

基于 DBN 的隧道地质超前预报自动解释算法

李宝奇¹, 贺昱曜¹, 郭元术², 邱业绩³

(1. 西北工业大学 航海学院, 陕西 西安 710072; 2. 长安大学 信息工程学院, 陕西 西安 710064;
3. 西安公路研究院, 陕西 西安 710065)

摘 要:针对隧道地质超前预报过程中,探地雷达(ground penetrating radar, GPR)线测图解释仅依靠专家经验,且存在准确率不高的问题,通过对 GPR 成像原理和隧道地质特性的研究,以及对深度置信网络(deep belief networks, DBN)计算复杂度的分析,提出一种改进的基于压缩感知和 DBN 的 GPR 线测图分类解释模型。该模型首先利用压缩感知技术对原始 GPR 线测图进行压缩处理,通过选择图像压缩比得到合理的压缩图像;然后将压缩后的图像送入 DBN 模型进行分类,根据分类结果对原始 GPR 线测图进行解释;最后利用广西六宜(六寨—宜州)高速公路隧道实测数据对模型的有效性进行验证,试验数据共 20 000 幅 GPR 图像,包括 6 种隧道地质类型,其中 15 000 幅图像作为训练样本集,5 000 幅图像作为测试样本集。研究结果表明:当 GPR 线测图压缩比为 256,反向微调数据为 1 000 幅图像,DBN 模型迭代次数为 30 时,模型对测试数据中 6 类探地雷达线测图的分类准确率达 100%,单次训练时间降低为原 DBN 模型的 8%左右;大量仿真试验发现 GPR 线测图的合理图像压缩比区间为 64~1 024,在此区间压缩的图像能最大限度地降低图像维度并且保留原始图像信息。该模型具有解释准确率高、训练速度快等优点,可为制定隧道施工和开挖计划提供合理依据。

关键词:隧道工程;隧道地质超前预报;探地雷达;深度置信网络;压缩感知;深度学习

中图分类号:U452.11

文献标志码:A

Automatic interpretation algorithm for tunnel geological prediction based on DBN

LI Bao-qi¹, HE Yu-yao¹, GUO Yuan-shu², QIU Ye-ji³

(1. School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an 710072, Shaanxi, China; 2. School of Information Engineering, Chang'an University, Xi'an 710064, Shaanxi, China; 3. Xi'an Highway Institute, Xi'an 710065, Shaanxi, China)

Abstract: In the process of tunnel geological prediction, Interpretations of GPR (ground penetrating radar) line images are mainly determined by experience of experts, so that the accuracy is low. Through in-depth study on the principle of GPR, the geological characteristics of tunnel as well as the analysis on computational complexity of DBN (deep belief networks), an interpretation model of GPR line images was proposed based on compressed sensing and DBN. Firstly, the raw GPR line images were compressed by compressed sensing to obtain reasonable

image with compression ratio. Secondly, the compressed images were sent to DBN model for classification. Then, the raw GPR line images were interpreted according to the classification results. Finally, the measured data of Liuyi (Liuzhai to Yizhou) Highway tunnels in Guangxi were used to verify the effectiveness of the proposed model. The experimental data contained 20 000 images which could be classified into 6 types of tunnel geology. 15 000 images of the experimental data were used as training dataset, and the other 5 000 images were used as testing dataset. The results show that when the compression ratio of GPR line images is 256, the reserve fine turning data is 1 000 images and the iteration number of DBN model is 30, the classification accuracy of the proposed model on the 6 types in testing dataset is 100%, and the single training time reduces to about 8% of that of the original DBN model. According to a large number of simulation experiments, the reasonable range of image compression ratio is 64 to 1 024, among which, the size of image can be greatly reduced and the information of raw image can be effectively preserved. Thus, it can be seen that the proposed model has the advantages of high accuracy of interpretation and fast training speed, and can provide reasonable basis for construction and excavation plan of tunnel. 3 tabs, 5 figs, 25 refs.

