

基于弱监督学习的去噪受限玻尔兹曼机 特征提取算法

杨 杰, 孙亚东, 张良俊, 刘海波

(武汉理工大学光纤传感技术与信息处理教育部重点实验室, 湖北武汉 430070)

摘 要: 针对现有特征提取方法难以实现从含有复杂背景的图像中提取有用目标特征的瓶颈问题, 提出了基于弱监督学习的去噪受限玻尔兹曼机特征提取算法. 首先, 利用训练样本, 通过无监督学习方式训练一个标准受限玻尔兹曼机模型, 从而获得一个包含可视单元层和隐藏单元层的层次结构模型; 然后, 对可视层的每个单元引入二值转换单元, 对隐藏层, 根据各节点的激活值大小和激活频率将其分为两组: 前景特征隐层单元和背景特征隐层单元, 得到一个二元混合式去噪受限玻尔兹曼机的模型; 最后, 通过多模交互方式, 利用有限数量的样本标签信息对输入样本逐像素地进行采样训练, 以此来提取目标特征. 实验表明, 本文的特征提取算法能够有效地从复杂的干扰背景中提取目标特征, 提高了目标识别精度.

关键词: 特征提取; 受限玻尔兹曼机; 目标识别

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112 (2014)12-2365-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2014.12.005

Weakly Supervised Learning with Denoising Restricted Boltzmann Machines for Extracting Features

YANG Jie, SUN Ya-dong, ZHANG Liang-jun, LIU Hai-bo

(Key Laboratory of Fiber Optic Sensing Technology and Information Processing, Ministry of Education,
Wuhan University of Technology, Wuhan, Hubei 430070, China)

Abstract: Existing feature extraction algorithms are difficult to capture useful information from complex images. A feature extraction approach is proposed based on the weakly supervised learning with denoising restricted Boltzmann machine (RBM). First, a standard RBM is pre-trained in an unsupervised learning way, which provides a hierarchical mode with a visible layer and a hidden layer. Second, for the visible layer, a stochastic binary switch node is employed. And for the hidden layer, it is divided into foreground-hidden nodes and background-hidden nodes based on the score of each hidden node's activation values and times, thus we can achieve a binary mixture denoising RBMs. Finally, the pixel-wise denoising RBMs is trained by using small number label information and stochastic switch nodes through multiplicative interaction. The experimental results show that significant performance improvement is achieved with our proposed method.

Key words: feature extraction; restricted Boltzmann machine (RBM); object recognition

1 引言

对实际的图像建立模型是非常具有挑战性的课题, 因为自然图像通常都具有连续、高维的特点, 且常常包含各种复杂的背景干扰因素. 构建一个具备从复杂的图像背景中提取鲁棒性特征的学习模型, 其最大的困难就是如何有效地处理与目标无关的各种背景噪声和干扰因素, 从而获得有效的目标特征.

近年来学者们开发的特征如 SIFT (Scale Invariant Feature Transform), HOG (Histogram of Oriented Gradients) 等

特征描述符, 在图像目标识别领域取得了巨大的成功, 但随着问题复杂程度的提高, 如实现复杂干扰背景下的目标识别、行为识别等, 这些特征描述符已难以满足现实需求^[1,2]. 另一方面, 基于层次架构的模型不仅能提取数据的初级自然特征, 同时还具有提取高层次目标特征的能力, 特别是基于深度学习的层次模型, 例如深信念网络^[3]、深度自编码网络^[4]及受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM)^[2,5,6]等模型, 这些模型通过逐层的贪婪训练方式和无监督的学习方法, 更易于为非线性的复杂高维数据建模和求解, 从而使得深度

学习模型在模式识别领域取得了令人瞩目的成绩.深度学习模型通常利用无监督学习方法获取数据特征.无监督学习把所有的输入数据都看作是有效的特征,并通过大量的无标签样本数据的训练来获取数据所隐含的特征.然而,当输入的数据样本中包含大量的背景干扰因素时,通过无监督学习方法获取特征目前仍然是一个具有挑战性的难题.

