

DOI:10.3969/j.issn.1003-5060.2023.03.006

基于 CNN 和 LSTM 的图像隐写分析

凌宝红^{1,2}, 郑钢¹, 胡敏¹, 彭银银¹, 胡东辉¹

(1. 合肥工业大学 计算机与信息学院, 安徽 合肥 230601; 2. 安徽广播影视职业技术学院 信息工程学院, 安徽 合肥 230011)

摘要: 为了进一步降低隐写分析算法的检测错误率, 文章提出一种基于卷积神经网络(convolutional neural network, CNN)和长短期记忆网络(long short-term memory, LSTM)的隐写分析算法。该算法利用 CNN 捕获载体图像的结构特征, 同时利用 LSTM 捕获图像的前后时序特征。为了验证混合神经网络的有效性, 该算法以 XuNet 和 SRNet 为基准隐写分析网络, 探讨 CNN 与 LSTM 的有效组合方式。实验结果表明, 所提方法可以有效提高隐写分析算法的检测能力。

关键词: 图像隐写分析; 卷积神经网络(CNN); 长短期记忆网络(LSTM)

中图分类号: TP309.2 **文献标志码:** A **文章编号:** 1003-5060(2023)03-0320-07

Image steganalysis based on CNN and LSTM

LING Baohong^{1,2}, ZHENG Gang¹, HU Min¹, PENG Yinyin¹, HU Donghui¹

(1. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China; 2. School of Information Engineering, Anhui Broadcasting Movie and Television College, Hefei 230011, China)

Abstract: To further improve the detection performance of the steganalysis algorithm, this paper proposes a steganalysis algorithm based on convolutional neural network(CNN) and long short-term memory(LSTM). The CNN is used to capture the structural features of cover images, while the LSTM is employed to capture the longer-term temporal feature relations of images in the proposed method. To verify the effectiveness of the hybrid neural network, the proposed method uses XuNet and SRNet as the benchmark steganalysis networks and explores the effective combination of CNN and LSTM. Experimental results show that when combining correctly, the hybrid networks of CNN and LSTM can improve the detection ability compared with the original steganalysis networks.

Key words: image steganalysis; convolutional neural network(CNN); long short-term memory(LSTM)

0 引言

隐写术是指通过将秘密消息嵌入到数字多媒体中实现隐蔽通信的技术。自适应隐写算法根据载体图像内容和待嵌入的秘密信息长度, 自适应选择复杂图像区域或更改后失真较小的位置进行

秘密信息嵌入, 具有更高的抗隐写分析能力。当前图像自适应隐写算法包括基于空域的像素块理优先自适应隐写算法^[1]、HUGO^[2]、S-UNIFORM^[3]和 HILL^[4], 以及 JPEG 域中的 J-UNIFORM 和 UED^[5-6]。

作为隐写术的对抗技术, 传统的隐写分析算

收稿日期: 2022-06-10; **修回日期:** 2022-07-23

基金项目: 国家自然科学基金资助项目(U1836102); 安徽省科技重大专项资助项目(201903a05020016); 安徽省科研编制计划资助项目(2022AH053074); 高校优秀青年骨干教师国内访问研修资助项目(gxgnfx2020132)和高等学校省级质量工程软件技术专业教学团队资助项目(2021jxtd051)

作者简介: 凌宝红(1976—), 女, 安徽怀宁人, 合肥工业大学访问学者, 安徽广播影视职业技术学院副教授;

胡敏(1967—), 女, 安徽合肥人, 博士, 合肥工业大学教授, 博士生导师;

胡东辉(1973—), 男, 安徽望江人, 博士, 合肥工业大学教授, 博士生导师。

法将图像的统计特征作为判别依据,手工设计了多种基于统计的隐写分析模型,其中包括空域模型^[7-8]和 JPEG 域模型^[9-10]。但随着深度学习在隐写算法中的成功应用,基于手工设计的隐写分析算法难以准确分辨隐写图像和原始图像。另外,手工设计的隐写分析算法大多依赖人为经验,需要耗费大量时间与精力,且难以检测基于深度学习的隐写算法。

