



# 智能系统学报

CAAII TRANSACTIONS ON INTELLIGENT SYSTEMS

## 基于孪生变分自编码器的小样本图像分类方法

王德文, 魏波涛

引用本文:

王德文, 魏波涛. 基于孪生变分自编码器的小样本图像分类方法[J]. *智能系统学报*, 2021, 16(2): 254–262.

WANG Dewen, WEI Botao. A small-sample image classification method based on a Siamese variational auto-encoder[J]. *CAAII Transactions on Intelligent Systems*, 2021, 16(2): 254–262.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.201906022>

## 您可能感兴趣的其他文章

### 结合度量融合和地标表示的自编码谱聚类算法

An autoencoder-based spectral clustering algorithm combined with metric fusion and landmark representation  
*智能系统学报*. 2020, 15(4): 687–696 <https://dx.doi.org/10.11992/tis.201911039>

### 基于级联宽度学习的多模态材质识别

Cascade broad learning for multi-modal material recognition  
*智能系统学报*. 2020, 15(4): 787–794 <https://dx.doi.org/10.11992/tis.201908021>

### 基于小样本学习的LCD产品缺陷自动检测方法

An automatic small sample learning-based detection method for LCD product defects  
*智能系统学报*. 2020, 15(3): 560–567 <https://dx.doi.org/10.11992/tis.201904020>

### 隐式特征和循环神经网络的多声部音乐生成系统

A polyphony music generation system based on latent features and a recurrent neural network  
*智能系统学报*. 2019, 14(1): 158–164 <https://dx.doi.org/10.11992/tis.201804009>

### 多标记学习自编码网络无监督维数约简

Unsupervised dimensionality reduction of multi-label learning via autoencoder networks  
*智能系统学报*. 2018, 13(5): 808–817 <https://dx.doi.org/10.11992/tis.201804051>

### 基于自编码器的特征迁移算法

Feature transfer algorithm based on an auto-encoder  
*智能系统学报*. 2017, 12(6): 894–898 <https://dx.doi.org/10.11992/tis.201706037>

 微信公众平台



关注微信公众号, 获取更多资讯信息

DOI: 10.11992/tis.201906022

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20200714.0932.004.html>

# 基于孪生变分自编码器的小样本图像分类方法

王德文, 魏波涛

(华北电力大学 控制与计算机工程学院, 河北 保定 071000)

**摘要:** 当前深度学习大都基于大量数据通过构建深层次的网络实现自动识别, 但在很多场景中难以获得大量的样本数据。针对这一问题, 提出一种基于孪生变分自编码器 (siamese variational auto-encoder, S-VAE) 的小样本图像分类方法。通过变分自编码器提取原始训练数据的高层语义特征, 然后由两个训练好的变分自编码器的编码器部分组建孪生网络的输入结构, 最后通过分类器对样本进行识别。变分自编码器可以解决样本数据量少带来的过拟合问题, 孪生网络的结构增加了样本数量较少的情况下的训练次数。在 Omniglot 数据集上进行的实验结果表明: 本方法与原始孪生神经网络相比正确率平均提高了 3.1%, 模型收敛速度更快, 证明了孪生变分自编码器能够较好地完成小样本数据分类任务。

**关键词:** 小样本; 变分自编码器; 孪生网络; 图像识别; 过拟合; 特征向量; 深度学习; 数据增强

**中图分类号:** TP183 **文献标志码:** A **文章编号:** 1673-4785(2021)02-0254-09

中文引用格式: 王德文, 魏波涛. 基于孪生变分自编码器的小样本图像分类方法 [J]. 智能系统学报, 2021, 16(2): 254-262.

英文引用格式: WANG Dewen, WEI Botao. A small-sample image classification method based on a Siamese variational auto-encoder[J]. CAAI transactions on intelligent systems, 2021, 16(2): 254-262.

## A small-sample image classification method based on a Siamese variational auto-encoder

WANG Dewen, WEI Botao

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071000, China)

**Abstract:** Currently, most deep learning is based on the use of large amounts of data and the construction of a deep network to achieve automatic recognition, but it is difficult to obtain a large amount of sample data in many scenarios. To solve this problem, we propose the use of a small-sample image classification method based on a Siamese variational auto-encoder (S-VAE). First, the high-level semantic features of the original training data are extracted by the variational auto-encoder. Then, the input structure of the Siamese network is constructed by the encoders of two trained variational auto-encoders. Lastly, the samples are identified by the classifier. The variational auto-encoder can solve the over-fitting problem caused by small amounts of sample data, and the structure of the Siamese network increases the training number when the sample size is small. The experimental results on the Omniglot dataset show that this method has a 3.1% average improvement in accuracy compared with the original Siamese network. The model convergence speed is also faster, which proves that the S-VAE can better complete the classification task when using small-sample data.

**Keywords:** small sample; variational auto-encoder (VAE); siamese network; image recognition; over-fitting; eigen-vector; deep learning; data augmentation

大量的图像样本数据和强大的计算资源, 使得深度学习在图像处理领域有着广阔的应用前

景。深度学习从大量的样本中学习样本的特征分布, 然后经过多次迭代优化各层权重, 最后通过分类器实现图像分类<sup>[1-3]</sup>。但是在一些特殊或者难以复现的场景中, 难以获得足够的样本<sup>[4]</sup>。由于样本数量很少, 使用深层神经网络往往会导致

收稿日期: 2019-06-12. 网络出版日期: 2020-07-14.

基金项目: 国家自然科学基金项目 (51677072).

通信作者: 魏波涛. E-mail: [764387445@qq.com](mailto:764387445@qq.com).

