

基于堆叠自编码网络与全连接层网络的手写数字识别算法的研究

查 帅

成都理工大学数理学院, 四川 成都

收稿日期: 2023年1月5日; 录用日期: 2023年2月6日; 发布日期: 2023年2月14日

摘 要

本文基于深度学习堆叠自编码网络与全连接层进行了手写数字的识别的算法研究, 堆叠自编码神经网络能够挖掘数据内部信息, 提取有效特征; 全连接层进行分类预测。在MINIST数据集和大学生手写数字数据集中, 与传统机器学习方法SVM及随机森林相比取得了更好的结果达到了0.967的准确率。本文设计的算法为堆叠自编码网络应用前景提供了研究基础。

关键词

深度学习, 堆叠自编码网络, 手写数字识别, MINIST

Research on Handwritten Digit Recognition Algorithm Based on Stack Auto-Encoder Network and Full Connection Layer Network

Shuai Zha

College of Mathematics and Physics, Chengdu University of Technology, Chengdu Sichuan

Received: Jan. 5th, 2023; accepted: Feb. 6th, 2023; published: Feb. 14th, 2023

Abstract

In this paper, the recognition algorithm of handwritten numerals is studied based on deep learning stack Auto-Encoder neural network and full connection layer. The Auto-Encoder neural network can mine the internal information of data and extract effective features; all connection layers are classified for prediction. Compared with traditional machine learning methods such as

SVM and Random Forest, the MINIST dataset and college students' handwritten digit dataset have achieved better results with an accuracy of 0.967. The algorithm designed in this paper provides a research basis for the application prospect of stacked Auto-Encoder neural networks.

Keywords

Deep Learning, Stack Auto-Encoder Neural Network, Handwritten Digit Recognition, MINIST

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

深度学习在很多领域引起了广泛的关注，并在传统的识别任务中取得了不错的效果[1]。基于多个隐藏层，深度学习可以很好地实现复杂高维函数的表示，因此具有强大的表示能力[2] [3] [4]，并且具有其他算法没有的优点。堆叠自编码网络(SAE)是深度学习中最重要模型之一[5]，可以从输入数据自动提取特征[6]，近几年，刘康等人并利用堆叠降噪自编码器(SDAE)解决数据噪声大、过拟合等问题，提高力学性能预测精度完成了航空发动机剩余寿命的预测[7]，李卫星等人实现发动机故障诊断与性能衰退评估[8]，潘蕾等人使用 SAE 网络提高化合物成药性预测的精准度[9]。以上例子说明了自编码网络算法在解决相关问题的能力，若能应用于生活之中，例如，如果能对学生的日常作业及试卷做出高质量的自动识别，做到线上自动批阅或者判分，那么将大大提高教师的工作效率和质量。因此本文构建了堆叠自编码网络与全连接层网络算法对手写数字识别进行实验讨论其可行性。

对手写数字识别问题，本文使用了基于堆叠自编码网络的无监督特征提取方法。它以自编码网络为基本单元，采用逐层贪心训练算法构建分层自编码网络模型，增强了网络的功能表达能力，使得网络模型可以从输入数据中自动提取特征来获得更好的效果，最后通过与 softmax 层连接实现对手写数字的识别。

本文分成三个部分，第一部分介绍网络模型与分析网络结构，第二部分进行手写数字识别实验并调参，第三部分与传统机器学习模型识别效果进行了比较。

2. 自编码神经网络

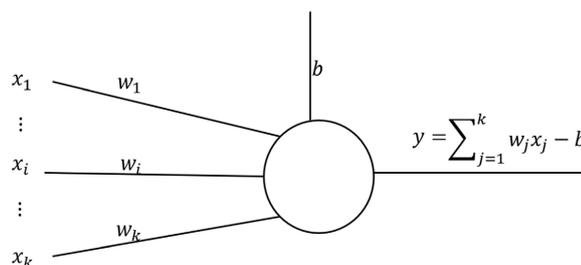


Figure 1. Schematic diagram of neuron structure

图 1. 神经元结构示意图

自编码神经网络是 BP 神经网络的一种特殊形式，基于若干神经元组成，如图 1 所示。自编码网络隐层神经元个数比输入输出节点数少，网络的输入数据与训练时输出数据的逼近目标都是同一组数据“见