研究者们将卷积神经网络(convolutional neural network, CNN)^[11-12]赋能到隐写分析算法中。在 JPEG 域中,文献[13]提出了一种基于混合深度学习框架的大尺寸 JPEG 图像隐写分析算法;为了更好地学习载体图像的特征,文献[14]提出了一种基于迁移学习的隐写分析框架;文献[15]设计了多层的 CNN 网络,且为了减少信息丢失,算法中利用卷积层代替模型中的池化层。在空域中,文献[16-17]对基于 CNN 的隐写分析算法进行了初步探索;文献[18]设计了一种具有绝对值层、BN 层和 TanH 激活层的隐写分析网络;文献[19]用线性截断单元作为激活函数并将选择通道与 CNN 网络结合在一起;文献[20]提出了 SRNet,该网络在不使用滤波器的情况下训练出一个检测能力强大的隐写分析特征提取结构,并且能够同时应用于空域和 JPEG 域。

与基于手工特征的隐写分析算法相比,基于 CNN 的隐写分析算法取得了巨大的进步,但针对低嵌入率下的高性能的隐写算法,隐写分析的检测准确率仍有待提高。长短期记忆网络(long short-term memory, LSTM)^[21]是一种特殊类型的递归神经网络(recurrent neural network, RNN),是为了解决 RNN 中长期依赖问题而专门设计出来的。LSTM 中的“门”结构可以过滤无用的信息并保留 LSTM 中的关键信息,它可以通过更改记忆单元的状态来删除和增加相关信息,以允许信息有选择地传递。

现有的基于 CNN 的隐写分析算法未能有效利用每个特征图之间的关系,因此模型在检测复杂多样的隐写信息方面存在局限性。本文提出了一种基于 CNN 和 LSTM 的隐写分析框架。为了探究 CNN 和 LSTM 的有效结合方式,设计了 2 种方案:① 在 CNN 网络的最后一个卷积层添加 LSTM;② 在每个卷积模块处添加 LSTM。为了验证框架的可行性,本文以 Xu-net^[18]为基准网络,设计了 C-LSTM-1 和 C-LSTM-5。实验结果验证了混合神经网络的有效性,特别是在低嵌入

率的情况下。为了更进一步验证混合模型对隐写分析算法的检测降低错误率,所提方法以 SRNet 为基准网络,设计了 SRNet-C-LSTM 结构。最后,通过 Grad-CAM 分析了所设计的方法^[22],以解释 LSTM 对隐写分析网络的影响。

1 所提方法

1.1 C-LSTM 的整体结构

在 C-LSTM 混合网络中, CNN 主要用于提取图像的隐写分析特征并生成特征图。LSTM 中的记忆单元用于存储特征图中的像素点。LSTM 通过特定的设计避免了传统 RNN 网络中长期依赖问题的发生,从而可以高效地保留住长期相关的信息。LSTM 通过一种叫“门”的结构来控制单元中信息的保留和删减。在 LSTM 的运行过程中,通过更新不同层之间隐藏层节点的“存储门”的状态,可以记住特征图中更有效的特征,因此 LSTM 可以参与更高级别特征的提取过程。卷积层使用卷积核提取像素之间的关系并生成特征图,而卷积核的大小通常较小,因此提取的特征主要是着重于局部周围像素之间的关系,而不关联更远的图像区域。在 C-LSTM 结构中, LSTM 可以增强整个图像之间的联系,不再局限于局部相邻像素。LSTM 根据其有效性对每个通道的特征图分配不同的权重,从而最终输入到 Softmax 层中进行分类的特征更有助于隐写分析。

