

# 基于改进 Inception 模型的乳腺癌病理学图像分类

李赵旭<sup>1</sup>, 宋涛<sup>2</sup>, 葛梦飞<sup>1</sup>, 刘嘉欣<sup>1</sup>, 王宏伟<sup>1,3</sup>, 王佳<sup>2\*</sup>

<sup>1</sup>新疆大学电气工程学院, 新疆 乌鲁木齐 830000;

<sup>2</sup>大连医科大学基础医学院, 辽宁 大连 110041

<sup>3</sup>大连理工大学控制科学与工程学院, 辽宁 大连 116023;

**摘要** 现有的深度学习方法在癌症的识别中仅利用深层特征, 忽略了浅层网络输出保存的空域细节信息, 从而导致识别精度不理想。为了进一步推进临床应用, 协助医生提高乳腺癌病理诊断的一致性和效率, 提出一种基于改进 Inception-v3 的图像分类优化算法, 该算法通过模型改进、迁移学习对网络模型进行优化。对大型公开数据库病理学图像进行乳腺癌分类, 对所提算法所改进的模型与现有的基于深度学习的图像分类模型进行了比较。实验结果表明, 所提算法所改进的模型不仅优于传统深度学习方法, 准确率达到 96%, 有效地提高了深度学习模型对于乳腺癌诊断的性能, 并且为进一步推进临床应用奠定理论和实践基础。

**关键词** 成像系统; 深度学习; 病理学图像; 图像分类; 卷积神经网络; 迁移学习

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.0817001

## Breast Cancer Classification from Histopathological Images Based on Improved Inception Model

Li Zhaoxu<sup>1</sup>, Song Tao<sup>2</sup>, Ge Mengfei<sup>1</sup>, Liu Jiixin<sup>1</sup>, Wang Hongwei<sup>1,3</sup>, Wang Jia<sup>2\*</sup>

<sup>1</sup>School of Electrical Engineering, Xinjiang University, Urumqi, Xinjiang 830000, China;

<sup>2</sup>School of Basic Medicine Science, Dalian Medical University, Dalian, Liaoning 110041, China;

<sup>3</sup>School of Control Science and Engineering, Dalian University of Technology, Dalian, Liaoning 116023, China

**Abstract** Existing deep learning methods only use deep layer features for recognizing cancer and ignore the spatial information stored in the output of the surface network, yielding unsatisfactory recognition accuracy. To further promote clinical applications and aid doctors improve the consistency and efficiency of breast cancer pathological diagnosis, an improved Inception-v3 image classification optimization algorithm is proposed. This algorithm optimizes the network model through model improvement and transfer learning. Breast cancer was classified based on the pathological images of a large open database. The improved model of the proposed algorithm is superior to the traditional deep learning method, with an accuracy rate of 96%, which effectively improves the performance of the deep learning model for breast cancer diagnosis. Moreover, the proposed algorithm lays a theoretical and practical foundation for further clinical applications.

**Key words** imaging systems; deep learning; histopathological image; image classification; convolutional neural network; transfer learning

**OCIS codes** 170.3880; 110.2960; 100.3008

收稿日期: 2020-08-05; 修回日期: 2020-09-01; 录用日期: 2020-09-10

基金项目: 国家自然科学基金(61863034)

\*E-mail: jiawang@mail.dlut.edu.cn

## 1 引言

乳腺癌是最常见的恶性疾病,在女性中尤为严重,其发病率占有女性新患癌症病例的 15%<sup>[1]</sup>,严重危害女性的健康。病理切片是临床上乳腺癌诊断的金标准。临床上通常需要具有多年工作经验的医师或专家对患者病情进行诊断,但人为诊断的主观性,往往会对诊断结果造成一定的偏差。因此,利用人工智能方法分析和处理医学病理图像数据<sup>[2]</sup>,为临床乳腺癌的筛查、诊断、疗效评估和随访提供科学方法和先进技术,对于减轻医师的负担、对于患者的诊疗和康复具有重要意义<sup>[3]</sup>。