图 2”。通过减小网络输出数据与目标数据的误差来训练模型。数据通过网络输入层经过降维把数据编码到维度更低的隐层(隐藏层),从而去除数据中的冗余信息,提取能表征原始数据间关系的特征,再从隐层到输出层进行解码恢复到原始数据空间[10]。

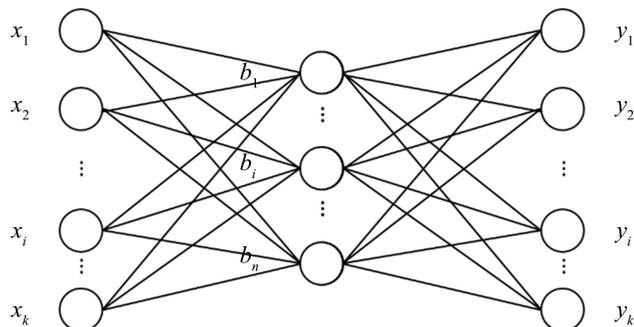


Figure 2. Schematic diagram of the structure of the self-encoder neural network

图 2. 自编码神经网络结构示意图

编码函数定义为

$$h = f_1(W^{(1)}\tilde{x}) + b^{(1)} \quad (1)$$

式(1), f_1 表示编码激活函数, $W^{(1)}$ 表示连接输入层与隐含层的权重; $b^{(1)}$ 表示输入层的偏置项。解码函数定义为

$$\hat{x} = f_2(W^{(2)}\tilde{x}) + b^{(2)} \quad (2)$$

式(2)中, f_2 表示解码激活函数, $W^{(2)}$ 表示连接隐含层与输出层的权重; $b^{(2)}$ 表示隐含层的偏置项。

由式(1)和式(2)可知, AE 的输出 \hat{x} 可表示为

$$\hat{x} = \hat{h}_{w,b}(x) = f_2\left\{W^{(2)}\left[f_1\left(W^{(1)}\tilde{x}\right) + b^{(1)}\right]\right\} + b^{(2)} \quad (3)$$

(3)式中, $\hat{h}_{w,b}$ 为输入数据的重构函数。

对于一个含有 m 个样本的样本集 $\{x_1, x_2, \dots, x_m\}$ 采用的 AE 目标函数

$$J(w, b; x) = \frac{1}{m} \sum_{i=1}^m \|h_{w,b}(\tilde{x}_i) - x_i\|^2 \quad (4)$$

2.1. 深度自编码网络

深度自编码(DAE)网络是由多个浅层自编码网络(AE)或其变形网络堆叠而成,以上述 AE 作为基本结构单元,在编码器和解码器中增加隐层数量而构成。输入层和输出层的神经元个数相同,均为数据的维数。用编码器的输出作为新特征向量代替原始特征向量输入到解码器(回归模型)中,可以大幅度提高模型预测的准确度。本文 DAE 采用的目标函数为

$$J(w, b; x) = \lambda_1 \frac{1}{m} \sum_{i=1}^m \|\hat{h}_{w,b}(\tilde{x}_i) - x_i\|^2 + \lambda_2 \frac{1}{m} \sum_{i=1}^m \|h_{w,b}(\tilde{x}_i) - x_i\|^2 \quad (5)$$

