

基于 5G 与 CNN 的智能电网稳定性预测^①



吕超¹, 朱雪阳¹, 丁忠林¹, 丁仪², 朱秋阳²

¹(南京南瑞信息通信科技有限公司, 南京 211106)

²(南京邮电大学 通信与信息工程学院, 南京 210003)

通讯作者: 吕超, E-mail: nryqc12138@163.com

摘要: 随着 5G 通信技术的研究以及新型基础设施的建设, 智能电网得到了快速发展. 同时, 在大数据时代, 万物互联导致海量的设备接入电力网络, 也给智能电网带来了较大的负担, 电力网络的稳定性问题亟待解决. 因此, 本文提出了一种基于 CNN 的智能电网稳定性预测算法, 通过收集电力网络产生的数据, 经过 CNN 模型的处理, 最后输出智能电网稳定性的判别结果. 经过仿真验证, 该算法与 SVM、AdaBoost、随机森林相比, 具有较高的准确率; 同时, 本文采用了 4 种不同的优化算法去改善 CNN 模型, 带有动量的 SGD 算法可以达到 98.13% 预测准确度, 利用该模型可以有效帮助电力系统对未知的问题提前预警, 降低了安全隐患并减少了电力事故的发生.

关键词: 5G; 智能电网; 稳定性; 卷积神经网络; 优化算法

引用格式: 吕超, 朱雪阳, 丁忠林, 丁仪, 朱秋阳. 基于 5G 与 CNN 的智能电网稳定性预测. 计算机系统应用, 2021, 30(7): 158-164. <http://www.c-s-a.org.cn/1003-3254/8026.html>

Stability Prediction of Smart Grid Based on 5G and CNN

LYU Chao¹, ZHU Xue-Yang¹, DING Zhong-Lin¹, DING Yi², ZHU Qiu-Yang²

¹(NARI Information & Communication Technology Co. Ltd., Nanjing 211106, China)

²(College of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: The research on 5G communication technology and the construction of new infrastructure has witnessed the rapid development of the smart grid. In the era of big data, the Internet of everything leads to the access of massive equipment to the power network, which also brings a great burden to the smart grid, and the stability problem of the power network is urgent to be solved. Therefore, we propose a prediction algorithm for smart grid stability based on Convolutional Neural Network (CNN). It collects the data generated by the power network, processes them in the CNN model, and finally outputs the judgment results of smart grid stability. The simulation results show that the algorithm has higher accuracy than SVM, AdaBoost, and random forest. Furthermore, four different optimization algorithms are used to improve the CNN model. SGD algorithm with momentum can achieve a prediction accuracy of 98.13%. The proposed model can effectively help the power system to pre-warn the unknown problems, reducing the security risks and power accidents.

Key words: 5G; smart grid; stability; Convolutional Neural Network (CNN); optimization algorithm

① 基金项目: 江苏省 2019 年度第二批省级工业和信息化产业转型升级专项资金 (5246DR180077)

Foundation item: The Second Batch of Provincial Special Funds for Transformation and Upgrading of Industry and Information Industry in Jiangsu Province in Year 2019 (5246DR180077)

收稿时间: 2020-11-06; 修改时间: 2020-12-12; 采用时间: 2020-12-19; csa 在线出版时间: 2021-06-30

第5代移动通信技术(fifth-Generation, 5G)是继4G之后,为了满足智能终端的快速普及和移动互联网的高速发展而正在研发的下一代无线移动通信技术^[1]. 目前,国内外正在对5G移动通信技术进行研究^[2-5]. 5G不仅为我们带来了更好的宽带体验,也将对电力行业产生深远的影响^[6-10]. 其中,智能电网作为5G与电力行业交叉融合下的一项典型应用,正在快速发展^[11-13].

作为电力系统的一项重大创新,智能电网方便了电力系统的管理,在很大程度上能够提升电力系统的服务质量.但是,电力网络中的传感器及其他接入设备的增多,将给电力系统带来了较大的负担.为了向用户提供源源不断、质量合格的电能,要求电力系统具有很高的稳定性和可靠性^[14,15].

