arXiv:2302.00332v1 [cs.AI] 1 Feb 2023

# IPAL：基于机器学习的智慧医疗框架，用于注意缺陷多动障碍（ADHD）的自动诊断

预印本

**Abhishek Sharma**
电子与通信工程，
The LNMIIT 贾斋浦尔，印度
abhishekshar ma@lnmiit.ac.in

**Arpit Jain**
计算机系科学与工程，
印度斋浦尔的 The LNMIIT
18ucs085@lnmiit.ac.in

**Shubhangi Sharma**
电子与通信工程，
印度斋浦尔的 The LNMIIT
18uec006@lnmiit.ac.in

**Ashutosh Gupta**
计算机科学系
科学与工程系，
The LNMIIT 贾斋浦尔，印度
18ucs200@lnmiit.ac.in

**Prateek Jain**
电子与仪器仪表工程，
尼尔玛大学艾哈迈达巴德，印度
prtk.ieju@gmail.com

**Saraju P. Mohanty**
计算机科学与工程，
北德克萨斯大学，美国
saraju.mohanty@unt.edu

2023年2月2日

**摘要**

注意缺陷多动障碍（ADHD）是年轻人群中一种常见的障碍。目前，标准评估技术使用评估表、患者访谈等方式。然而，其症状与抑郁症、品行障碍和对立违抗障碍等许多其他障碍的症状相似，因此现有的诊断技术并不十分有效。因此，先进的计算模型有望为这一问题提供一种有前景的诊断解决方案。本研究尝试利用多种成熟的机器学习技术（如神经网络和支持向量机模型）的组合，在 ADHD200 数据集上诊断 ADHD，并探索神经科学领域。在本研究中，使用支持向量机模型对表型数据进行多类别分类。与逻辑回归、K近邻、AdaBoost 等其他监督学习技术相比，表型数据取得了更好的结果。此外，研究还基于从40名受试者的磁共振成像数据中获得的功能连接实施了神经网络，在没有神经科学先验知识的情况下实现了较高的准确率。随后，将其与表型分类器结合，通过集成技术构建二分类器。该模型进一步在 ADHD200 数据集中的824名受试者里选取400名进行训练和测试，在二分类中达到了92.5%的准确率；使用集成分类器时，训练和测试准确率最高达到99%。

## 1 引言

注意缺陷多动障碍（ADHD）是一种普遍存在的神经发育障碍，影响着年轻群体。不过，ADHD也影响着许多成年人 [1]。被诊断为ADHD的人通常会出现注意力不集中（无法适当集中注意力）、多动（不适合静坐的过度活动）和冲动行为（可能不考虑后果便采取行动）。精神障碍的症状包括难以集中注意力、容易烦躁、容易分心以及其他异常心理状况 [2, 3]。这是一个重要的心理健康问题，也是下一代面临的挑战。如今，人们需要在不受认知、时间和医学专家可用性限制的情况下，高效治疗精神障碍。医疗专家与患者之间的远程连接，是为患者提供更优质、先进服务的流行解决方案。当前与症状相关的问题见图1。

随着当前医疗保健方法不断更新，消费者对自身健康的关注度也呈上升趋势 .

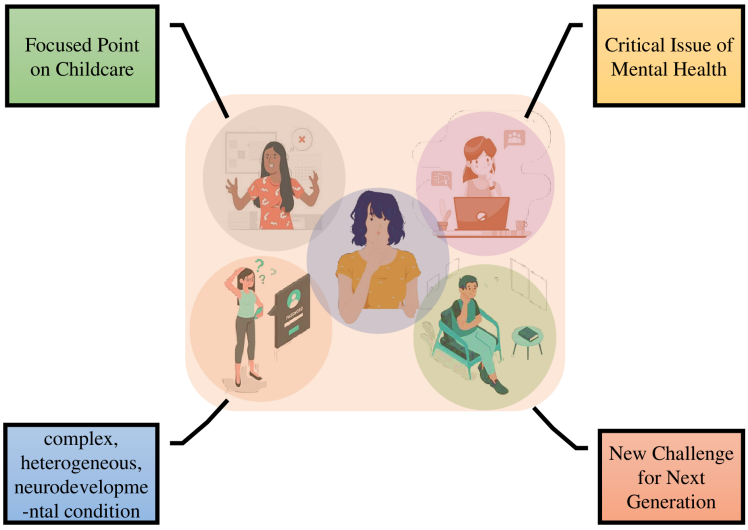


图1：ADHD症状及未来挑战

在特定情境下，远程医疗保健的需求比以往任何时候都更加突出。目前的物联网医疗框架鼓励医疗中心提升治疗质量，同时全面优化成本 [4]。随着生活方式日益复杂，注意缺陷多动障碍诊断也需要不断更新；患者需要能够立即获得治疗，不受任何基本障碍的阻碍。因此，有必要提出一种用于智慧医疗的ADHD护理框架，使患者能够及时获得医疗代表的支持，并确保治疗可靠；患者可以远程联系专家，不受时间限制 [5]。

## 2 相关研究

根据调查分析，儿童和青少年（年龄为 <18 岁）的ADHD总体平均患病率估计为2.2% [6]。许多研究采用机器学习有效诊断ADHD。为推动ADHD诊断研究，ADHD-200 联盟在国际神经影像数据共享倡议（INDI）的支持下，在全球范围内举办了ADHD-200竞赛。研究人员使用高斯随机场对脑表面进行统计分析，以探究该领域的研究进展 [7]。与此同时，随着技术进步，功能性磁共振成像被用作ADHD检测的资源。此外，研究人员还监测脑电信号以进行手势识别，从而验证脑信号的变化。研究工作致力于优化信号参数，以构建精确的框架。研究人员提取了不同特征，以提高对ADHD程度进行判定的准确率。然而，仍需建立可靠的框架，以确认精神障碍的程度。

先前的研究采用支持向量机，明确解决了 ADHD-200 [8] 的不平衡数据集问题。通过使用三目标支持向量机，分别明确处理正向和负向经验误差。在尝试了许多传统分类器并将其与基于深度学习的 CNN VGG 16 进行比较后，CNN VGG 16 模型取得了最高准确率 [9]。此前的研究展示了如何利用公开的 ADHD-200 数据集，通过多种机器学习模型使用功能性磁共振成像诊断 ADHD [10-12]。结果展示了 ADHD 与对照受试者的分类，区分了这两类人群的功能连接，并评估了表型数据对 ADHD 预测的重要性 [13]。研究人员在计算功能连接、进行基于弹性网络的特征选择并整合表型信息后，使用支持向量机对 ADHD 进行分类。在这项研究中，采用分层极限学习机（H-ELM）分类器进行了多类别分类 [14]。研究人员还比较了 H-ELM 分类器与支持向量机及基础极限学习机（ELM）分类器在 ADHD-200 数据集中 159 名 ADHD 患者皮层 MRI 数据上的表现。该研究使用带递归特征消除的支持向量机（RFE-SVM）取得了 61% 的准确率。总体而言，将 RFE-SVM 与 H-ELM 分类器结合用于结构磁共振成像数据，取得了较高的多类别分类准确率。在综述了许多有关 ADHD 预测的研究后，研究人员还发现，支持向量机和人工神经网络是最有效的分类技术 [15]。