式中 λ_1 和 λ_2 分别为自编码和解码过程损失函数的权重系数, $h_{w,b}$ 为自编码网络输出。网络结构如图 3。

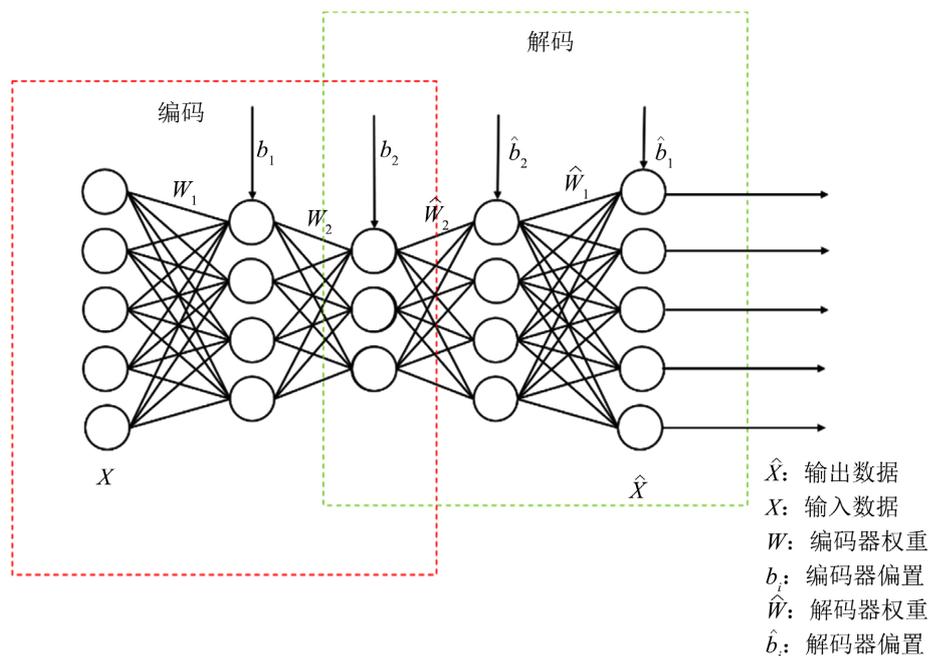


Figure 3. DAE network structure diagram
图 3. DAE 网络结构图

2.2. 堆叠自编码网络

堆叠自编码网络(SAE)是由多层 AE 堆叠构成的层级深度神经网络,是一种基于逐层贪婪的无监督学习方法。SAE 网络在预训练时第 1 层 AE 通过最小化重构误差将 X 维的原始输入数据映射到第 1 个含有 n_1 个神经元的隐藏层,得到 n_1 维的 X' ,即训练 $X-X'-X$ 这个自编码器,训练结束后保留编码层的权重和偏差;以编码层得到的 n_1 维的特征向量 X' 作为输入向量,再训练一个 $X'-X''-X'$ 的自编码器,然后保留第 2 层 AE 的网络参数;以第 2 层 AE 编码得到的特征向量 X' 再作为下一层的输入向量,训练第 3 层的 AE,……,以此类推,通过最小化输入和输出信号的重构误差来完成对输入数据的层层压缩,实现对输入数据的特征提取。通过这种方式,对整个 SAE 网络进行逐层预训练直到得到最后一个 AE 层,保存每一个 AE 的编码器参数,并将每个编码层串联起来形成预训练过的 SAE 模型,该 SAE 模型可以对化合物原始结构信息进行表征学习和降维。

3. 实验数据

本文使用 MNIST 数据集和大学生手写数字数据集[11],MNIST 数据集它是机器学习领域的一个经典数据集。MNIST 每个样本都是一张 28×28 像素的灰度手写数字图片,且每个样本都对应着一个唯一的标签。大学生手写数字数据集的像素尺寸有差别,我们预处理后让它的尺寸也为 28×28 像素。数据集包含 60,000 张训练图像和 10,000 张测试图像,本文使用 10,000 张图片做训练其中 10%拿来验证集,5000 张 MNIST 和大学生手写数字数据集图片做预测验证。

4. 模型算法构建与训练

采用堆叠自编码器 SAE 算法,首先构建了特征提取网络;之后将具有 10 个神经元的分类器连接到 SAE 网络上,最终构成预测手写数字十分类网络,网络结构见图 3。其中,隐藏层一共 2 层,第 1 层神经元数为 100,第 2 层神经元节点数为 50。详情见图 4。