随着计算能力的提高以及数据量的急速增长,深度学习取得了重大的发展<sup>[4-5]</sup>,尤其卷积神经网络(CNN)<sup>[6-8]</sup>在图像的特征提取方面能力尤为突出,在诸如 X 光片图像、核磁共振图像等医疗图像领域的分类和定位应用<sup>[9]</sup>颇多,也取得了非常不错的成果。Naik 等<sup>[10]</sup>提出了一种基于灰度图像的纹理特征和细胞核空间结构相结合的支持向量机特征分类方法,分类的准确率达到 95.8%,但该方法为手工提取细胞核特征,无法对乳腺癌进行自动分类检测。Spanhol 等<sup>[11-12]</sup>根据 82 例乳腺癌病理构建了一个名为 BreakHis 的乳腺癌组织病理学图像数据集。他们从多个放大倍数的乳腺癌病理图像中提取切片,训练 AlexNet 并结合三种融合规则进行分类任务。Bayramoglu 等<sup>[13]</sup>在相同的数据集上采用固定缩放倍数的深度学习方法,该方法达到了较高的识别率。Araújo 等<sup>[14]</sup>提出了一种基于 512×512 像素块的特征提取 CNN 架构,并对 2015 年乳腺癌组织分类挑战赛提供的 249 张高分辨率图像进行分类,该方法使 CNN 能够处理极高分辨率的组织病理学图像,但是模型结构复杂,易造成过拟合现象。Wei 等<sup>[15]</sup>提出了一种基于深度 CNN 的 BiCNN 模型,该模型对标签标定的乳腺癌组织病理学图像进行分类,达到了 97% 的分类正确率,但是该分类方法复杂,计算量大、训练时间过长。

针对以上问题,本文设计了一种基于改进的 Inception-v3 乳腺癌病理学图像分类的算法,并通过迁移学习训练和优化网络参数。利用癌症和肿瘤基因图谱数据库(TCGA)中 1779 张苏木精-伊红(H&E)染色组织切片图像<sup>[16-17]</sup>作为实验数据训练模型。同时在分类结果的敏感度、特异性和准确性方面与其他主流的分类模型进行比较,从而证明所提算法改进的模型的有效性。

## 2 数据收集和预处理

本研究收集来自 TCGA 共计 1779 张 637 例 H&E 染色的组织病理学图像进行“正常组织”和“肿瘤组织”切片的自动分类。使用的标签标准为 TCGA 数据库提供的标签。这些标签是 GDC 数据经过多名经验病理专家共同检查后意见一致的结果。基因组共享数据库的 1779 张完整的图像包含 1215 个肿瘤组织和 564 个正常组织。1779 张完整的病理图像按照 7:2:1 分成三组,分别用于模型的训练、验证和测试。由于整个图像尺寸太大,无法用作神经网络的直接输入,因此使用从整体图像的非重叠块中获得的像素块来训练、验证和测试该网络。数据预处理步骤:1)选择使用 20×放大倍数对图像进行观察,以获取足够的图像特征;2)按照一定尺寸对放大后图像进行切割,此步骤会产生数千至上万块切片;3)在非重叠的像素窗口中将切片平铺,删除仅包含少量信息的切片,即删除所有表面被背景覆盖低于 50% 的图块(所有 RGB 值在颜色空间中均低于 220),切片如图 1 所示;4)根据 7:2:1 的比例将预处理图像数据分类为训练组、验证组及测试组。




图 1 经过图像预处理后的病理切片

Fig. 1 Histopathological patches after image preprocessing

## 3 基于深度学习的乳腺癌病理学图像分类

### 3.1 卷积神经网络

CNN 是广泛应用于机器视觉及医学图像领域

的网络<sup>[18]</sup>。典型的 CNN 结构如图 2 所示,包括卷积层、池化层及全连接层。第一层使用大小为  $a \times a$  的  $n$  个卷积滤波器生成大小为  $i \times i$  的卷积映射(c1)。卷积层输出表达式为