该研究提出了一种多通道深度神经网络模型，在 ADHD-200 数据集的连接组数据与表型数据组合数据上取得了令人瞩目的结果，准确率达到 95% [16]。此外，通过融合多尺度脑连接组数据，与单尺度方法相比，多通道深度神经网络模型显著提升了 ADHD 检测性能 [16]。该研究证实，结构磁共振成像数据能够有效区分 ADHD 患者与对照组 [17]。在这项研究中，研究人员使用深度学习神经网络，确定 ADHD 儿童与 ADHD 成人脑部神经解剖学变化的相似之处。不仅如此，该研究还展示了神经网络作为分类模型的有效用途，可用于检验有关发育连续性的假设并预测 ADHD。该研究提出了一种深度神经网络多层感知机，用于诊断精神病性障碍（PDD） [18]。先前的研究表明，神经网络能够有效预测 ADHD [9, 16, 18]。图中展示了从早期技术到近期技术的发展历程，用于检测精神障碍。这些层级报告呈现在图2中。然而，准确率

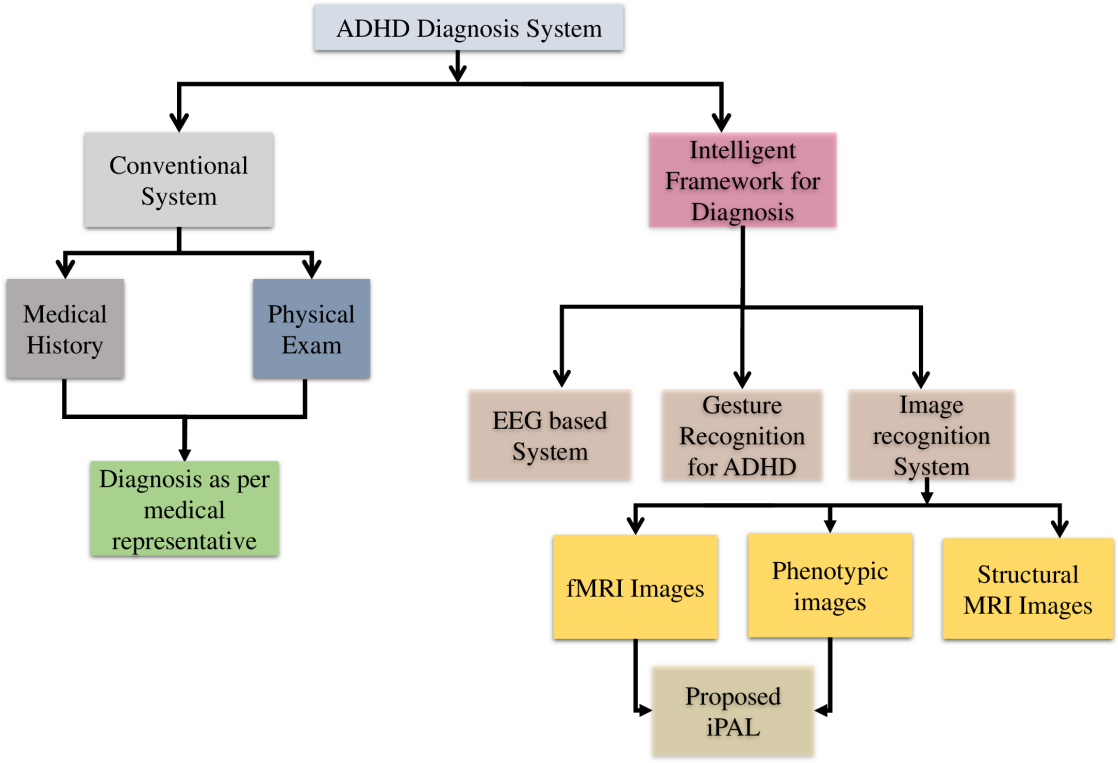


图2：注意缺陷多动障碍相关的既有研究

可靠性是未来研究面临的最新挑战。本研究提出该方法的主要动机，是探索神经科学领域高效的监督学习技术，并实现最高准确率，同时结合两类数据的结果，即表型数据和磁共振成像数据。尽管已有许多此类研究，这一问题仍有待进一步探索，至今仍备受关注，因为相关研究仍在持续开展，而 ADHD-200 数据集依然是这些研究的重要贡献。

## 3 本文的贡献

### 3.1 本文所解决的问题

目前，精神障碍患者需在接受咨询并与精神科医生讨论后接受治疗。根据医疗及个人病史，专家能够判断精神障碍的严重程度，并据此提供医疗治疗。这种传统流程存在一个缺点：患者有时可能无法咨询专家，导致治疗不够恰当或可靠。许多时候，特定地区没有专家。因此，在这些情况下，问题可能会变得十分严重。

### 3.2 本文提出的解决方案

为缓解此类问题，本文提出了一种用于智慧医疗的 ADHDcare 框架 iPAL。系统将根据症状采集脑影像，并通过计算模型进行处理；该模型已使用样本完成训练和测试。结果将以障碍状态的形式呈现，并更新给身处异地、通过互联网服务器连接的医学专家。患者可在自己方便的时间接受医学专家的咨询。数据将存储在云服务器上，用户、医务人员和专家均可访问这些数据，用于治疗和临床研究。传统流程和所提出的系统如图3所示。

