机器学习型自旋结构检测

作者

Labrie-Boulay, Isaac*[1]; Winkler, Thomas B.*[1]; Franzen, Daniel[2]; Romanova, Alena[1]; Fangohr, Hans[3,4]; Kläui, Mathias[1]

1：约翰内斯·古腾堡大学物理研究所，德国美因茨 55099。

2：约翰内斯·古腾堡大学计算机科学研究所，德国美因茨 55099。

3：马克斯·普朗克物质结构与动力学研究所计算科学科学支持部门，德国汉堡 22761。

4：计算建模组，工程与物理科学学院，南安普顿大学，南安普顿，汉普郡，英国。

*：两位作者对本研究的贡献相同

邮箱：twinkler@uni-mainz.de，klaeui@uni-mainz.de，

摘要

最重要的磁性自旋结构之一是拓扑稳定的斯格明子准粒子。其有趣的物理性质使其成为存储器和高效神经形态计算方案的候选者。为了实现器件运行，需要检测斯格明子的位置、形状和尺寸，通常采用磁成像。磁光克尔显微镜是一种常用技术，但测量数据会受到噪声、低对比度、强度梯度或其他光学伪影的影响，这取决于样品材料成分、温度、材料生长过程等。传统图像分析软件包需要人工处理，因此需要一种更自动化的解决方案。

我们报告了一种专为分割问题设计的卷积神经网络，用于检测测量数据中斯格明子的位置和形状。我们采用特定技术对网络进行调整，以优化预测；研究发现，检测类别的数量尤其会影响网络性能。本研究结果表明，经过良好训练的网络是实现磁显微技术中数据预处理自动化的可行方法。该方法可轻松扩展至其他自旋结构和其他磁成像方法。

引言

在过去十年中，磁性准粒子 [1], [2] 因其有趣的性质以及在下一代存储器和神经形态器件中的潜在应用价值而引起了研究人员的关注 [2],[3]。特别是，磁性薄膜中的斯格明子由于其拓扑稳定性、较小的尺寸，以及能够通过自旋电流轻松操控的能力而受到研究 [4],[5]。然而，根据薄膜的磁性，斯格明子的尺寸可能从几纳米[6] 变化到几微米 [7]。此外，斯格明子可以呈圆形、椭圆形或其他形状，图2（a）插图中展示了具有布洛赫畴壁的斯格明子的典型自旋结构。对于随机计算 [8], [9], 、基于令牌的布朗计算 [10], [11], 和储备池计算 [12]–[14]等多种非常规计算方案，人们已经提出并通过实验验证了斯格明子的应用。实现所有这些方案的共同前提是可靠检测斯格明子。特别是，磁光克尔效应（MOKE）显微镜用于研究直径达到微米尺度的磁性斯格明子 [5], [9], [9]。在克尔显微镜中获得的灰度对比图像对应于样品的面外磁化强度。为了分析斯格明子及其静态和动态性质，需要识别所有斯格明子的位置及其形状 [9], [15]。到目前为止，这一过程一直非常耗费人力，因为通常需要手动完成，从而无法进行大规模系统分析。此外，为了使用图像分析软件，通常还需要进行手动数据预处理，才能正确评估数据。所面临的挑战包括热噪声和电噪声，或低对比度；这些问题可能源于不完美的

偏振滤光片的对准、杂散光，以及为避免样品氧化而必须使用的非磁性封盖层，而封盖层同时还会部分吸收光线。此外，如果样品未实现完美对准或存在不均匀性，数据中还可能出现强度梯度。结构缺陷、尘埃颗粒以及样品边缘也可能妨碍数据评估。在图2a、2d和2g中，我们展示了一组典型的MOKE显微镜数据。

斯格明子的研究通常涉及评估斯格明子的大小、位置并追踪其运动。这通常首先通过创建测量数据的二值掩膜来完成，然后对其采用标准的数据分析技术。通过图像处理软件创建二值掩膜，需要手动执行一系列高度依赖于测量数据的操作，将原始数据转换为掩膜 [16]。这些操作包括去噪、对比度增强、应用高斯滤波器、阈值处理等，具体取决于测量数据。此外，没有任何经典滤波器能够可靠地区分斯格明子或不同的磁结构，例如条纹畴、涡旋或畴壁。图 2d 和 2g 展示了使用传统方法进行预处理时需要付出大量努力的测量数据示例。

神经网络能够为自动化评估过程提供强有力的手段，因为图像分割是卷积神经网络的关键能力之一。由于通用图形处理器[17] (GPGPUs)的广泛应用，过去十年取得了巨大进展。鉴于机器学习此前已成功应用于磁学问题 [18]–[21], 我们在此着手解决检测最重要的自旋结构——斯格明子这一关键问题，从而实现磁显微测量分析的自动化，并推动非常规计算等应用。

本研究探讨卷积神经网络（CNN）对我们的 MOKE 显微镜数据进行分割并自动检测斯格明子的能力。我们比较了包含缺陷的二分类网络和三分类网络，并对 CNN 进行调优，以优化斯格明子和缺陷分割，使其性能超越传统模式检测。迄今为止，还没有机器学习方法被提出用于解决磁性薄膜自旋结构数据分割这一特定任务；不过，CNN 是一种值得探索的选择，本文接下来将对此进行探讨。

结果与讨论

用于光学模式识别的卷积神经网络采用下采样结构（称为收缩路径）和上采样结构（称为扩展路径）（见图 1）。收缩路径由两个 3×3 卷积和一个修正线性单元（ReLU）激活层组成，最后在我们的案例中通过步幅为 2 [21] 的 2×2 最大池化层完成下采样（见图 1）。每个下采样块中特征通道的数量都会加倍。扩张路径将收缩路径中相应深度的特征图进行拼接，应用两个 3×3 卷积和一个 ReLU 激活层，并通过 2×2 上卷积 [21] 对特征图进行上采样（见图 1）。为了实现定位，需要将左侧的高分辨率特征与右侧上采样后的输出拼接起来。这些连接称为快捷连接。还应注意，常用的 U-Net 实现采用无填充卷积，因此生成的掩膜尺寸会小于输入图像。我们的实现采用一致的填充，使输出保持原始图像的尺寸。本研究所用 CNN 的示意图见图 1。这个二分类 CNN 在其 3×3 卷积块之间设置了 5% 的 Dropout 率。Dropout 是一种正则化技术，可使某一层中的节点在训练过程中被随机忽略 [22], [23]。网络和分析的详情见“方法”部分。

为了训练我们的卷积神经网络，我们进行了 5 次训练，每次训练 100 个训练轮次。我们使用了几个 TensorFlow 回调函数来防止过拟合（EarlyStopping、ReduleLROnPlateau、ModelCheckpoint [24]）。验证数据预测的平均马修斯相关系数为 0.7520，标准差为 0.032。下文图 2c、2f 和 2i 展示了该基准模型的预测示例。