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

式中: $x$  为节点输入输出; $M$  为每个特征图节点区域的集合; $k$  为卷积核矩阵; $b$  为偏置项。池化层由  $p$  个尺寸为  $j \times j$  的特征图组成,进行窗口大小为  $b \times b$  的下采样操作。卷积层通过指定大小的卷积滤波器构成输入信号的特征图<sup>[19]</sup>。池化层对卷积后得到的特征图进行特征缩放整合,池化方式包括平均池化和最大池化两种方式。特征通过网络前向传播到具有单元输出层的全连接层,反向传播学习算法可以通过梯度下降法更新模型参数。

对于含有  $m$  个样本的数据集  $\{(x^{(1)}, y^{(1)})$

$(x^{(2)}, y^{(2)}) \dots (x^{(d)}, y^{(d)}) \dots (x^{(m)}, y^{(m)})\}$ , CNN 模型代价函数为

$$J(\omega, b) = \left\{ \frac{1}{m} \sum_{i=1}^m \left[ \frac{1}{2} \left\| h_{\omega, b}(x^{(i)}) - y^{(i)} \right\|^2 \right] \right\} + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{S_l} \sum_{j=1}^{S_{l+1}} (\omega_{ji}^l)^2, \quad (2)$$

式中: $\lambda$  为权重惩罚项; $n_l$  为网络层数; $S_l$  为第  $l$  层神经元个数; $h_{\omega, b}(x)$  为拟合值。使用随机梯度下降法优化网络参数,使网络整体代价函数最小。使用链式求导法则对每一层权重和偏置进行更新,公式为

$$\omega_{ij}^l = \omega_{ij}^l - \alpha \frac{\partial}{\partial \omega_{ij}^l} J(\omega, b), \quad (3)$$

$$b_i^l = b_i^l - \alpha \frac{\partial}{\partial b_i^l} J(\omega, b), \quad (4)$$