如上所述, C-LSTM 包括 LSTM 部分和 CNN 部分。LSTM 部分使用的是 BiLSTM 双向递归神经网络, CNN 部分使用的是 Xu-net。C-LSTM 的运行过程如下:先将图像解压缩到空域中,然后用 DCT 核进行卷积以获得残差图像;继而将残差图像输入到量化截断层、卷积层、激活函数层、BN 层和 LSTM 层中以提取特征;最后分类结果由 Softmax 层输出。本文设计 2 种类型的 C-LSTM 结构,即 C-LSTM-1 和 C-LSTM-5。C-LSTM-1 在原始的基于 CNN 的 Xu-Net 网络结构上增加了 LSTM 层,旨在优化 CNN 生成的最终特征图。C-LSTM-5 在 Xu-Net 网络结构上增加了 5 个 LSTM 层。原始的 Xu-Net 网络结构可以看作 5 个模块,每个模块包含 2 个残差结构,因此在此结构中,本文向每个模块添加 LSTM,旨在对 CNN 提取特征全过程进行连续优化。C-LSTM-1 和 C-LSTM-5 的详细结构如图 1 所示。

在 SRNet-C-LSTM 结构中,所提方法利用残差结构结合 CNN 和 LSTM。SRNet 特征提取性

能已经非常出色,因此 C-LSTM 的结构不适用于 SRNet。残差结构仅仅在原有特征基础上学习新

的特征,而不是对特征进行重新组织。SRNet-C-LSTM 结构的详细结构如图 2 所示。




图 1 C-LSTM 的网络结构




图 2 SRNet 和 SRNet-C-LSTM 之间的结构差异

1.2 CNN 与 LSTM 结合

LSTM 最重要特性就是时序性。以时间的前后顺序将数据输入 LSTM。为了满足 LSTM 的这一特性,将 CNN 网络生成的特征图分组(按

行、按块和按列等模式)输入到 LSTM。以按行的输入为例。首先,将特征图的第 1 行输入到 LSTM 中,然后在下一刻输入特征图的第 2 行,直到将特征图的每一行输入到 LSTM 中为止。对于每个输入,LSTM 都有一个输出,并且所对应的输出和单元状态会传输到下一个输入,直到 LSTM 结束。LSTM 最终输出所有先前输出的组合,然后再将其传输到 CNN。

1.3 LSTM 和 BiLSTM

RNN 是一种具有特殊结构的神经网络。一般的神经网络的输出仅与当前的输入相关,未考虑输入时序的影响。RNN 在处理与时间序列有关的问题上表现良好,但在 RNN 训练过程中,早期信息将变小甚至消失,从而导致梯度消失或梯度爆炸的问题。为了解决上述问题,研究人员提

出了 LSTM。LSTM 记忆单元结构如图 3 所示,其主要的结构包括 3 个“门”,“门”的作用在于控制信息是否传递,其中的门控单元 f_t 、 i_t 和 o_t 的值均为 0~1 之间。

(1) 遗忘门。该门有选择地遗忘前一刻控制信息 c_{t-1} 。先计算出 f_t , 然后与 c_{t-1} 进行逐元素相乘,从而达到遗忘的目的。 f_t 的计算式为:

$$f_t = \sigma(\omega_f h_{t-1} + \mu_f X_t) \quad (1)$$

(2) 输入门。先计算 i_t , 它的含义是当前状态由哪些元素决定,再计算每个元素的新状态 \tilde{c}_t 。

$$i_t = \sigma(\omega_i h_{t-1} + \mu_i X_t) \quad (2)$$

$$\tilde{c}_t = \tanh(\omega_c h_{t-1} + \mu_c X_t) \quad (3)$$

将以上 2 个步骤的结果逐元素相乘得到结果,再与遗忘门的输出做向量和就可以得出当前单元的状态,然后将其作为隐含层节点状态传给下一个节点。

$$c_t = i_t \tilde{c}_t + f_t c_{t-1} \quad (4)$$

(3) 输出门。该过程决定输出哪些已处理信息。其中

$$o_t = \sigma(\omega_o h_{t-1} + \mu_o X_t) \quad (5)$$

$$h_t = o_t \tanh c_t \quad (6)$$

通常,在 LSTM 中,状态传输是从前向后进行的。当前时刻仅与先前状态有关,而与随后状态无关。因此,每次的输出和单元状态仅与先前的输入有关,而后续的输入不会影响当前时间的输出和状态。当按行输入特征图时,LSTM 仅增强当前行与先前输入线之间的关系,而不能增强整个特征图之间的关系。为了解决这个问题,本文使用 BiLSTM。