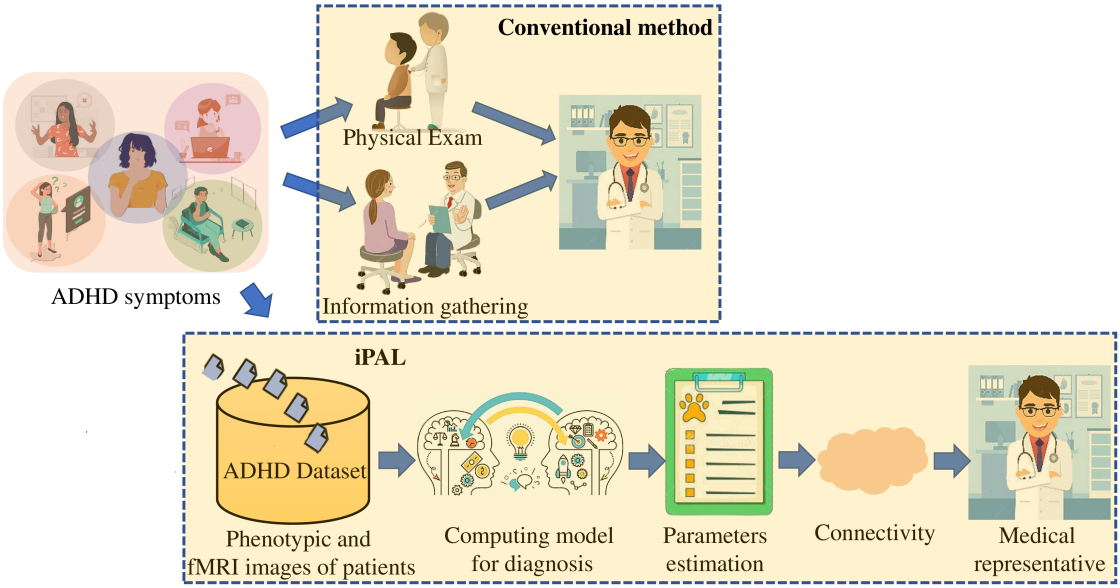


图3：用于智慧医疗的注意缺陷多动障碍诊断框架

### 3.3 所提解决方案的新颖性与重要意义

迄今为止，已有研究在精神障碍的精确判定方面开展了大量工作，早期研究中对此已有阐述。许多模型对脑电信号和不同类型的脑影像进行分类。该框架已在规模可观、包含足够数量且具有多种情况受试者的 ADHD-200 数据集上进行校准和测试。采用表型和功能性磁共振成像进行预处理、条件处理和分类，以实现 ADHD检测。提取多种特征用于分类。数据按照分析标准进行了划分。该框架被呈现为一种有效的虚拟模型，可作为实时框架，用于即时诊断注意缺陷多动障碍。研究成果经过审慎报告，展现了 ADHD检测领域近期技术的进步。

1. 提出了一种结合功能磁共振成像和表型影像的实时框架，用于智慧医疗，使患者能够远程联系医学专家。2. 提取关键特征，并采用精确的分类器，按照规定的数据分析方案进行注意缺陷多动障碍诊断。3. 使用实时脑影像训练模型，并将训练好的模块或数据应用于人群，以实现精确检测。4. 训练并测试多个分类器，以分析优化后的模型，从而为精神障碍的判定提供可靠结果。5. 精确模型取得了出色的性能指标，可实现可靠诊断。

本研究提出了一种独特的方法，可根据实时表型数据和功能磁共振成像图像，对精神障碍作出准确判断。图4展示了相关可视化结果，体现了所提出框架的重要性。

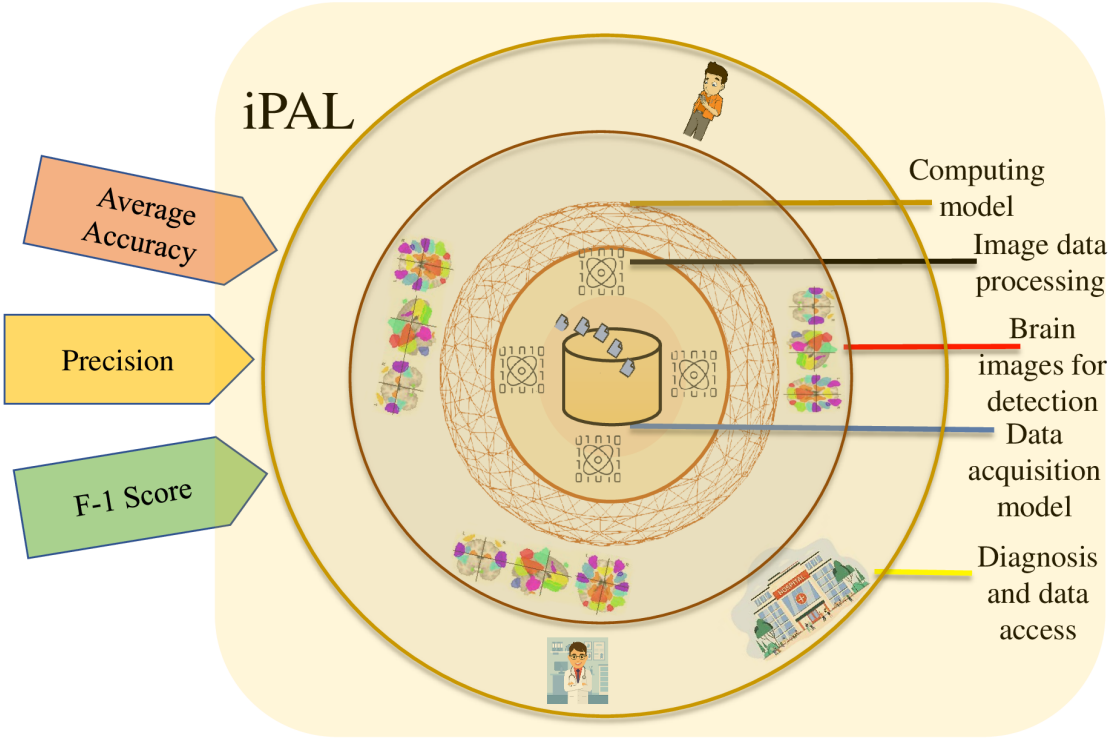


图4：iPAL 的重要性与有效范式

## 4 自动注意缺陷多动障碍诊断框架：iPAL 概述

在本研究中，我们选取了不同的患者（受试者），构建高效的数据集，用于训练注意缺陷多动障碍诊断框架。数据按70:30的比例划分为训练集和测试集。对实时图像进行预处理，并提取特征以进行分类。通过多个模型进行分析后，计算出准确率等参数。结果存储在云服务器上，供医学专家和患者进一步访问。数据可供多个医疗中心用于后续临床试验，并受到安全保护。所提出的 iPAL 经过训练和测试后，能够诊断注意缺陷多动障碍。该框架的主要优势在于速度快、可靠且成本低：借助 iPAL 对精神障碍进行判断的成本较低，而且患者和医生可以在异地访问该框架。因此，相较之下，该方案速度更快、可靠性更高。图5展示了所提出 iPAL 的架构视图。