我们注意 到模型在对缺陷进行分类时存在困难，图 2f 展示了一个示例。通常，这些 e
缺陷 由于样品漂移和背景，呈现出各种差异很大的对比度 d

在进行磁光克尔效应减法显微镜测量时，其中一部分会被分类为斯格明子，另一部分则被分类为背景。尽管缺陷在形状和对比度上与斯格明子存在显著差异，但模型仍难以将二者轻松分类为两个不同的对象。

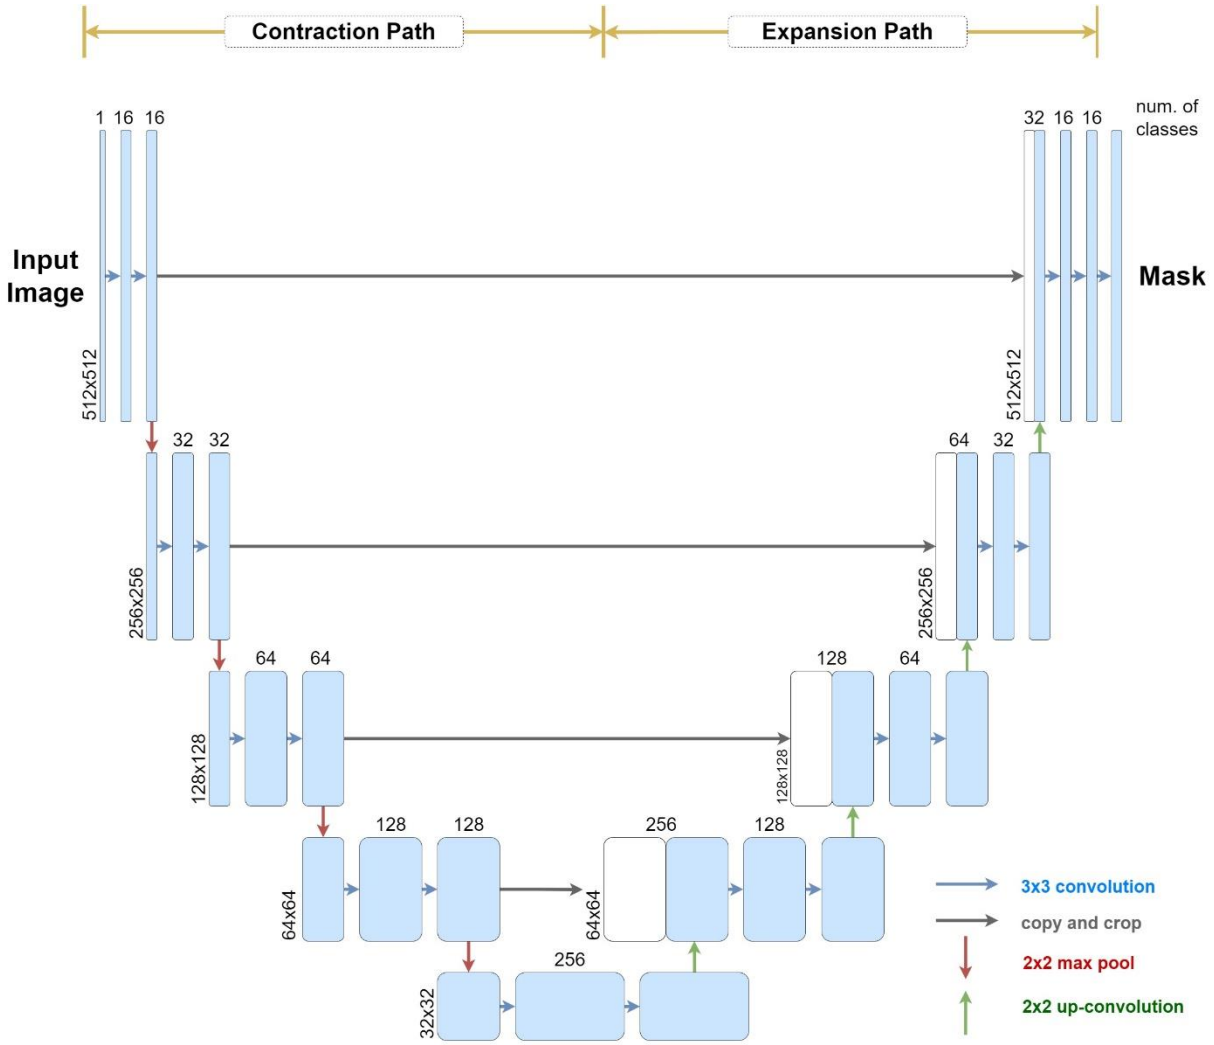

图 1. 本研究所用卷积神经网络的网络拓扑。左侧为收缩路径，右侧为扩张路径。连接两条路径的灰色箭头表示跳跃连接。图改编自参考文献 [21]。

此外，对于含噪图像，模型生成的掩膜预计会出现微小的斯格明子斑点。图 2i 展示了对一个此类样本的预测。这从应用物理学的角度来看是个问题。举例来说，实验物理学家可能会分析一组测量数据，以找出并追踪斯格明子的平均尺寸。可以看出，这些微小斑点可能会给可靠检测带来困难。