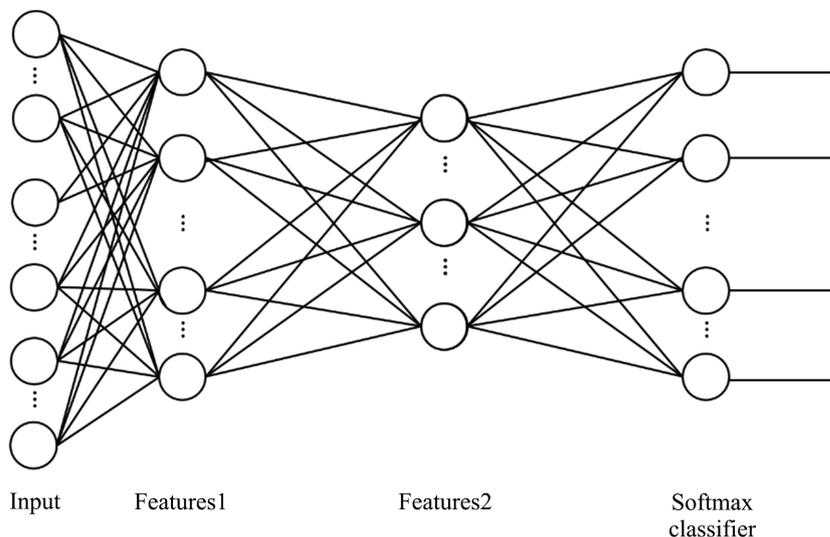


Figure 4. A schematic diagram of the model network structure
图 4. 模型网络结构示意图

模型训练分为 2 步：第一，逐层对 SAE 特征提取网络进行训练；第二接入 BP 神经网络也就是(分类层)，将 SAE 训练得到的权重和偏差作为网络的初始化参数，并通过反向传播对整个网络进行微调，通过最小化目标变量的预测误差来获得改进的权重，直至模型稳定收敛。

模型训练过程包含了网络层数，节点数，激活函数，优化器，学习率以及 batchsizes 等，具体超参数设置如下表 1。

Table 1. SAE hyperparameter setting table
表 1. SAE 超参数设置表

SAE 超参数设置表	
超参数	设置
Kernel_initializer	Glorot_uniform
Number of hidden layer nodes	100, 50
Dropout	0.1
Activation	Relu
Learning rate	0.001
Optimizer	Adam
Batchsize	20
Loss function	Mean squared error

初始化函数使用默认产生正态分布随机数；特征提取网络共有 2 个隐藏层，节点数为 100 和 50；在输入层使用 0.1 的防止过拟合；用 sigmoid 作为激活函数；Batchsize 设为 20；优化器采用 Adam 对模型进行训练并且学习率设置为 0.001，利用梯度下降算法和梯度反向传播得参数进行更新，直至模型收敛。

训练分类模型时，特征提取层使用 SAE 训练的参数值；分类层节点数设为 10；激活函数采用分类函数 softmax；损失函数设为 crossentropy。

由图 5 可知，在 20 个 epoch 之前下降，在 20 个 epoch 之后训在一定范围内波动；在验证集中，二元交叉熵损失函数在 20 个 epoch 之前逐渐下降，在 30 个 epoch 之后在较小范围内波动趋近平稳；训练集上的准确率在 20 epoch 之前逐渐上升之后趋于平缓；验证集的准确率在 20 个 epoch 之前逐渐上升，20 个 epoch 之后也趋于平缓。这说明此模型在第 20 个 epoch 时候收敛。