为了有效获取鲁棒性的输入数据特征,本文提出了一种基于弱监督学习的深度学习模型,即去噪受限玻尔兹曼机模型.该模型是利用多模交互方式,对输入图像的每个像素建立一个混合结构的二元受限玻尔兹曼机层次模型,数据样本在训练的过程中,有用的目标信息特征出现的频率总是要高于背景干扰特征,因此,可以利用少量的样本标签信息作为校正信息,将层次模型中含有目标特征的隐藏层划分为两组,即含有目标特征的前景隐藏层和含有干扰特征的背景隐藏层.为了获取具有鲁棒性和简洁性的目标特征,层次模型在输入层每个节点引入一个二值转换单元.通过这个转换单元,可以使模型在样本训练的过程中以多模交互方式,控制隐藏层两组单元独立的获取各自的前景目标特征和背景干扰特征.

2 模型框架

去噪受限玻尔兹曼机模型框架如图1所示.与传统判别式模型不同,它是一种生成式的特征提取模型.整个算法步骤可描述为:首先,以无监督学习方式,预训练一个标准的受限玻尔兹曼机(RBM)模型,此步骤可视为特征提取算法的初始化过程.通过初始化步骤,获取模型的初始隐藏层;第二步,通过运用少量的样本标签信息,根据初始隐藏层各单元激活值的大小和频率,将隐藏层进行分组,即划分为前景隐藏层和背景隐藏层;第三步,在可见层引入二值转换单元,并利用少量标签信息,以逐像素的多模交互方式进行训练.




图1 去噪受限玻尔兹曼机模型框架

2.1 预训练标准 RBM 模型

RBM 是一种两层无向的概率图模型,也可以看作

是一种特殊形式的对数线性马尔科夫随机场.RBM 模型的节点通常符合贝努力分布^[7],但是如果采用平均场逼近方法,RBM 模型的节点也可视为符合任意的指数族函数分布^[8].从结构上看,RBM 模型是一种对称连接且无自反馈的随机神经网络模型,层间全连接,层内无连接.由于 RBM 模型是马尔科夫随机场的一种特例,且其所有节点的联合分布均服从玻尔兹曼分布,因此,可以将 RBM 作为一种能量模型,并引入概率测度对能量模型进行求解.对于马尔科夫随机场,其模型节点之间没有明确的因果关系,它的联合概率分布会表达为一系列势函数的乘积.这些乘积的积分通常情况下并不等于 1,因此,需对其进行归一化以便形成一个有效的概率分布.所以,对一个可见层-隐藏层的 RBM 模型系统,其能量函数矩阵形式定义为:

$$E(\mathbf{v}, \mathbf{h}) = -\mathbf{v}^T \mathbf{W} \mathbf{h} - \mathbf{b}^T \mathbf{v} - \mathbf{c}^T \mathbf{h} \quad (1)$$

其中, $\{\mathbf{W}, \mathbf{b}, \mathbf{c}\}$ 是 RBM 模型参数.基于这个能量函数,可以定义可见层与隐藏层节点之间的联合概率分布:

$$P(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} e^{-E(\mathbf{v}, \mathbf{h})} = \frac{1}{Z} (e^{\mathbf{v}^T \mathbf{W} \mathbf{h}}) \cdot (e^{\mathbf{b}^T \mathbf{v}}) \cdot (e^{\mathbf{c}^T \mathbf{h}}) \quad (2)$$