式中: $\alpha$  为学习率。当网络误差损失最小时,得到训练好的模型。

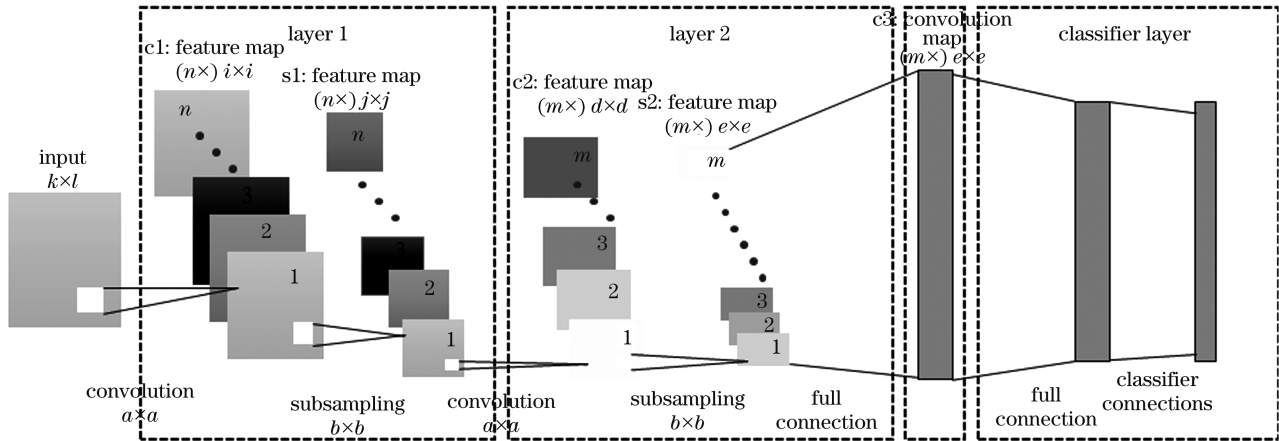


图 2 卷积神经网络框图

Fig. 2 Architecture of convolutional neural network

### 3.2 迁移学习

在医学图像分析和处理中,最常见的问题之一是用于研究的可用数据数量十分有限且稀缺。因此,用少量数据训练像 CNN 这样的深层网络结构可能会导致过度拟合,这通常是低泛化能力的原因。迁移学习<sup>[20]</sup>将训练好的模型参数传递给新模型,以帮助新模型的训练,即在一个非常大的数据集上共享有效且训练有素的网络的学习参数<sup>[21]</sup>。迁移学习的概念是使用一个预先训练好的模型(该模型已经在大数据集上进行了训练),并将其预先训练的学习参数,特别是权值转移到目标网络模型中。为了能够将网络用于解决新数据集分类问题,最后使用预先训练的权重对一个全连接层进行训练。虽然数据集不同于网络训练时使用的数据集,但底层特征是相似的。通过预训练模型的

参数传递,可以为新的目标模型提供一个强大的特征提取能力,减少应变计算时间和存储开销。迁移学习在医学影像学中得到了广泛的应用,在准确性、训练时间和错误率方面表现出了巨大的功效。本研究要将网络参数初始化为 ImageNet 竞赛中最佳的参数集,可采用 Fine-tune 迁移学习方法。Fine-tune 方法基于一个预训练好的深度学习模型,采用相同的网络结构,使用不同于预训练的数据,根据所要完成任务的要求,调整输出,在预训练好的模型参数上进行再训练,解决小数据量情况下的模型训练问题。

### 3.3 模型框架

为使模型更好地适应乳腺癌病理学图像分类实验,对 Inception-v3 模型进行了改进,去掉模型的后三层,增加了 dropout 层进行正则化处理,防止模型

发生过拟合<sup>[22]</sup>。模型结构如图 3(a)所示,其中 Pre-treatment 模块如图 3(b)所示,Inception 模块如

图 3(c)所示,Inception 模块由 1×1、3×3 的卷积层和池化层组成。

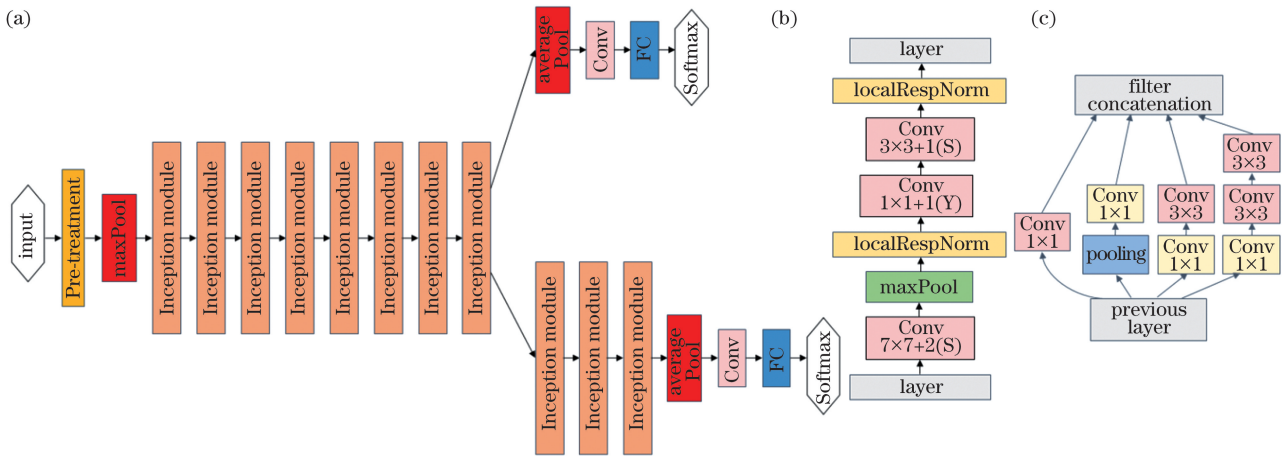


图 3 模型及内部结构图。(a)改进后的模型结构;(b) Pre-treatment 模块结构;(c) Inception 模块结构

Fig. 3 Architecture of model and internal structure. (a) Architecture of improved model; (b) architecture of Pre-treatment module; (c) architecture of Inception module