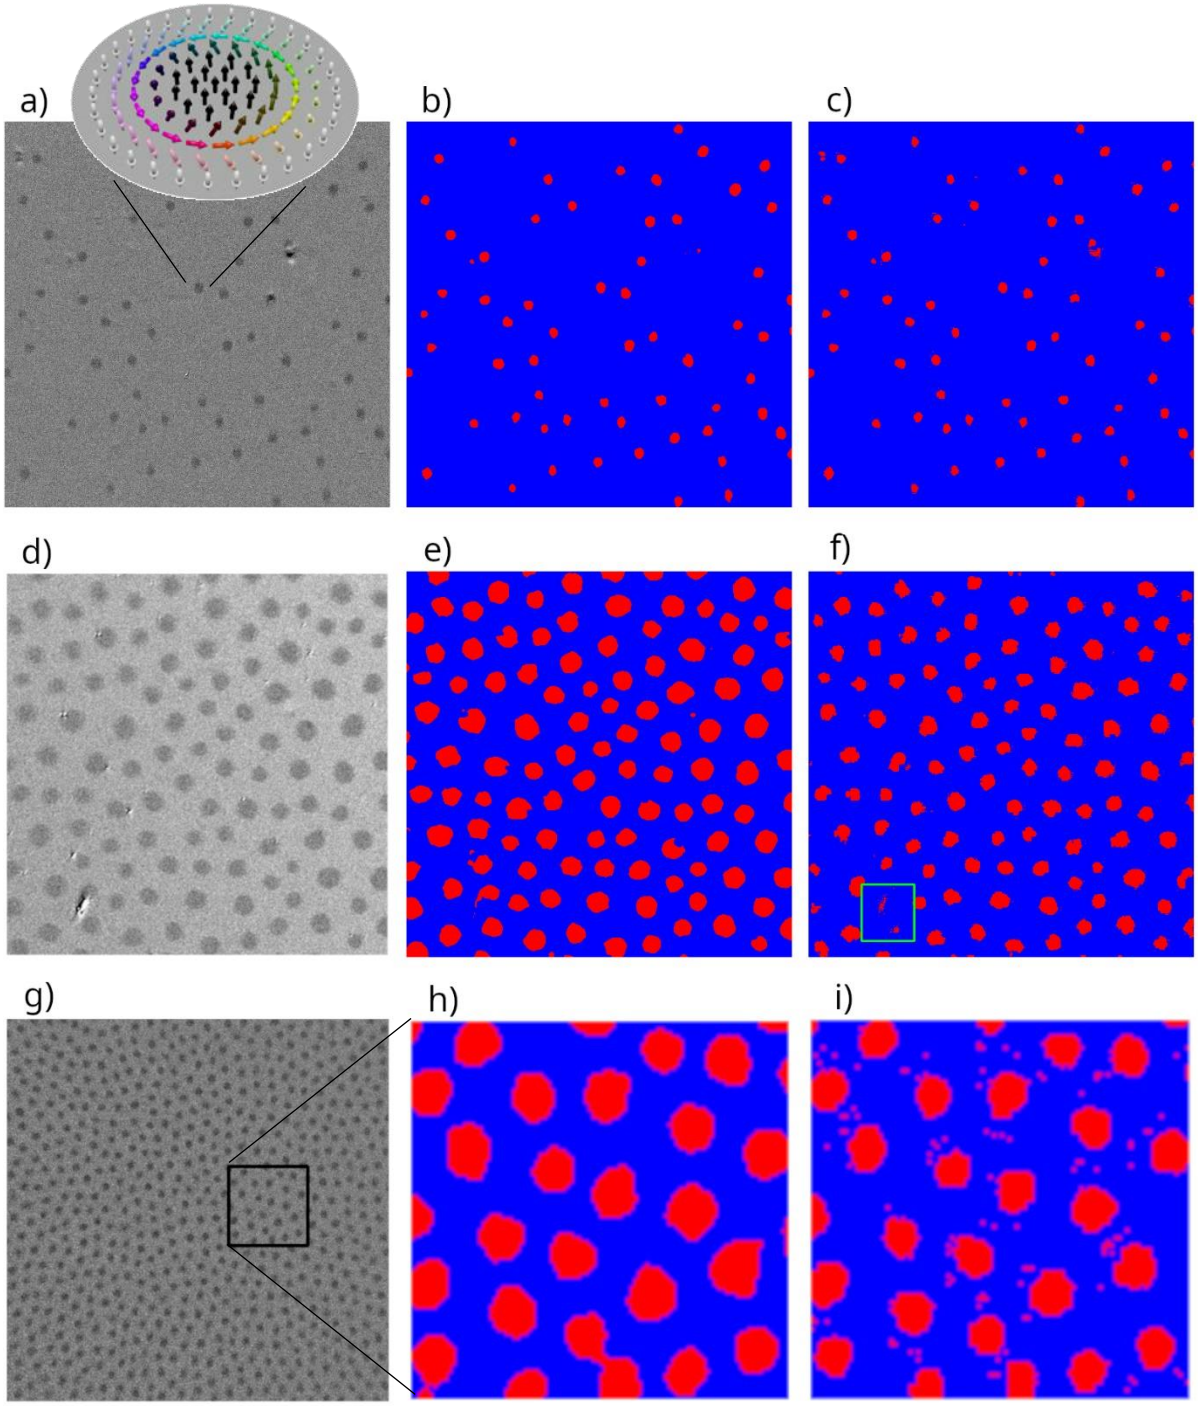

图 2. 二分类模型预测。左侧图像显示的是难以用传统方法进行掩膜处理的磁光克尔效应测量数据，中间列显示这些测量数据的标签，右侧列显示这些二分类模型给出的预测。(a) 一个有少量缺陷的样品。插图展示了斯格明子的自旋结构。斯格明子中心的磁化“向下”会产生黑色对比度，而周围区域的磁化“向上”会产生浅灰色对比度。请注意，由于空间分辨率有限，插图中彩色的布洛赫畴壁在实验图像中不可见。(b) 图 2a 的标签。(c) 图 2a 的预测。(d) 该样品有缺陷，并存在轻微的亮度梯度。(e) 图 2d 的标签。(f) 图 2d 的预测，其中绿色方框示例说明了这些模型如何预测缺陷。(g) 该样品噪声尤其严重，黑色方框表示放大区域。(h) 图 2g 标签的 4 倍放大图。(i) 图 2g 预测结果的 4 倍放大图（注意其中表示错误检测的小斑点）。

本着可解释人工智能的理念，我们发现，这一问题的原因在于模型主要依据强度值进行预测。我们发现，灰度图像分析能够揭示这一点：我们

要求其中一个模型对255幅颜色均匀的8位灰度图像进行预测，其颜色范围为0至255。该实验发现，任何值小于88的像素都会被分类为斯格明子，而高于该值的像素则被预测为背景。结果见图3c。这为关于斑点为何出现在含噪图像中的这一推测提供了明确证据。噪声会产生范围广泛的像素亮度值。亮度较高的随机像素会被分类为斯格明子。

进一步开展这项分析后，要求模型对图3a中的反转样本进行预测，此时斯格明子像素具有较高的灰度值，而背景具有较低的灰度值。模型的预测结果如下图3b所示。正如预期，可以看到模型会自动将任何深色物体分类为斯格明子（白色），从而产生几乎完全反转的预测结果。

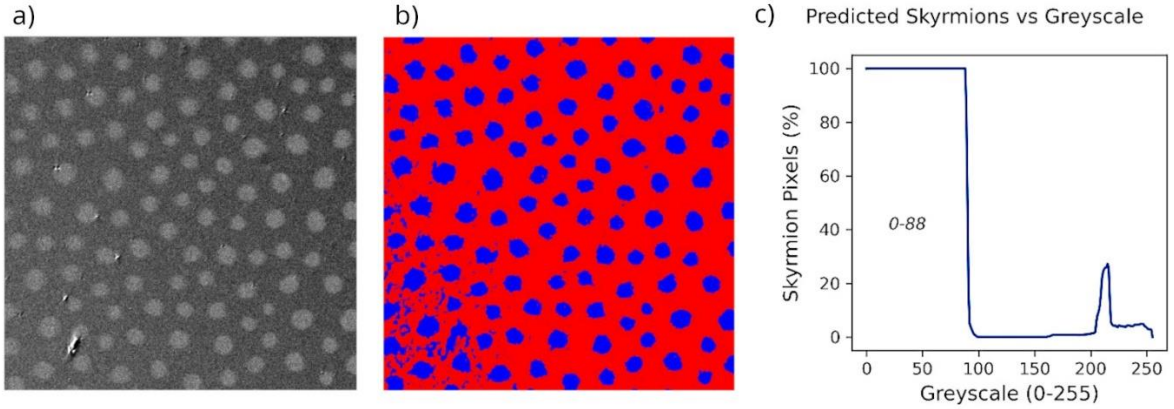

图 3. 反转数据预测。(a) 颜色反转样本。(b) 预测结果。此图表明，在二分类情况下，任何暗色像素几乎都会自动被分类为斯格明子。左下角的斑块可能是因为样本存在颜色渐变，图像从左下角到右上角逐渐变暗。(c) 灰度值在 0 到 88 之间的像素有 100% 的概率被预测为斯格明子。