其中, Z 就是归一化因子.由于 RBM 的特殊结构(即层间有连接,层内无连接),当给定可见单元的状态时,隐藏单元的激活状态之间是条件独立的.因此隐藏单元的激活概率可以定义为:

$$P(\mathbf{h} | \mathbf{v}) = \prod_{j=1}^n P(h_j = 1 | \mathbf{v}) \quad (3)$$

$$P(h_j = 1 | \mathbf{v}) = \sigma(c_j + \sum_{i=1}^m v_i W_{ij}) \quad (4)$$

其中 $\sigma(x)$ 为 sigmoid 函数.因为 RBM 的结构是对称的,当给定隐藏单元的状态时,各可见单元的激活状态之间也是条件独立的,可见单元的激活概率定义为:

$$P(\mathbf{v} | \mathbf{h}) = \prod_{i=1}^m P(v_i = 1 | \mathbf{h}) \quad (5)$$

$$P(v_i = 1 | \mathbf{h}) = \sigma(b_i + \sum_{j=1}^n W_{ij} h_j) \quad (6)$$

由于归一化因子 Z 的存在, $P(\mathbf{v}, \mathbf{h})$ 所表示的可见单元与隐藏单元的联合分布无法直接计算.通常做法是采用基于对比散度算法(Contrastive Divergence, CD)来近似计算.

2.2 去噪受限玻尔兹曼机模型建立

去噪受限玻尔兹曼机模型首先将预训练的 RBM 模型隐藏层分两组,然后以混合结构的 RBM 方式对输入数据的前景特征和背景特征分别建模和训练.

当一个标准的 RBM 模型预训练过程完成以后,去噪模型便获得一个包含目标潜在特征的隐藏层.由于目标特征在训练过程中出现的频率总是高于背景干扰或噪声,因此其对应的隐藏单元激活值更大,且激活的次数更多.依据这个特点,我们对隐藏单元进行聚类分

组,其分组的阈值函数定义为:

$$z_{jk} = \frac{1}{1 + \exp(-c_j - \sum_{i=1}^m v_i W_{ij})} \quad (7)$$

$$W_j = \begin{cases} w, & \text{if } z_{jk} \rightarrow y_k \\ \bar{w}, & \text{otherwise} \end{cases} \quad (8)$$

$$\text{score}(W_j) = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad (9)$$

其中, z_{jk} 为第 j 个样本,第 k 个隐藏单元对应的激活值. W_{ij} 是 RBM 模型的权值, y_k 是样本标签信息, w 和 \bar{w} 为隐藏单元的激活时状态值和非激活时状态值, \bar{x}_1, \bar{x}_2 为相应的均值, σ_1 和 σ_2 为相应的方差, n_1 和 n_2 为相应的激活和非激活的次数. 在样本训练过程中,由于目标某一特征出现的频率总是高于背景干扰特征,因此我们利用隐藏单元激活与非激活状态对应的均值、方差及响应次数信息,把隐藏层中激活值大且频率高的单元提取出来,并以此作为目标的特征提取单元.

根据以上阈值函数,可以将隐藏层分组为前景隐藏层和背景隐藏层.通过这种聚类分组方式,使模型对原始的输入变量特征进行预备性选择.这种预备性的选择对去噪模型即起到了良好的初始化作用,同时又为模型通过训练学习出最终的前景和背景特征的统计结构起到优化作用.

对于可视层(输入层)每个输入节点,模型引入了二值转换单元,表示为 $s_i \in \{0, 1\}$.在模型训练的过程中,对二值转换单元和隐藏单元之间采取逐像素多模交互方式重构可视层每个单元.在这种情况下,去噪模型的能量函数和联合概率分布分别定义为:

$$P(\mathbf{v}, \mathbf{s}, \mathbf{h}) = \frac{1}{Z} e^{-E(\mathbf{v}, \mathbf{s}, \mathbf{h})} \quad (10)$$

$$\begin{aligned} E(\mathbf{v}, \mathbf{s}, \mathbf{h}) &= E_1(\mathbf{v}, \mathbf{s}, \mathbf{h}^1) + E_2(\mathbf{v}, \mathbf{s}, \mathbf{h}^2) \\ &= -(\mathbf{s} \cdot \mathbf{v})^T \mathbf{W}^1 \mathbf{h}^1 - (\mathbf{b}_1)^T (\mathbf{s} \cdot \mathbf{v}) - (\mathbf{c}_1)^T \mathbf{h}^1 \\ &\quad - ((1 - \mathbf{s}) \cdot \mathbf{v})^T \mathbf{W}^2 \mathbf{h}^2 - (\mathbf{b}_2)^T ((1 - \mathbf{s}) \cdot \mathbf{v}) - (\mathbf{c}_2)^T \mathbf{h}^2 \end{aligned} \quad (11)$$