过拟合的现象出现, 减少网络层数则会影响特征提取, 导致分类正确率下降<sup>[5]</sup>。小样本图像分类现在仍是深度学习中一个重要的研究问题<sup>[6]</sup>。

小样本学习问题由李飞飞等<sup>[7]</sup>于 2006 年提出, 使用贝叶斯的方法在一个或少数几个图像学习问题中成功提取出了信息模型。文献 [8] 于 2015 年提出分层贝叶斯模型, 该模型能从少量样本中完成计算任务, 并且达到了相当于人类水平的识别率。随后迁移学习的提出给小样本学习带来了新的处理方法<sup>[9]</sup>。文献 [10] 提出一种基于堆栈降噪自编码与支持向量回归机的混合模型, 在相似源域大数据上预训练混合模型借助对该知识的迁移, 在目标域微调该混合模型, 从而提升支持向量回归机在小样本噪声数据上的学习预测精度。

目前对于小样本图像分类问题, 主要有增加样本数量和根据问题选择特定算法两种方式<sup>[11-12]</sup>。最初的样本数量增强技术, 例如原始样本的旋转、翻转和增加对比度等方法, 在一定程度上解决了样本的数量问题, 但是往往因为相似度过大, 产生过拟合现象。如今, 统计学上的各种采样方法、生成对抗网络的提出, 为样本的数量增强提供了新的解决思路<sup>[13]</sup>。文献 [14] 采用 Bootstrap 法来解决电力负荷数据少的问题, 利用放回重复抽样的方法得到新的样本, 利用一种类比关系来进行统计推断, 将小样本转换为大样本问题, 但是该方法会造成被估参数的均值过分依赖样本子集的情况, 不利于参数估计的稳健性。根据研究问题的不同, 选择特定的算法也可以显著地提高实验效果<sup>[15-16]</sup>。文献 [17] 提出了利用蒙特卡罗随机试验可以对特征参量进行统计估计的特性, 计算高光谱图像的最优降维特征数, 对小样本的高光谱图像进行降维, 实验证明使用该方法后图像的分类精度有了较大提高。但是, 蒙特卡罗的结果和准确性很大程度依赖于母体所建立的数学模型。

2005 年 Chopra 等<sup>[18]</sup>第一次提出了孪生网络的结构, 该方法在人脸识别数据集上进行训练和测试, 取得了很好的识别效果。孪生网络创新地采用了两个样本组成一对作为神经网络的输入的结构。在不改变样本数量的条件下, 增加了整体样本循环一个批次的训练次数, 更有效地完成特征的提取, 减少因样本少带来的过拟合问题。在处理类别较多、每个类别样本少的分类任务有着极强的优势。

为了解决小样本图像分类问题, 采用以变分

自编码器为核心的孪生网络结构来实现对小样本图像数据的分类。特征提取通过变分自编码器来实现, 无需人工提取, 而孪生网络的相似度匹配结构, 可以有效地提高分类的正确率。

## 1 相关理论

### 1.1 孪生网络

孪生网络是一种特殊类型的神经网络结构, 与传统一个学习过程对应一个输入然后进行分类的模型不同, 该神经网络每个学习过程具有两个输入, 使用相同权重的神经网络对两个输入数据进行处理, 计算提取到的特征的相似度来分辨两个数据的是否为同一类别。孪生网络结构如图 1 所示。

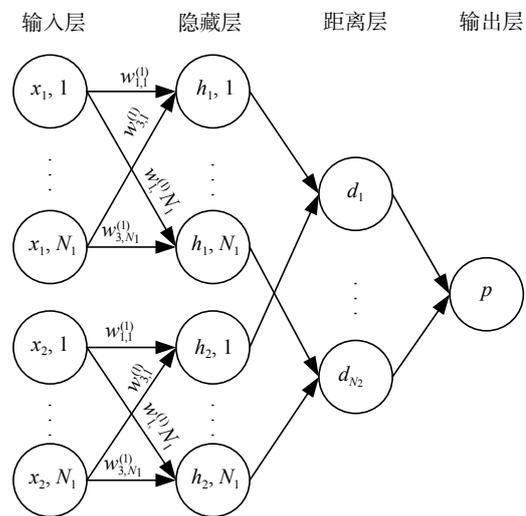


图 1 孪生网络结构  
Fig. 1 Siamese network

最初的孪生网络基于全连接网络。网络有  $L$  个全连接层, 每层有  $N_l$  个神经元,  $\mathbf{h}_{1,l}$  表示在第一个孪生网络分支  $l$  层的隐向量,  $\mathbf{h}_{2,l}$  表示在第二个孪生网络分支  $l$  层的隐向量, 网络在前  $L-1$  层中使用 ReLU 作为激活函数, 对于  $l \in \{1, 2, \dots, L-1\}$  层网络中隐向量  $\mathbf{h}_{1,m}$ 、 $\mathbf{h}_{2,m}$  按式 (1) 和式 (2) 计算:

$$\mathbf{h}_{1,m} = \max(0, \mathbf{W}_{l-1}^T \mathbf{h}_{1,(l-1)} + b_l) \quad (1)$$

$$\mathbf{h}_{2,m} = \max(0, \mathbf{W}_{l-1}^T \mathbf{h}_{2,(l-1)} + b_l) \quad (2)$$

式中:  $\mathbf{W}_{l-1}$  为  $N_{l-1} \times N_l$  共享的权值矩阵;  $b_l$  为  $l$  层向量的偏置;  $\max$  为求最大值。

经过输入层和隐藏层的前馈操作后, 在距离层按式 (3) 比较孪生网络生成的特征的距离  $E(W)$ , 用来评估特征的相似程度。

$$E(W) = \|\mathbf{h}_{1,m} - \mathbf{h}_{2,m}\| \quad (3)$$

孪生网络结构具有两个权重相同、结构相同的姐妹网络。输入图像两两组成一对, 图像对中的两个图像将分别送到两个姐妹网络中, 然后使

用对比损失函数来优化网络。原始的姐妹网络使用的是全连接结构，全连接网络参数众多，训练效率低。文献 [19] 对网络的特征提取过程进行改进，使用卷积神经网络作为姐妹网络来提取图像特征，取得了很好的效果。但是，卷积神经网络在样本数据量小时，易于产生过拟合现象。