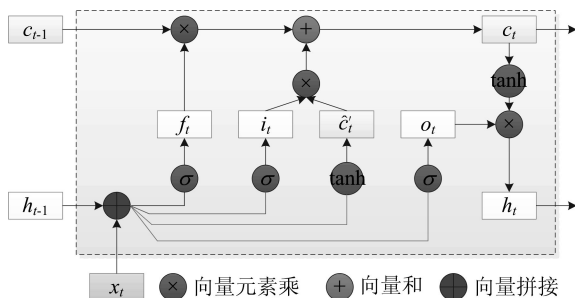


图 3 LSTM 的内部结构

BiLSTM 可以看作是 2 个单向 LSTM 的组合,并且 2 个网络都连接到同一输出层。输出由这 2 个 LSTM 网络控制,如图 4 所示。

BiLSTM 是前向和后向 2 个单向的 LSTM 的组合,因此可以从正反 2 个方向将数据输入到 BiLSTM。通过将 CNN 生成的特征图提供给

BiLSTM,可以将当前时刻输入的行与上一次输入的行,以及随后时刻的行连接起来,以更有效地提取整个图像相似(或特征)之间的关系。




图 4 BiLSTM 的结构示意图

2 实验结果与分析

2.1 实验数据和设置

实验采用 BOSSbase v1.01 作为图像数据集,并将其裁剪分割为 10 000 幅大小为 512×512 的灰度图像。使用高性能显卡 NVIDIA GeForce RTX 2080Ti 来训练网络,并利用 TensorFlow 深度学习框架。

在 JPEG 域中,实验中使用的隐写算法 J-UNIWARD 是迄今为止最安全的 JPEG 隐写方法之一。其中图像质量因子为 75、95,载密图像的嵌入率为 0.1~0.4 bit/像素。在实验预处理过程中,使用传统的处理 JPEG 图像方法将图像从 JPEG 域完整的解压到空域,而没有四舍五入为整数。数据集由 10 000 对载体和载密图像组成,并将其分为训练集和测试集,每个包含 5 000 对图像。CNN 模型的动量设置为 0.9,梯度下降的权重衰减为 0.000 5,学习率设定为 0.01,每 5 000 次迭代降低到 90%。每个训练迭代的输入是 20 幅图像(10 幅体图像和相应的载密图像)。微型批量随机梯度下降法用于解决混合网络模型中 C-LSTM 的反向传播问题。训练中的最大迭代次数固定为 90 000。在模型的预处理层中,用于生成残差图像的滤波内核值是固定的,其学习率和权重衰减率均为 0,反向传播不会更新该层的任何参数。卷积层中卷积内核的参数初始化为 0.01 标准偏差的高斯分布。为验证 SRNet-C-LSTM 的有效性,实验利用 HILL 隐写算法在嵌入率为 0.1~0.4 bit/像素时,进行空域隐写分析实验。

2.2 混合模型的性能分析

研究过程中发现,隐藏层的神经元个数 M 对模型性能有影响。若隐藏层的神经元个数设置太小,则输出的特征维度也将非常小,这将导致

大量的特征信息丢失;若将其设置太大,则特征图的过滤效果将减弱,并且会增加计算量,减慢网络的训练速度。实验发现 C-LSTM-1 的参数 M 设置为 256 和 512 是比较合理的选择。与 C-LSTM-1 相比,C-LSTM-5 模型具有更深的网络模型和更长的训练时间。考虑时间和 GPU 显存的双重限制,C-LSTM-5 的 M 设置为 256。