为消除此缺陷并创建一个更适合区分缺陷与随机噪声的模型，我们加入了一个代表缺陷的第三类。通过强制模型区分这两种不同的对象，网络便必须学习根据形状及其他因素进行预测，而不仅仅依据颜色强度。这个新的多类别模型（斯格明子、缺陷、背景）使用三分类标签进行监督。

本研究的训练数据包含先前发表的文献中的数据，这些文献研究的区域缺陷较少。因此，这些数据中的缺陷很少。为此，我们在此添加了 100 组新的测量数据，其中有意包含了许多缺陷，并由人工准确标注；随后使用这些图像训练模型，使其能够在原有的 1901 幅图像中标注缺陷。预测标签经过后处理，使三分类模型包含 2001 幅图像，并将其称为弱标注。三分类模型还设有验证集和测试集，两者均包含 200 幅图像/标签，且均由人工标注。

计算马修斯相关系数时，将斯格明子作为正类，并将缺陷和背景合并为负类。与原始网络一样，三分类卷积神经网络在100个训练轮次中重复训练了5次。三分类预测在验证集上的马修斯相关系数均值为0.849，标准差为0.0075，这表明预测能力显著提升。该模型的预测示例见图4c、4f和4i。需要注意的是，在该模型中，小型斯格明子斑点现已全部消失。

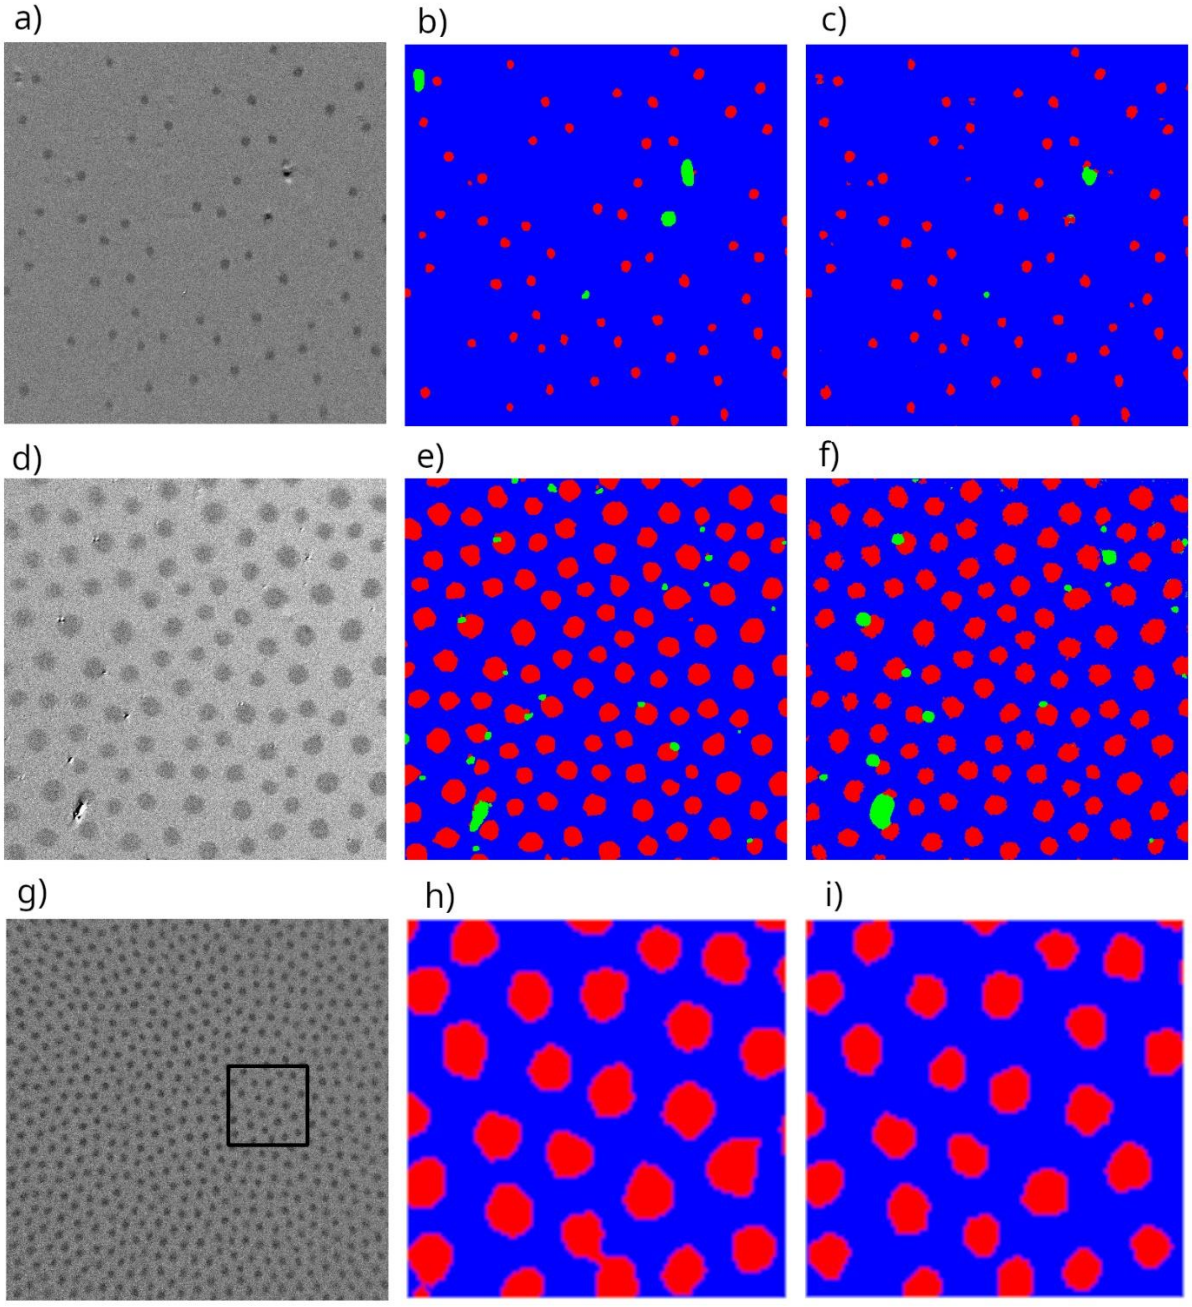

图 4. 三分类模型预测。左侧图片显示磁光克尔效应测量数据，中间列显示标签（请注意以绿色标记的缺陷），右侧列显示这些三分类模型作出的预测。(c) 和 (d) 显示，该模型架构能够区分斯格明子和缺陷。正如 (i) 中所示，这类模型不再在含噪图像中预测微小的斯格明子斑点。