使用孪生网络训练时，由于其逐对训练的原理，将有平方级别对的数据可以用来训练模型，这让模型很难过拟合。假设数据集样本有  $E$  类，每类有  $C$  个样本，则一共有  $C \times E$  张图片，总共可组成的样本对数计算公式为

$$N_{\text{pairs}} = \frac{(C \cdot E)}{2!(C \cdot E - 2)} \quad (4)$$

以 Omniglot 数据集为例，对于数据集中的 964 类（每类 20 个样本），剔除其中相同类别的配对，仍有 183 160 对组合。孪生网络在不增加样本的前提下，通过输入对匹配的方式，增加了样本的训练次数，从而提高了网络的学习能力，避免出现过拟合问题。

### 1.2 变分自编码器

变分自编码器是 2014 年提出的一种基于变分贝叶斯推断的生成式结构模型<sup>[20]</sup>。变分自编码器总体上分为两个神经网络：Encoder 和 Decoder。Encoder 通过变分参数的不断迭代、更新来最大化观测数据的边缘似然函数的下界，近似不可观测变量的后验概率，输出隐变量的概率分布。Decoder 则是根据 Encoder 输出的隐变量概率分布还原生产原始数据的近似概率分布。

变分自编码器具有和 Dropout 类似正则化作用的隐层采样过程，这使得模型的整个训练过程不容易发生过拟合问题<sup>[21]</sup>，与传统特征提取模型相比，更加适合解决样本数量较少的问题。变分自编码器现在已经广泛应用于高维数据降维、特征提取等方面<sup>[17-24]</sup>。

## 2 基于孪生变分自编码器的小样本图像分类

### 2.1 孪生变分自编码结构

综合变分自编码器减少过拟合问题和孪生网络扩大样本训练次数的优点，对孪生网络进行改进，使用变分自编码器的 Encoder 结构代替全连接网络提取样本特征，减少了网络参数，提高训练效率。孪生变分自编码器首先建立变分自编码器网络进行特征提取的无监督学习，然后使用两个权重完全相同的变分自编码器 Encoder 结构搭建孪生网络用于提取样本特征，在距离层计算特

征向量的相似度，得到输入样本的分类结果。最后，对神经网络权重进行训练、调整。孪生变分自编码器结构如图 2 所示。

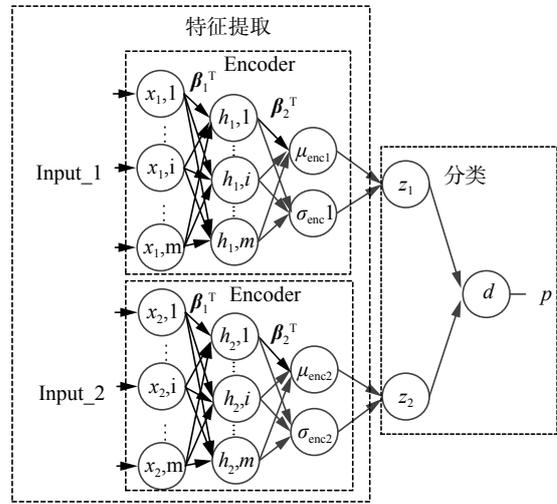


图 2 孪生变分自编码器结构

Fig. 2 Siamese variational auto-encoder

Input\_1、Input\_2 是样本数据的一组组合输入，特征提取功能由变分自编码器的 Encoder 实现， $(x_{1,l})$ 、 $(x_{2,l})$  为 Input\_1、Input\_2 展开得到的输入向量。 $(h_{1,l})$  为 Input\_1 输入第一个 Encoder 结构得到的隐向量， $(h_{2,l})$  为 Input\_2 输入第二个 Encoder 结构后得到的隐向量。 $\beta_1^T$  及  $\beta_2^T$  为 Encoder 的权重，并且两个 Encoder 结构的权重完全相同。 $\mu$ 、 $\sigma$  为输入数据经由 Encoder 结构提取到的期望与方差，该部分的计算原理同变分自编码器相同， $z_1$ 、 $z_2$  分别为 Input\_1、Input\_2 提取到的特征向量。 $d$  为距离层，针对获得的特征选择欧式距离计算相似度，最后将输出归一化到 [0,1] 之间，使用 sigmoid 函数使之成为一个概率。

根据图 2 的孪生变分自编码器结构，给出相应孪生变分自编码器的计算流程，如图 3 所示。

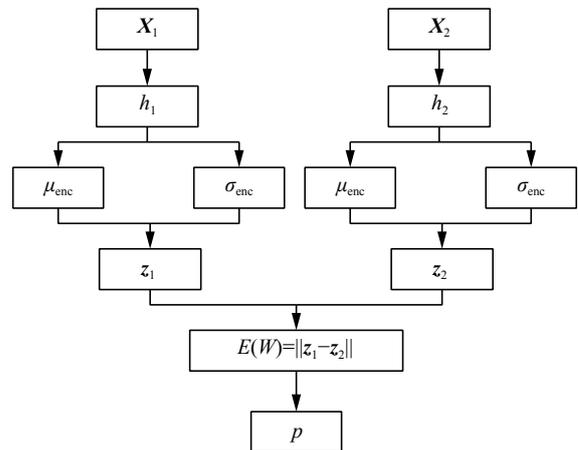


图 3 孪生变分自编码器的计算流程

Fig. 3 Computation process of S-VAE

图 3 中  $X_1$ 、 $X_2$  为输入样本对展开后得到的一维向量;  $h_1$ 、 $h_2$  为网络第 1 层的输出;  $\mu_{enc}$ 、 $\sigma_{enc}$  为网络第 2 层的输出。  $z_1$ 、 $z_2$  为输入对经由变分自编码器提取到的特征向量;  $E(W)$  在距离层计算两个特征向量的欧式距离;  $p$  为归一化后得到的分类准确率。输入样本对经过两个权重相同的 Encoder 结构提取到特征, 组成孪生网络, 通过相似度匹配算法, 得到最终分类的类别以及正确率。

利用上述孪生变分自编码器的结构和计算流程对小样本图片进行分类的具体过程如下:

1) 将数据集以适当的比例分为训练数据集和测试数据集, 对训练数据集使用变分自编码器进行无监督的学习, 训练特征提取模型。

2) 初始化孪生变分自编码器结构, 载入训练好的特征提取模型, 将训练数据集作为输入对网络进行训练, 调整网络各层权值。

3) 将测试数据集作为输入, 利用训练好的网络来进行分类任务。

## 2.2 孪生变分自编码器特征提取

孪生变分自编码器特征提取采用的是变分自编码器的 Encoder 结构。变分自编码器是一个无监督学习的神经网络, 本质上是构建了一个从隐变量  $z$  (隐含特征) 生成目标数据  $Y$  的模型, 通过缩小原始输入  $X$  与输出  $Y$  之间的重构误差进行学习。变分自编码器的“瓶颈”的结构可以有效地降低原始数据的维数, 提取样本特征, 实现对原始样本的表示学习。变分自编码器结构如图 4 所示。

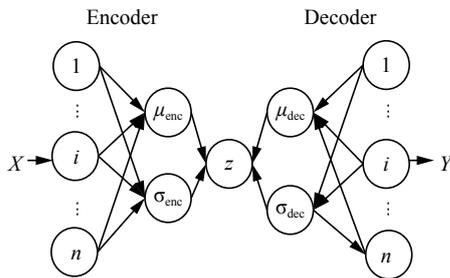


图 4 变分自编码器

Fig. 4 Variational auto-encoder

对于原始样本集  $X$ , 定义其特征值为隐变量  $z$ , 根据贝叶斯准则,  $z$  的后验概率密度函数为

$$p(z|x) = \frac{p(x|z)p(z)}{p(x)} \quad (5)$$

但是, 边缘似然概率密度函数  $p(x)$  计算复杂, 因此变分贝叶斯推理中, 通过引入近似分布函数  $q(z|x)$  来拟合真实后验分布  $p(z|x)$ , 并利用 Kullback-Leibler (KL) 散度来比较两个分布的相似

程度。

$$D_{KL}(p(z|x)||q(z|x)) = \sum p(z|x) \log \frac{p(z|x)}{q(z|x)} \quad (6)$$

根据变分贝叶斯方法, 样本数据  $x$  的边缘似然函数可以简化为

$$\log p_\theta(x^{(i)}) = D_{KL}(q_\phi(z|x^{(i)})||p_\theta(z|x^{(i)})) + L(\theta, \phi; x^{(i)}) \quad (7)$$

式中:  $\phi$  为真实后验分布参数;  $\theta$  为隐层的近似分布参数; 式 (7) 中第一项为隐层的近似分布与真实后验分布之间的 KL 散度, 由于 KL 散度为非负值, 仅当两个分布完全一致时, KL 散度为 0, 因此, 可以展开为

$$\log p_\theta(x^{(i)}) \geq L(\theta, \phi; x^{(i)}) = -D_{KL}(q_\phi(z|x^{(i)})||p_\theta(z)) + E_{q_\phi(z|x^{(i)})}[\log p_\theta(x^{(i)}|z)] \quad (8)$$

通过最大化变分下界, 即可以得到样本集的最优估计。同时, 可以将式 (8) 重写为

$$L(\theta, \phi; x^{(i)}) = \frac{1}{2} \sum_{j=1}^J \left( 1 + \log \left( \left( \sigma_{encj}^{(i)} \right)^2 \right) - \left( \mu_{encj}^{(i)} \right)^2 - \left( \sigma_{encj}^{(i)} \right)^2 \right) + \frac{1}{L} \sum_{l=1}^L \left( -\log \left( \sigma_{dec}^{(i,j)} \sqrt{2\pi} \right) - \frac{\left( x^j - \mu_{dec}^{(i,j)} \right)^2}{2\sigma_{dec}^{(i,j)^2}} \right) \quad (9)$$

式中:  $\mu_{enc}$ 、 $\sigma_{enc}$  为编码器的输出;  $\mu_{dec}$ 、 $\sigma_{dec}$  为解码器的输出;  $j$  为隐变量  $z$  的维度;  $L$  为隐变量  $z$  在后验分布上的采样次数。然后, 选择随机梯度下降法 (stochastic gradient descent, SGD) 来优化神经网络的参数, 当式 (9) 收敛, 编码器部分的输出即为提取的特征值, 解码器的输出为重构的原始样本。

针对图 3 孪生变分自编码器的计算流程, 孪生变分自编码器特征提取过程可以表示为

$$\begin{cases} h_1 = f(W_{h_1}x + b_{h_1}) \\ \mu_{enc} = f(W_{\mu_{enc}}x + b_{\mu_{enc}}) \\ \log \sigma_{enc} = f(W_{\sigma_{enc}}x + b_{\sigma_{enc}}) \\ z = \mu_{enc} + \sigma_{enc} \odot \varepsilon, \varepsilon \sim N(0, 1) \end{cases} \quad (10)$$

式中:  $W$ 、 $b$  为各层的权重和偏置项;  $x$  为输入数据, 实际使用的是变换为一维数据的 Omniglot 图像;  $h_1$  为网络第 1 层的输出;  $\mu_{enc}$ 、 $\sigma_{enc}$  为网络第二层的输出;  $f$  是激活函数, 基于高斯分布参数  $\mu$ 、 $\sigma$ , 利用  $q_\phi(z|x^{(i)})$  采样得到隐层输出  $z$ , 其中,  $N(0, 1)$  为标准正态分布。

## 2.3 孪生变分自编码器图像分类

两个原始数据成对输入 Encoder, 通过训练好的编码器网络进行分布参数提取, 可以得到两个输入数据的特征向量  $z_1$ 、 $z_2$ , 在距离层计算两个特征向量的欧式距离,  $E_w$  为两个样本对输出特征的欧式距离。

$$E_w = \|z_1 - z_2\| \quad (11)$$

使用 sigmoid 函数将匹配度映射到 [0,1] 之间成为一个分类结果的概率,同时方便使用交叉熵作为训练网络的代价函数。相似度为

$$p = \sigma\left(\sum_j \|z_1 - z_2\|\right) \quad (12)$$

孪生网络的对比损失函数为

$$L(W) = \sum_{i=1}^p L(W, (Y, X_1, X_2)^i) \quad (13)$$

式 (13) 可以展开为

$$L(W, (Y, X_1, X_2)^i) = (1 - Y)(E_w(X_1, X_2)^i) + Y(-E_w(X_1, X_2)^i) \quad (14)$$