实验按行将特征图输入到 LSTM 中,超参数 N 代表 LSTM 认为每个输入数据与前多少个连续输入的数据有联系。实验以 C-LSTM-1-256 为基准,在 M 为 256、隐写算法为 J-UNIWARD 且嵌入率为 0.1 bit/像素的情况下,将 N 分别设置为 8、16、32 时,检测错误率分别为 0.367 9、0.363 4、0.368 5。实验结果显示 N 的取值对 C-LSTM-1-256 的性能有一定的影响。当 N 为 16 时,模型的错误率最低,比 N 为 8 的错误率低约 0.4,比 N 为 32 的错误率低约 0.5。因此,后续实验将 N 设置为 16。

C-LSTM-1、C-LSTM-5 和 Xu-netis 在检测质量因子为 75、95,嵌入率为 0.1~0.4 bit/像素的 J-UNIWARD 算法时的实验结果,见表 1 所列。实验结果表明,C-LSTM-1 的性能优于 Xu-net,且 C-LSTM-1 的性能优于 C-LSTM-5。当嵌入率为 0.4 bit/像素时,C-LSTM-5 的性能低于 Xu-net。C-LSTM-5 在 5 个卷积模块的每一个中添加了 5 个 LSTM。当 C-LSTM-5 优化生成特征图时,它可能会导致遗忘掉过多的信息,并且除了丢失冗余信息之外,还可能丢失部分有效信息。因此 C-LSTM-5 的检测错误率高于 C-LSTM-1。C-LSTM-1-256 和 C-LSTM-1-512 的性能不同,但差异很小。

表 1 所提 C-LSTM 结构与 Xu-netis 检测错误率对比

质量因子	嵌入率/ (bit · 像素 ⁻¹)	C-LSTM-1-256	C-LSTM-1-512	C-LSTM-5	Xu-net
75	0.1	0.363 4	0.364 8	0.371 9	0.373 2
	0.2	0.216 5	0.219 3	0.223 9	0.228 7
	0.3	0.123 3	0.122 4	0.127 1	0.128 4
	0.4	0.067 8	0.069 2	0.071 5	0.070 1
95	0.1	0.500 0	0.500 0	0.500 0	0.500 0
	0.2	0.420 4	0.422 5	0.435 7	0.437 4
	0.3	0.328 7	0.325 9	0.330 5	0.332 3
	0.4	0.259 2	0.253 5	0.261 1	0.262 4

LSTM 结构有一些变体,这些变体的整体结构与标准的 LSTM 结构相同,而内部单元结构则

有所不同。GRU 是 LSTM 的变体之一,在一定程度上简化了 LSTM 的内部结构。GRU 中只有更新门和重置门 2 个“门”。其中:更新门是合并输入门和遗忘门形成的;重置门是用来控制前一时刻的单元状态。为了探索标准 LSTM 结构和 GRU 结构对所提出模型性能的影响,以 C-LSTM-1-256 为例,仅将标准 LSTM 结构替换为 GRU 结构以获得 C-GRU-1-256。在 JPEG 压缩的质量因子为 75 和嵌入率为 0.1 bit/像素的情况下,C-LSTM-1-256 和 C-GRU-1-256 的检测错误率分别为 0.363 4 和 0.368 0。由于 C-LSTM-1-256 的检测错误率比 C-GRU-1-256 的检测错误率低约 0.005,这表明标准的 LSTM 结构更加适用于本文提出的模型。GRU 仅包含 2 个“门”,其参数少于标准 LSTM 的参数,因此 C-GRU-1-256 的总体训练速度快于 C-LSTM-1-256 的训练速度。通常,建议的模型使用标准的 LSTM 结构(检测错误率较低),但是若时间要求较高,则可以选择 GRU。当将特征图输入到 LSTM 时,可以按行、列、块 3 种方式输入,逐列输入加强了整个特征图中列之间的关系,按块输入需要首先将特征图划分为一定大小的块,然后将每个块转换为一维向量。以 C-LSTM-1-256 为例,当 JPEG 图像质量因子为 75,嵌入率为 0.1 bit/像素时,探索了输入模式对所提出模型性能的影响。按行、列、块组织数据的检测错误率分别为 0.363 4、0.364 3、0.358 7。其中逐块输入时,C-LSTM-1-256 的检测错误率最低。