目前,很少有对智能电网稳定性预测的相关研究,但有许多针对电力系统稳定性分析的研究可供参考. 隐式梯形积分法是电力系统暂态稳定性分析中的最基本的数值计算方法之一,文献[16]通过采用隐式梯形积分法得出系统最大相对摇摆角曲线图,进而去判定系统的暂态稳定性. 文献[17]运用电力系统动态等值分析原理,以耦合特性分析为切入点研究电力系统稳定性分析方法,但该方法不能较好的适应于非线性系统. 文献[18]针对该问题,提出了一种适合非线性复变系统的综合动态等值法来评估电力网络的静态电压稳定性. 元件参数也是影响系统稳定性的重要因素之一,文献[19]综合运用摄动原理、轨迹灵敏度方法、参数灵敏度分析方法研究了同步发电机、调速器、励磁系统、主要输电线路和变压器等参数对电网暂态稳定性的影响. 除了以上的数值分析方法,文献[20]从动力学角度出发,将电力网络的非线性动力学方程和复杂网络相结合来研究电力网络的稳定性.

在5G时代,机器学习和深度学习赋予了这个社会“智能”,这些概念自提出以来就得到了广泛的关注,并且出现了多方面的应用. 文献[21]使用机器学习前沿算法XGBoost算法对电力系统暂态稳定性问题进行建模,并将模型输出进行概率化,以评估模型预测的可靠程度. 分布式智能电网(Decentralized Smart Grid, DSG)是针对存在弹性节点的电力网络所提出的新技术,陈旭等人为了分析DSG的系统稳定性,应用具有代表性的6种机器学习分类模型,结合电力系统安全性、稳定性、经济性3个方面的需求测试了各分类模型对

DSG系统稳定性预测的效果^[22],然而由于电力数据庞大且参数众多,简单的机器学习模型并不能满足对电力网络准确预测的要求. 因此,本文提出了一种基于卷积神经网络的智能电网稳定性预测算法,首先对从智能电网中采集到的数据进行处理,之后将其输入到CNN模型中,经过不断的迭代运算,最终得到一个电力网络稳定性预测模型. 经过仿真验证,该模型对于智能电网稳定性预测有较高的准确率.

1 基于CNN的智能电网稳定性预测

有关机器学习的各种算法例如决策树,随机森林,SVM(支持向量机),KNN(最近邻算法)在电力系统中都有广泛的应用. 在这些传统的机器学习算法上,虽然能够得到对电力网络稳定性的预测,但是需要耗费不小的精力去对特征进行处理,并且预测的准确度不够高. 本章将介绍一种基于CNN的智能电网稳定性预测的算法,该算法由两个卷积层,两个池化层以及两个全连接层构成,仿真验证了该算法有良好的准确率. 并且本文还比较了Adam^[23], RMSprop^[24]、SGD以及带有动量的SGD(MSGD)4种不同优化算法对于模型训练的影响^[25].

1.1 基于卷积神经网络的数学建模

本文采用的卷积神经网络的基本单位为神经元,神经元的结构模仿了人类脑部的神经系统,多个神经元相互连接而成一个神经网络. 一个基本的神经元由线性函数和激活函数两部分构成,神经元的一侧接收输入信号,经过线性函数的加权和加偏置处理,将结果输入至激活函数,之后由另一侧输出最终结果. 具有3个树突的单个神经元建模如图1所示.




图1 单个神经元建模图

神经元模型的公式为:

$$h = f\left(\sum_i w_i x_i + b\right) \quad (1)$$

其中, w_i 为线性函数的权重, b 为偏置单元.

接着, 需要通过损失函数来优化模型, 损失函数的定义如下:

$$L(w, b) = \frac{1}{n} \sum_{i=1}^n (h^{(i)} - y^{(i)})^2 \quad (2)$$

其中, n 为训练集的数量, $h^{(i)}$ 为预测的输出, $y^{(i)}$ 真实值.