由于本文的去噪模型可以看作是一种随机神经网络,因此对可视层、隐藏层和转换单元来说,彼此间是相互条件独立的.所以,隐藏层的条件概率分布可以分别定义为:

$$P(h_j^1 = 1 | \mathbf{v}, \mathbf{s}) = \sigma(c_r^1 + \sum_{i=1}^m s_i \cdot v_i W_{ij}^1) \quad (12)$$

$$P(h_j^2 = 1 | \mathbf{v}, \mathbf{s}) = \sigma(c_r^2 + \sum_{i=1}^m (1 - s_i) \cdot v_i W_{ij}^2) \quad (13)$$

式(12)和(13)表明,隐藏层中的两组单元的状态,可通过可视层单元与二值单元的状态转换来确定,这就保

证了模型在训练中,两组隐藏单元能够独立地学习各自类型的重要特征.当确定隐藏层各单元状态后,二值转换单元状态的条件概率分布函数定义为:

$$P(s_i = 1 | \mathbf{v}, \mathbf{h}^1, \mathbf{h}^2) = \sigma(v_i (b_i^1 + b_i^2 + \sum_{j=1}^n W_{ij}^1 h_j^1 + \sum_{j=1}^n W_{ij}^2 h_j^2)) \quad (14)$$

式(14)可以理解为转换单元状态由隐藏层的两组单元根据输入样本和重构样本之间差异反复训练来确定的.相应的,重构的可视层单元由转换层和隐藏层的两组单元共同来确定:

$$P(v_i = 1 | \mathbf{s}, \mathbf{h}^1, \mathbf{h}^2) =$$

$$\sigma(s_i (b_i^1 + \sum_{j=1}^n W_{ij}^1 h_j^1) + (1 - s_i) (b_i^2 + \sum_{j=1}^n W_{ij}^2 h_j^2)) \quad (15)$$

为了计算分类误差,我们采用了线性 SVM 分类器,并将两组隐藏层节点和标签信息作为其输入信息.由于式(12)至式(15)不能直接通过计算获得,本文采用交替 Gibbs 采用方法来近似计算.模型在训练过程中分为两个阶段:正向学习阶段和反向学习阶段.

正向学习阶段:通过输入样本和初始参数,模型对式(12)~(14)进行迭代并采样而获得 $\mathbf{h}^1, \mathbf{h}^2$ 和 \mathbf{s} .

反向学习阶段:通过由正向学习阶段获得的隐藏单元的状态值和转换单元的状态值,模型对式(12)至式(15)进行迭代并采样而获得重构的 $\hat{\mathbf{v}}, \hat{\mathbf{h}}^1, \hat{\mathbf{h}}^2$ 和 \mathbf{s}' .当训练过程中计算梯度时,模型采用对比散度(Contrastive Divergence, CD)算法近似获得梯度.

2.3 算法时间复杂度与收敛性分析

设模型的输入单元个数为 I ,隐藏单元个数为 H ,迭代次数为 n ,对比散度迭代次数为 k_{CD} ,则算法时间复杂度推导过程如下:

第一步:正向学习阶段,其所用时间复杂度为:

$$f_1(n) = O(I \times I \times I \times H \times n \times 4) \quad (16)$$

第二步:反向学习阶段,其时间复杂度为:

$$f_2(n) = O(I \times I \times I \times H \times k_{\text{CD}} \times 6) \quad (17)$$

则整个算法的时间复杂度为:

$$O(f_1(n) + f_2(n)) = O(I^3 \times H \times (n + k_{\text{CD}})) \quad (18)$$

式(18)可以看出,算法中的时间复杂度取决于四个因素:输入单元个数,隐藏层单元个数,算法迭代次数和对比散度迭代次数.