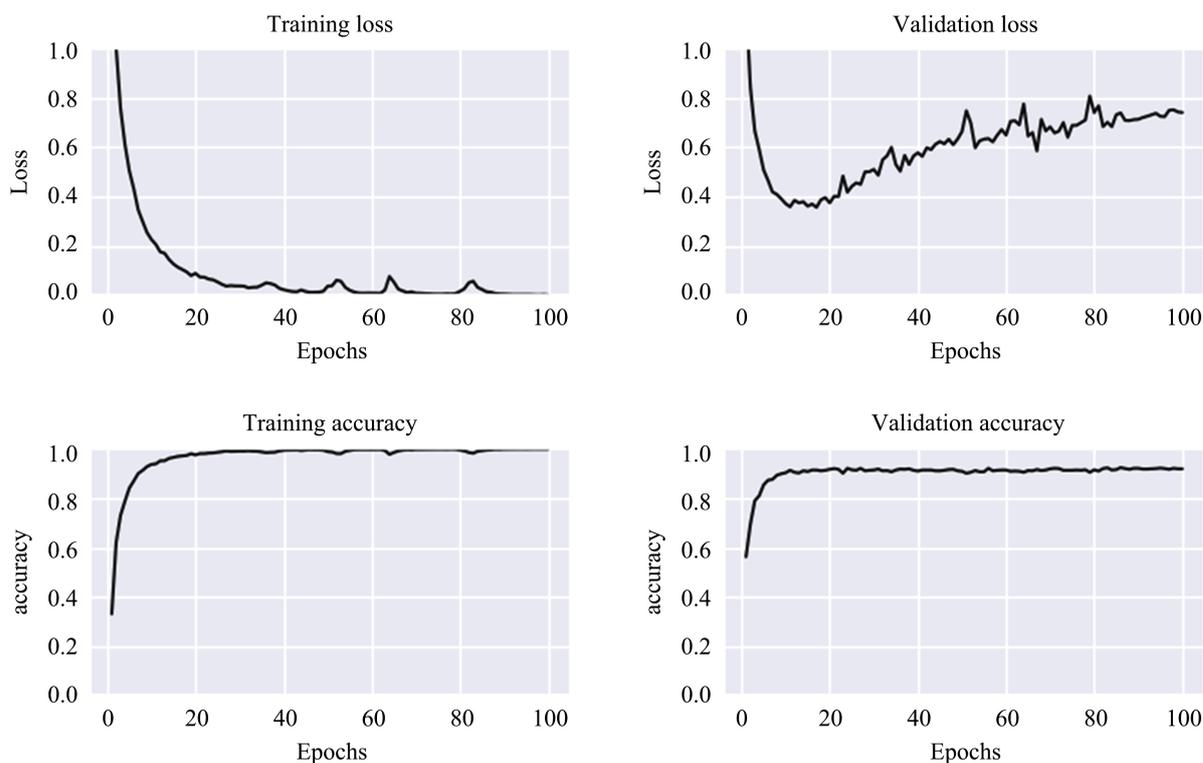


Figure 5. Training graph

图 5. 训练图

5. 实验结果与分析

实验在测试集上准确率为 0.967，与传统机器学习 SVM 准确率为 0.902，随机森林准确率为 0.932。可以看出 SAE 分类网络在手写数字识别上是优于传统机器学习方法的。具体表 2 如下。

Table 2. The comparison of the accuracy rate of the test set model

表 2. 测试集模型正确率对比

测试集模型正确率对比	
模型	准确率
SAE 分类网络	0.967
SVM	0.902
随机森林	0.932

6. 结束语

文中基于堆叠自编码神经网络与全连接层(softmax)结合进行了手写数字的识别。堆叠自编码神经网络是一种深度学习模型,它能够充分挖掘数据内部信息,提取有效特征,排除无关数据。此模型在 MNIST 数据集和大学生手写数字上取得了不错的效果,说明此方法的可行性。由于网络结构深度没有特别深,正确率只有相对高的 0.967,若对网络结构进行调整与改进,网络参数进行优化相信其分类预测正确率会更高。这说明堆叠自编码神经网络与全连接层结合的深度学习网络算法应用到数字识别可行性,此外除了对数字的识别,此深度学习算法能通过微调网络结构等方式可用在其他领域。比如目标检测,异常识别等领域等。相信随着时间推移的和愈多的科研人员的努力,此算法能在更多领域发挥作用。

参考文献

- [1] 杨轲. 基于深度学习算法的计算机网络安全技术研究[J]. 电脑编程技巧与维护, 2022(10): 163-166.
- [2] 宋玥. 基于深度学习的多策略肺结节检测与分类算法研究[D]: [硕士学位论文]. 太原: 中北大学, 2022.
- [3] 聂振业. 融合 HowNet 的深度学习文本分类方法研究[D]: [硕士学位论文]. 沈阳: 辽宁大学, 2022.
- [4] 侯文擎, 叶鸣, 李巍华. 基于改进堆叠降噪自编码的滚动轴承故障分类[J]. 机械工程学报, 2018, 54(7): 87-96.
- [5] 蔺素珍, 韩泽. 基于深度堆叠卷积神经网络的图像融合[J]. 计算机学报, 2017, 40(11): 2506-2518.
- [6] 栾迪, 周广证. 基于 LSTM 和注意力机制的 Minist 手写数字识别算法设计[J]. 电子元器件与信息技术, 2021, 5(9): 140-141+156.
- [7] 刘康, 肖娜. 基于堆叠稀疏自编码神经网络的航空发动机剩余寿命预测方法研究[J]. 计算机测量与控制, 2019, 27(12): 29-33+38.
- [8] 李卫星. 发动机故障诊断及性能预测方法研究[D]: [硕士学位论文]. 上海: 上海交通大学, 2019.
- [9] 潘蕾, 倪冰苇, 赵鸿萍. 融合堆叠自编码神经网络算法和全连接神经网络算法的化合物成药性预测模型[J]. 中国新药杂志, 2021, 30(14): 1309-1315.
- [10] 程先琼, 蒋科植. 基于深度降噪自编码神经网络的中国大陆地壳厚度反演[J]. 地震学报, 2021, 43(1): 34-47+136.
- [11] 宋晓茹, 吴雪, 高嵩, 陈超波. 基于深度神经网络的手写数字识别模拟研究[J]. 科学技术与工程, 2019, 19(5): 193-196.