单层的神经元构成的神经网络虽然简单, 但学习能力有限, 只能处理一些简单的线性分类任务, 具有很大的局限性. 而通过电力系统采集到的数据具有非线性和复杂的特点, 因此, 为了处理这些较为复杂的问题, 本章采用了引入非线性函数的 CNN 来进行智能电网稳定性的预测. 基于 CNN 的电力网络稳定性预测建模如图 2 所示.




图2 基于 CNN 的智能电网稳定性预测建模图

卷积神经网络的工作原理就是通过不断地迭代去更新线性函数的权重和偏置单元, 使得损失函数的值最小, 同时得到一个较高的分类准确度. CNN 具有参数共享和稀疏连接的功能, 这些功能模仿了生物视觉细胞只对局部视野或者特征敏感的特点.

基于 CNN 的智能电网稳定性预测模型通过卷积层自动提取与电网稳定性相关的 12 个特征, 再经过池化层对数据进行降维, 最后通过全连接层以及 Softmax 分类函数得到预测结果. 衡量 CNN 模型优劣的 Accuracy 值的范围在 0 到 1 之间, Loss 值一般也在 1 以下. Accuracy 值越低, Loss 值越高, 则代表该模型的预测结果较差, 反之则表明模型越优.

1.2 基于 CNN 的智能电网稳定性预测

除了分析电网系统维护人员的不良行为或者误触行为, 依据电网产生的数据对其稳定性预测也是有效减少电力事故, 提高电力系统安全性的有效方法. 因此, 本文提出了基于 CNN 的智能电网稳定性预测模型, 该模型采用了 kaggle 上来自国外某电网系统采集到的 68000 个数据.

对于数据集, 由于各个特征值的范围不同, 因此需要对数据进行预处理. 预处理的目的是将数据的大小归一到一个统一的尺度内, 加快模型的训练速度, 提高分类精度. 数据预处理的方式通常有两种: 一种是标准化, 另一种是归一化. 归一化方法容易受到数据集结构不均衡的影响, 因此在这里采用标准化对数据进行预处理. 处理的步骤如下: 首先求取各个特征的数学期望

$E(X_i)$ 和标准差 S_i , 然后根据以下公式得到标准化值:

$$Z_{ij} = \frac{X_{ij} - E(X_i)}{S_i} \quad (3)$$

其中, X_{ij} 是数据第 i 个特征的第 j 个值, $E(X_i)$ 为第 i 个特征的均值, S_i 为第 i 个特征的标准差.

CNN 模型会自动提取电力网络中参与者的反应时间, 标准功率, 价格系数等 12 个特征, 并对其进行标准化, 为了能够将数据输入 CNN 模型中, 需要调整数据结构将其转化为与 CNN 输入矩阵大小一致的特征矩阵.

本节首先将经过标准化处理电力网络数据集后得到的 12 个特征转化为矩阵, 并输入 CNN 模型进行特征的提取. 其中, CNN 模型中卷积层的权重更新如下:

(1) 首先, 需要定义误差函数, 公式如下:

$$C^N = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^K (y_k^n - p_k^n)^2 \quad (4)$$

其中, N 是样本的个数, K 是样本的类别 (即样本被分 K 类), y_k^n 表示第 n 个样本 y_k 的第 k 维, p_k^n 是第 n 个样本 p_k 网络输出的第 k 维.

最小化式 (4) 中的 C 可更新网络的权值, 使得 CNN 模型的输出预测值更加接近真实值.