由于本文算法是一种基于马尔科夫蒙特卡罗(MCMC)采样的随机逼近算法,该逼近算法一般表达形式为^[9]:

$$\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}_t - \gamma_t S(\boldsymbol{\theta}_t, N_t) \quad (19)$$

其中, $\boldsymbol{\theta}$ 为待估计的模型参数, $\boldsymbol{\theta}_t$ 为第 t 次参数估计, N_t 是一个符合 $P_n(N)$ 分布的随机变量, γ_t 是阻尼系数,

$S(\cdot, \cdot)$ 是任意函数. 为确保算法能够收敛于 θ^* 状态, 需要满足一定的收敛条件. 根据 Younes 等^[10] 提出收敛理论, 式(19)收敛的条件包括^[11]:

条件 1: 期望值向负梯度方向递减.

条件 2: 期望均方梯度有界.

条件 3: 阻尼系数 γ_t 为非降的正序列.

对于条件 1, 由于我们采用的是基于受限玻尔兹曼机的对比散度 CD 迭代方法, 可保证模型向梯度下降方向迭代, 其详细的证明过程可参考文献[11], 因此条件 1 满足. 对于条件 3, 我们设 $\gamma_t = 1/t, \forall t$ 即可满足. 所以, 只需证明算法满足条件 2 即可说明其收敛性. 对于模型参数 θ , 其对数似然梯度可表示为:

$$S(\theta_k, N_k) = \frac{\partial \log P(\mathbf{v})}{\partial \theta} = -\frac{\partial F(\mathbf{v})}{\partial \theta} + \sum_{\tilde{\mathbf{v}}} P(\tilde{\mathbf{v}}) \frac{\partial(\tilde{\mathbf{v}})}{\partial \theta} \quad (20)$$

其中, $F(\mathbf{v}) = -\log \sum_h e^{-E(\mathbf{v}, s, h)}$, $P(\mathbf{v}) = \frac{1}{Z} e^{-E(\mathbf{v}, s, h)}$.

运用 Fischer 等^[12] 提出的对比散度收敛的引理, 这里以前景隐藏层单元为例证明算法的收敛性. 设起始点为 \mathbf{v}_1 , 其满足收敛条件 1 的吉布斯链为: $\mathbf{v}_1 \Rightarrow \mathbf{h}_1^1 \Rightarrow \mathbf{v}_2 \Rightarrow \mathbf{h}_2^1 \dots$, 只需证明期望均方梯度有界, 即模型参数的对数似然梯度满足:

$$\begin{aligned} \frac{\partial \log P(\mathbf{v}_1)}{\partial \theta} &= -\frac{\partial F(\mathbf{v}_1)}{\partial \theta} + E_{\mathbf{v}_k} \left[\frac{\partial F(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right] \\ &+ E_{\mathbf{v}_k} \left[\frac{\partial \log P(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right] \end{aligned} \quad (21)$$

并且 $E_{\mathbf{v}_k} \left[\frac{\partial \log P(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right]$ 有界.

证明 根据 Fischer 引理, 对数似然梯度可以表示为:

$$\frac{\partial \log P(\mathbf{v}_1)}{\partial \theta} = -\frac{\partial F(\mathbf{v}_1)}{\partial \theta} + \frac{\partial F(\mathbf{v}_k)}{\partial \theta} + \frac{\partial \log P(\mathbf{v}_k)}{\partial \theta} \quad (22)$$

根据引理, 基于 \mathbf{v}_1 条件的马尔科夫链, 其期望为:

$$\begin{aligned} \frac{\partial \log P(\mathbf{v}_1)}{\partial \theta} &= -\frac{\partial F(\mathbf{v}_1)}{\partial \theta} + E_{\mathbf{v}_k} \left[\frac{\partial F(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right] \\ &+ E_{\mathbf{v}_k} \left[\frac{\partial \log P(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right] \end{aligned} \quad (23)$$