式中:  $p$  表示输入的总样本数;  $i$  为当前样本的下标。其中  $Y$  表示样本对的标签,  $Y \in \{1, 0\}$ 。当  $Y=0$  时,表明本次输入样本对是同一类图片。此时的样本对的损失函数  $L(W)$  越小说明模型的参数越合理。若  $L(W)$  很大,则需要网络使用反向传播机制,对模型参数进行优化。当  $Y=1$  时,表明本次输入样本对  $X_1$ 、 $X_2$  不是同一类。此时,优化损失函数  $L(W)$  会使使得来自不类别图像的损失尽可能变大。结合式 (12),本文模型的代价函数为

$$L(W, (Y, z_1, z_2)^i) = (1 - Y)\log(p(z_1, z_2)^i) + Y\log(1 - p(z_1, z_2)^i) \quad (15)$$

式中:  $Y$  为输入对是否是同类的标签;  $p(z_1, z_2)^i$  为第  $i$  个样本对输入网络后得到的归一化后的特征距离。代价函数可以使用标准反向传播算法进行模型训练。

### 3 实验结果与分析

#### 3.1 Omniglot 数据集构建

实验使用 Tensorflow 框架设计神经网络并进行训练和测试,实验的硬件环境为 i5-8300H 处理器,8 GB 内存,软件环境为 Windows 10 操作系统。

Omniglot 数据集拥有 50 种文字,1 623 类手写字符。对于每类字符仅有 20 个样本,每个样本分别由不同的人绘制而成,分辨率为  $105 \times 105$ 。图 5 为数据集的 4 个示例。



图 5 Omniglot 数据集  
Fig. 5 Omniglot dataset

针对 Omniglot 数据集的测试实验主要围绕 N-way K-shot 展开:每种方法利用未经训练的  $N$  类中的  $K$  个已标记的样本进行训练,然后对一

组属于  $N$  类中不相交的未标记样本进行分类。本文进行的实验是 5-way 1-shot、5-way 5-shot、20-way 1-shot 和 20-way 5-shot。

#### 3.2 Omniglot 分类实验分析

整个模型分为 5 层,特征提取部分网络层数为 3 层。第 1 层输入层为 22050 个节点,第 2 层为 2048 个节点,第 3 层为 4 个节点,第 4 层为 4 个节点,第 5 层输出层为 1 个节点。训练该模型提取样本图像的高层语义特征,然后再针对样本图像提取的高层语义特征利用孪生变分自编码器模型进一步进行训练,最后使用分类器进行分类。

通过 Omniglot 数据集对孪生变分自编码器进行测试,与原始孪生网络以及其他针对小样本图像分类方法实验结果进行对比。实验中用于对比的小样本分类方法主要有文献 [25] 中引用的原始孪生网络实验结果、文献 [19] 中提出的卷积孪生网络、文献 [26] 提出的分层贝叶斯学习方法 (HBPL) 以及文献 [27] 提出的预采样匹配网络 (SSMN)。实验结果如表 1 所示。

表 1 Omniglot 数据集 N-way K-shot 平均正确率  
Table 1 Average accuracy of N-way K-shot of Omniglot dataset %

模型	5-way	5-way	20-way	20-way
	1-shot	5-shot	1-shot	5-shot
Siamese net <sup>[25]</sup>	93.7	98.4	88.2	97.0
HBPL <sup>[26]</sup>	-	-	95.2	-
Convolution net <sup>[25]</sup>	96.7	98.4	92.0	96.5
SSMN <sup>[27]</sup>	97.4	98.6	93.3	98.7
S-VAE	98.0	98.7	94.1	98.9

从表 1 中可以看出, S-VAE 实验结果中,4 种条件下孪生变分自编码器分类结果均高于卷积孪生神经网络。20-way 1-shot 情况下略微低于 HBPL 模型,较其他方法,孪生变分自编码器具有更高的分类正确率。20-way 5-shot 情况下本文提出的模型正确率最高,为 98.9%。从表中可以看出, S-VAE 相较于原始的孪生网络分类正确率在 4 个对比实验下均有所提高,平均提高 3.1%。

由于 HBPL 模型是一种针对 Omniglot 进行特定处理的方法,在 Omniglot 笔画层次上进行图像的分割,继而进行学习,缺乏在其他问题上的拓展能力。因此,对余下 3 种算法和本文提出的模型,进行训练时间的比较,结果如表 2 所示。

从表 2 的训练时间来看,孪生变分自编码器在训练接近 2 个小时后,可以完成训练,并且训练用时最短,这说明孪生变分自编码器可以实现对

小样本数据的快速分类, 相较于另外 3 种算法, 效率更高。

表 2 Omniglot 数据集 N-way K-shot 训练时间  
Table 2 Training time of N-way K-shot of Omniglot dataset

模型	5-way		20-way	
	1-shot	5-shot	1-shot	5-shot
Siamese net	21337.9	21663.1	21545.4	21581.3
Convolution net	17943.6	17736.4	17898.1	17975.1
SSMN	15936.5	15081.7	15573.6	15459.4
S-VAE	6954.69	7031.60	6714.38	7366.87

图 6~9 为本文提出模型的实验结果, 主要包括 5-way 1-shot、5-way 5-shot、20-way 1-shot 和 20-way 5-shot 的测试错误率以及损失函数值的结果。结合表 1 中的平均正确率, 从图 6 中 5-way 1-shot 的测试实验结果可以看出, 整体样本正确率达到 98.0%, 一部分样本可以 100% 地识别出来, 与原始孪生网络相比, 分类正确率提高了 4.3%。结合图 8 可以看出, 当样本类别数量增加到 20 类时, 20-way 1-shot 场景下整体测试样本正确率达到了 94.1%, 与原始孪生网络相比, 分类正确率提高了 5.9%。