(2) 其次, 定义卷积层第 l 层的输出 x_j^l 为:

$$x_j^l = f \left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (5)$$

其中, x_j^l 表示第 l 层的第 j 个特征, f 是 CNN 的激活函数, M_j 表示输入数据的特征矩阵, k_{ij}^l 为 l 层中连接输入的第 i 类特征和输出的第 j 类特征的卷积核, b_j^l 则为 l 层中 j 特征对应的偏置参数。

(3) 误差灵敏度 δ_j^l 可表示为:

$$\delta_j^l = \beta_j^{l+1} (f'(\mu_j^l) up(\delta_j^{l+1})) \quad (6)$$

其中, $\mu_j^l = w^l x_j^{l-1} + b^l$, w 是权重, b 为偏置单元. l 层是卷积层, $l+1$ 是池化层, up 是使 $l+1$ 层的矩阵的尺寸与 l 层的尺寸保持一致的上采样操作, β_j 是卷积核 k_{ij}^l 中的值。

(4) 接下来求误差函数对偏置 b_j^l 和卷积核 k_{ij}^l 的偏导:

$$\frac{\partial E}{\partial b_i} = \sum_{u,v} (\delta_j^l)_{u,v} \quad (7)$$

$$\frac{\partial E}{\partial k_{ij}^l} = \sum_{u,v} (\delta_j^l)_{u,v} (q_i^{l-1})_{u,v} \quad (8)$$

式 (7)、式 (8) 是对 l 层中所有的误差灵敏度进行求和, (u,v) 是灵敏度矩阵中各元素的位置。

CNN 模型中池化层的权值更新如下:

(1) 池化层的第 l 层的输出 x_j^l 可被定义为:

$$x_j^l = f(\text{down}(x_j^{l-1}) + b_j^k) \quad (9)$$

其中, f 是激活函数, down 是下采样操作, b_j^k 为偏置。

(2) 令 $\mu_j^l = w^l x_j^{l-1} + b^l$, 误差灵敏度 δ_j^l 可表示为

$$\delta_j^l = \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_{ij}^{l+1}), \text{full}^l) f'(u_j^l) \quad (10)$$

池化层中误差函数 C 对偏置 b_j 的偏导等于卷积层中误差函数 E 对偏置 b_j 的偏导。

在神经网络中, 常用的非线性激活函数有 Sigmoid 函数、ReLU 函数、tanh 函数等, 其中 Sigmoid 函数和 tanh 函数随着自变量 x 的增加, 其梯度会越来越小, 趋近于 0, 这将导致迭代过程中权重的值更新缓慢, 因此, 为了解决梯度消失这个现象, 在 CNN 模型中采用 ReLU 函数作为激活单元. ReLU 函数在 $x > 0$ 时梯度恒为 1, 在 $x < 0$ 时恒为 0, 结构简单并且计算成本较低, 速度较快, 为 CNN 模型的快速收敛提供了保障。

激活单元 ReLU 函数的定义为:

$$f(x) = \max(0, x) \quad (11)$$

在 CNN 模型中, 不同的优化算法对电力网络稳定性预测的准确度不同, 并且不同的优化算法的收敛速度也不一致. 因此, 为了找到一个适合此模型的最优化

算法以及比较不同优化算法之间的差异, 本文分别采用了 Adam^[23], RMSprop^[24]、SGD 以及带有动量的 SGD (MSGD) 4 种不同优化算法对 CNN 模型进行优化^[25]。

SGD 算法即随机梯度下降算法, 它可以加快收敛的速度, 使 Loss 函数收敛到更小的最小值, 然而, 由于更新的频率比较快, SGD 会产生梯度震荡, 导致收敛不稳定. 因此, 本文采用了加有动量的 SGD 算法对权重 w 和偏置 b 进行更新, 带有动量的 SGD 会在前一步的累计梯度上有一个跳跃, 之后加入了一个修正单元对其进行修正, 更新公式如下:

$$v_{dw} = \beta v_{dw} + (1 - \beta) dw \quad (12)$$

$$v_{db} = \beta v_{db} + (1 - \beta) db \quad (13)$$

$$w = w - \alpha v_{dw} \quad (14)$$

$$b = b - \alpha v_{db} \quad (15)$$

其中, β 为超参数, 取值 0.9 左右, α 是学习速率, 取值 0.01 左右。

RMSprop 优化算法采用指数加权平均, 旨在消除梯度下降中的摆动, 如果在某一处梯度值比较大, 则指数加权平均的结果就大, 反之则小, 以此来保证不同维度的梯度值都处在同一范围, 进而提高的稳定性. 它的更新公式如下:

$$s_{dw} = \beta s_{dw} + (1 - \beta) dw^2 \quad (16)$$

$$s_{db} = \beta s_{db} + (1 - \beta) db^2 \quad (17)$$

$$w = w - \alpha \frac{dw}{\sqrt{s_{dw} + \epsilon}} \quad (18)$$

$$b = b - \alpha \frac{db}{\sqrt{s_{db} + \epsilon}} \quad (19)$$

其中, β 为超参数, 取值 0.9 左右, α 是学习速率, 取值 0.01 左右, ϵ 是一个偏差修正单元, 取值一般为 10^{-8} 。

Adam 结合了 Momentum 梯度下降法和 RMSprop 算法, 它能加快模型的学习速度. Adam 算法的参数更新公式如下:

$$v_{dw} = \beta_1 v_{dw} + (1 - \beta_1) dw \quad (20)$$

$$v_{db} = \beta_1 v_{db} + (1 - \beta_1) db \quad (21)$$

$$s_{dw} = \beta_2 s_{dw} + (1 - \beta_2) dw^2 \quad (22)$$

$$s_{db} = \beta_2 s_{db} + (1 - \beta_2) db^2 \quad (23)$$

其中, β_1 和 β_2 为梯度累计的指数, 是两个超参数, 在一般情况下 β_1 取值 0.9, β_2 取值 0.999, dw 和 bd 是在一次

batch 上, 损失函数 L 关于权重 w 和偏置 b 的梯度值; v_{dw} 和 v_{db} 是算法在前 $t-1$ 次迭代过程中的累计的梯度动量, 同样的, s_{dw} 和 s_{db} 也是算法前 $t-1$ 次迭代过程中的累计的梯度动量。

算法在前期的迭代中会出现不小的偏差, 为了解决这个问题, 在公式中加入了偏差修正:

$$V_{dw}^c = \frac{v_{dw}}{(1-\beta_1^t)} \quad (24)$$

$$V_{db}^c = \frac{v_{db}}{(1-\beta_1^t)} \quad (25)$$

$$S_{dw}^c = \frac{s_{dw}}{(1-\beta_2^t)} \quad (26)$$

$$S_{db}^c = \frac{s_{db}}{(1-\beta_2^t)} \quad (27)$$

加入偏差修正之后, 即可对权重和偏置进行更新, 公式如下:

$$w = w - \alpha \frac{V_{dw}^c}{\sqrt{S_{dw}^c + \epsilon}} \quad (28)$$

$$b = b - \alpha \frac{V_{db}^c}{\sqrt{S_{db}^c + \epsilon}} \quad (29)$$

其中, α 为学习速率, 在训练过程中可以通过微调学习速率来优化权重的更新速度, ϵ 为超参数, 取值通常为 10^{-8} 。

在智能电网稳定性预测算法中, CNN 模型中的权重 w 和偏置 b 在一次次迭代过程中不断被更新, CNN 算法通过不断地迭代, 去更新权重 w 和偏置 b , 使得 Loss 函数无限逼近一个趋近于 0 的极小值, 同时 Accuracy 函数会不断增大, 表明模型的预测效果在不断地迭代中变得越来越好。

2 结果及分析

本文提出了一种基于 CNN 的智能电网稳定性预测算法, 采用了 kaggle 上来自国外某电力系统的数据, 该数据包含 60 000 个样本, 它含有每个网络参与者的反应时间、每个网络参与者产生 (正) 或消耗 (负) 的标准功率、每个网络参与者的价格弹性系数等 12 个特征。

