混合 Q: 混合经典-量子生成对抗网络用于皮肤病图 像生成

Qingyue Jiao¹, Kangyu Zheng², Yiyu Shi¹, and Zhiding Liang²

¹ University of Notre Dame, Notre Dame IN 46556, USA qjiao@nd.edu

² Rensselaer Polytechnic Institute, Troy NY 12180, USA

摘要 机器学习辅助诊断在皮肤疾病检测中越来越受欢迎,但训练有效的 模型需要大量高质量的数据。皮肤疾病数据集经常面临类别不平衡、隐私 问题和目标偏差,使得数据增强变得至关重要。虽然经典生成模型被广泛 使用,但它们需要大量的计算资源和漫长的训练时间。量子计算提供了一 个有前景的替代方案,但现有的基于量子的图像生成方法只能产生灰度低 质量图像。通过一种新颖的经典-量子潜在空间融合技术,我们的工作克服 了这一限制,并引入了第一种能够生成彩色医学图像的经典-量子生成对抗 网络(GAN)。我们的模型在图像生成质量和分类性能提升方面优于经典 深度卷积 GAN 和现有的混合经典-量子 GAN,当用作数据增强时也是如 此。此外,性能提升与使用最先进的经典生成模型所达到的相当,但参数 减少了超过 25×,训练周期减少了 10×。这样的结果表明,随着量子硬件 的发展,量子图像生成有着光明的未来。最后,我们在带有硬件噪声的真 实 IBM 量子机器上展示了我们模型的强大性能。

Keywords: 量子机器学习 · 医学图像生成 · 皮肤病诊断。

1 介绍

常见的数据增强技术包括基于深度学习的方法,如卷积神经网络和生成 模型,以及传统的增强技术,例如随机裁剪、旋转和平移[12]。生成模型可 以用来生成高质量的合成图像,这些图像可以用作数据集的增强。生成模型 的例子包括生成对抗网络(GANs)[21]和基于扩散的模型[5]。虽然这些模 型在图像生成方面展示了令人鼓舞的结果,但它们仍然面临诸如训练时间长 和模式崩溃等挑战。量子计算最近因其可能增强机器学习而受到关注,包括 混合经典-量子 GANs,它在优化和效率上提供了有前景的优势。然而,由于 噪声和 Noisy Intermediate-Scale Quantum (NISQ)硬件的规模限制,混合

经典-量子 GANs 的模型容量显著小于经典的生成模型,这限制了它们生成高复杂度逼真图像的能力。

在这项工作中,我们引入了 HybridQ,它建立在一个新的经典和量子潜 在空间融合的概念之上。这使得混合的经典-量子 GAN 能够缓解量子计算 机中的可扩展性和噪声问题,并且首次在文献中实现了量子计算机生成实用 的彩色医学图像。生成的图像被用于两个皮肤疾病数据集的数据增强评估: ISIC 2019 皮肤病变数据集 [20] [3] [4] 和 Fitzpatrick17k 数据集 [7] [6] 。视 觉和定量评估均表明,与经典深度卷积 GAN[17] 和最先进的混合经典-量子 GAN MosaiQ[18] 相比,HybridQ 可以生成质量更高且变化更多的图像。然 后在分类任务中测试这些生成的图像以评估其增强性能,在这方面 HybridQ 再次优于其他两种方法。此外,即使存在量子硬件限制,HybridQ 实现的精 度/召回率改进与最先进的医疗图像生成模型 VQ-MAGE[21] 相当,后者需 要超过 25 倍的参数和 10 倍的训练时间。随着量子硬件错误校正和可扩展性 的快速进步,尽管尚未超越最先进的经典生成模型性能,HybridQ 在未来具 有快速高效地生成高质量医疗图像的巨大潜力。HybridQ 的鲁棒性在 IBM Brisbane 量子机器上进行了评估。

2 背景

量子计算因其独特的量子力学性质,如叠加、纠缠和平行性,在量子机器学习领域引起了极大的兴趣。变分量子电路(VQCs)是量子机器学习算法的基本组成部分。VQCs中的门具有可调参数,并通过利用已建立的经典损失函数和优化技术以混合方式训练。