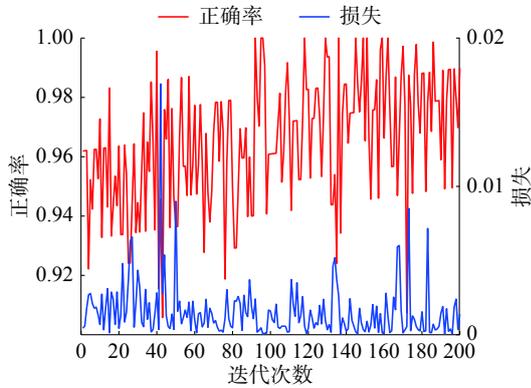


图 6 5-way 1-shot 测试正确率和损失函数值  
Fig. 6 Test accuracy and loss of 5-way 1-shot

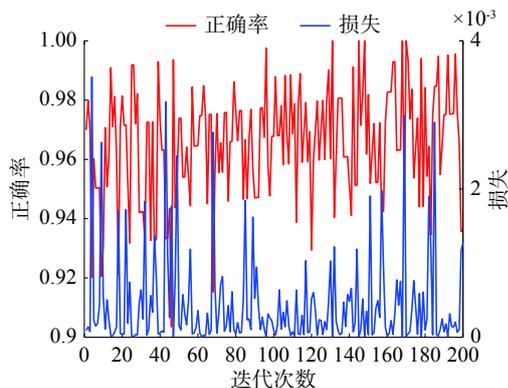


图 7 5-way 5-shot 测试正确率和损失函数值  
Fig. 7 Test accuracy and loss of 5-way 5-shot

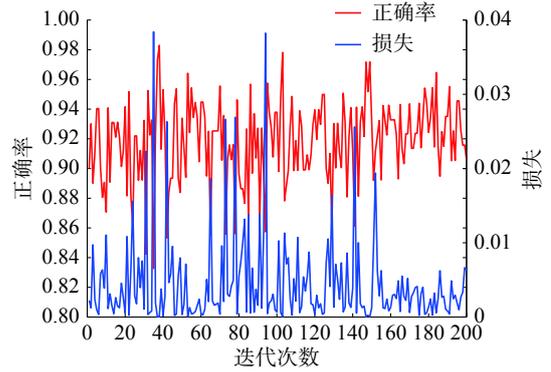


图 8 20-way 1-shot 测试正确率和损失函数值  
Fig. 8 Test accuracy and loss of 20-way 1-shot

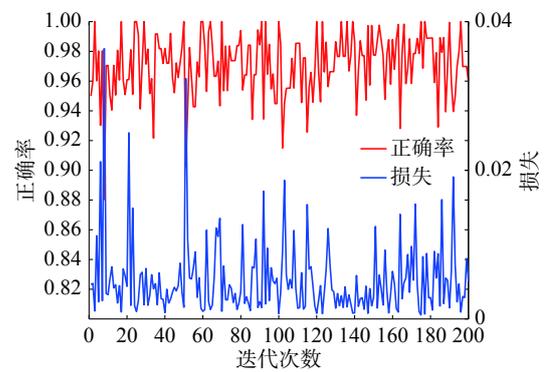


图 9 20-way 5-shot 测试正确率和损失函数值  
Fig. 9 Test accuracy and loss of 20-way 5-shot

图 10~12 是以 20-way 1-shot 和 5-way 1-shot 为例, 反映了不同类别, 相同的训练样本数据集经过测试后的结果有着明显差距。当训练数据集样本数相同时, 随着训练样本类别的增加, 最终识别难度变大, 分类正确率下降。当样本类别达到 20, 训练样本只有一个时, 训练难度最大, 图 10 体现出 20-way 1-shot 收敛速度明显慢于 5-way 1-shot 条件下的收敛速度, 正确率也略微下降。结合图 7 以及表 1 中的平均正确率可以看出在难度最大的 20-way 1-shot 条件下, 样本在迭代 700 次之后收敛, 测试正确率达到 94.1%。

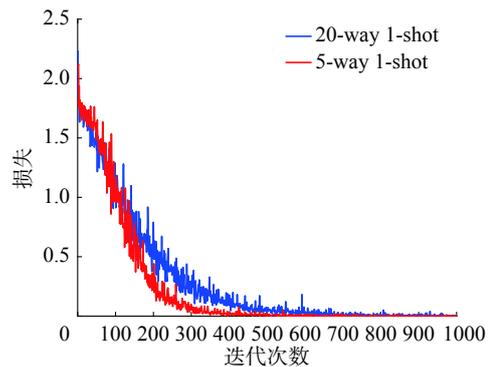


图 10 different-way 1-shot 训练损失函数值  
Fig. 10 Training loss of different-way 1-shot

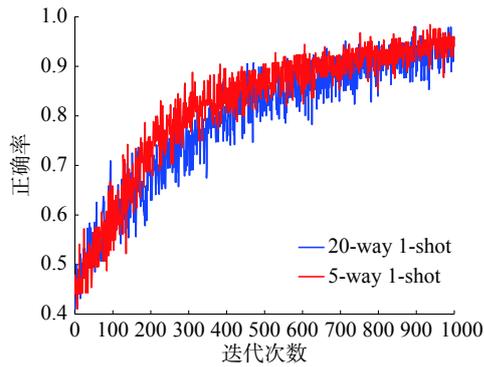


图 11 different-way 1-shot 训练正确率  
Fig. 11 Training accuracy of different-way 1-shot

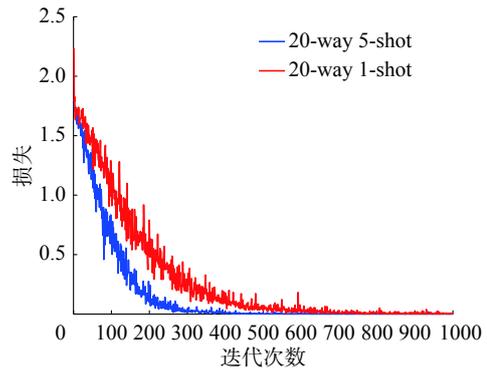


图 13 20-way different-shot 训练损失函数值  
Fig. 13 Training loss of 20-way different-shot