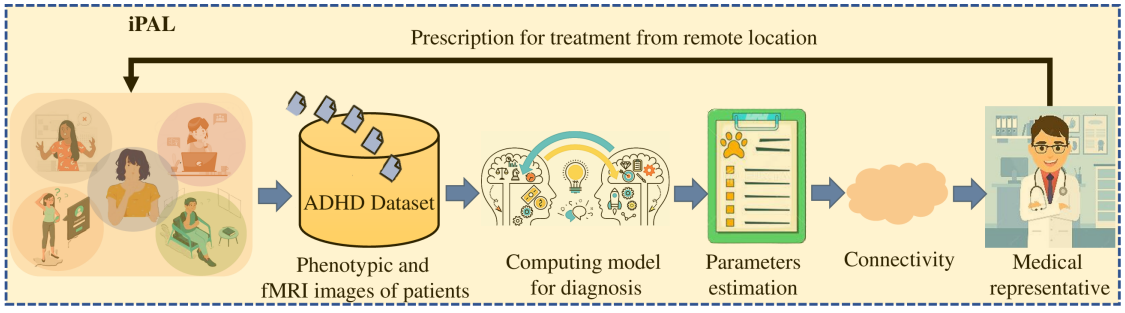


图5：iPAL 的架构示意图

### 4.1 拟议 iPALFramework 校准与初步测试数据集

为了解决精神障碍相关问题，根据既往研究，儿童和青少年（年龄为 <18 岁）的 ADHD 平均患病率估计为 2.2% [6]。诊断 ADHD 的常见方法包括填写评估表、体格检查、与患者访谈等。因此，许多研究致力于利用智能学习有效诊断 ADHD。为诊断 ADHD，ADHD-200 联盟在国际神经影像数据共享倡议（INDI）的支持下，在全球范围内举办了 ADHD-200竞赛。图6大致展示了 ADHD-200 及其数据集的研究动机和目的。ADHD-200 数据集包含 900 多名受试者的静息态功能磁共振成像（rs-fMRI）和结构磁共振成像（s-MRI）图像。该竞赛旨在确定区分典型发育儿童（TDC）与 ADHD 患者的预测准确率。最初，基于影像数据得到的最高准确率为 2011 年的 60.51%。这促使众多研究人员利用竞赛数据开展有关 ADHD 的各类研究和预测，至今仍有许多相关工作在进行。NITRC 还公开提供了预处理后的ADHD-200数据，以便更多研究人员参与研究、进一步开发并取得更好的结果。

ADHD-200 数据集包含两类数据：个人特征数据和磁共振成像（MRI）数据，后者包括静息态功能磁共振成像（rs-fMRI）和结构磁共振成像（s-MRI）。然而，随着 ADHD-200全球竞赛的开展，相关研究显著增加。ADHD-200 数据集为此类研究提供了大规模数据集，推动了这些研究的发展。因此，许多模型相继问世，其中不少仍在开发中。注意缺陷多动障碍（ADHD）是一种广泛影响年轻群体的神经发育障碍。然而，许多成年人也会受到 ADHD 的影响。被诊断为 ADHD 的人通常会出现注意力不集中（无法恰当地集中注意力）、多动（坐着时出现不合宜的过度活动）和冲动行为（可能不假思索地行动，不考虑后果）等症状。根据既往研究，儿童和青少年（年龄为 <18 岁）的 ADHD 总体平均患病率估计为 2.2% [6]。诊断 ADHD 的常见方法包括填写评估表、体格检查、患者访谈等。因此，许多研究利用智能学习方法，致力于有效诊断 ADHD。为诊断 ADHD，ADHD-200 联盟在国际神经影像数据共享倡议（INDI）的支持下，在全球范围内举办了 ADHD-200竞赛。图6大致展示了 ADHD-200 及其数据集背后的动机和目的。ADHD-200 数据集包含 900 多名受试者的静息态功能磁共振成像（rs-fMRI）和结构磁共振成像（s-MRI）图像。该竞赛旨在提高区分典型发育儿童（TDC）与 ADHD 患者的预测准确率。最初，使用成像数据所得的最高准确率于 2011 年达到 60.51%。这促使众多研究人员利用竞赛数据开展 ADHD 相关研究和预测工作，至今仍有许多研究正在进行。NITRC 还公开提供了预处理后的ADHD-200数据，以便更多研究人员参与研究、进一步改进并取得更好的结果。ADHD-200 数据集包含两类数据：个人特征数据和磁共振成像（MRI）数据，后者包括静息态功能磁共振成像（rs-fMRI）和结构磁共振成像（s-MRI）。然而，随着 ADHD-200全球竞赛的开展，相关研究显著增加。ADHD-200 数据集为此类研究提供了大规模数据集，推动了这些研究的发展。因此，许多模型相继问世，其中不少仍在开发中。

图6大致展示了 ADHD-200 及其数据集背后的动机和目的。ADHD-200 数据集包含 900 多名受试者的静息态功能磁共振成像（rs-fMRI）和结构磁共振成像（s-MRI）图像 [10, 11]。这项竞赛旨在确定区分典型发育儿童（TDC）与注意缺陷多动障碍患者的预测准确率。最初，仅使用影像数据时，2011 年的最高准确率为 60.51%。这激励了众多研究人员利用竞赛数据，对注意缺陷多动障碍开展各种研究并进行预测；时至今日，仍有许多相关研究在进行。NITRC 还公开了预处理后的 ADHD-200 数据，以便更多研究人员参与研究、进一步开发并取得更好的结果。ADHD-200 数据集包含两类数据：个人特征数据和磁共振成像（MRI）数据，其中包括静息态功能磁共振成像（rs-fMRI）和结构磁共振成像（s-MRI）。然而，随着 ADHD-200全球竞赛的推出，相关研究显著增多。ADHD-200 数据集提供了如此大规模的数据集，为这些研究提供了便利。因此，近年来涌现了许多模型，其中不少仍在开发中。

### 4.2 自动注意缺陷多动障碍诊断数据集描述

表型数据集由 ADHD-200 数据集中 973 名参与者的个人特征数据组成，例如 ScanIDDir、站点、性别、年龄、利手、诊断、次要诊断、注意缺陷多动障碍测量值、注意缺陷多动障碍指数、注意力不集中、