由于三分类模型的表现明显更好，下一步是对三分类神经网络进行更多优化测试，以确定这些优化是否能进一步提升性能。每次只进行一项修改，并记录马修斯相关系数的均值和标准差。最终，将所有表现有所改善的修改组合起来，生成一个主模型。随后使用测试数据对主模型进行测试，以避免其偏向验证集。对于本研究，训练轮次减少并限制为15轮。回调函数超参数也进行了相应调整。

在我们的网络上测试的优化方法及其带来的性能表现见表2。值得注意的是，为了与优化模型进行比较，二分类和三分类基准模型也都训练了15轮。我们探索了不同的激活函数、对丢弃率进行微调、不同程度的标签平滑，以及两种不同的数据增强方案。

数据增强是指在训练过程中对数据进行随机变换的一种技术。这样一来，训练数据的数量便能以人工方式增加，正如先前提出的那样 [25]。测试时增强是指在预测阶段（训练后）进行的数据增强。它通过汇集给定测试输入的多个变换版本的预测结果，得出一个“平滑”的预测 [26]。在我们的方案中，会对图像的三个不同变换版本分别进行预测，最终预测结果取这三者的平均值。

数据增强所用的数据变换见下文表1。应用随机旋转90°、随机横向平移或随机缩放，只是以人工方式扩充所见测量图像的数量。最大缩放因子设为0.2，以免模型在训练时看到包含不必要地放大的斯格明子的图像。部分图像会被随机注入高斯噪声，让模型接触更多带噪声的数据。图像还会随机改变亮度和对比度。由于MOKE显微镜测量的特性，部分缺陷含有被裁剪或接近8位灰度图像255上限而被裁剪的像素。缺陷的高亮度是由克尔显微镜测量中的持续背景扣除造成的。这些背景扣除对于获取磁性数据至关重要，但经过一段时间后，显微镜照明强度的漂移会变得非常明显，从而在非常明亮的缺陷周围形成类似阴影的形状。为了防止模型将由裁剪像素均匀构成的物体识别为目标，亮度和对比度仅允许放大≤ 0.2倍，如表1所示。

部分模型采用相同的数据增强技术和随机图像反转进行训练。这样做是为了迫使网络不仅根据相对对比度差异，还要根据整体形状来区分斯格明子。需要注意的是，反转磁场会在磁光克尔效应测量中产生负像，因此这一潜在特征非常有价值。

数据增强技术
随机旋转90°
高斯噪声
随机平移
随机缩放（最大系数为 0.2）
随机对比度变化，范围为 (-0.3, 0.3)
随机亮度变化，限制范围为（-0.3，3）
图像反转*

表1。所使用的数据增强。本表总结了数据增强模型中使用的数据变换。图像反转标有星号，表示仅有部分模型在训练和测试时接受了此增强处理。

优化类型	优化	均值和标准差 （马修斯 相关系数）
二分类模型	N/A	0.752（标准差 = 0.064）
三分类初始模型	N/A	0.896（标准差 = 0.002）
数据增强	不进行反演	0.898（标准差 = 0.003）
	w 反演	0.884（标准差 = 0.012）
激活函数	prelu	0.885（标准差 = 0.006）
	tanh	0.869（标准差 = 0.014）
	mish	0.891（标准差 = 0.006）
标签平滑	30%	0.875（标准差 = 0.033）
	40%	0.884（标准差 = 0.005）
Dropout	0%	0.896（标准差 = 0.002）
	10%	0.900（标准差 = 0.006）
	15%	0.892（标准差 = 0.004）

表2。三分类模型优化的性能。本表展示了每种优化的马修斯相关系数值。测试的激活函数包括参数化整流线性单元函数（PReLU）、双曲正切函数（Tanh）和“Mish”，其数学定义为 $f(x) = x\tanh(softplus(x))$。这些都是神经网络中常用的激活函数。对于标签平滑，我们测试了 α =0.3 和 $\alpha = 0.4$。默认模型使用 $\alpha = 0.2$。我们还尝试在3×3 卷积之后使用不同程度的 Dropout（10%和15%）来训练模型。

考虑到表2所示的标准差，各项优化相较于三分类初始基准均未显示出显著提升。大多数优化反而导致性能下降。我们的默认模型的激活函数（ReLU）和标签平滑（20%）表现最佳。数据增强使马修斯相关系数提高了 0.002。加入图像反转的数据增强很可能迫使模型完成一项复杂得多的任务：精准识别斯格明子和缺陷的形状，因此性能有所下降。此外，将 Dropout 率提高到 10% 似乎能使马修斯相关系数提高 0.004。考虑到这些微小的提升，我们创建了主网络。

最后，主模型经过 15 个训练轮次的训练，并用于预测测试集。所有数据集的预测结果如图 5 所示。该图还展示了验证集和训练集上的表现。主模型在测试集上的预测表现与基准模型几乎相同。生成的掩膜质量都较为合理。