为评价基于 CNN 的智能电网稳定性预测模型的训练效果, 本节利用相同的数据集进行了 Loss 函数和

Accuracy 函数的仿真, 并对比了 SVM、AdaBoost, 随机森林 3 种不同的算法, 如图 3 和图 4 所示。

从图 3、图 4 可以看出, 本文提出的算法与 SVM、AdaBoost, 随机森林相比, 有着较高的准确率。图 3 表明, 随着数据量的增大, 算法的准确度不断提高, 并且 CNN 算法的准确度要远远高于其余 3 种算法; 图 4 表明, 损失函数随着数据量的增大而不断减小且逐渐趋于稳定, CNN 算法的损失函数始终处于最低水平。因此, 可以认为 CNN 算法可以更好地为智能电网的稳定性作出预测。

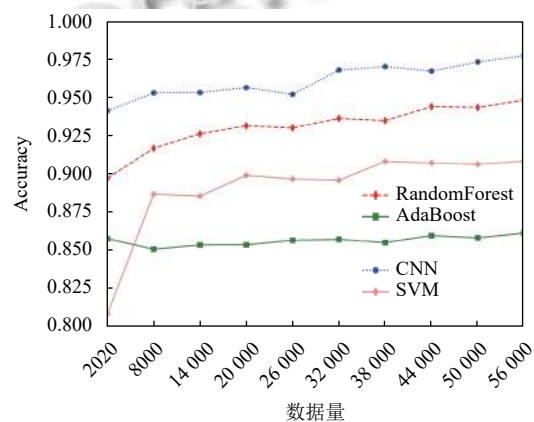


图 3 不同模型准确度比较

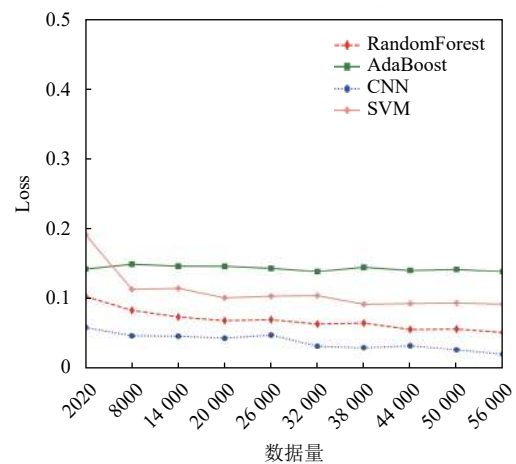


图 4 不同模型损失函数比较

本文还比较了 Adam^[23], RMSprop^[24]、SGD 以及带有动量的 SGD(MSGD)4 种不同优化算法对于 CNN 模型训练的影响^[25], 如图 5 和图 6 所示。

从图 5、图 6 可以看出, CNN 模型的 Accuracy 值与训练集的数量成正相关, Loss 的值与训练集的数量之间成负相关, 并且随着智能电网数据集的增加, 该模

型的 Loss 值和 Accuracy 值逐渐趋于平稳. 图 5 表明, 在相同的数据集下, MSGD 算法的准确度 > Adam > RMSprop > SGD, 且随着数据集的增大, SGD 算法的准确度逐渐趋于稳定且始终大于其余 3 种算法. 图 6 表明, 4 种优化算法的损失函数都随着数据量的增大而减小并趋于稳定, 且 MSGD 算法的损失函数始终小于其他 3 种算法. 这说明了, 带有动量的 SGD 算法比 RMSprop、Adam、SGD 算法有更好的训练效果.