混合经典量子生成对抗网络首次在 [13] 中提出,作者展示了量子相对于 经典生成对抗网络的潜在优势。在 [11] 中的量子生成器表现出与经典生成 对抗网络相当的性能,同时使用了 94.98% 更少的参数。半监督 qSGAN[15] 表明,量子生成器丰富的表达能力可能解决经典的难以处理的分类问题。为 了追求更高的图像生成质量,QGPatch[10] 和 MosaiQ[18] 采用了量子子生 成器和降维技术以增强量子生成对抗网络的可扩展性。尽管已经做出了努 力,可扩展性仍然是一项重大挑战:QGPatch[10] 处理 8CE8 灰度图像,而 MosaiQ[18] 则在 28CE28 灰度图像上进行了评估。

3



图 1: HybridQ 的工作流程。黑色箭头表示训练处理的流程。橙色箭头表示 推理过程的流程。

3 方法

3.1 基于潜在空间的训练

图 1展示了 HybridQ 的整体结构。为了提高可扩展性,我们提出了一种 基于潜在空间的新型训练方案。我们不是在原始图像上训练量子生成器,而 是采用一个简单而强大的经典预处理层将真实图像转换为其潜在表示形式。 预处理层包括一个 4x4 卷积,接着是一个泄漏修正线性单元 (Leaky ReLU)。 前馈层将展平的输出映射到 100 维特征空间中。我们将具有相同潜在维度的 自适应噪声向量输入量子生成器组中,如第 3.2 节所示。这种基于量子生成 器与经典判别器之间训练损失比率更新的自适应噪声减轻了类内模式崩溃, 并提高了生成图像的多样性 [18]。

在推理过程中,一个经典的后处理层从量子输出中重构图像。经典后处 理层接收来自量子生成器的100维输出,并通过一层前馈层进行解码,然后 是一个 ReLU 函数。一个3x3卷积后面跟着双曲正切函数(Tanh)输出生成 的图像。

这种基于潜在空间的训练和推理方法缓解了硬件约束,并最大化了量子 信息处理的潜力。先前的工作[2]已经探索了基于潜在空间的量子生成器;然 而,完全的量子 GAN——包含量子生成器和量子判别器——很难扩展。此 外,我们的目标不是完全抛弃已经表现出色的经典组件。我们旨在结合经典 计算能力和量子计算能力的优势。这种基于潜在空间的方案使我们能够构建 首个用于复杂彩色图像的混合经典-量子 GAN。

3.2 量子生成器

在 HybridQ 中,生成器是一个混合的经典-量子网络,判别器由一个经 典卷积神经网络组成 [17]。量子生成器由量子子生成器构成,每个作为变分 量子电路实现,如图所示 2。特征在子生成器之间的分布不仅提高了可扩展 性,还缓解了当前量子硬件的噪声问题。每个变分量子子生成器包括三个 主要部分:数据编码门、可训练量子门和测量门。变分电路设计遵循类似于 MosaiQ[18] 的结构,因为这种浅层且简洁的设计提供了足够的表达能力,而 不会引发贫瘠高原 [14] 问题,这是当量子电路变得复杂时出现的优化挑战。 数据编码块具有固定的参数,并将经典特征编码为每个量子比特上的旋转角 度。中心量子层由六个量子门组重复组成。第一个旋转门具有可调的旋转角 度并使用单个量子比特处理信息。接下来的受控非(CNOT)门在连续的量 子比特之间创建纠缠,这一独特的量子属性有效增加了量子电路的表达能 力。最后,测量门产生潜在空间中的经典输出。



图 2: 变分量子电路假设设计的每个量子子生成器

4 实验

4.1 数据集、指标和基线

HybridQ 在 ISIC 2019 数据集上进行了评估,这是一个包含九类诊断分 类 [20] [3] [4] 的皮肤镜图像数据集,并且在 Fitzpatrick17k 数据集上也进行 了测试,该数据集是一种带有 Fitzpatrick 皮肤类型标签的皮肤病数据集 [7]