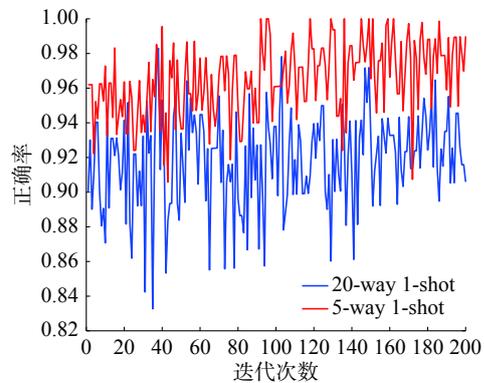


图 12 different-way 1-shot 测试正确率  
Fig. 12 Test accuracy of different-way 1-shot

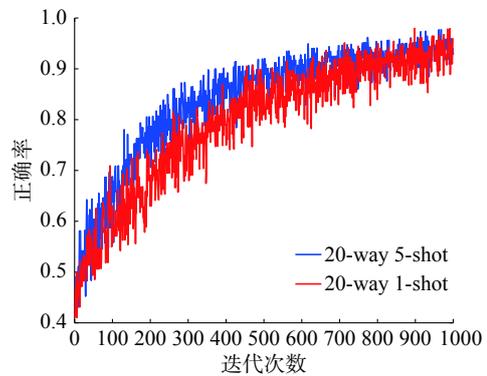


图 14 20-way different-shot 训练正确率  
Fig. 14 Training accuracy of 20-way different-shot

图 13~15 是以 20-way 5-shot 和 20-way 1-shot 为例,反映了相同类别,不同的训练样本数据集经过测试后的结果。当训练数据集样本数相同时,随着训练样本类别的增加,最终识别难度变大,分类正确率下降。结合表 1 中平均正确率的实验结果对比,与原始的 Siamese Net<sup>[25]</sup> 相比,在难度最高的 20-way 1-shot 情况下,孪生变分自编码器分类正确率提高了 5.9%,其他情况下最低提高了 0.3%,可以在说明本文所提出的混合模型的先进性。与 Lake 等<sup>[26]</sup> 提出的分层贝叶斯学习结构相比,孪生变分自编码器正确率低 0.9%,但是 Lake 的方法使用的不是原始图像的像素,而是 Omniglot 的笔画数据,虽然在 Omniglot 数据集上具有极高的分类正确率却失去了向其他数据集拓展的能力,本文所提出的模型与之相比具有更好的泛化能力。从 4 种条件下的损失函数结合表 2 中几个方法的训练时间对比,孪生变分自编码器可以很快速的收敛,在训练 1000 次后就达到了比较不错的分类效果。

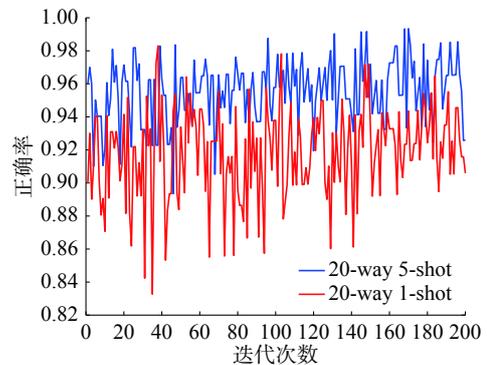


图 15 20-way different-shot 测试正确率  
Fig. 15 Test accuracy of 20-way different-shot

#### 4 结束语

针对小样本图像分类问题,本文提出了孪生变分自编码器网络模型。首先对训练样本数据使用变分自编码器进行降维处理,提取样本的隐含特征,然后通过孪生网络,对成对输入的两个样本进行相似度匹配,返回与待测样本标签为同类的样本类别以及正确率,完成物体的分类。通过 Omniglot 数据集对模型效果进行 4 组实验验证,本文提出的改进模型与原始孪生神经网络相比最

高提高了 5.9%, 平均提高 3.1%。

下一步工作将本文方法拓展应用到实际问题中。在电力设备故障诊断中, 只有很少的实际采集样本, 因此, 通常会额外生成模拟数据进行实验, 本文下一步工作即通过孪生变分自编码器在仅使用实际采集样本的情况下对故障类型进行分类。