图 5 准确度和训练集数量的关系

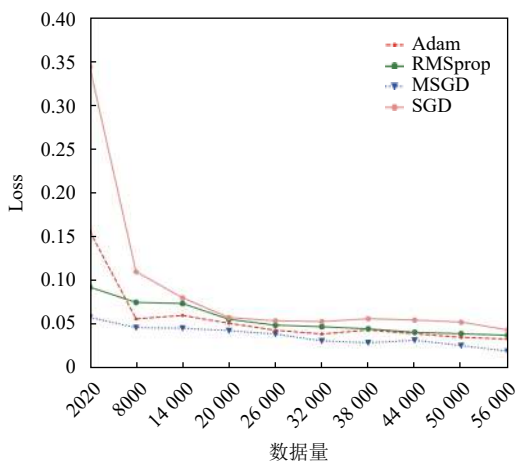


图 6 损失函数和训练集数量的关系

图 7、图 8 表明, CNN 模型的 Loss 值与迭代次数成负相关, Accuracy 值与迭代次数成正相关. 从图 7 可以看出, 算法的准确度: MSGD > Adam > RMSprop > SGD, 并且随着迭代次数的增加, 准确度不断提高. 从图 8 可以看出, 随着迭代次数的增加, 四种优化算法的损失函数都逐渐下降, 且 MSGD 算法的损失函数始终低于其他 3 种算法. 这表明 MSGD 算法比 SGD、RMSprop 以及 Adam 有更低的误差损失, 用 MSGD 算法去优化 CNN 模型具有更好的效果.

综上所述可以看出, 与 SVM、AdaBoost, 随机森林相比, CNN 模型特可以更好地帮助我们去预测智能电网的稳定性, 这是因为 CNN 特有的参数共享和稀疏连接功能可以自动化处理高维特征; 对于 CNN 模型的优化方面来讲, Adam 和 RMSprop 是仅次于 MSGD 的最优的两个算法, 这两种算法都能够自适应学习速率, 其中, RMSprop 采用了递推的形式记录历史梯度平均作为动量, 缓和了参数变化的剧烈程度; Adam 综合了 Momentum 和 RMSprop, 既记录了历史梯度均值作为动量, 又考虑了历史梯度平方和实现各个参数学习率的自适应调整, 因此, 两种算法都具有较好的训练效果. SGD 方法的训练效果最差, 这是由于 SGD 方法的更新方向完全依赖于当前的 batch, 更新不稳定造成的, 而在引入动量后, 它的更新在一定程度上保留了之前的方向, 同时利用 batch 的梯度对当前方向进行微调, 这样一来, 可以学习得更快同时还有一定摆脱局部最优的能力, 因此, MSGD 的训练效果很好并且超过了 Adam 和 RMSprop 算法.

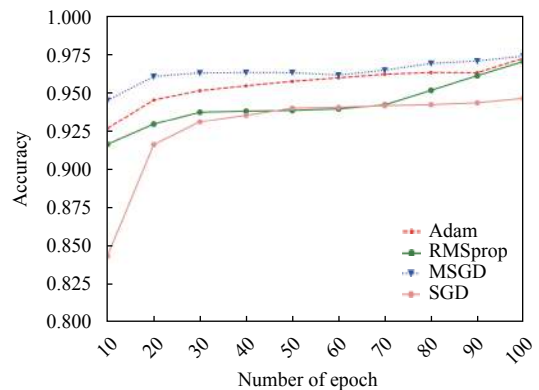


图 7 准确度和迭代次数的关系




图 8 损失函数和迭代次数的关系

3 结束语

本文提出了一个基于 5G 和 CNN 的智能电网稳定性预测算法, 首先对电力网络产生的数据进行采集, 接着针对采集到的数据进行预处理并输入进 CNN 模型, 经过 CNN 的卷积、池化、以及 Softmax 函数等的处理以及不断地迭代, 最终得到智能电网稳定性预测模型。同时, 为了探究不同优化算法对于 CNN 预测模型的影响, 分别利用 SGD、MSGD、RMSprop 以及 Adam 对模型进行优化和训练, 对比了 3 种算法在不同情况下的 Accuracy 和 Loss 值变化情况。最终的结果表明, 带有动量的 SGD 算法 (MSGD) 去优化 CNN 模型可以达到 98.13% 预测效果, 利用该模型可以有效地帮助电力系统对未知的问题提前预警, 降低了安全隐患, 避免了电力事故的发生。