为了在更强大的基于 CNN 的隐写分析网络上验证所提出方法的有效性,本文基于 SRNet 设计了 SRNet-C-LSTM 结构。实验使用的隐写算法为 HILL,嵌入率为 0.1~0.4 bit/像素。SRNet-C-LSTM 与原始 SRNet 以及 SCA-YeNet^[19] 相比的实验结果见表 2 所列。显然,SRNet-C-LSTM 的检测性能优于 SRNet 和 SCA-YeNet,但是在低嵌入率情况下的性能提升不是很明显。

表 2 SRNet-C-LSTM 结构与其他结构检测错误率对比

隐写算法	嵌入率/ (bit · 像素 ⁻¹)	SRNet-LSTM-res	SRNet	SCA-YeNet
HILL	0.1	0.316 4	0.318 0	0.338 0
	0.2	0.230 7	0.236 1	0.253 8
	0.3	0.183 4	0.187 8	0.194 9
	0.4	0.148 8	0.153 3	0.170 8

2.3 梯度加权类别激活映射

梯度加权类别激活映射 (gradient-weighted class activation mapping, Grad-CAM) 利用目标卷积层的梯度生成一个热力图,突出显示图像中用于预测的重要区域。本文用此方法分析 LSTM 在网络中发挥的作用,由图 5 所示。图 5a 和图 5e 为原始图片;图 5b 和图 5f 为隐写算法嵌入的位置,图中像素点从冷色调到热色调的程度表示该像素点对网络把该图片标记为载密图像有

正面影响的大小(例如蓝色像素点表明影响小,红色表明影响大);图 5c 和图 5g 为原始网络生成的热力图,它们倾向于标记图像的嵌入位置;图 5d 和图 5h 为混合网络生成的热力图,它们倾向于标记图像嵌入位置和非嵌入位置之间的边界。这是由于 LSTM 将特征图的前后像素点关联起来,从而使对网络性能有正面影响的像素点迁移到了嵌入位置和非嵌入位置的边界。实验结果表明本文所提出的方法在隐写分析方面取得了一定进步。