Key words: tunnel engineering; tunnel geological prediction; GPR; DBN; compressed sensing; deep learning

0 引言

在隧道建设的勘察阶段,一般都要查清隧道区域的工程和水文地质情况,给设计部门提供地质资料,并以此作为设计依据。由于隧道是深埋于地下的隐蔽工程,其工程岩体的工程地质、水文地质条件复杂多变,限于目前的地质勘探水平,不可能在勘察阶段就准确无误地查明其工程岩体的状态、特征以及可能发生地质灾害的不良地质体的位置、规模和性质,因此,必须在施工中开展深入细致的地质超前预报工作^[1-2]。

探地雷达(ground penetrating radar, GPR)作为隧道地质超前预报的主要手段,具有探测速度快、对隧道环境破坏小、操作方便等优点,但 GPR 线测图解释却十分困难^[3-4]。朱军涛等提出一种基于短时傅里叶变化(STFT)的聚类分析方法,该方法提取 4 类铁路路基 GPR 线测图的时频特征值,根据特征值在特征空间中的位置实现 GPR 线测图的解释,然而聚类分析方法不适合处理类型相近的数据,同时该方法还具有较强的主观性,并不能定量评价数据解释的准确程度^[5]。周辉林等利用支持向量机(SVM)方法对高速公路路基好坏进行解释,该方法通过某种事先选择的非线性函数将 GPR 线测图的特征向量映射到一个高维特征空间,然后在这个空间中构造最优分类超平面进行分类处理,但 SVM 方法主要处理 2 种类型的数据,当数据类型增多时,

SVM 方法的计算量显著增加,同时分类的效果也会越来越差^[6]。

隧道内地质通常由多种混合介质发育而成,存在化学和物理上的变化,并且不同类型地质介电常数存在重叠,GPR 线测图显得更加复杂和不确定,依靠人工经验以及浅层的学习方法很难对其进行准确解释。为此,本文提出改进的基于深度学习方法 GPR 线测图分类解释模型,并以广西六宜(六寨—宜州)高速公路隧道实测数据为基础,对模型参数的选取以及模型的有效性进行试验验证,为隧道地质超前预报过程中 GPR 数据提供准确率高、训练时间短的解释方法。

1 基于 DBN 模型的探地雷达图像分类和解释

深度置信网络(DBN)模型是由 Hinton 等提出的一个混合结构的深度学习模型^[7-9]。模型的训练分为 2 步:首先采用无监督贪婪逐层迭代的学习方式计算 DBN 模型的初始权重;然后利用反向微调算法使权重快速达到局部最优。模型的顶层为一个双向连接的关联记忆层,其他层为有向连接贝叶斯网络模型。Hinton 等建立了固定权重的有向无限图与双向连接的限制波尔兹曼机(restricted Boltzmann machines, RBM)等价关系,因此可以通过求解 RBM 的方式来确定有向贝叶斯网络的权重,即 DBN 模型可以通过逐层叠加 RBM 得到^[9]。

1.1 RBM 模型

RBM 的结构如图 1 所示,其中:上层为隐含单元层 h ;下层为可见单元层 v ; w_{ij} 为可见单元 v_j 和隐含单元 h_i 的连接权重; b_j, c_i 分别为第 j 个可见单元和第 i 个隐含单元的偏置。可见单元与隐含单元之间双向连接,同一层内的神经元之间互不连接^[10]。从概率论的角度,这也就意味着在给定可见单元的状态下各个隐含单元之间相互独立,反之亦然。




图 1 RBM 模型

Fig. 1 RBM model

对于参数为 $\theta = (w_{ij}, b_j, c_i)$ 的 RBM 模型,给定训练样本,即一组可见单元 v 时,它的对数似然函数为

$$\ln[L(\theta/v)] = \ln\left[\frac{1}{Z} \sum_h e^{-E(v,h)}\right] = \ln\left[\sum_h e^{-E(v,h)}\right] - \ln\left[\sum_{v,h} e^{-E(v,h)}\right] \quad (1)$$

其中

$$\begin{cases} Z = \sum_{v,h} e^{-E(v,h)} \\ E(v,h) = - \sum_{i=1}^n \sum_{j=1}^m w_{ij} h_i v_j - \sum_{j=1}^m b_j v_j - \sum_{i=1}^n c_i h_i \quad i \in (1, \dots, n), j \in (1, \dots, m) \end{cases} \quad (2)$$