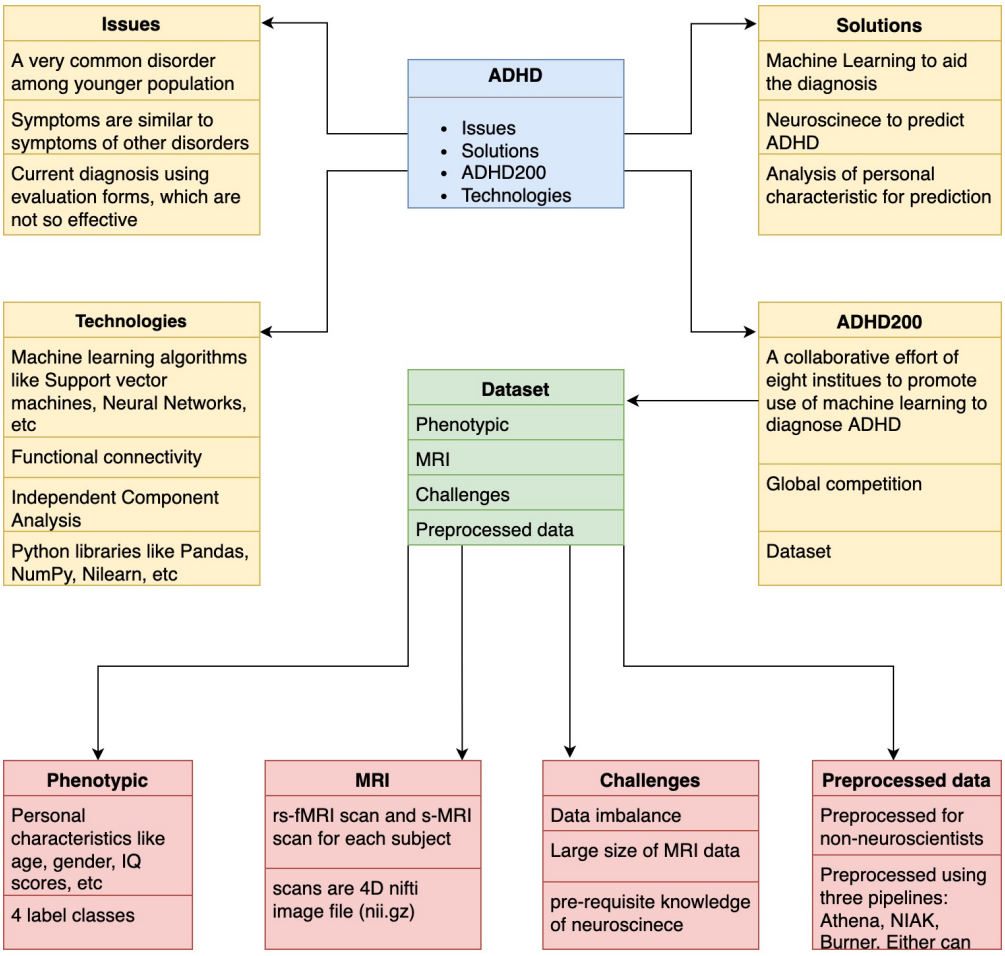


图6：注意缺陷多动障碍数据集流程图

多动/冲动、智商测量、言语智商、操作智商、Full2智商、Full4智商、用药状态、QC_Athena、QC_NIAK，如表1所述。由于数据集中存在一些差异和隐含取值，我们筛除了一些行以处理这种不平衡。例如，该数据的标签“诊断”有四种取值：注意缺陷多动障碍-混合型、注意缺陷多动障碍-多动冲动型、注意缺陷多动障碍-注意缺陷型，以及健康对照/典型发育对照组（TDC），并用于多分类器模型。

对于磁共振成像数据，从 Athena处理流程预处理后的数据中选取了824名受试者，并使用自定义 Python 脚本进行整理，供功能磁共振成像模型使用；该数据包含来自全部八个网站的数据。筛选时仅使用预处理后的静息态功能性磁共振扫描。通过筛选，将受试者的相关数据汇集到一处，以便与个体的表型信息一同使用。我们使用自定义 Python 脚本加载这些数据，并将其整理为可用格式。数据标签（即“ADHD”/“label”）最初也有四个取值：ADHD-C、ADHD-H、ADHD-I 和 TDC，之后转换为二元取值：“1”表示患有注意缺陷多动障碍，“0”表示未患有注意缺陷多动障碍。此外，还使用了 nilearn 库提供的40名受试者样本。

采用来自 NITRC 的 ADHD-200 竞赛中 973 名受试者的表型数据，预测并诊断 7 至 18 岁儿童的 ADHD。如 [8], 所述，所提出的多目标分类方案避免了超参数选择。此外，对参数进行了平衡，以避免过拟合。表型数据包括个人特征，例如 ScanIDDir 、站点、性别、年龄、利手、诊断、次要诊断、注意缺陷多动障碍测量值、注意缺陷多动障碍指数、注意力不集中、多动/冲动、智商测量、言语智商、操作智商、Full2智商、Full4智商、用药状态、QC_Athena、QC_NIAK（表1）。数据分为四种分类类型，即典型发育儿童（TDC）、注意缺陷多动障碍-注意缺陷型（ADHD-I）、注意缺陷多动障碍-多动冲动型（ADHD-H）和注意缺陷多动障碍-混合型（ADHD-C）。数据中存在一些隐含值和缺失值。为处理这些隐含值和差异，筛除了不必要的列，并删除了缺少 ADHD 预测关键数据的行。筛选后，数据规模缩减至 505 名受试者，并应用多种分类算法以更好地预测数据。主要使用的分类模型包括支持向量机、随机森林、AdaBoost、K近邻、逻辑回归

回归。支持向量机的预测准确率最高；此外，分类图中参数之间的关系显示，ADHD 与可能影响该障碍的因素之间存在显著关联。

本研究结合了个体的表型信息与静息态功能磁共振成像。在从 nilearn 数据集中选取的 40 名受试者样本上进行测试时，支持向量机的准确率达到 100%。相比之下，基于功能连接组数据实现的神经网络准确率为 75%。使用各项权重相等的投票分类器诊断注意缺陷多动障碍，准确率达到 100%。这种综合高准确率是因为，基于功能磁共振成像实现的神经网络在预测注意缺陷多动障碍时准确率为 100%，但无法完美预测对照组。因此，支持向量机能够筛除对照组样本，使总体准确率达到 100%。随后，该方法进一步拓展，并应用于公开的 ADHD-200 数据集。通过独立成分分析（ICA） [19], , 利用 CanICA 从功能磁共振成像的体素时间序列中提取多个感兴趣区域（ROIs）。这些感兴趣区域还可用于计算功能连接，例如“切线”“偏相关”和“相关”。此外，还利用得到的有效功能连接绘制功能连接图。根据 [15], , 功能连接指体素或脑区之间的无向耦合强度，并使用标准相关性度量进行计算。因此，功能连接图是这些连接的表示。由此，功能连接还可用作预测模型的输入。

先前研究中的模型准确率为 65% [20-27]。研究发现，准确率达到了 92.50%。因此，本研究尝试进一步提高准确率。

本研究通过纳入更多患者记录扩充了数据库。总计使用了来自 [11]的 824 条患者记录。进一步分析可用记录时，考虑到数据差异和隐含取值，经过数据处理后，记录数量缩减至 400 条。通过这种方式，扩展了算法的学习部分，从而提升了模型的泛化能力。研究进一步使用支持向量机（SVM）分析这 400 名受试者的表型数据，并使用神经网络分析功能性磁共振成像数据，以进行分类。SVM 在表型数据上的准确率为 99.16%，神经网络在基于磁共振成像的数据上的准确率为 86.66%。最后，进一步对数据进行分类时，采用等权重投票的数据集成方法提高了准确率，最终准确率达到 92.50%。目前，该数据集使用广泛的参数来预测儿童是否患有注意缺陷多动障碍、可能出现的症状，以及儿童更容易患上注意缺陷多动障碍的年龄。

## 5 数据特征与预处理

### 5.1 表型数据集

使用了来自 [11] 和 [28] 的数据集，其中包括表型数据集和磁共振成像数据集。其中一个数据集包含从 nilearn 库中获取的 40 名受试者的数据。它有四种重要的数据集类型，即 'func'、'confounds'、'phenotypic' 和 'description'。这些数据包含许多有助于诊断患者是否患有注意缺陷多动障碍的特征，尤其是表型数据，其中包含 f0、RestScan、平均FD、NumFD_greater_than_020、函数依赖均方根、FDquartiletop14thFD、PercentFD_greater_than_020、Subject、平均DVARS 等特征。在数据预处理中，大多数取值不可用或为空值的特征会被剔除。删除所有此类特征并对数据进行优化处理后，数据集缩减为 39 名受试者和 18 个表型特征，分别为 f0、Subject、RestScan、平均FD、NumFD_greater_than_020、函数依赖均方根、FDquartiletop14thFD、Per- centFD_greater_than_020、平均DVARS、MeanFD_Jenkinson、站点、data_set、年龄、性别、典型发育对照组、注意缺陷多动障碍、sess_1_rest_1和 sess_1_anat_1，如表 1 所示，以应用支持向量机。

