等级有巨大差别。本节结合现场素描结果和  $Q$  分类围岩分级数据, 将该地下工程按照出水量划分为 3 个等级: 大水流、局部小水流和干燥。具体结果见图 7。

#### 4. 基于深度学习搭建围岩多分类器

利用上节中所提供的数据集, 构建深度学习分类网络, 将机器学习应用到围岩图像特征提取与围岩分级中。本文采用卷积神经网络中的 ResNet 和 EfficientNet 框架, 并采用迁移学习的方式, GPU 为 RTX 2080 Ti (11 GB)。

训练模型时, 采用 SGD 算法对网络权重进行迭代优化, 设置初始学习率为 0.001, 权重衰减系数为 0.0001, 每次迭代计算的样本大小 batch\_size 设置为 16, 循环训练次数设置为 100 次, 随着迭代次数的增加, 计算并记录模型准确率和损失函数大小。

##### 4.1. 围岩分类网络训练

**Table 4.** Training set and verification set data

**表 4.** 训练集与验证集组成

图片分类		训练集数量/张	验证集数量/张
围岩分级	II	426	182
	III	426	182
	IV	417	178
	V	444	189
岩体发育程度	Joint_1	487	208
	Joint_2	532	228
	Joint_3	542	232
	Joint_4	511	219

Continued

节理面强度	Alteration_1	437	187
	Alteration_2	446	190
	Alteration_3	445	190
赋存条件	Water_1	432	185
	Water_2	427	183
	Water_3	388	166

利用现场获得的照片和整理的数据进行分类训练, 为了避免过拟合现象发生, 数据集越大, 深度学习效果越好。计算所采用的训练集和测试集组成样本见表 4 所示, 利用 ResNet-34、ResNet-50 和 EffcientNet\_B3 模型分别对样本进行训练, 最终选取 EffcientNet\_B3 训练结果进行分析, 结果见图 8。

运用模型训练关于围岩分级、岩体完整程度、岩石节理面强度和岩石节理面赋存条件的损失率和准确率结果见图 8。




Figure 8. Loss rate and accuracy of training surrounding rock classification results

图 8. 训练围岩分级结果损失率和准确率

从图中可以看出, 利用 EffcientNet\_B3 模型训练围岩分级网络的准确率最大为 88.6%, 损失率减小为 0.074。利用 EffcientNet\_B3 模型训练岩体完整性的准确率最大为 84.6%, 损失率减小为 0.074。利用 EffcientNet\_B3 模型训练节理面强度的准确率最大为 78.8%, 损失率减小为 0.076。利用 EffcientNet\_B3 模型训练赋存条件的准确率最大为 92.1%, 损失率减小为 0.04。

#### 4.2. 洞库围岩分级应用

选取掌子面图片, 代入模型进行预测, 预测结果分别为 III、III、III 和 IV 级围岩(图 9(a)), 预测结果与现场地质素描结果相吻合。此外, 按照节理发育程度判断, 岩体分别属于非常密集节理、非常密集节理、疏节理和非常密集节理的对应概率为 77.4%、99.4%、95%和 100% (图 9(b)); 按照节理面强度判断, 岩体分别属于轻度蚀变、强蚀变、轻度蚀变和强蚀变的对应概率为 99.6%、99.6%、85.3%和 92.4% (图 9(c)); 分析岩体赋存条件, 岩石分别属于干燥、干燥、干燥和局部小水流的概率对应为 100%、99.2%、100%和



99.1% (图 9(d))。




Figure 9. Results of multiple classification of cave surrounding rock  
图 9. 洞库围岩多分类结果

## 5. 结论

由于  $Q$  值法受施工人员, 环境, 设备等因素影响, 分级参数有很大操作空间。基于此引入深度学习分类网络, 利用计算机完成不同类型围岩特征学习, 减少不必要因素影响, 提高分级结果准确性。首先, 结合现场素描结果和  $Q$  分类围岩分级数据, 构建了用于分类学习的图像数据集(II 级、III 级、IV 级和 V 级)。为了进一步获取图片所蕴含的信息, 参考相关地质学将围岩图片基于节理面发育程度、节理面强度和岩体赋存条件进一步分类, 完成图像信息深层次提取。其次, 选用 EfficientNet\_B3 训练结果, 围岩分级模型训练的准确率为 88.6%, 节理发育程度模型训练的准确率为 86%, 节理面强度模型训练的准确率为 78.8%, 赋存条件模型训练的准确率为 92.1%。最终, 将围岩分级优化方法应用于具体施工面, 其预测结果均与现场地质素描结果相吻合。