### 3.4 评价标准

为客观评价所提改进模型的性能,采用敏感度( $S_{en}$ )、特异性( $S_{pe}$ )、准确率( $A_{cc}$ )三个指标对建立模型的性能进行评判。敏感度表示真阳性的概率,数值越高代表诊断越敏感,公式为

$$S_{en} = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (5)$$

特异性表示真阴性概率,数值越高代表诊断越准确,公式为

$$S_{pe} = \frac{N_{TN}}{N_{FP} + N_{TN}} \quad (6)$$

准确率表示预测正确的个数占样本总数的概率,公式为

$$A_{cc} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \quad (7)$$

式中: $N_{TP}$  为被正确分类为阳性的样本个数; $N_{FP}$  为被错误分类为阳性的样本个数; $N_{TN}$  为被正确分类为阴性的样本个数; $N_{FN}$  为被错误分类为阴性的样本个数。

## 4 实验及结果

### 4.1 实验设计

本研究采用的整体训练策略如图 4 所示。其中图 4(a)显示用于训练系统的步骤,包括对从基因组公共数据库下载的乳腺癌病理学图像图片的预处理切割和训练;图 4(b)表示使用已训练模型进行测试,将测试图片分类为正常组织图片与癌症组织图片的过程。采用十折交叉验证法对实验结果进行验证。




图 4 实验整体策略。(a)训练步骤;(b)测试步骤

Fig. 4 Overall strategy of experiment. (a) Process of training; (b) process of testing

## 4.2 实验环境

本实验基于 Ubuntu16.04 系统,采用 TensorFlow 深度学习框架实现乳腺癌病理学的图像分类检测。采用 8 核 3.6GHz 的 CPU,16GB 内存,GPU GTX1080,实验语言为 Python。

## 4.3 数据预处理和参数选定

为了达到最优的病理图像分类效果,对网络模型进行训练。调整网络的图片输入格式、批处理数(batch\_size)、学习率(learning\_rate)等步骤对模型进行初始化。将深度学习中的 Inception-v3 模型引入到乳腺癌病理学图像分类的检测中,选用 Softmax 函数作为损失函数,通过 Inception-v3 基本网络结构,结合一些网络训练技巧,对网络进行修正,从而训练出一种适合病理学图像的模式。

### 1) 模型输入图片格式的选择

模型的训练收敛时间是一项评价模型优劣的重要指标,采用三种图片输入规格对模型进行训练,实验结果如表 1 所示。

表 1 不同图像尺寸下模型的收敛时间

Table 1 Convergence time of model under different the image sizes

Picture size	Convergence times /min
299 pixel×299 pixel	967
512 pixel×512 pixel	713
700 pixel×700 pixel	1219

从表 1 可得出,当选用图片大小为 512 pixel×512 pixel 时,模型达到收敛所需时间最优,该大小模式下的图片特征更为清晰,像素分布更为合理,因此采用该像素值作为病理学图像分类的输入格式。

### 2) batch\_size 的选择

batch\_size 的选取策略需要考虑计算机内存和 GPU 显存等资源、数据集样本量及输入图片尺寸。对于大批量训练场景,需要确保使用更为合适的 batch\_size,避免出现内存溢出等情况,通过实验比较,最终确定的 batch\_size 为 200。

### 3) learning\_rate 的选择

learning\_rate 作为深度学习中重要的参数,决定着目标函数能否收敛到局部最小值及何时收敛到最小值。合适的学习率能够使目标函数在合适的时间内收敛到局部最小值。在相同的网络结构下,分别选取 0.1,0.01,0.001 的 learning\_rate 进行训练,实验结果如表 2 所示。

表 2 learning\_rate 对应的测试结果

Table 2 Test results corresponding different learning\_rate

learning_rate	Precision /%	Recall /%
0.1	86.3	75.1
0.01	91.7	89.4
0.001	96.1	93.1