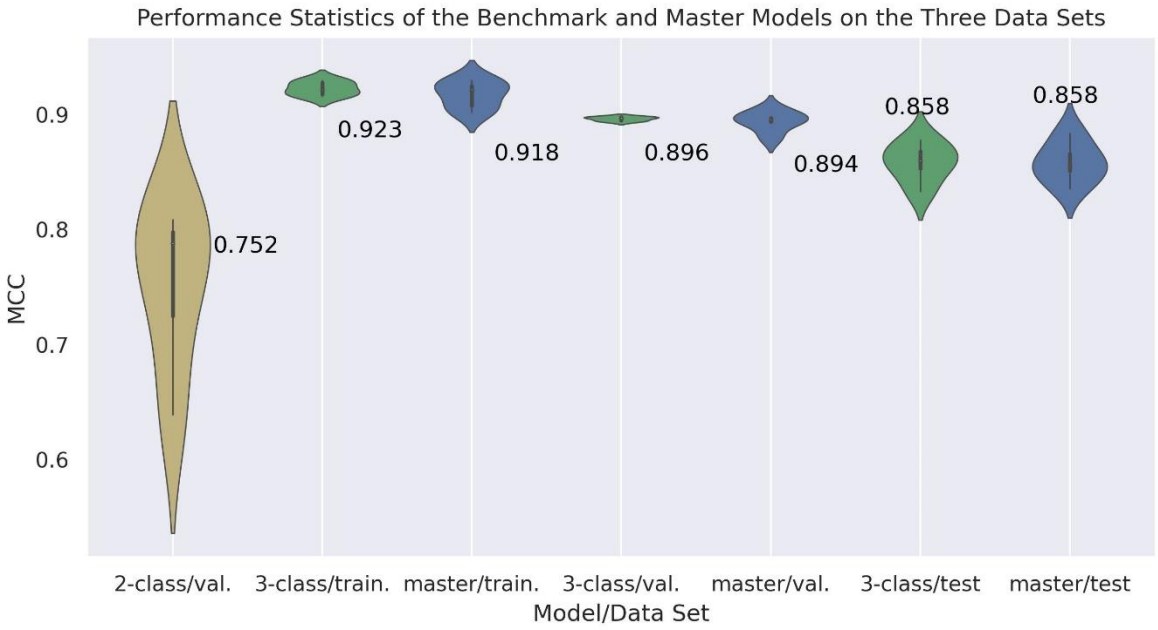

图5. 基准模型和主模型在三组数据上的性能统计。该图比较了三分类基准模型和主模型在全部三个数据集上的平均马修斯相关系数及其标准差。

马修斯相关系数（MCC）指标仅用于衡量预测的逐像素质量。由于我们关注的是完整对象，因此比较了测试集中斯格明子的真实尺寸与预测尺寸。这样一来，考察的就是语义层面，而非像素级层面。图 6 展示了斯格明子的真实尺寸与主模型预测尺寸的对比直方图。如图所示，预测的分布与真实尺寸分布相符。不过，在约 150 个像素处还可以看到一个较小的次峰。需要指出的是，由于在标注数据时难以估算斯格明子的真实尺寸，加之三分类标签的重新标注较为粗略，标签中斯格明子的尺寸不应与其真实尺寸混为一谈。换言之，标签本身并不能完美表示磁化分布。

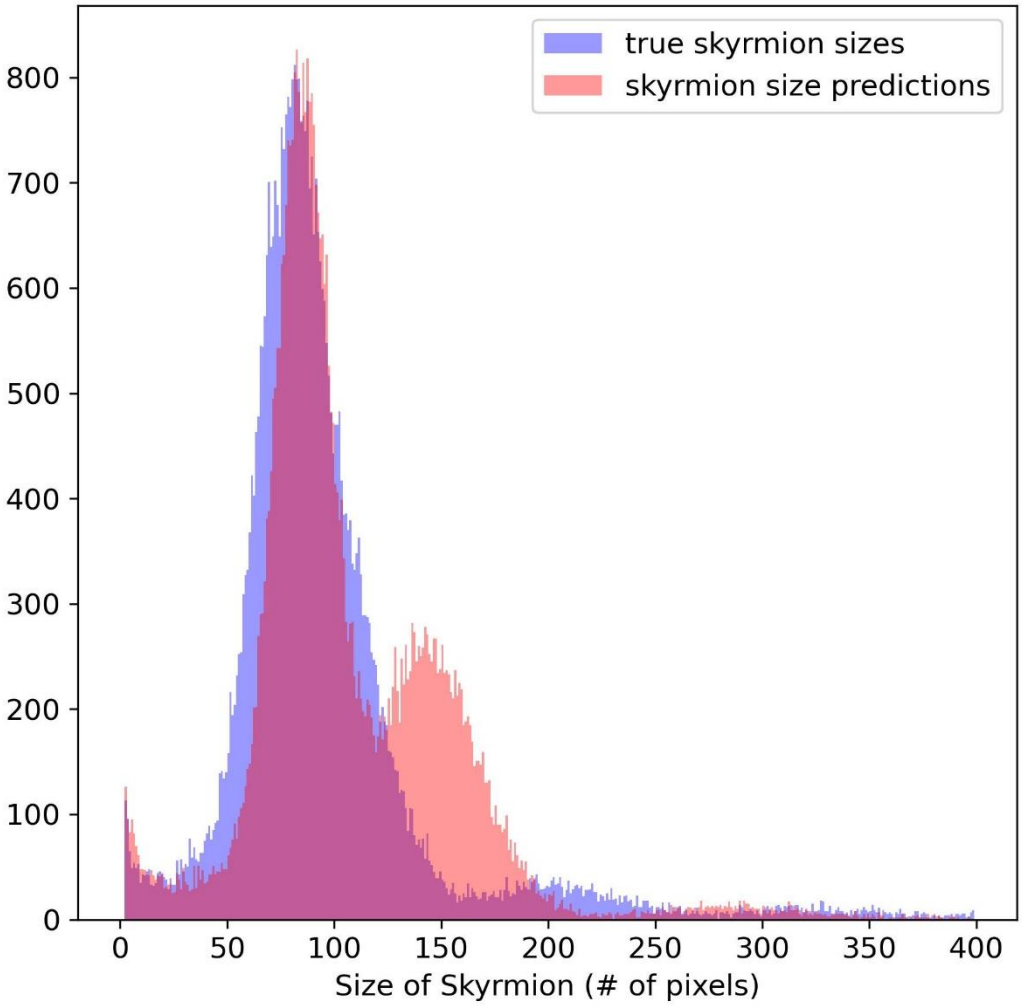

图6. 测试集中斯格明子的尺寸预测。该图展示了测试集斯格明子标签的斯格明子尺寸分布，以及主模型对该测试集的预测。

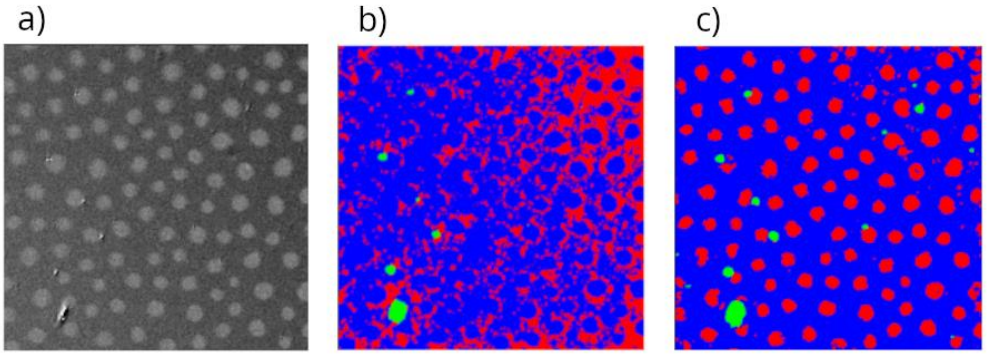

图7. 主模型和使用反转数据增强训练的模型对反转数据的预测。(a) 反转样本。(b) 主模型的预测。(c) 反转模型的预测。

结论

总之，我们证明了，经过优化的卷积神经网络能够生成机器学习模型，从磁性克尔显微图像中创建准确的斯格明子检测掩膜。二元分类器难以区分缺陷和斯格明子，在含噪图像上的表现也不尽理想。我们发现，原因之一是二分类模型在进行预测时过于依赖亮度/对比度。将缺陷作为第三类加入后，预测质量大幅提升。平均马修斯相关系数显著提高，预测结果也与真实标注非常接近。数据集和网络已上传，供开放获取使用 [27]。