对于满足收敛条件 1 的马尔科夫链, 有:

$$P(\mathbf{V}_k = \mathbf{v} \mid \mathbf{V}_1 = \mathbf{v}_1) = P(\mathbf{v}) + \epsilon_k(\mathbf{v}) \quad (24)$$

其中, $\sum_{\mathbf{v}} \epsilon_k(\mathbf{v}) = 0, \lim_{k \rightarrow \infty} \epsilon_k(\mathbf{v}) = 0$. 所以, 式(23)最后一项的期望可以写成如下形式:

$$\begin{aligned} E_{\mathbf{v}_k} \left[\frac{\partial \log P(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right] &= \sum_{\mathbf{v}_k} P(\mathbf{v}_k) \frac{\partial \log P(\mathbf{v}_k)}{\partial \theta} \\ &+ \sum_{\mathbf{v}_k} \epsilon_k(\mathbf{v}_k) \frac{\partial \log P(\mathbf{v}_k)}{\partial \theta} \end{aligned} \quad (25)$$

根据 Fischer 引理, 第一项求和为 0, 而根据极值定

理, 第二项满足下列不等式:

$$\begin{aligned} \left| E_{\mathbf{v}_k} \left[\frac{\partial \log P(\mathbf{V}_k)}{\partial \theta} \mid \mathbf{v}_1 \right] \right| &\leq \sum_{\mathbf{v}_k} |\epsilon_k(\mathbf{v}_k)| \\ &\cdot \frac{\partial \log P(\mathbf{v}_k)}{\partial \theta} \leq (N_{\mathbf{v}} \max_{\mathbf{v}} \left| \frac{\partial \log P(\mathbf{v})}{\partial \theta} \right|) \epsilon_k \end{aligned} \quad (26)$$

其中, $N_{\mathbf{v}}$ 为可视单元的数目. 由此可证对数似然梯度期望有界, 证毕.

3 算法验证

3.1 模型参数设置

为验证算法模型的有效性, 我们以手写数字数据库作为实验对象, 该数据库含有三类不同背景干扰或噪声的手写数字图像库^[13]. 其中, mnist-back-rand 数据库背景干扰为随机噪声; mnist-back-image 数据库背景干扰为黑白图像块; mnist-rot-back-image 数据库为旋转手写数字且背景干扰为黑白图像块. 每个数据库包含 10000 个训练样本, 2000 个检验样本(含标签信息)和 5000 个测试样本(含标签信息). 样本图像参见实验结果及分析部分. 本文模型的参数设置根据数据库类型的不同而有所不同. 表 1 是以 mnist-back-rand 数据库为例, 列举了模型的主要参数及具体数值.

表 1 模型主要参数设置(以 mnist-back-rand 数据库为例)

参数	预训练阶段	训练阶段
输入层节点 m	784	784
隐藏层节点 r	1500	前景: 750; 背景: 750
稀疏性参数 ρ	0.05	0.05
权值衰减系数 λ	0.001	0.001
迭代次数 n	400	400
CD 迭代次数 k_{CD}	30	10

3.2 实验结果及分析

提出去噪受限玻尔兹曼机模型算法的目的在于能够从复杂的背景干扰图像中提取有用的目标特征. 图 2、图 3、图 4 中所示为该算法在三种类型数据获取的特征, 其中, 第一列为样本图像, 可以清楚地看到手写数字及背景干扰的类型. 第二列为 RBM 模型训练后获取的特征, 由于输入的训练样本包含复杂的背景干扰, 所以模型提取的特征含有各种特征, 即包含有用的目标特征, 也包含无用的背景特征. 第三列为算法模型中前景隐藏单元提取的特征, 被称作“笔划”特征. 第四列为背景单元获取的背景特征. 从提取的特征图像可以看到, 该模型的前景隐藏单元可以获取更为简洁的目标特征. 值得注意的是图 4(c) 所示的特征, 虽然 mnist-rot-back-image 数据库中手写数字是以 0 至 2π 角度范围内任意旋转而得到的, 但模型前景隐藏单元提取的“笔划”特征仍然与图 2(c) 和图 3(c) 保持了一致. 从以上这些分析表明, 去噪受限玻尔兹曼机模型算法不但能够

有效地从复杂背景图像中提取有用的目标特征,而且

提取的特征具有更好的简洁性.