从表 2 可以看出,准确率(precision)与召回率(recall)均随着 learning\_rate 的降低而上升。大的 learning\_rate 会导致实验结果跳过最优点而取得局部最优点,使准确率偏低;而小的学习率虽然会使训练速度相对降低,但会取得更接近最优点的结果,所以准确率和召回率相对偏高。

最终确定的训练模型输入图像尺寸为 512 pixel×512 pixel, batch\_size 设定为 200, learning\_rate 设定为 0.001。确定好网络结构及参数后,接下来进行模型训练,图 5 为模型训练过程中损失的变化情况。可以看出:在训练初期,初始化网络权重时,网络整体稳定性较差,损失值较大且有一定波动;随着网络迭代次数的增加,网络稳定性逐渐增强,迭代到 10000 次时,损失值逐渐下降,当迭代到 30000 次时,损失值趋于稳定,训练总计迭代 60000 次。损失值最终收敛于较为合理的区间值,模型稳定。




图 5 训练迭代过程中损失的变化

Fig. 5 Loss change during training iterative process

## 4.4 模型敛时间对比

对所提模型与其他几种经典的深度模型进行关于训练过程中收敛时间的对比,结果如表 3 所示。所提模型在收敛速度上较为出色,相较其他网络模型,有更大的实用价值。

表 3 不同模型的收敛时间

Table 3 Convergence time of different models

Model	Convergence times/min
LeNet	1346
AlexNet	1120
VGG-16	1219
GoogleNet	927
Proposed model	713

#### 4.5 实验结果及分析

采用十倍交叉验证方法对实验结果进行验证。十倍交叉验证将数据集分成 10 个大小相同的部分,每次依次取一部分作为测试集,其余部分作为训练集,最后取 10 个结果的平均值作为模型的度量值估

表 4 不同模型的性能

Table 4 Performance of the different models

Model	Sensitivity / %	Specificity / %	Accuracy / %
LeNet	76.32	77.83	74.57
AlexNet	89.23	91.22	90.10
VGG-16	93.15	96.17	93.21
GoogleNet	96.1	93.1	95.19
Proposed model	96.13	98.47	96.12

## 5 结 论

提出了一种基于深度学习的乳腺癌病理学图像分类方法。通过改进的 Inception-v3 模型对网络结构进行优化及适时地引入 dropout 层等措施,解决了传统图像分类方法中网络结构复杂易于过拟合等问题。同时,使用迁移学习方法对网络参数进行初始化,训练病理学图像分类模型。实验结果表明,与各类传统的深度学习模型相比,所提针对乳腺癌病理学图像的分类方法具有较高的准确性。在未来的工作中,将使用所提算法改进的模型解决其他医学图像的分类任务并尝试在多分类任务领域对其进行研究。

### 参 考 文 献

- [1] Coudray N, Ocampo P S, Sakellaropoulos T, et al. Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning[J]. Nature Medicine, 2018, 24(10): 1559-1567.
- [2] Guo L L, Li Y N. Histopathological image classification algorithm based on product of experts [J].

计值。十倍交叉验证的步骤为

1) 将数据集平均分为 10 部分,每部分包含相同数量的图像;

2) 一次选择一个部分作为测试集,其余的数据集作为模型输入来训练模型;

3) 训练结束后,依次记录测试集的真阳性、假阳性、真阴性、假阴性;

4) 取 10 个记录的平均值,得到最终测试结果的平均灵敏度和平均特异性。

对所提算法所改进的模型和其他几种经典的深度学习模型进行比较,实验结果如表 4 所示。可看出,与其他的深度学习模型相比,所提模型具有更好的敏感度、特异性及准确率,表示该模型在对乳腺癌病理学图像进行分类的工作当中具有可行性。

Laser & Optoelectronics Progress, 2018, 55(2): 021008.

郭琳琳, 李岳楠. 基于专家乘积系统的组织病理图像分类算法[J]. 激光与光电子学进展, 2018, 55(2): 021008.