另一个数据集取自 [11], , 其中包含受试者的表型数据和磁共振成像数据。我们提取了每位受试者的数据，然后将其合并，形成一个独立的数据集。随后，我们对 824 名受试者的表型数据集进行进一步分析，所涉及的特征包括 ScanDir ID、站点、性别、年龄、利手、注意缺陷多动障碍、注意缺陷多动障碍测量值、注意力不集中、多动/冲动、智商测量、言语智商、操作智商、Full4智商、用药状态、QC_Athena 和 QC_NIAK。分析中剔除了空值或未定义取值超过 60% 的特征，随后从数据集中删除了其余含有空值的行。数据清理后，剩下 400 条记录和 14 个特征，分别为 ScanDir ID、站点、性别、年龄、注意缺陷多动障碍、注意缺陷多动障碍测量值、注意力不集中、多动/冲动、智商测量、言语智商、操作智商、Full4智商、QC_Athena 和 QC_NIAK，如表1所示，这些数据将用于进一步分析。图7展示了 ADHD-200 数据集中多个属性的相关矩阵。图8展示了使用 Nift Map Masker 在三维脑掩膜图像上通过独立成分分析（ICA）获得的默认模式网络（DMN）及各成分的可视化结果。

来自 ADHD-200 样本的一次磁共振成像扫描中某个体素的时间序列可视化。这里，x 轴对应时间单位，y 轴对应血氧水平依赖（BOLD）功能磁共振成像信号。体素可分为

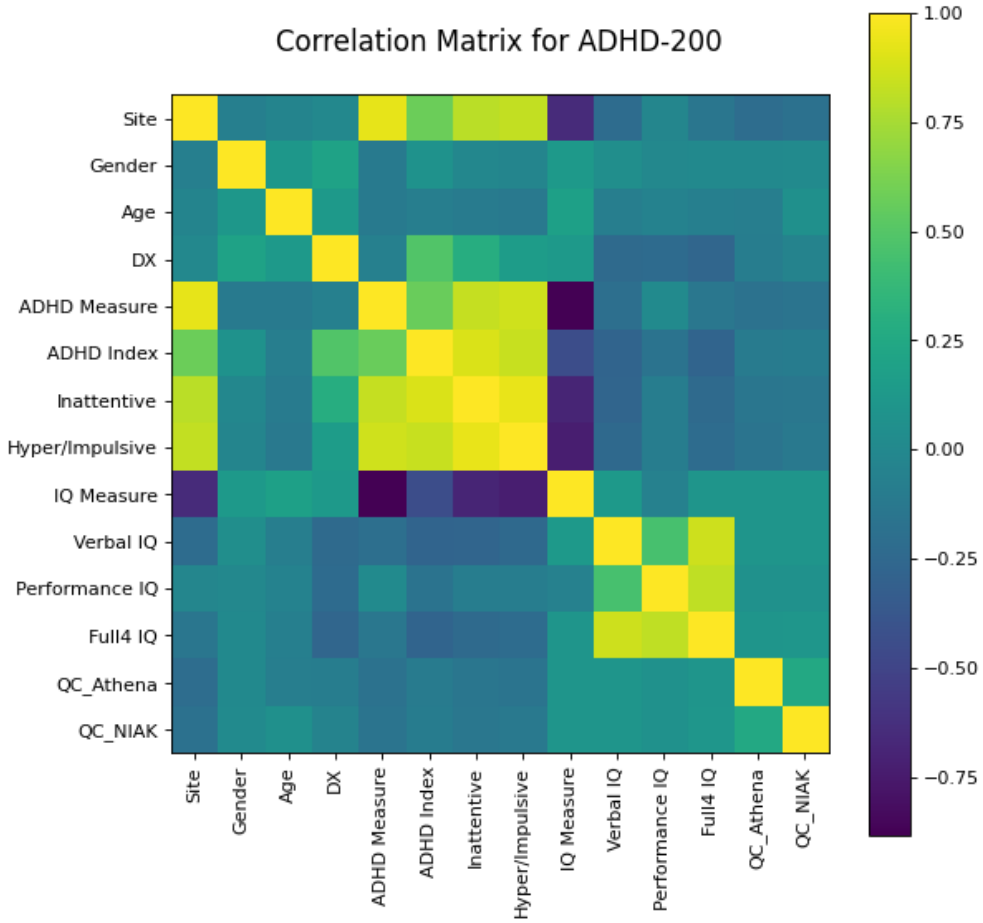


图7：相关矩阵展示了用于分类的表型数据集多个属性之间的关系。

“活跃”或“不活跃”，具体取决于这些信号的强度。进一步计算该时间序列后，可得到功能连接。其可视化结果见图9。连接性生物标志物的准确率图见图10。

从 [11] 中选取表型文件，用于注意缺陷多动障碍的诊断与分类。该文件包含973个个体的数据，存在许多差异，因此在将数据输入多个多类别分类模型之前，需要先处理这种不平衡情况。为确定结果，采用了特征的各种组合，同时考虑这些特征对于注意缺陷多动障碍的实用性，最终将范围缩小至包含多个特征的505个个体。这些特征包括站点、性别、年龄、注意缺陷多动障碍测量值、注意缺陷多动障碍指数、注意力不集中、多动/冲动、智商测量、言语智商、操作智商、Full4智商、QC_Athena和QC_NIAK，如表1所示。图7中的相关矩阵展示了多个特征之间的关系，而列分布有助于理解数据中各元素的分布情况。

#### 5.2 磁共振成像数据集

所用磁共振成像数据取自 [11]中经Athena处理流程预处理的数据。共使用824名受试者的数据；处理隐式数据后，范围缩小至400名。静息态功能磁共振成像数据以四维NIfTI图像文件（.nii.gz）的形式存储，并已移除噪声变量。在四维NIfTI图像中，前三个维度表示三维空间的三个坐标，即x、y和z，第四个维度表示时间。因此，四维图像是若干对应于各个时间单位的三维图像的集合。三维图像由体素构成，正如二维图像由像素构成。每个体素都关联着某种功能磁共振成像信号；在此情况下，该信号为血氧水平依赖（BOLD）信号（在功能磁共振成像中检测）。将体素的这些信号随时间绘制出来，称为时间序列。这些时间序列为进一步计算功能连接提供数据，并有望推动机器学习应用和研究。表1列出了ADHD-200表型数据的标准记法。