图2 mnist-back-rand数据库样本及去噪模型提取的特征




图3 mnist-back-image数据库样本及去噪模型提取的特征




图4 mnist-rot-back-image数据库样本及去噪模型提取的特征

为了定量的分析模型的判别性能,表2列出了各种算法在这三类数据库中的识别效果.从表2可以看到,去噪受限玻尔兹曼机模型获得的分类误差最小,分别为6.45%、10.19%和42.33%.优异的识别性能表明该算法相对于其他方法具有更好的判别性能.

为2.46,2.71和2.87.以上两点分析反映出,去噪受限玻尔兹曼机模型所提取的特征能够有效地逼近训练样本所蕴含的规律,因而具有良好的泛化性能.

图5所示为三种类型数据库的检验样本和测试样本分类误差曲线图和相应的误差取值范围直方图.从误差曲线的走势可以看出,检验样本和测试样本的分类误差变化趋势基本保持一致.而从分类误差的取值范围直方图可以看出,测试样本误差比检验样本误差稍大,但两种误差取值范围比较接近,其均值相差分别

表2 算法分类误差性能比较表

方法	随机噪声背景	图像块背景	旋转加图像块背景
baseline SVM	14.58	22.61	55.18
imRBM ^[14]	10.46	16.35	51.03
discRBM ^[15]	10.29	15.56	48.34
supervised PGBM ^[16]	6.87	12.85	44.67
DBN-3 ^[17]	6.73	16.31	47.39
CAE-2 ^[18]	10.90	15.50	45.23
本文算法	6.45	10.19	42.33

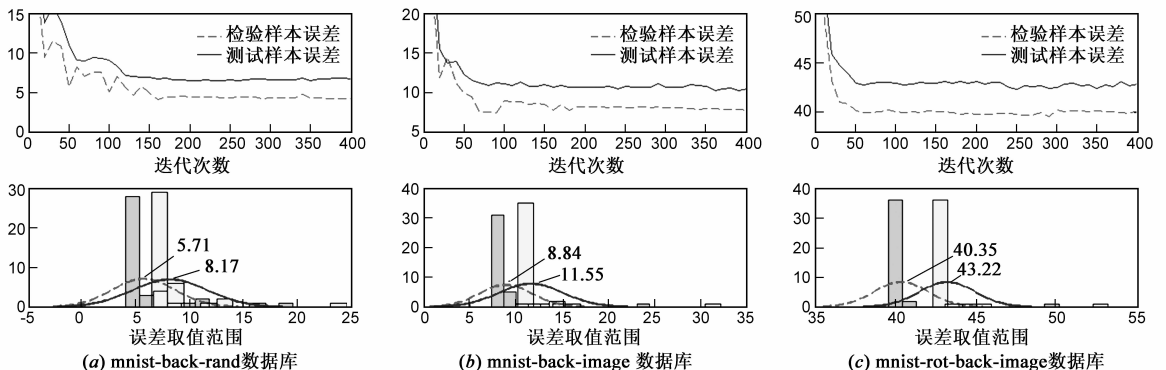


图5 三种数据库的检验样本和测试样本的分类误差

4 结论

从包含复杂背景的图片中提取有用的目标信息是提高目标识别性能的关键. 本文提出的一种鲁棒的目标特征提取算法能够从输入数据中独立地分离前景和背景特征, 并提取与目标有关的特征, 以此来提高目标的识别性能. 通过在 MNIST 库中三种类型背景干扰数据库中识别实验表明, 该算法从复杂的背景干扰中提取的目标特征具有更佳的简洁性、良好的泛化性和优异的判别性能, 因而是一种有效的、鲁棒性的特征提取方法. 在未来的工作中, 我们将对本文的算法进一步扩展至深度随机网络中, 即在本模型的基础上采取多层的去噪 RBM 模型, 从而进一步研究基于深度去噪有限玻尔兹曼机模型算法性能.