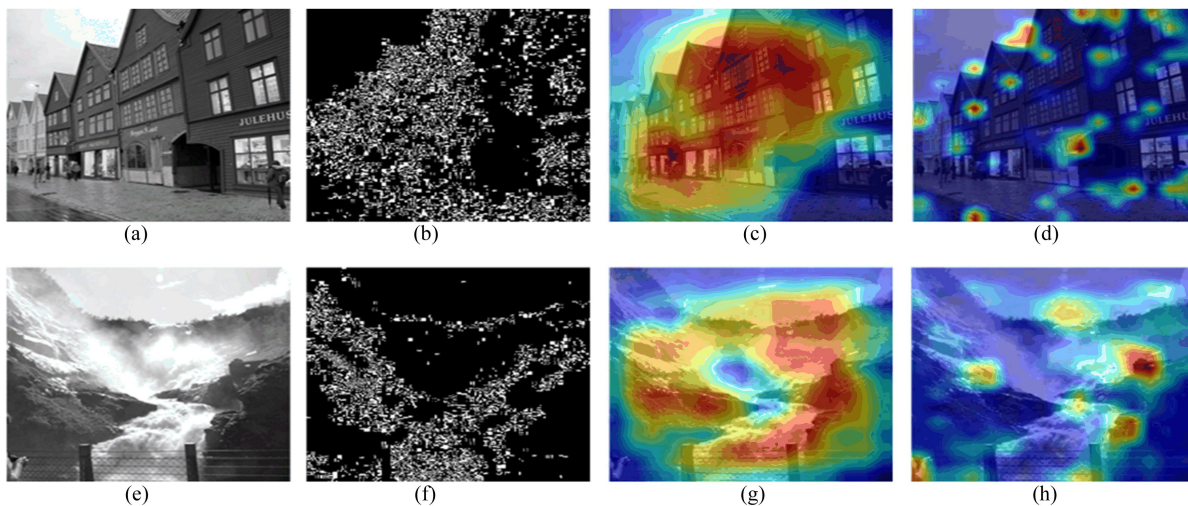


图 5 所提方法与原模型的热力图对比

3 结 论

本文提出了一种基于 LSTM 和 CNN 的混合隐写分析结构 C-LSTM。该结构使用 CNN 提取特征,然后将提取的特征转移到 LSTM 层中优化提取特征之间的联系,以保留有效的隐写分析特征,而忽略不利的特征。实验结果表明:所提出的混合结构相较于原始结构提高了隐写分析检测准确性;将 LSTM 和 CNN 组合的方式以及 LSTM 的特征图输入方式都会影响混合模型的最终性能。根据目前最先进的隐写分析网络 SRNet,本文进一步提出了一种 SRNet-C-LSTM 混合结构,该结构在隐写分析检测性能上比原始的 SRNet 略有提高,实验结果验证了所设计方法的有效性。

【参 考 文 献】

- [1] 师夏阳,马赛兰,胡永健,等.一种基于像素块的纹理优先自适应隐写算法[J].电子学报,2015,43(6):1094-1100.
- [2] PEVNY T, FILLER T, BAS P. Using high-dimensional image models to perform highly undetectable steganography [C]//International Workshop on Information Hiding. [S. l.]: Springer, 2010: 161-177.
- [3] HOLUB V, FRIDRICH J, DENEMARK T. Universal dis-

tortion function for steganography in an arbitrary domain [J]. EURASIP Journal on Information Security, 2014 (1): 1-13.

- [4] LI B, WANG M, HUANG J, et al. A new cost function for spatial image steganography [C]//2014 IEEE International Conference on Image Processing. [S. l.]: IEEE, 2014: 4206-4210.
- [5] GUO L, NI J, SHI Y Q. An efficient JPEG steganographic scheme using uniform embedding [C]//2012 IEEE International Workshop on Information Forensics and Security (WIFS). [S. l.]: IEEE, 2012: 169-174.
- [6] GUO L, NI J, SU W, et al. Using statistical image model for JPEG steganography: uniform embedding revisited [J]. IEEE Transactions on Information Forensics and Security, 2015, 10(12): 2669-2680.
- [7] FRIDRICH J, KODOVSKY J. Rich models for steganalysis of digital images [J]. IEEE Transactions on information Forensics and Security, 2012, 7(3): 868-882.
- [8] HOLUB V, FRIDRICH J. Random projections of residuals for digital image steganalysis [J]. IEEE Transactions on Information Forensics and Security, 2013, 8(12): 1996-2006.
- [9] HOLUB V, FRIDRICH J. Phase-aware projection model for steganalysis of JPEG images [C]//Media Watermarking, Security, and Forensics 2015. [S. l. : s. n.], 2015: 259-269.