[6]。从 ISIC 2019 中选择了三个类别用于混合 GAN 网络的训练和评估:黑 色素瘤 (MEL)、黑素细胞痣 (NV) 和基底细胞癌 (BCC)。每个类别的训练 样本分别为 4114、11419 和 3317。Fitzpatrick17k 数据集被划分成三个更高 级的类别:良性 (B)、恶性 (M) 和非肿瘤性 (NE)。每个类别的训练样本数 量分别为 1339、1357 和 7221。对于两个数据集,所有图像都调整为 64Œ64 的大小。训练样本根据类别标签分开,并且对每个类别训练了一个无条件的 GAN。

生成的图像通过 Fréchet Inception Distance (FID) 分数 [9] 来评估,该 分数计算真实图像和生成图像在深度特征空间中的分布距离。在此工作中, Inception v3[19] 被用作特征提取器。较低的 FID 分数表示更好的生成质量。

为了评估数据增强的有效性,我们对 ResNet-50[8] 进行了微调,使用不同比例的真实图像和生成图像进行混合。混合比例 α 定义为训练数据集中 生成图像的比例。两个数据集在类别中的训练样本数量都不平衡。我们保 持相同的类别分布,并使用原始数据集的 10% 部分,通过添加生成图像来 增强它。测试图像仅来自真实数据集。用于微调分类模型的学习率设置为 1×10⁻³。分类性能使用准确率 (ACC)、精确度和召回率进行评估。



图 3: 生成图像的视觉评估。

生成和增强性能对比了经典的和量子的生成模型。作为经典基线,我 们使用 DCGAN (630 万参数),遵循在 [17] 中的实现。DCGAN 训练了 100 个周期。MosaiQ[18] (3921 参数)是最先进的混合量子 GAN 网络。原始的

表 1: FID 分数 (↓) 用于评估在 ISIC 2019 (左侧) 和 Fitzpatrick17k (右侧) 中生成的不同皮肤病图像。

模型	熔断器	NV	BCC	模型		М	不导电
DCGAN [17]	21.23	16.51	19.60	DCGAN [17]	25.16	28.42	26.56
MosaiQ [18]	36.22	53.39	43.00	MosaiQ [18]	36.22	53.39	43.00
VQ-MAGE [21]	10.91	9.88	7.18	VQ-MAGE [21]	7.18	6.99	6.05
HybridQ	14.93	21.76	13.29	HybridQ	18.34	13.29	9.99

MosaiQ 架构设计用于 28Œ28 灰度图像,包含 8 个量子子生成器,每个有 5 个量子比特。为了扩大模型规模,我们使用了 10 个量子子生成器,每个含有 10 个量子比特。MosaiQ 在 IBM 的量子模拟器上训练了 500 个周期。此外,还使用了一个带有适配器 [21] 的预训练 VQ-MAGE 模型用于医学图像生成 (约 9400 万可训练参数),因为它代表了医学数据集高质量图像生成的最先 进技术。该适配器经过 1000 个周期的微调以达到收敛。最后,对于 HybridQ (370 万参数),它使用 PyTorch[16] 和 Pennylane[1] 进行训练。训练在 IBM 的量子模拟器上完成。Adam 优化器被使用,量子电路的学习率为 0.3,经典 预处理和后处理层的学习率为 2×10^{-4} ,鉴别器的学习率为 2×10^{-3} 。由于 IBM 量子模拟器的限制,HyrbidQ 训练了 100 个周期。



(a) 图像质量 (FID) 与训练周期的关系



(b) 增强性能(召回率)与混合比例

图 4: 图像质量和使用增强数据微调的分类模型的性能,均在 Fitzpatrick17k 上进行评估。

7

4.2 生成性能

图 3展示了来自各种模型的随机采样生成图像。表 1列出了每个模型在 训练结束时的 FID 分数。

我们从 HybridQ 与经典和最先进的混合经典-量子生成对抗网络(GAN) 的比较开始。从图 3可以看出,DCGAN 产生的图像明显模糊,特征不够清 晰。MosaiQ 是目前最先进的混合经典-量子 GAN,未能生成有意义的图像。 这可能是因为它使用主成分分析(PCA)进行降维,并使用 PCA 的逆变换 从量子输出中重构图像。虽然 PCA 对较小的灰度图像效果很好,但对于更 复杂的数据集会导致信息丢失。HybridQ 由于具有经典预处理和后处理层, 保留了足够的信息。生成的图像显示出清晰的特征,与每类的真实图像非常 相似,并且比 DCGAN 的图像模糊程度低。然而,在 Fitzpatrick17k 数据集 上的生成质量并不是很好。由于 Fitzpatrick17k 包含人体部位的图像并且训 练样本数量较少,因此跨类别学习分布更具挑战性。这一点在良性与恶性类 别的生成图像中尤为明显。对于非肿瘤图像,其具有显著更多的训练样本, HybridQ 成功地生成了与真实图像相似的图像。