## 参考文献

- [1] Barton, N.R., Lien, R. and Lunde, J. (1974) Engineering Classification of Rock Masses for the Design of Rock Support. *Rock Mechanics*, **6**, 189-236. <https://doi.org/10.1007/BF01239496>
- [2] 马云飞. 隧道围岩  $Q$  值分级与支护设计优化[J]. 交通科技, 2013(2): 83-84.
- [3] 康小兵, 许模, 陈旭. 岩体质量  $Q$  系统分类法及其应用[J]. 中国地质灾害与防治学报, 2008, 19(4): 91-95.
- [4] 刘现春, 石豫川, 童建刚.  $Q$  系统在西南某水电 TBM 施工隧洞围岩质量分类中的应用[J]. 水资源与水工程学报, 2011, 22(5): 167-170.
- [5] 肖春华. 岩体质量指标  $Q$  分类法在汕头 LPG 工程中的应用[J]. 隧道建设, 2002(4): 4-9.
- [6] Xu, D., Huang, X., Li, S., et al. (2022) Predicting the Excavation Damaged Zone within Brittle Surrounding Rock Masses of Deep Underground Caverns Using a Comprehensive Approach Integrating *in Situ* Measurements and Numerical Analysis. *Geoscience Frontiers*, **13**, Article ID: 101273. <https://doi.org/10.1016/j.gsf.2021.101273>
- [7] 史永跃, 李苍松, 李春林, 等. 某地下油库蚀变岩工程特性及岩体质量评价技术研究[J]. 现代隧道技术, 2019, 56(Z1): 150-158.
- [8] 冷彪. 数字图像处理在隧道掌子面图表像中的研究与实现[D]: [硕士学位论文]. 成都: 西南交通大学, 2005.
- [9] 李汪石. 公路隧道围岩云分级系统的开发与应用[D]: [硕士学位论文]. 长沙: 长沙理工大学, 2017.
- [10] Dongho, K., Sukhpreet, S.B., Dharshan, L.G. and Young-Jin, C. (2020) Hybrid Pixel-Level Concrete Crack Segmentation and Quantification Across Complex Backgrounds Using Deep Learning. *Automation in Construction*, **118**, Article ID: 103291. <https://doi.org/10.1016/j.autcon.2020.103291>
- [11] Jia, A.K., Xue, X.L., Wang, Y., Luo, X.W. and Xue, W.R. (2020) An Integrated Approach to Automatic Pixel-Level Crack Detection and Quantification of Asphalt Pavement. *Automation in Construction*, **114**, Article ID: 103176. <https://doi.org/10.1016/j.autcon.2020.103176>
- [12] Amir, R., Radhakrishna, A., Michele, G. and Katrin, B. (2020) Comparison of Crack Segmentation Using Digital Image Correlation Measurements and Deep Learning. *Construction and Building Materials*, **261**, Article ID: 120474. <https://doi.org/10.1016/j.conbuildmat.2020.120474>
- [13] 朱鑫. 隧道结构表面病害特征快速检测研究[D]: [硕士学位论文]. 成都: 西南交通大学, 2014.
- [14] 查焕奕. 基于 ResNet 模型的隧道围岩云分级系统开发[D]: [硕士学位论文]. 长沙: 长沙理工大学, 2018.
- [15] 柳厚祥, 李汪石, 查焕奕, 蒋武军, 许腾. 基于深度学习技术的公路隧道围岩分级方法[J]. 岩土工程学报, 2018, 40(10): 1809-1817.
- [16] 李赤谋, 吕明, 袁青, 陈宇佳, 王树英. 基于三维重建与 Unet 神经网络的隧道掌子面围岩快速分级技术[J]. 隧道建设(中英文), 2022, 42(1): 33-40.
- [17] He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep Residual Learning for Image Recognition. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- [18] Tan, M. and Le, Q. (2019) EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of 36th International Conference on Machine Learning*, Long Beach, 9-15 June 2019, 6105-6114.