## 参考文献:

- [1] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论 [J]. 智能系统学报, 2019, 14(1): 1–19.  
HU Yue, LUO Dongyang, HUA Kui, et al. Overview on deep learning[J]. CAAI transactions on intelligent systems, 2019, 14(1): 1–19.
- [2] 马世龙, 乌尼日其其格, 李小平. 大数据与深度学习综述 [J]. 智能系统学报, 2016, 11(6): 728–742.  
MA Shilong, WUNIRI Qiqige, LI Xiaoping. Deep learning with big data: state of the art and development[J]. CAAI transactions on intelligent systems, 2016, 11(6): 728–742.
- [3] 王昊, 刘高军, 段建勇, 等. 基于特征自学习的交通模式识别研究 [J]. 哈尔滨工程大学学报, 2019, 40(2): 354–358.  
WANG Hao, LIU GaoJun, DUAN Jianyong, et al. Transportation mode detection based on self-learning of features[J]. Journal of Harbin Engineering University, 2019, 40(2): 354–358.
- [4] 张程熠, 唐雅洁, 李永杰, 等. 适用于小样本的神经网络光伏预测方法 [J]. 电力自动化设备, 2017, 37(1): 101–106, 111.  
ZHANG Chengyi, TANG Yajie, LI Yongjie, et al. Photovoltaic power forecast based on neural network with a small number of samples[J]. Electric power automation Equipment, 2017, 37(1): 101–106, 111.
- [5] 洪雁飞, 魏本征, 刘川, 等. 基于深度学习的椎间孔狭窄自动多分级研究 [J]. 智能系统学报, 2019, 14(4): 1–9.  
HONG Feiyan, WEI Benzhen, LIU Chuan, et al. Deep learning based automatic multi-classification algorithm for intervertebral foramina stenosis[J]. CAAI transactions on intelligent systems, 2019, 14(4): 1–9.
- [6] 王翔, 胡学钢. 高维小样本分类问题中特征选择研究综述 [J]. 计算机应用, 2017, 37(9): 2433–2438, 2448.  
WANG Xiang, HU Xuegang. Overview on feature selection in high-dimensional and small-sample-size classification[J]. Journal of computer applications, 2017, 37(9): 2433–2438, 2448.
- [7] LI Feifei, FERGUS R, PERONA P. One-shot learning of object categories[J]. IEEE trans pattern anal mach intell, 2006, 28(4): 594–611.
- [8] LAKE B M, SALAKHUTDINOV R, TENENBAUM J B. Human-level concept learning through probabilistic program induction[J]. Science, 2015, 350(6266): 1332–1338.
- [9] 宋丽丽. 迁移度量学习行人再识别算法 [J]. 计算机工程与应用, 2019, 55(20): 170–176, 201.  
SONG Lili. Transfer metric learning for person re-identification[J]. Computer engineering and applications, 2019, 55(20): 170–176, 201.
- [10] 任俊, 胡晓峰, 朱丰. 基于深度学习特征迁移的装备体系效能预测 [J]. 系统工程与电子技术, 2017, 39(12): 2745–2749.  
REN Jun, HU Xiaofeng, ZHU Feng. Effectiveness prediction of weapon equipment system-of-systems based on deep learning feature transf[J]. Systems engineering and electronics, 2017, 39(12): 2745–2749.
- [11] 谭本东, 杨军, 赖秋频, 等. 基于改进 CGAN 的电力系统暂态稳定评估样本增强方法 [J]. 电力系统自动化, 2019, 43(1): 149–160.  
TAN Bendong, YANG Jun, LAI QiuPin, et al. Data augment method for power system transient stability assessment based on improved conditional generative adversarial network[J]. Automation of electric power systems, 2019, 43(1): 149–160.
- [12] 王建敏, 吴云洁. 基于聚类云模型的小样本数据可信度评估 [J]. 系统仿真学报, 2019, 31(7): 1263–1271.  
WANG Jianmin, WU Yunjie. Credibility evaluation method of small sample data based on cluster cloud model[J]. Journal of system simulation, 2019, 31(7): 1263–1271.
- [13] 杨懿男, 齐林海, 王红, 等. 基于生成对抗网络的小样本数据生成技术研究 [J]. 电力建设, 2019, 40(5): 71–77.  
YANG Yinan, QI Linhai, WANG Hong, et al. Research on generation technology of small sample data based on generative adversarial network[J]. Electric power construction, 2019, 40(5): 71–77.
- [14] 韩冬, 马进, 贺仁睦. 基于 Bootstrap 的实测负荷模型参数优选 [J]. 电工技术学报, 2012, 27(8): 141–146.  
HAN Dong, MA Jin, HE Renmu. Parameter optimization of measurement-based load model based on bootstrap[J]. Transactions of China electrotechnical society, 2012, 27(8): 141–146.
- [15] 马晓, 张番栋, 封举富. 基于深度学习特征的稀疏表示的人脸识别方法 [J]. 智能系统学报, 2016, 11(3): 279–286.  
MA Xiao, ZHANG Fandong, FENG Jufu. Sparse representation via deep learning features based face recognition method[J]. Transactions of China electrotechnical society, 2016, 11(3): 279–286.
- [16] 马忠丽, 刘权勇, 武凌云, 等. 一种基于联合表示的图像

- 分类方法 [J]. 智能系统学报, 2018, 13(2): 220–226.
- MA Zhongli, LIU Quanyong, WU Lingyu, et al. Syncretic representation method for image classification[J]. CAAI transactions on intelligent systems, 2018, 13(2): 220–226.
- [17] 赵春晖, 齐滨, Eunseog Youn. 基于蒙特卡罗特征降维算法的小样本高光谱图像分类 [J]. 红外与毫米波学报, 2013, 32(1): 62–67.
- ZHAO Chun Hui, QI Bin, EUNSEOG Youn. Hyperspectral image classification based on Monte Carlo feature reduction method[J]. *Journal of infrared and millimeter waves*, 2013, 32(1): 62–67.
- [18] CHOPRA S, HADSELL R, LECUN Y. Learning a similarity metric discriminatively, with application to face verification[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, USA, 2005: 539–546.
- [19] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]// Proc of the ICML Deep Learning Workshop, Lille, France 2015.
- [20] KINGMA D P, WELING M. Auto-encoding variational bayes[C]//International Conference on Learning Representations, [S.l.], 2014.
- [21] LIU Guojun, LIUYang, GUO Maozu, et al. Variational inference with Gaussian mixture model and householder flow[J]. *Neural networks*, 2019, 109: 43–55.
- [22] 宋辉, 代杰杰, 张卫东, 等. 基于变分贝叶斯自编码器的局部放电数据匹配方法 [J]. 中国电机工程学报, 2018, 38(19): 5869–5877, 5945.
- SONG Hui, DAI Jiejie, ZHANG Weidong, et al. A data matching method of partial discharge data based on auto-encoding variational Bayes[J]. *Proceedings of the CSEE*, 2018, 38(19): 5869–5877, 5945.
- [23] Lu Guangquan, Zhao Xishun, Yin Jian, et al. Multi-task learning using variational auto-Encoder for sentiment classification[J]. *Pattern recognition letters*, 2018.
- [24] ZAKHAROV N, SU H, ZHU J, et al. Towards controllable image descriptions with semi-supervised VAE[J]. *Journal of visual communication and image representation*, 2019, 63: 102574.
- [25] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning [C]// Proc of the Advances in Neural Information Processing Systems, 2016: 3630–3638
- [26] LAKE B M, SALAKHUTDINOV R, TENENBAUM J B. One-shot learning by inverting a compositional causal process[C]// International Conference on Neural Information Processing Systems. Curran Associates Inc 2013.
- [27] ZHANG Ling, LIU Jun, LUO Minnan, et al. Hauptmann, Scheduled sampling for one-shot learning via matching network[J]. *Pattern Recognition*, 2019, 96: 106962.

#### 作者简介:



王德文, 副教授, 博士, 主要研究方向为人工智能与大数据。发表学术论文 60 余篇。



魏波涛, 硕士研究生, 主要研究方向为人工智能与图像处理。