定量上,HybridQ 在除一个类别外的所有类别中都实现了比 DCGAN 更低的 FID 分数,并且其 FID 评分始终低于 MosaiQ。为了进一步研究经 典和量子 GAN 的训练过程,图 4(a)显示了不同方法在 Fitzpatrick17k 数 据集上前 30 个训练周期中的 FID 分数。从该图可以看出,HybridQ 的 FID 分数最快达到稳定。这表明量子 GAN 具有加速学习的潜力。随着量子硬件 的进步,量子模型在图像生成中的优势和加速效果将会更加明显。此外,从 表 1可知,在训练样本有限的情况下,如 Fitzpatrick17k 中良性 (B)和恶性 (M) 类别中,HybridQ 也表现出色,证明其能够有效学习少量真实图像的 分布。

接下来,我们将 HybridQ 与最先进的经典医学图像生成模型 VQ-MAGE 进行比较。从图 3可以看出,预训练的 VQ-MAGE 模型表现出了最好的整体 结果;这一结论也得到了表 1结果的支持。值得注意的是,VQ-MAGE 利用 了一个预训练的 MAGE 模型,并进一步通过适配器对模型进行了微调。这种训练和微调过程需要大量的数据以及计算资源,如图 4 (a) 所示。仅仅微 调适配器就需要 1000 个周期才能收敛,而 HybridQ 仅需从头开始使用 100 个周期进行训练,减少了 10×。

	ISIC 2019			菲茨帕特里克 17k		
	准确率 (%)	精度	回忆	准确率 (%)	精度 回忆	
无八月	71.67	0.62	0.56	56.89	$0.56 \ 0.56$	
深度卷积生成对抗网络 [17]	73.67	0.67	0.68	60.00	$0.60 \ 0.59$	
MosaiQ[18]	70.06	0.56	0.62	51.25	$0.49 \ 0.50$	
VQ-MAGE[21]	76.22	0.74	0.71	61.33	$0.62 \ 0.61$	
混合量子	74.67	0.72	0.70	61.22	$0.62 \ 0.62$	

表 2: 分类模型使用不同方法生成的数据进行微调的准确性、精确性和召回率。

4.3 增强性能

为了验证生成的图像在扩充医学数据集和提高诊断结果方面的有效性, 我们使用不同比例的方法生成的图像与真实图像对 ResNet-50 进行了微调。 图 4(b) 展示了随着训练数据集中生成图像比 α 例变化时分类召回率的变化。 从图表中我们可以看到,随着训练样本数量的增加,性能首先提升,但当生 成的图像占据训练数据集大多数时,分数开始下降。表 2展示了在两个数据 集中使用最优混合比例微调后的 ResNet-50 的准确性、精确性和召回率。

我们首先将 HybridQ 与经典和最先进的混合经典-量子 GAN 进行比较。从表 2可以看出,与 DCGAN 和 MosaiQ 相比,HybridQ 达到了最高的性能提升。由于 MosaiQ 无法生成高质量的图像,这对其性能产生了负面影响。与仅使用真实数据微调的 ResNet-50 相比,混合 HybridQ 生成的图像分别在 ISIC 2019 和 Fitzpatrick17k 上提高了 3% 和 4.33% 的准确率。HybridQ 还将精度分别提高了 0.10 和 0.06, 召回率分别提高了 0.14 和 0.06,在 ISIC 2019 和 Fitzpatrick17k 上。

接下来,我们将 HybridQ 与最先进的医学图像生成模型 VQ-MAGE 进行比较。从表 2可以看出,虽然 VQ-MAGE 的准确率增益略高于 HybridQ,但两者在精度和召回率方面几乎相同的改进,这些是不平衡数据集的关键指标。再次注意,VQ-MAGE 使用了一个预训练的 MAGE 模型,该模型比HybridQ 大 25×倍,并且训练适配器所需的周期数比从头开始训练 HybridQ 多 10×个。