参考文献

- 董爱先, 王学军. 第 5 代移动通信技术及发展趋势. 通信技术, 2014, 47(3): 235–240. [doi: 10.3969/j.issn.1002-0802.2014.03.001]
- 葛亚炯. 物联网形势下的 5G 通信技术应用. 电子世界, 2020, (19): 162–163.
- 周琦. 5G 移动通信技术及发展趋势展望. 电子世界, 2020, (19): 4–5.
- 黄震, 刘军, 李洋. 5G 商用元年发展现状及应用挑战. 电力信息与通信技术, 2020, 18(1): 18–25.
- 王智慧, 汪洋, 孟萨出拉, 等. 5G 技术架构及电力应用关键技术概述. 电力信息与通信技术, 2020, 18(8): 8–19.
- 张臣瀚. 5G 将深远影响电力行业. 通信世界, 2020, (23): 26–27. [doi: 10.3969/j.issn.1009-1564.2020.23.014]
- 孙柏林. 5G 技术在电力系统的应用. 电气时代, 2019, (12): 30–34.
- 王毅, 陈启鑫, 张宁, 等. 5G 通信与泛在电力物联网的融合: 应用分析与研究展望. 电网技术, 2019, 43(5): 1575–1585.
- Baranda J, Mangués-Bafalluy J, Vettori L, *et al.* Arbitrating network services in 5G networks for automotive vertical industry. IEEE Conference on Computer Communications Workshops (INFOCOM 2020). Toronto, ON, Canada. 2020. 1318–1319.
- Rostami A. Private 5G networks for vertical industries: Deployment and operation models. 2019 IEEE 2nd 5G World Forum (5GWF). Dresden, Germany. 2019. 433–439.
- Matinkhah SM, Shafik W. Smart grid empowered by 5G technology. 2019 Smart Grid Conference. Tehran, Iran. 2019. 1–6.
- Zheng WM, Sun K, Zhang XD, *et al.* Cellular communication for ubiquitous internet of things in smart grids: Present and outlook. 2020 Chinese Control and Decision Conference (CCDC). Hefei, China. 2020. 5592–5596.
- 韩治, 张晋. 5G 网络切片在智能电网的应用研究. 电信技术, 2019, (8): 5–8. [doi: 10.3969/j.issn.1000-1247.2019.08.001]
- Darbandi F, Jafari A, Karimipour H, *et al.* Real-time stability assessment in smart cyber-physical grids: A deep learning approach. IET Smart Grid, 2020, 3(4): 454–461. [doi: 10.1049/iet-stg.2019.0191]
- Kumar Samanta S, Chanda CK. Smart grid stability analysis on smart demand load response in coordinated network. 2018 2nd International Conference on Power, Energy and Environment: Towards Smart Technology (ICEPE). Shillong, India. 2018. 1–6.
- 代祥, 刘飞, 陈程, 等. 电力系统暂态稳定计算分析方法的研究. 电力学报, 2018, 33(5): 439–448.
- 胡臻. 基于耦合特性的电力系统稳定性分析方法及应用 [博士学位论文]. 长沙: 湖南大学, 2017.
- 朱永强. 基于综合动态等值的电力系统静态电压稳定性分析 [硕士学位论文]. 长沙: 湖南大学, 2016.
- 左煜. 电力系统元件参数对暂态稳定性影响的研究 [硕士学位论文]. 长沙: 湖南大学, 2015.
- 谢蓉. 基于动力学角度的电力网络同步及稳定性研究 [硕士学位论文]. 桂林: 广西师范大学, 2016.
- 张晨宇. 机器学习和网络嵌入算法在电力系统暂态稳定、电压稳定评估中的应用 [硕士学位论文]. 杭州: 浙江大学, 2019.
- 陈旭, 安源, 孙正龙, 等. 基于机器学习的分布式智能电网稳定性分析. 广东电力, 2020, 33(11): 1–8.
- Zhang ZJ. Improved Adam optimizer for deep neural networks. 2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS). Banff, AB, Canada. 2018. 1–2.
- Reddy RVK, Rao BS, Raju KP. Handwritten Hindi digits recognition using convolutional neural network with RMSprop optimization. 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS). Madurai, India. 2018. 45–51.
- Zaheer R, Shaziya H. A study of the optimization algorithms in deep learning. 2019 Third International Conference on Inventive Systems and Control (ICISC). Coimbatore, India. 2019. 536–539.