式中: $L(\theta/v)$ 为已知可见单元 v 对参数 θ 的似然函数。

对式(1)计算关于 w_{ij} 的偏导数,得

$$\Delta w_{ij} = \langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{model}} \quad (3)$$

式中: $\langle v_i h_j \rangle_{\text{data}}$ 为由数据决定的可见单元与隐含单元期望值,通过一次并行计算即可求得; $\langle v_i h_j \rangle_{\text{model}}$ 为由模型决定的可见单元与隐含单元期望值,需运行足够长的马尔科夫链才能收敛到稳定的分布,通常 $\langle v_i h_j \rangle_{\text{model}}$ 的计算会采取一些近似方法,如对比散度、并行退火等。

利用上述步骤,同样可以得到关于 b_j, c_i 的增量。

1.2 从 RBM 模型到 DBN 模型

一旦 RBM 训练完成,利用权重和偏置就可以定义关于可见单元和隐含单元的联合分布 $P(v, h)$; 同时也能定义边缘分布 $P(v)$ 和 $P(h)$ 、条件分布 $P(v/h)$ 和 $P(h/v)$, 即

$$P(v; \theta) = \sum_{h^{(1)}} P(h^{(1)}; W^{(1)}) P(v/h^{(1)}; W^{(1)}) \quad (4)$$

式中: $P(h^{(1)}; W^{(1)}) = \sum_v P(h^{(1)}, v; W^{(1)})$, 为关于 $h^{(1)}$ 的先验概率并隐含 $W^{(1)}$, “;” 后部分为隐含内容, $h^{(1)}$ 为第 1 层隐含单元的偏置, $W^{(1)}$ 为第 1 个 RBM 的连接权重; $P(v/h^{(1)}; W^{(1)})$ 为有向贝叶斯网络中父节点向子节点的概率传递。

训练第 2 层 RBM 时,使由第 1 层 RBM 确定的 $P(v/h^{(1)}; W^{(1)})$ 不变,用式(5)替代 $P(h^{(1)}; W^{(1)})$, 即

$$P(h^{(1)}; W^{(2)}) = \sum_{h^{(2)}} P(h^{(1)}, h^{(2)}; W^{(1)}) \quad (5)$$

式中:第 1 层 RBM 的隐含单元 $h^{(1)}$ 为第 2 层 RBM 的可见单元; $h^{(2)}$ 为第 2 层 RBM 的隐含单元; $W^{(2)}$ 为隐含单元层 $h^{(1)}$ 与隐含单元层 $h^{(2)}$ 之间的连接权重。

用第 1 层 RBM 训练得到的 $P(h^{(1)}; W^{(1)}) = \sum_v P(h^{(1)}, v; W^{(1)})$ 作为第 2 层 RBM 的开始,同训练第 1 层 RBM 一样训练第 2 层 RBM。

第 2 层 RBM 训练结束以后,应用相同的策略可以训练更高层的 RBM,这样就可以得到一个完整的 DBN 模型。经过大量的无标签数据初始训练, DBN 模型的初始权重会回落到一个合理的区域,通过微调就可以使系统的初始权重快速地达到局部最优值。

目前主要存在 2 种类型的 DBN 模型: DBN 生成模型和 DBN 分类模型^[11]。DBN 生成模型通过 wake-sleep 算法进行微调, wake-sleep 算法主要是通过单边固定向上的认知权重或者向下的生成权重,使生成权重和认知权重达成一致,整个过程为一个无监督的学习过程^[12]。DBN 分类模型是通过少量的有标签数据进行微调,当顶层设计为分类目标函数时,微调过程等价于神经网络方法,只不过 DBN 模型的权重初值不是随机选取的,而是通过大量无标签数据训练得到的更加合理的初始值。DBN 模型极大地提高了计算机解决复杂和不确定性问题的能力,在图像分类^[13-14]、语音识别^[15]、文本分析^[16]、时间序列信号预测^[17-18]、场景解析^[19] 等方面有均广泛应用。