参考文献


- [1] R Mittelman, et al. Weakly supervised learning of mid-level features with beta-Bernoulli process restricted Boltzmann machines[A]. Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition[C]. USA: IEEE, 2013. 476 – 483.
- [2] M Ranzato, et al. On deep generative models with applications to recognition[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. USA: IEEE, 2011. 2857 – 2864.
- [3] H Lee, et al. Unsupervised learning of hierarchical representations with convolutional deep belief networks[J]. Communications of the ACM, 2011, 54(10): 95 – 103.
- [4] Le QV, et al. Building high-level features using large scale unsupervised learning [A]. Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing[C]. USA: IEEE, 2013. 8595 – 8598.
- [5] H Goh, et al. Unsupervised and supervised visual codes with restricted Boltzmann machines [A]. Proceedings of European Conference on Computer Vision [C]. Heidelberg Berlin: Springer, 2012. 298 – 311.
- [6] Mohamed, et al. Acoustic modeling using deep belief networks [J]. IEEE Transactions on Audio, Speech, and Language Processing, 2012, 20(1): 14 – 22.
- [7] G E Hinton. Training products of experts by minimizing contrastive divergence[J]. Neural computation, 2002, 14(8): 1771 – 1800.
- [8] M Welling, et al. Exponential family harmoniums with an application to information retrieval[A]. Advances in Neural Information Processing Systems[C]. Cambridge: MIT Press, 2004. 1481 – 1488.
- [9] Sinha N K, Griscik M P. A stochastic approximation method [J]. IEEE Transactions on Systems, Man and Cybernetics, 1971, 4: 338 – 344.
- [10] L Younes. On the convergence of Markovian stochastic algorithms with rapidly decreasing ergodicity rates[J]. Stochastics: An International Journal of Probability and Stochastic Processes, 1999, 65(3 – 4): 177 – 228.
- [11] A Yuille. The convergence of contrastive divergences [J]. Convergence, 2006, 3: 4.
- [12] A Fischer, C Igel. Bounding the bias of contrastive divergence learning[J]. Neural Computation, 2011, 23(3): 664 – 673.
- [13] Dumitru Erhan. Variations on the MNIST digits[DB/OL]. <http://www.iro.umontreal.ca/~lisa/twiki/bin/view/Public/MnistVariations>, 2012-10-23.
- [14] V Nair, G E Hinton. Implicit mixtures of restricted Boltzmann machines [A]. Advances in Neural Information Processing Systems[C]. Cambridge: MIT Press, 2008. 1145 – 1152.
- [15] H Larochelle, Y Bengio. Classification using discriminative restricted Boltzmann machines[A]. Proceedings of International Conference on Machine Learning [C]. New York: ACM, 2008. 536 – 543.
- [16] K Sohn, et al. Learning and selecting features jointly with point-wise gated Boltzmann machines[A]. Proceedings of International Conference on Machine Learning[C]. New York: ACM, 2013. 217 – 225.
- [17] P Vincent, et al. Extracting and composing robust features with denoising autoencoders[A]. Proceedings of International Conference on Machine Learning [C]. New York: ACM, 2008. 1096 – 1103.
- [18] S Rifai, et al. Contractive auto-encoders: Explicit invariance during feature extraction [A]. Proceedings of International Conference on Machine Learning [C]. New York: ACM, 2011. 833 – 840.

作者简介



杨杰 女, 1960年2月出生, 湖北武汉人, 教授、博士生导师. 1978年、1985年、1996年分别在西北电讯工程学院、武汉交通科技大学、上海交通大学获工学学士、工学硕士和工学博士学位. 主要研究方向为计算机视觉与模式识别、信息传输理论及应用.

E-mail: jieyang509@163.com



孙亚东 男, 1977年3月出生, 山东巨野人, 现为武汉理工大学信息工程学院在读博士研究生, 研究方向为图像处理、计算机视觉与机器学习.

E-mail: shunhm-baby@sohu.com