对网络进行微调以创建主卷积神经网络后，在测试集上的表现并未显著提升。尽管如此，各项单项优化都没有显示出明确的独立改进效果。原因在于，我们的大多数三分类模型都能轻松完成这项任务；而鉴于微调前的大多数预测已经几乎完美地通过了目视检查测试，要将马修斯相关系数提升至 0.90 以上可能极其困难。这可能是因为训练数据集非常完善，也可能是因为测试集缺少更具挑战性的样本。本研究的数据集仍仅限于以往实验所获得的数据。目前，为了在测试集之外考验网络的预测能力，我们在反转图像上测试了使用图像反转数据增强进行训练的模型，其表现也尚可，见图 7。不过，总体而言，主模型的表现优于使用反演增强训练的模型。事实上，日常使用时，准确度稍低但模块化程度更高、能够处理反转图像的模型或许更为理想。此外，当测量过程中磁对比度发生切换时，仅通过一次推理便能检测两种配置的能力也可能很实用。

总而言之，我们开发了一种卷积神经网络，用于检测和表征磁显微图像中的斯格明子。由于对实验物理学中的含噪克尔显微术斯格明子图像进行预处理既复杂又耗时，因此实现自动化对于提高研究效率至关重要。本文表明，利用合适的训练数据，可以训练卷积神经网络生成非常准确的斯格明子掩膜。未来的一个研究方向是探究能否训练神经网络，自动对其他磁结构进行预处理，例如斯格明子泡 [28], 条纹畴 [28], 甚至畴壁 [28]。此外，我们的方法也适用于克尔显微术以外的多种磁显微技术，例如磁力显微术、洛伦兹显微术或偏振分析扫描电子显微术，因此我们的结果具有广泛的适用性。此外，还可以探究使用视频而非图像进行训练，能否构建出更强大的模型（采用长短期记忆网络或回声状态网络）[29], [30]。我们在 Zenodo 上提供了数据和训练好的模型，参见文献 [27] 。

方法

数据集的标签采用两个类别的独热编码。该模型使用从 19 段独立的克尔显微镜视频中抽取的 1901 张训练图像进行训练。标签由人工使用图像处理软件 ImageJ[16]，通过传统的掩膜创建技术制作。验证数据集由从 5 段不同视频中获取的 200 张图像组成。可以使用不同的卷积神经网络。本文选择了 U-Net 的一种衍生架构，因为该框架足够灵活，能够检测图像中的不同物理实体 [21]。训练完成后，模型会对验证集进行预测，据此可以基于混淆矩阵提取其性能指标。性能指标可用于比较模型，以便针对特定任务优化神经网络。完成所有优化后，使用测试集进行最终基准测试。在本研究中，测试集由来自 6 段不同视频的 200 张图像组成，这些视频拍摄的是不同的样本。需要注意的是，验证集和测试集都包含各种尺寸的斯格明子图像，也包含噪声程度各异以及存在不同缺陷的图像。训练集中共有 1466843 个斯格明子，其中 18.9% 的像素被标记为斯格明子。验证集中的斯格明子占比为 17.8%，测试集中的占比为 9.9%。

用于对我们的模型进行基准测试的评分指标是马修斯相关系数（MCC） [31]。研究表明，对于各种数据集上的正类

偏向和负类偏向预测，该系数都能提供很有参考价值的性能评分 [31]。一般来说，正类偏向的预测能够准确预测正值，但在预测负值时表现不佳。无论是在正类不平衡数据集、负类不平衡数据集还是平衡数据集上，MCC 都能够恰当地评估正类和负类偏向的预测 [31]。因此，该指标被用作不同研究领域中不平衡数据的参考性能指标。在我们的数据集中，斯格明子被归类为正类，背景则被归类为负类。由于图像中的背景像素多于斯格明子像素，我们的数据集属于负类不平衡数据集。因此，MCC 能够考虑类别不平衡这一特性 对我们的研究至关重要。

二分类器的马修斯相关系数为：

$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}}$ [31].

每个模型均训练五次。每次训练都会计算马修斯相关系数。随后计算每个模型性能的均值和标准差。这种分析模型性能的方法能够更真实地反映其表现。请注意，与其他标准指标不同，$MCC \in [-1,1]$ 其中 -1 表示完全错误的分类，0 表示完全无法确定，1 表示完美分类。不过，马修斯相关系数仅通过逐像素方法衡量预测性能，缺乏对数据的物理解释。

这些模型使用 Python 编写，采用 TensorFlow 2.9 [24] 机器学习库，并在其上运行 Keras[32] 以提供高级 API。该研究的软件还利用了 NumPy [33], scikit-learn [34], 和 PIL [35]的功能。所有模型均在 NVIDIA RTX 3060 GPU [17]上完成训练。

致谢

I. Labrie-Boulay 衷心感谢德国学术交流中心（DAAD）和 Mitacs 颁发奖学金，使他得以在美因茨约翰内斯·古腾堡大学物理研究所完成实习。他还感谢 T. B. Winkler 在实习期间提供技术支持并给予指导。我们感谢 Karin Everschor-Sitte 进行的富有成效的讨论。Daniel Franzen 的经费由德国研究联合会（DFG）项目资助，项目编号：233630050（TRR 146）。本研究还获得 emergentAI 中心的资助；该中心本身由卡尔·蔡司基金会资助。此外，本研究还获得德国研究联合会（DFG）项目 403502522（优先计划 2137“斯格明子学”）、49741853 和 268565370（协同研究中心 TRR 173 项目 A01 和 B02）的资助。本研究还得到欧盟委员会“地平线 2020”框架计划 FET-Open 项目资助协议 ERC-2019-SyG（编号 856538，3D MAGiC ）以及 “ 地平线欧洲 ” 计划项目（编号 101070290，NIMFEIA ）的支持，我们对此深表感谢。

参考文献

[1] K. Everschor-Sitte、J. Masell、R. M. Reeve 和 M. Kläui，《观点：磁性斯格明子——活跃研究领域的最新进展综述》，《应用物理学杂志》，第 124 卷，第 24 期，第 240901 页，2018 年 12 月，doi：10.1063/1.5048972。[2] A. Fert、V. Cros 和 J. Sampaio，《轨道上的斯格明子》，《自然·纳米技术》，第 8 卷，第 3 期，第 152–156 页，2013 年 3 月，doi：10.1038/nnano.2013.29。[3] J. Grollier、D. Querlioz、K. Y. Camsari、K. Everschor-Sitte、S. Fukami 和 M. D. Stiles，《神经形态自旋电子学》，《自然·电子学》，2020 年 3 月，doi：10.1038/s41928-019-0360-9。[4] S. Woo 等，《超薄金属铁磁体中室温磁性斯格明子的观测及其电流驱动动力学》，《自然·材料》，2016 年 2 月，doi：10.1038/nmat4593。[5] W. Jiang 等，《磁性斯格明子气泡的膨胀》，《科学》，第 349 卷，第 6245 期，第 283–286 页，2015 年 7 月，doi：10.1126/science.aaa1442。[6] S. Meyer 等，《超薄钴薄膜中孤立的零场亚 10 纳米斯格明子》，《自然·通讯》，第 10 卷，第 1 期，第 3823 页，2019 年 8 月，doi：10.1038/s41467-019-11831-4。[7] J. Zázvorka 等，《薄膜多层结构中的斯格明子晶格相》，《先进功能材料》，第 30 卷，第 46 期，第 2004037 页，2020 年 11 月，doi：10.1002/adfm.202004037。