1.3 改进的 DBN 分类模型

采用 DBN 模型直接处理原始 GPR 线测图时,

会出现计算量过大、训练时间过长的问题^[20-26]。其主要原因是 DBN 模型的计算复杂度与神经元个数存在指数关系,而模型可见单元层神经元的个数与输入数据的维数相等。为此考虑在最大限度保留原始信息的同时,对 GPR 线测图进行压缩处理。隧道 GPR 线测图是利用探地雷达仪器对隧道掌子面连续扫描得到的成像图,反映一段距离内隧道的内部特征和特征变化情况。虽然线测图的内容与扫描距离有关,但隧道掌子面的面积有限,考虑地质发育的特点,不存在在一个小区域内同时存在多种地质类型的可能,所以隧道 GPR 线测图比一般图像信号的冗余度要高。

压缩感知技术是将原始数据投影到稀疏空间上,稀疏空间上的非零元素保留了原始数据的几乎全部信息,同时稀疏空间上的非零元素个数远远小于零元素的个数,因此对稀疏空间进行大尺度压缩后,非零元素丢失的概率很小^[27]。可以用压缩后的数据以很高的概率恢复原始数据,压缩比大约为 30%,针对内容单一的隧道 GPR 线测图可以选取更低的压缩比。

本文利用压缩感知技术对隧道 GPR 线测图进行压缩处理。图 2 为 GPR 线测图采用压缩感知技术压缩前后的对比情况,其中图 2(a)为原始 GPR 线测图,图像尺寸为 256 像素×256 像素;图 2(b)为压缩后的 GPR 线测图,图像尺寸为 64 像素×64 像素。由于压缩感知是将原始数据映射到另外一个空间,所以图 2(b)不再具备明确的物理意义,但它依然保留了图 2(a)的绝大部分信息,通过计算可以以很高的概率将图 2(b)恢复成图 2(a)。

由于原始 GPR 线测图本身不具有稀疏特性,需要通过稀疏矩阵(例如快速傅里叶变换、小波变换等)使其稀疏化,然后再利用测量矩阵对稀疏后的 GPR 线测图进行压缩处理。结合隧道地质分类情况,改进后的 DBN 分类解释模型如图 3 所示。

2 仿真试验

2.1 参数设置

试验数据为广西六宜高速公路隧道实测数据,其中训练数据集为 15 000 幅图像,测试数据集为 5 000 幅图像,原始 GPR 线测图为 256 像素×256 像素。训练数据集由无标签数据(未知 GPR 数据类型)和有标签数据(已知 GPR 数据类型)组成,测试数据集则全部由有标签数据组成。根据隧道内岩土的破碎程度及含水量的多少,将隧道地质类型分为




图 2 原始 GPR 线测图和压缩后的 GPR 成像
Fig. 2 Original GPR scanning image and compressed GPR image

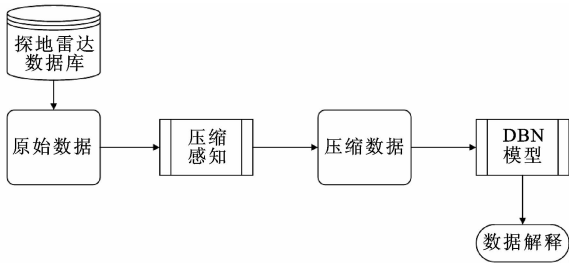


图 3 改进的基于 DBN 模型的探地雷达线测图分类解释模型
Fig. 3 Improved classification and interpretation model based on DBN model for GPR

空腔型溶洞、泥夹石填充型溶洞、局部破碎围岩、富水破碎围岩、低含水量全破碎围岩、无明显异常围岩(Ⅲ级围岩)6 种类型。测试数据集的构成如表 1 所示。

表 1 测试数据集
Tab. 1 Testing dataset

类型	空腔型 溶洞	泥夹石 填充型 溶洞	局部破 碎围岩	富水破 碎围岩	低含水 量全破 碎围岩	无明显 异常围岩
数据量	718	909	895	870	695	913

试验采用如图 3 所示的改进模型。压缩感知部

分使用的快速傅氏变换(FFT)矩阵为稀疏矩阵, 高斯随机矩阵为测量矩阵。DBN 为一个 4 层混合结构的分类模型(4 层结构的 DBN 模型是最简单的深度学习模型, 便于设计和计算), 其中第 1 层为可见单元层, 神经元的个数与压缩后的 GPR 数据向量形式长度相同; 第 2 层为第 1 隐含单元层, 神经元的个数为 1 024; 第 3 层为第 2 隐含单元层, 神经元的个数为 2 048; 第 4 层的神经元个数为 6, 与隧道地质类型总数相同。各层之间的初始连接权重服从均值为 0, 方差为 0.001 的高斯分布, 第 1 层的初始偏置由输入数据决定, 其他层的初始偏置设置为 0。