- [3] Veta M, Pluim J P W, van Diest P J, et al. Breast cancer histopathology image analysis: a review [J]. IEEE Transactions on Biomedical Engineering, 2014, 61(5): 1400-1411.
- [4] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [5] Fang L, Wang C, Li S, et al. Attention to lesion: lesion-aware convolutional neural network for retinal optical coherence tomography image classification [J]. IEEE Transactions on Medical Imaging, 2019, 38(8): 1959-1970.
- [6] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [7] Zhou F Y, Jin L P, Dong J. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40(6): 1229-1251.
- [8] Liu J P, Yang Y Z, Chen M Y, et al. Image

- dehazing algorithm based on convolutional neural network and dynamic ambient light[J]. *Acta Optica Sinica*, 2019, 39(11): 1110002.
- 刘洁平, 杨业长, 陈敏园, 等. 结合卷积神经网络与动态环境光的图像去雾算法[J]. *光学学报*, 2019, 39(11): 1110002.
- [9] Murtaza G, Shuib L, Abdul Wahab A W, et al. Deep learning-based breast cancer classification through medical imaging modalities: state of the art and research challenges [J]. *Artificial Intelligence Review*, 2020, 53(3): 1655-1720.
- [10] Naik S, Doyle S, Agner S, et al. Automated gland and nuclei segmentation for grading of prostate and breast cancer histopathology [C] // 2008 5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro, May 14-17, 2008, Paris, France. New York: IEEE Press, 2008: 284-287.
- [11] Spanhol F A, Oliveira L S, Petitjean C, et al. A dataset for breast cancer histopathological image classification[J]. *IEEE Transactions on Biomedical Engineering*, 2016, 63(7): 1455-1462.
- [12] Spanhol F A, Oliveira L S, Petitjean C, et al. Breast cancer histopathological image classification using convolutional neural networks[C]//2016 International Joint Conference on Neural Networks (IJCNN), July 24-29, 2016, Vancouver, BC, Canada. New York: IEEE Press, 2016: 2560-2567.
- [13] Bayramoglu N, Kannala J, Heikkilä J. Deep learning for magnification independent breast cancer histopathology image classification [C] // 2016 23rd International Conference on Pattern Recognition (ICPR), December 4-8, 2016, Cancun, Mexico. New York: IEEE Press, 2016: 2440-2445.
- [14] Araújo T, Aresta G, Castro E, et al. Classification of breast cancer histology images using convolutional neural networks [J]. *PLoS One*, 2017, 12 (6): e0177544.
- [15] Wei B Z, Han Z Y, He X Y, et al. Deep learning model based breast cancer histopathological image classification [C] // 2017 IEEE 2nd International Conference on Cloud Computing and Big Data Analysis (ICCCBDA), April 28-30, 2017, Chengdu, China. New York: IEEE Press, 2017: 348-353.
- [16] Ehteshami Bejnordi B, Veta M, Johannes van Diest P, et al. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer [J]. *JAMA*, 2017, 318 (22): 2199-2210.
- [17] Meng T, Liu Y H, Zhang K Y. Algorithm for pathological image diagnosis based on boosting convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2019, 56(8): 081001.
- 孟婷, 刘宇航, 张凯昱. 一种基于增强卷积神经网络的病理图像诊断算法[J]. *激光与光电子学进展*, 2019, 56(8): 081001.
- [18] Li H, Zhang L M, Jiang M R, et al. Multi-focus image fusion algorithm based on supervised learning for fully convolutional neural networks[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081015.
- 李恒, 张黎明, 蒋美容, 等. 基于监督学习的全卷积神经网络多聚焦图像融合算法[J]. *激光与光电子学进展*, 2020, 57(8): 081015.
- [19] Deng L. Deep learning: methods and applications [J]. *Foundations and Trends © in Signal Processing*, 2014, 7(3/4): 197-387.
- [20] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [21] Shin H C, Roth H R, Gao M C, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1285-1298.
- [22] Alom M Z, Yakopcic C, Nasrin M S, et al. Breast cancer classification from histopathological images with inception recurrent residual convolutional neural network[J]. *Journal of Digital Imaging*, 2019, 32 (4): 605-617.