9

4.4 混合量子在真实 NISQ 计算机上

最后,HybridQ 中的经典神经网络层不仅有助于扩展性,还减轻了真实 量子硬件的噪声。为了证明这一点,我们在 IBM 的后端机器 Brisbane 上运 行训练好的 HybridQ 来生成皮肤病图像,该机器有 127 个量子比特。生成的 图像在 ISIC 2019 中分别为 MEL、NV 和 BCC 以及 Fitzpatrick17k 中的 B、 M 和 NE 实现了 23.25、24.76、15.59、21.65、18.75 和 10.25 的 FID 分数。与 表 1中从量子模拟器获得的结果相比,FID 分数没有显著增加。

5 结论

在这项工作中,我们介绍了HybridQ,这是一种用于皮肤疾病图像生成和数据集扩增的新颖混合经典-量子GAN。HybridQ是首个能够生成复杂彩色图像的混合经典-量子GAN。随着量子硬件在错误纠正和扩展方面的持续进步,增强型量子医疗图像处理将在更多实际医学成像应用中提供益处。

参考文献

- Bergholm, V., Izaac, J., Schuld, M., Gogolin, C., Ahmed, S., Ajith, V., Alam, M.S., Alonso-Linaje, G., AkashNarayanan, B., Asadi, A., Arrazola, J.M., Azad, U., Banning, S., Blank, C., Bromley, T.R., Cordier, B.A., Ceroni, J., Delgado, A., Matteo, O.D., Dusko, A., Garg, T., Guala, D., Hayes, A., Hill, R., Ijaz, A., Isacsson, T., Ittah, D., Jahangiri, S., Jain, P., Jiang, E., Khandelwal, A., Kottmann, K., Lang, R.A., Lee, C., Loke, T., Lowe, A., McKiernan, K., Meyer, J.J., Montañez-Barrera, J.A., Moyard, R., Niu, Z., O'Riordan, L.J., Oud, S., Panigrahi, A., Park, C.Y., Polatajko, D., Quesada, N., Roberts, C., Sá, N., Schoch, I., Shi, B., Shu, S., Sim, S., Singh, A., Strandberg, I., Soni, J., Száva, A., Thabet, S., Vargas-Hernández, R.A., Vincent, T., Vitucci, N., Weber, M., Wierichs, D., Wiersema, R., Willmann, M., Wong, V., Zhang, S., Killoran, N.: Pennylane: Automatic differentiation of hybrid quantum-classical computations (2022), https://arxiv.org/abs/1811.04968
- Chang, S.Y., Thanasilp, S., Saux, B.L., Vallecorsa, S., Grossi, M.: Latent style-based quantum gan for high-quality image generation (2024), https://arxiv.org/abs/2406.02668
- Codella, N.C.F., Gutman, D., Celebi, M.E., Helba, B., Marchetti, M.A., Dusza, S.W., Kalloo, A., Liopyris, K., Mishra, N., Kittler, H., Halpern, A.: Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic) (2018), https://arxiv.org/abs/1710.05006