2.2 仿真试验

采用 DBN 模型处理压缩后的训练样本集和测试样本集数据, 模型预处理阶段将训练样本集当作无标签训练集使用, 训练样本集中的标签数据参与预训练, 但不使用标签, 反向微调阶段使用训练样本集中的标签数据进行 DBN 模型参数的进一步调整, 反向微调数据个数为 1 000, 模型训练完毕后使用测试样本集对模型的性能进行验证。DBN 模型采用随机梯度下降法对参数进行优化求解, 随着迭代次数增多, 模型的性能趋于稳定, 每一批次处理 500 幅图像。

2.2.1 试验 I

在相同的试验平台下, 利用相同的试验数据比较本文方法与其他方法之间的性能差异, 试验结果如表 2 所示。文献[5]中方法是提取图像时域和小波域的特征, 然后利用 SVM 方法对特征数据进行分类。基于图像特征矩的 SVM 方法是提取图像的特征矩, 并将特征矩作为特征参数利用 SVM 方法进行分类。

表 2 本文方法与其他方法的性能比较

Tab. 2 Performance comparison of the method proposed in this paper with other methods

方法	训练样本集个数	测试样本集个数	准确估计个数	准确率/%
文献[5]中方法	15 000	5 000	1 436	28.72
基于图像特征矩的 SVM 方法	15 000	5 000	1 684	33.68
本文方法	15 000	5 000	5 000	100.00

在针对 6 种类型的探地雷达数据进行分类时, 文献[5]中方法的准确率仅为 28.72%, 基于特征矩的 SVM 方法的准确率也仅为 33.68%, 显然这样的分类准确率是不能满足实际工程要求的。本文方法在压缩比为 256, 迭代次数为 30, 反向微调数据数为 1 000 时, 模型的分类准确率达到 100%, 即能准确

实现 6 种类型探地雷达数据的分类和解释。SVM 方法只能区分探地雷达数据“好”与“坏”, 当 GPR 数据类型需要更精确的区分, 且需要分类的种类增多时, SVM 方法显然就不再适用。本文方法是在 DBN 模型基础上提出的一个改进模型, 它保存了 DBN 对多类数据的区分能力, 同时通过合理选择压缩比, 也消除了 DBN 计算量过大的缺点。

2.2.2 试验 II

训练样本集为 15 000 幅图像, 反向微调样本集为 1 000 幅图像, 测试样本集为 5 000 幅图像, 迭代次数为 5~100, 步长为 5, 计算不同迭代次数条件下 3 种压缩比对模型分类性能的影响。图像压缩比为原始图像的像素乘积与压缩后图像的像素乘积的比值。

从图 4 可以看出, 随着迭代次数的增加, 3 种压缩比下改进模型的分类性能都逐渐改善。压缩比为 4 096 的改进模型分类准确率曲线呈缓慢上升趋势, 迭代次数为 50 时分类准确率为 95.9%, 迭代次数继续增加分类准确率保持在 95% 左右, 并不能达到 100%; 压缩比为 256 的改进模型分类准确率曲线呈快速上升趋势, 迭代次数为 30 时分类成功率已达 100%; 压缩比为 16 的改进模型分类准确率曲线在迭代次数为 50 之前为 20.07%, 保持在一个较低的水平, 当迭代次数增加到 55 时, 分类准确率为 97.24%, 当迭代次数增加至 60 时, 分类准确率达 100%。




图 4 三种压缩比下改进模型的分类性能

Fig. 4 Classification performance of improved model under three kinds of compression ratios

图 4 中, 压缩比为 4 096 代表过压缩, 压缩比为 16 代表欠压缩, 压缩比为 256 代表合理压缩。过压缩会导致原始图像部分特征信息丢失, 仅依靠部分