表1：ADHD-200表型数据中使用的特征相关符号

| 参数 | 描述 | 取值 |
|---|---|---|
| 受试者ID/个体ID | 七位整数值 | |
| Site | 为个体提供其 data | 1 北京大学 2 布拉德利医院/布朗大学 3 肯尼迪·克里格研究所 4 NeuroIMAGE样本 5 纽约大学儿童研究中心 6 俄勒冈健康与科学大学 7 匹兹堡大学 8 华盛顿圣路易斯大学 |
| 性别 | 性别信息 | 0 女性 1 男性 |
| Age | 测试时年龄 | 年龄为 7 至 18 岁的儿童。平均值：11.37 岁 |
| DX | 注意缺陷多动障碍诊断 | 0 - 典型发育儿童 1 - 注意缺陷多动障碍——混合型 2 - 注意缺陷多动障碍—多动/冲动型 3 - 注意缺陷多动障碍—注意缺陷型 |
| ADHD | 注意缺陷多动障碍诊断 | 0 - 典型发育儿童 1 - 注意缺陷多动障碍——混合型，多动/冲动，注意力不集中 |
| 注意缺陷多动障碍测量值 | 测量方法 | 1 注意缺陷多动障碍评定量表第四版（ADHD-RS） 2 康纳斯父母评定量表修订版长版（CPRS-LV） 3 康纳斯评定量表第三版 |
| 注意缺陷多动障碍指数 | 注意缺陷多动障碍测量 | 取值范围为 18 - 99。平均值：49.37 |
| 注意力不集中值 | 基于注意缺陷多动障碍 测量采用 | 取值范围为 9 - 90。平均值：41.61 |
| 多动/冲动值 | 采用的注意缺陷多动障碍测量值 | 取值范围为 9 - 99，平均值：39.85 |
| 智商测量 | 用于测量的方-法：智商 | 1 韦氏儿童智力量表第四版 (WISC-IV) 2 韦氏简式智力量表（WASI）3 中国儿童韦氏儿童智力量表修订版（WISCC-R）4 WASI双分测验 5 两项分测验：WISC或韦氏成人智力量表——积木图案和词汇 |
| 言语智商 | 基于智商测量 | 取值范围为 65 - 158。平均值：112.80 |
| 操作智商 | 基于智商测量 | 取值范围为 54 - 139。平均值：106.01 |
| Full4智商 | Full4智商测量值 | 取值范围为 73 - 153。平均值：110.41 |
| 质量控制_ Athena | 对某个个体相对于 Athena 的数据进行质量控制检查处理流程 | 0 存疑 1 通过质量控制_NIAK |
| 质量控制 | 对个人数据的检查相对于 NIAK处理流程 | 0 存疑 1 通过 |
| 静息态扫描 | 静息态扫描类型 | 全部为‘静息态1’_ |
| 平均FD | Mean 功能依赖 | 0 到 1 之间的浮点值 |
| NumFD_大于_于_020 | 函数 依赖强度为 > 20% | 整数值 |
| 函数依赖均方根 | 函数依赖的均方根关系 | 介于 0 到 1 之间的浮点值 |
| 函数依赖百分比_大于_则_020 | 函数 依赖项强度为 > 20% (%) | 介于 0 和 1 之间的浮点值 |
| 平均DVARS | 平均变化量全脑信号年龄 | 浮点值 |
| 平均FD _Jenkinson | 平均相关性运动参数 | 浮点值 |
| 数据集_ | Type 数据集的，最初由 nilearn 使用 | ‘测试集’/‘数据集’ – – |
| tdc/ 典型发育对照组 | 典型发育对照的缩写典型发育对照 | 0 或 1 |