(下转第 391 页)

- communities and microbial interactions to long-term heavy metal contamination[J]. *Environmental Pollution*, 2017, 231:908-917.
- [26] GREGERSEN L H, BRYANT D A, FRIGAARD N U. Mechanisms and evolution of oxidative sulfur metabolism in green sulfur bacteria[J]. *Frontiers in Microbiology*, 2011, 2:110-116.
- [27] HILLLE A, HE M, OCHMANN C, et al. Application of two component biodegradable carriers in a particle-fixed biofilm airlift suspension reactor: development and structure of biofilms[J]. *Bioprocess and Biosystems Engineering*, 2009, 32:31-39.
- [28] SALAH Z B, CHARLES C J, HUMPHREYS P N, et al. Genomic insights into a novel, alkalitolerant nitrogen fixing bacteria, *Azoxexus* sp. strain ZS02[J]. *Journal of Genomics*, 2019, 7:1-6.
- [29] TROIS C, COULON F, DE COMBRET C P, et al. Effect of pine bark and compost on the biological denitrification process of non-hazardous landfill leachate; focus on the microbiology[J]. *Journal of Hazardous Materials*, 2010, 181:1163-1169.
- [30] SEBASTIAN L, MICHAEL W, FRANK M, et al. A *Nitrospira* metagenome illuminates the physiology and evolution of globally important nitrite-oxidizing bacteria[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2010, 107(30):13479-13484.
- [31] LI X M, ZHANG W, LIU T X, et al. Changes in the composition and diversity of microbial communities during anaerobic nitrate reduction and Fe(II) oxidation at circumneutral pH in paddy soil[J]. *Soil Biology and Biochemistry*, 2016, 94:70-79.
- [32] 李誉琦, 马佩钰, 刘涵, 等. 一株耐高温亚硝酸盐型反硝化细菌的鉴定及脱氮特性[J]. *生物技术通报*, 2019, 35(9):194-201.

(责任编辑 张淑艳)

(上接第 325 页)

- [10] HOLUB V, FRIDRICH J. Low-complexity features for JPEG steganalysis using undecimated DCT [J]. *IEEE Transactions on Information Forensics and Security*, 2014, 10(2):219-228.
- [11] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11):2278-2324.
- [12] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C]//European Conference on Computer Vision. [S. l.]:Springer, 2014:818-833.
- [13] ZENG J, TAN S, LI B, et al. Large-scale JPEG image steganalysis using hybrid deep-learning framework [J]. *IEEE Transactions on Information Forensics and Security*, 2017, 13(5):1200-1214.
- [14] QIAN Y, DONG J, WANG W, et al. Learning and transferring representations for image steganalysis using convolutional neural network[C]//2016 IEEE international conference on image processing (ICIP). [S. l.]:IEEE, 2016:2752-2756.
- [15] XU G. Deep convolutional neural network to detect J-UNIWARD[C]//Proceedings of the 5th ACM Workshop on Information Hiding and Multimedia Security. [S. l.]:ACM, 2017:67-73.
- [16] TAN S, LI B. Stacked convolutional auto-encoders for steganalysis of digital images[C]//Signal and Information Processing Association Annual Summit and Conference (APSIPA). [S. l.]:IEEE, 2014:1-4.
- [17] QIAN Y, DONG J, WANG W, et al. Deep learning for steganalysis via convolutional neural networks[C]//Media Watermarking, Security, and Forensics 2015. [S. l.]:s. n., 2015:171-180.
- [18] XU G, WU H Z, SHI Y Q. Structural design of convolutional neural networks for steganalysis[J]. *IEEE Signal Processing Letters*, 2016, 23(5):708-712.
- [19] YE J, NI J, YI Y. Deep learning hierarchical representations for image steganalysis[J]. *IEEE Transactions on Information Forensics and Security*, 2017, 12(11):2545-2557.
- [20] BOROUMAND M, CHEN M, FRIDRICH J. Deep residual network for steganalysis of digital images[J]. *IEEE Transactions on Information Forensics and Security*, 2018, 14(5):1181-1193.
- [21] SUNDERMEYER M, SCHLÜTER R, NEY H. LSTM neural networks for language modeling[C]//Thirteenth Annual Conference of the International Speech Communication Association. [S. l.]:s. n., 2012:194-197.
- [22] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: visual explanations from deep networks via gradient-based localization[C]//Proceedings of the IEEE International Conference on Computer Vision. [S. l.]:s. n., 2017:618-626.

(责任编辑 李 凯)