特征信息会降低 DBN 模型的学习效率,影响模型的收敛速度,同时无法达到 100% 的准确分类;欠压缩则是过多地保留了原始图像的无用信息,由于无用信息的干扰,使得模型很难在较少迭代次数下就能对数据进行准确区分。选择合理的压缩比能保留有用特征信息,抑制无用干扰信息,同时还能有效减少模型的计算量和迭代次数。

表 3 给出了模型压缩比的关键点训练时间,经过大量仿真试验研究,针对隧道探地雷达数据分类问题,分别给出了过压缩、合理压缩、欠压缩的近似区间分布,以及不同压缩比条件下模型计算 1 次的时间。欠压缩比近似区间为(1,64),在此区间选择压缩比会出现迭代次数过多,计算量过大的问题;过压缩比近似区间为(1 024,+∞),在此区间内选择压缩比会出现收敛速度慢的问题,同时分类准确率也不能实现 100%;合理压缩比近似区间为(64,1 024),在这此区间选择压缩比能够获得合理的压缩数据,同时也能减少计算量,提高收敛速度。

表 3 不同压缩比(关键点)条件下的训练时间

Tab. 3 Training time under different compression ratios (keypoints)


压缩类型	过压缩	合理压缩			欠压缩		
压缩比关键点	4 096	1 024	256	64	16	4	1
运行时间/s	31	47	66	79	121	291	825

2.2.3 试验Ⅲ


将未知类型的 GPR 线测图[图 5(a)]用已训练好的 DBN 分类模型进行解释。分类结果显示为第 3 类(围岩局部破碎)。结合线测图的位置信息,通过开挖验证发现在 CK10+037~CK10+028 范围内围岩较破碎,节理、裂隙较发育,有少量次生矿物,如图 5(b)所示,与改进模型分类结果一致。

3 结 语

- (1)提出改进的基于 DBN 模型的隧道 GPR 线测图分类解释模型,在压缩比为 256,迭代次数为 30,反向微调数据为 1 000 时,模型的分类准确率达 100%,比基于 SVM 方法的 GPR 数据分类解释模型准确率有较大提升。
- (2)影响该模型性能最重要的因素是压缩比,针对隧道 GPR 线测图分类解释问题,给出了合理压缩比的近似区间,在该区间内选择压缩比能获得更好的性能。
- (3)本试验所使用的检测数据来源于同一区域的隧道,数据类型受当地地质环境约束,因此可考虑



(a) GPR线测图



(b) 开挖结果

图 5 开挖验证

Fig. 5 Excavation verification

引入不同区域隧道的 GPR 线测图做为训练集,以扩大模型的适用范围。

参考文献:

References:

[1] 宋先海,顾汉明,肖柏勋.我国隧道地质超前预报技术述评[J].地球物理学进展,2006,21(2):605-613.
SONG Xian-hai, GU Han-ming, Xiao bo-xun. Overview of tunnel geological advanced prediction in China [J]. Progress in Geophysics, 2006, 21(2): 605-613.

[2] 李术才,刘 斌,孙怀凤,等.隧道施工超前地质预报研究现状及发展趋势[J].岩石力学与工程学报,2014,33(6):1090-1113.
LI Shu-cai, LIU Bin, SUN Huai-feng, et al. State of art and trends of advanced geological prediction in tunnel construction[J]. Chinese Journal of Rock Mechanics and Engineering, 2014, 33(6): 1090-1113.

[3] 李希忠,朱自强,柳群义.隧道超前地质预报的方法探讨[J].工程地球物理学报,2009,6(4):475-479.
LI Xi-zhong, ZHU Zi-qiang, LIU Qun-yi. Research of the advanced geological forecast technology of the tunnel[J]. Chinese Journal of Engineering Geophysics, 2009, 6(4): 475-479.

[4] 方建立,应 松,贾 进.地质雷达在公路隧道超前地质预报中的应用[J].中国熔岩,2005,24(2):160-163.
FANG Jian-li, YING Song, JIA Jin. Application of GPR in geological forecast for highway tunnels[J]. Carsologica Sinica, 2005, 24(2): 160-163.