[8] D. Pinna 等，《用于概率计算的斯格明子气体操控》，ArXiv170107750 Cond-Mat Physicsphysics，2017 年 1 月，访问日期：2017 年 3 月 12 日。[在线]。网址：http://arxiv.org/abs/1701.07750[9] J. Zázvorka 等，《用于重排器件的热斯格明子扩散》，Nat. Nanotechnol.，第 14 卷，第 7 期，第 658–661 页，2019 年 7 月，doi：10.1038/s41565-019-0436-8。[10] M. A. Brems、M. Kläui 和 P. Virnau，《利用电路和激发实现基于布朗令牌的斯格明子计算》，Appl. Phys. Lett.，第 119 卷，第 13 期，第 132405 页，2021 年 9 月，doi：10.1063/5.0063584。[11] T. Nozaki 等，《斯格明子气泡的布朗运动及其电压施加控制》，Appl. Phys. Lett.，第 114 卷，第 1 期，第 012402 页，2019 年 1 月，doi：10.1063/1.5070101。[12] D. Prychynenko 等，《作为非线性电阻元件的磁性斯格明子：储备池计算的潜在构建模块》，Phys. Rev. Appl.，第 9 卷，第 1 期，第 014034 页，2018 年 1 月，doi：10.1103/PhysRevApplied.9.014034。[13] K. Raab 等，《利用几何约束下的斯格明子动力学实现布朗储备池计算》，Nat. Commun.，第 13 卷，第 1 期，文章编号 1，2022 年 11 月，doi：10.1038/s41467-022- 34309-2。[14] T. Yokouchi，《利用斯格明子的磁场诱导动力学进行神经形态计算的模式识别》，[在线]。网址：https://arxiv.org/ftp/arxiv/papers/2204/2204.13260.pdf [15] N. Kerber 等，《由磁场诱导对称性破缺控制的各向异性斯格明子扩散》，Phys. Rev. Appl.，第 15 卷，第 4 期，第 044029 页，2021 年 4 月，doi：10.1103/PhysRevApplied.15.044029。[16] C. A. Schneider、W. S. Rasband 和 K. W. Eliceiri，《从 NIH Image 到 ImageJ：25 年的图像分析》，Nat. Methods，第 9 卷，第 7 期，第 671–675 页，2012 年 7 月，doi：10.1038/nmeth.2089。[17] J. Ghorpade，《CUDA架构中的GPGPU处理》，Adv. Comput. Int. J.，第 3 卷，第 1 期，第 105–120 页，2012 年 1 月，doi：10.5121/acij.2012.3109。[18] G. Katsikas、C. Sarafidis 和 J. Kioseoglou，《磁性材料中的机器学习》，Phys. Status Solidi B，第 258 卷，第 8 期，第 2000600 页，2021 年 8 月，doi：10.1002/pssb.202000600。[19] A. Kovacs 等，《学习磁化动力学》，J. Magn. Magn. Mater.，第 491 卷，第 165548 页，2019 年 12 月，doi：10.1016/j.jmmm.2019.165548。[20] H. Y. Kwon 等，《利用深度学习技术进行磁性哈密顿量参数估计》，Sci. Adv.，第 6 卷，第 39 期，第 eabb0872 页，2020 年 9 月，doi：10.1126/sciadv.abb0872。[21] O. Ronneberger、P. Fischer 和 T. Brox，《U-Net：用于生物医学图像分割的卷积网络》，2015，doi：10.48550/ARXIV.1505.04597。[22] J. Kukačka、V. Golkov 和 D. Cremers，《深度学习的正则化：分类综述》，2017，doi：10.48550/ARXIV.1710.10686。[23] N. Srivastava、G. Hinton、A. Krizhevsky、I. Sutskever 和 R. Salakhutdinov，《Dropout：防止神经网络过拟合的简易方法》，Journal of Machine Learning Research，第 56 期，第 1929–1958 页，2014 年。[24] TensorFlow开发者，《TensorFlow》。Zenodo，2022 年 5 月 23 日。doi：10.5281/ZENODO.4724125。[25] C. Shorten 和 T. M. Khoshgoftaar，《深度学习图像数据增强综述》，J. Big Data，第 6 卷，第 1 期，第 60 页，2019 年 12 月，doi：10.1186/s40537-019-0197-0。[26] R. Müller、S. Kornblith 和 G. Hinton，《标签平滑何时有用？》，2019，doi：10.48550/ARXIV.1906.02629。[27] Winkler, Thomas Brian、Labrie-Boulay, Isaac、Romanova, Alena、Fangohr, Hans 和 Kläui, Mathias，《MOKE 显微镜斯格明子数据集》。Zenodo，2023 年 2 月 17 日。doi：10.5281/ZENODO.7636109。[28] B. Göbel、I. Mertig 和 O. A. Tretiakov，《超越斯格明子：替代磁性准粒子的综述与展望》，Phys. Rep.，第 895 卷，第 1–28 页，2021 年 2 月，doi：10.1016/j.physrep.2020.10.001。[29] S. Hochreiter 和 J. Schmidhuber，《长短期记忆》，Neural Comput.，第 9 卷，第 8 期，第 1735–1780 页，1997 年 11 月，doi：10.1162/neco.1997.9.8.1735。

[30] H. Jaeger，《回声状态网络》，*Scholarpedia*，第 2 卷，第 9 期，第 2330 页，2007 年，doi：10.4249/scholarpedia.2330。[31] D. Chicco 和 G. Jurman，《马修斯相关系数（MCC）在二分类评估中优于 F1分数和准确率的优势》，*BMC Genomics*，第 21 卷，第 1 期，第 6 页，2020 年 12 月，doi：10.1186/s12864-019-6413-7。[32] F. Chollet 等人，《Keras》，2015 年。[在线]。网址：https://keras.io[33] C. R. Harris 等人，《使用 NumPy 进行数组编程》，*Nature*，第 585 卷，第 7825 期，第 357–362 页，2020 年 9 月，doi：10.1038/s41586-020-2649-2。[34] L. Buitinck 等人，《机器学习软件的 API设计：来自 scikit-learn 项目的经验》，2013 年，doi：10.48550/ARXIV.1309.0238。[35] Wiredfool，《python-pillow/Pillow：4.0.0》。Zenodo，2017 年 1 月 1 日。doi：10.5281/ZENODO.3733071。