- 10 Q. Jiao et al.
- Combalia, M., Codella, N.C.F., Rotemberg, V., Helba, B., Vilaplana, V., Reiter, O., Carrera, C., Barreiro, A., Halpern, A.C., Puig, S., Malvehy, J.: Bcn20000: Dermoscopic lesions in the wild (2019), https://arxiv.org/abs/1908.02288
- Dhariwal, P., Nichol, A.: Diffusion models beat gans on image synthesis. In: Proceedings of the 35th International Conference on Neural Information Processing Systems. NIPS '21, Curran Associates Inc., Red Hook, NY, USA (2021)
- Groh, M., Harris, C., Daneshjou, R., Badri, O., Koochek, A.: Towards transparency in dermatology image datasets with skin tone annotations by experts, crowds, and an algorithm. Proceedings of the ACM on Human-Computer Interaction 6(CSCW2), 1–26 (2022)
- Groh, M., Harris, C., Soenksen, L., Lau, F., Han, R., Kim, A., Koochek, A., Badri, O.: Evaluating deep neural networks trained on clinical images in dermatology with the fitzpatrick 17k dataset. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. pp. 1820–1828 (2021)
- He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp. 770–778. IEEE (2016). https://doi.org/10.1109/CVPR.2016.90
- Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., Hochreiter, S.: Gans trained by a two time-scale update rule converge to a local nash equilibrium. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. p. 6629 – 6640. NIPS'17, Curran Associates Inc., Red Hook, NY, USA (2017)
- 10. Huang, H.L., Du, Y., Gong, M., Zhao, Y., Wu, Y., Wang, C., Li, S., Liang, F., Lin, J., Xu, Y., Yang, R., Liu, T., Hsieh, M.H., Deng, H., Rong, H., Peng, C.Z., Lu, C.Y., Chen, Y.A., Tao, D., Zhu, X., Pan, J.W.: Experimental quantum generative adversarial networks for image generation. Physical Review Applied 16(2) (Aug 2021). https://doi.org/10.1103/physrevapplied.16.024051, http://dx.doi.org/10.1103/PhysRevApplied.16.024051
- Huang, K., et al.: Quantum generative adversarial networks with multiple superconducting qubits. npj Quantum Inf. 7, 165 (2021). https://doi.org/10.1038/s41534-021-00503-1
- Liu, C., Fan, F., Schwarz, A., Maier, A.: Cut to the Mix: Simple Data Augmentation Outperforms Elaborate Ones in Limited Organ Segmentation Datasets . In: proceedings of Medical Image Computing and Computer Assisted Intervention – MICCAI 2024. vol. LNCS 15008. Springer Nature Switzerland (October 2024)

- Lloyd, S., Weedbrook, C.: Quantum generative adversarial learning. Phys. Rev. Lett. 121, 040502 (Jul 2018). https://doi.org/10.1103/PhysRevLett.121.040502, https://link.aps.org/doi/10.1103/PhysRevLett.121.040502
- McClean, J.R., Boixo, S., Smelyanskiy, V.N., Babbush, R., Neven, H.: Barren plateaus in quantum neural network training landscapes. Nature Communications 9(1), 4812 (Nov 2018). https://doi.org/10.1038/s41467-018-07090-4, https://doi.org/10.1038/s41467-018-07090-4
- Nakaji, K., Yamamoto, N.: Quantum semi-supervised generative adversarial network for enhanced data classification. Scientific Reports 11(1) (Oct 2021). https://doi.org/10.1038/s41598-021-98933-6, http://dx.doi.org/10.1038/s41598-021-98933-6
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Kopf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., Chintala, S.: Pytorch: An imperative style, high-performance deep learning library. In: Wallach, H., Larochelle, H., Beygelzimer, A., d'Alché-Buc, F., Fox, E., Garnett, R. (eds.) Advances in Neural Information Processing Systems. vol. 32. Curran Associates, Inc. (2019)
- Radford, A., Metz, L., Chintala, S.: Unsupervised representation learning with deep convolutional generative adversarial networks (2016), https://arxiv.org/abs/1511.06434
- Silver, D., Ranjan, A., Patel, T., Gandhi, H., Cutler, W., Tiwari, D.: MosaiQ: Quantum Generative Adversarial Networks for Image Generation on NISQ Computers . In: 2023 IEEE/CVF International Conference on Computer Vision (ICCV). pp. 7007–7016. IEEE Computer Society, Los Alamitos, CA, USA (Oct 2023). https://doi.org/10.1109/ICCV51070.2023.00647, https://doi.ieeecomputersociety.org/10.1109/ICCV51070.2023.00647
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z.: Rethinking the inception architecture for computer vision (2015), https://arxiv.org/abs/1512.00567
- Tschandl, P., Rosendahl, C., Kittler, H.: The ham10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. Scientific Data 5 (2018), https://api.semanticscholar.org/CorpusID:263789934
- Yuan, Z., Fang, Z., Huang, Z., Wu, F., Yao, Y.F., Li, Y.: Adapting Pre-trained Generative Model to Medical Image for Data Augmentation . In: proceedings of Medical Image Computing and Computer Assisted Intervention – MICCAI 2024. vol. LNCS 15005. Springer Nature Switzerland (October 2024)