[5] 朱军涛,廖红建,谢勇勇,等.采用短时傅里叶变换的

- 铁路车载探地雷达数据解译方法[J]. 西安交通大学学报, 2012, 46(7): 108-114.
- ZHU Jun-tao, LIAO Hong-jian, XIE Yong-yong, et al. Data interpretation of ground-penetrating radar (GPR) via short-time Fourier transform for railway track detection[J]. Journal of Xi'an Jiaotong University, 2012, 46(7): 108-114.
- [6] 周辉林, 姜玉玲, 徐立红, 等. 基于 SVM 的高速公路路基病害自动检测算法[J]. 中国公路学报, 2013, 26(2): 42-47.
- ZHOU Hui-lin, JIANG Yu-ling, XU Li-hong, et al. Automatic detection algorithm for expressway subgrade diseases based on SVM[J]. China Journal of Highway and Transport, 2013, 26(2): 42-47.
- [7] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [8] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [9] SALAKHUTDINOV R R, HINTON G E. An efficient learning procedure for deep Boltzmann machines[J]. Neural Computation, 2012, 24(8): 1967-2006.
- [10] FISCHER A, IGEL C. Training restricted Boltzmann machines: An introduction[J]. Pattern Recognition, 2014, 47(1): 25-39.
- [11] HINTON G E. Where do features come from? [J]. Cognitive Science, 2014, 38: 1078-1101.
- [12] HINTON G E, DAYAN P, FREY B J, et al. The "wake-sleep" algorithm for unsupervised neural networks[J]. Science, 1995, 268(5214): 1158-1161.
- [13] LIU Y, ZHOU S S, CHEN Q C. Discriminative deep belief networks for visual data classification[J]. Pattern Recognition, 2011, 44(10/11): 2287-2296.
- [14] HINTON G E. Learning to represent visual input[J]. Philosophical Transactions: Biological Sciences, 2010, 365(1537): 177-184.
- [15] MOHAMED A R, DAHL G E, HINTON G E. Acoustic modeling using deep belief networks[J]. IEEE Transactions on Audio, Speech and Language Processing, 2012, 20(1): 14-22.
- [16] HINTON G E, SALAKHUTDINOV R R. Discovering binary codes for documents by learning deep generative models[J]. Topics in Cognitive Science, 2011, 3(1): 74-91.
- [17] YUAN M L, TANG H J, LI H Z. Real-time keypoint recognition using restricted Boltzmann machine[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(11): 2119-2126.
- [18] KUREMOTO T, KIMURA S, KOBAYASHI K, et al. Time series forecasting using a deep belief network with restricted Boltzmann machines [J]. Neurocomputing, 2014, 137: 47-56.
- [19] FARABET C, COUPRIE C, NAJMAN L, et al. Learning hierarchical features for scene labeling[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8): 1915-1929.
- [20] YU D, DENG L. Deep learning and its applications to signal and information processing [J]. IEEE Signal Processing Magazine, 2011, 28(1): 145-154.
- [21] LECUN Y, BENGIO Y, HINTON G E. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [22] 贺昱曜, 李宝奇. 一种组合型的深度学习模型学习率策略[J]. 自动化学报, 2016, 42(6): 953-958.
- HE Yu-yao, LI Bao-qi. A combinatory form learning rate scheduling for deep learning model[J]. Acta Automatica Sinica, 2016, 42(6): 953-958.
- [23] INDIVERI G, LIU S C. Memory and information processing in neuromorphic systems[J]. Proceedings of IEEE, 2015, 103(8): 1379-1397.
- [24] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-127.
- [25] 焦 莉. 综合超前地质预报技术在隧道施工中的应用[J]. 筑路机械与施工机械化, 2012, 29(7): 83-85, 88.
- JIAO Li. Application of comprehensive advanced geological forecast technology in tunnel construction[J]. Road Machinery & Construction Mechanization, 2012, 29(7): 83-85, 88.
- [26] 赵玉成, 隋传毅, 张艳东. TSP203 超前地质预报系统在田坝岭隧道中的应用[J]. 筑路机械与施工机械化, 2010, 27(7): 70-72.
- ZHAO Yu-cheng, SUI Chuan-yi, ZHANG Yan-dong. Application of TSP203 system in Tianbaling Tunnel [J]. Road Machinery & Construction Mechanization, 2010, 27(7): 70-72.
- [27] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.