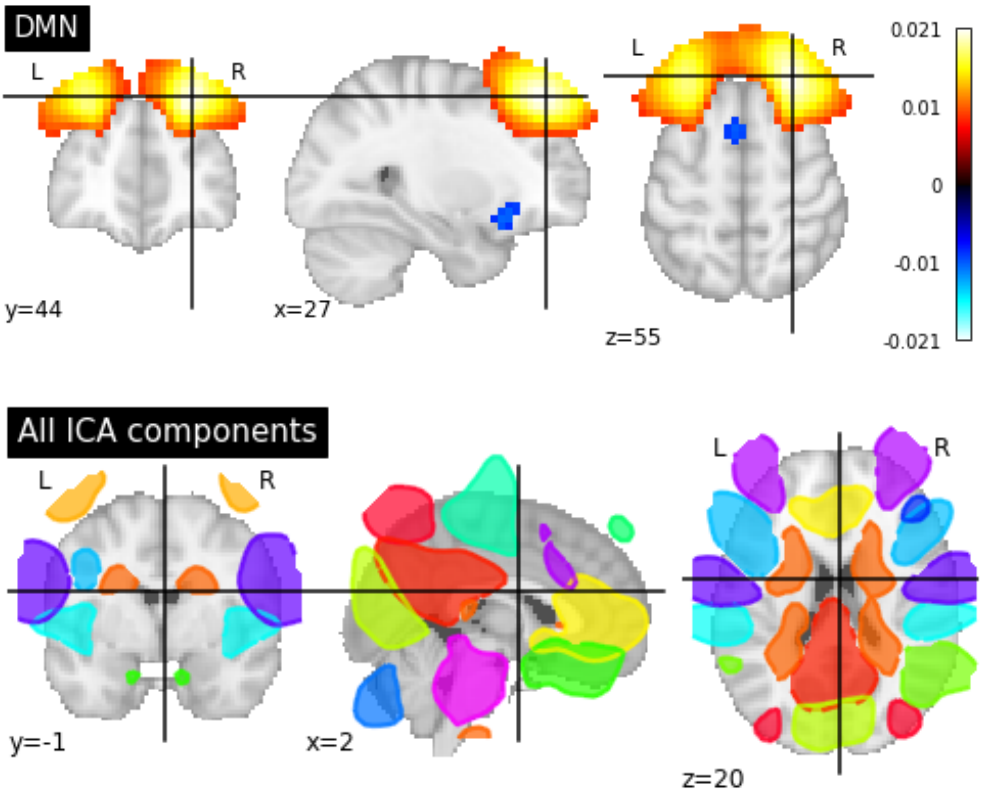


图 8：使用 Nift Map Masker 对三维脑掩膜图像进行独立成分分析（ICA）后得到的默认模式网络（DMN）和成分的可视化。

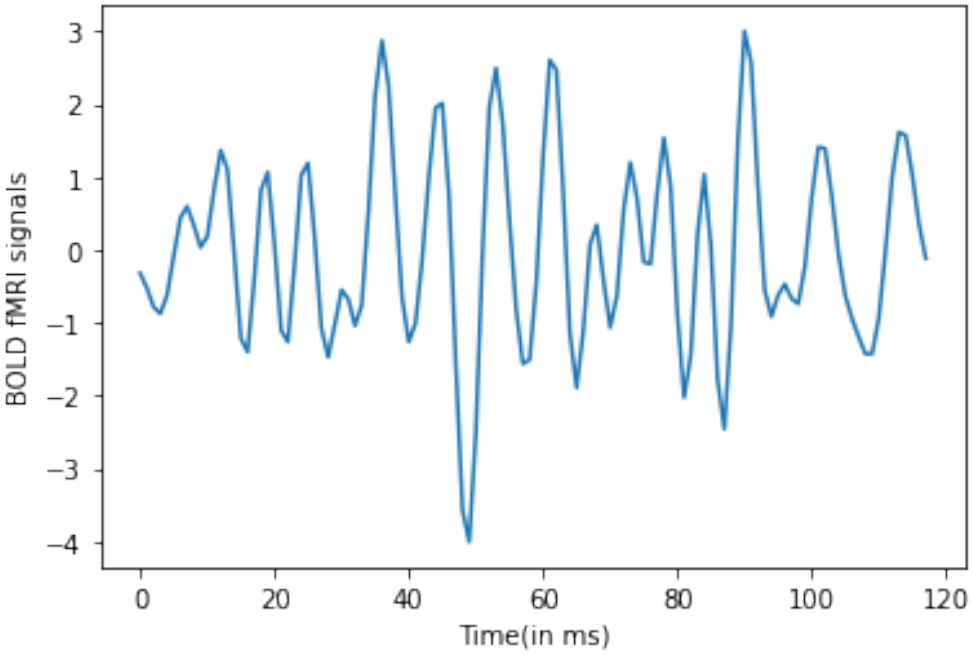


图 9：ADHD-200样本中一份 MRI扫描的体素时间序列可视化。

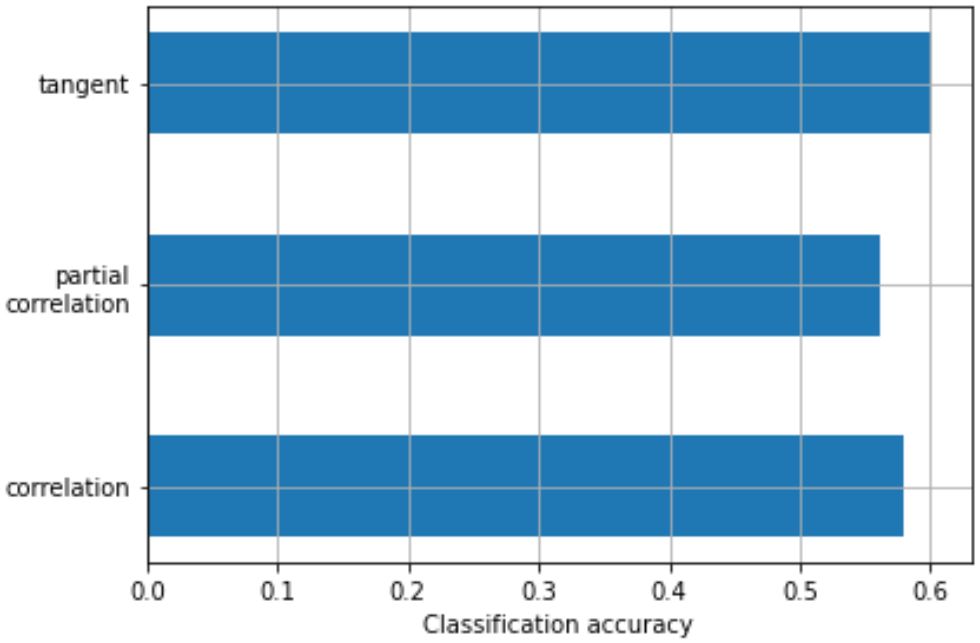


图10：连接性生物标志物的准确率图：“切线”、“偏相关”、“相关”

分别在图11和图12中展示了一名患有注意缺陷多动障碍的受试者的20个脑区之间的连接矩阵，以及所有受试者的平均功能连接矩阵。

### 5.3 注意缺陷多动障碍框架的特征选择

#### 5.3.1 表型数据集

973名受试者的表型数据集包含多个特征，但并非所有特征对注意缺陷多动障碍诊断的贡献都相同。通过应用逻辑回归并考察系数，可以了解哪些特征具有显著贡献。这些特征包括站点、性别、注意缺陷多动障碍测量值、注意缺陷多动障碍指数、注意力不集中、多动/冲动、智商测量、言语智商和操作智商。其他影响不显著的特征包括年龄、利手、Full4智商、Full2智商、用药状态、QC_Athena 和 QC_NIAK，这可能是由多种因素造成的。现有数据样本所涵盖的年龄范围较窄，因此在该范围内，诊断可能与个体年龄无关。利手测量取决于所采用测量方法的大学，因此存在较大差异。一些个体的取值为二元或三元整数，另一些个体的利手取值则为小数，导致了相当大的不一致性。用药状态和Full2智商对诊断几乎没有影响，却占用了大量隐含值，因此最好将其删除，以便使用更大的数据集。得出这一结论的依据是：在考虑和不考虑这些属性的情况下运行脚本，并发现含有这些属性的大多数实例要么没有可用值（N/A），要么包含超出范围的值，例如 -999。因此，由于存在显著的不一致性，不能声称某个特征在数据集范围之外仍有用处。我们按用药状态和Full2智商对数据进行排序并将其输入分类器后发现，这两个特征都未对结果产生显著影响。因此，我们整合了站点、性别、年龄、诊断、注意缺陷多动障碍测量值、注意缺陷多动障碍指数、注意力不集中、多动/冲动、智商测量、言语智商、操作智商、Full4智商、QC_Athena 和 QC_NIAK 的表型信息，如表1所示；这些信息将用于后续分析，分析所用数据来自505名受试者。

#### 5.3.2 MRI数据集

静息态功能磁共振成像数据中，有些功能磁共振成像文件已去除噪声变量，有些则仍包含噪声变量。尽管时间序列在神经影像学中很常用，但纳入所有体素及其时间序列会大幅增加数据量。因此，我们通过概率分析和统计分析提取感兴趣区域（ROI），即那些暂时相关且活跃的体素。其余体素没有实际意义，被视为噪声体素。一种此类方法是独立成分分析（ICA）。使用

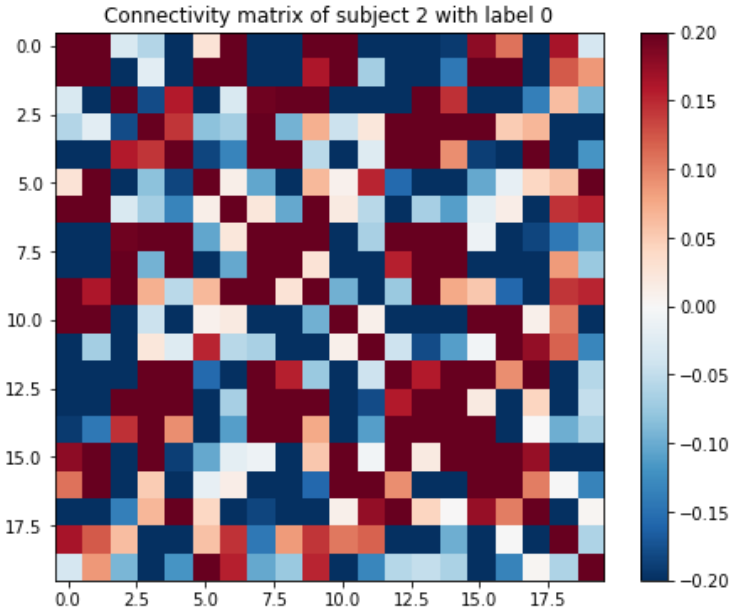


(a) 第一种情况

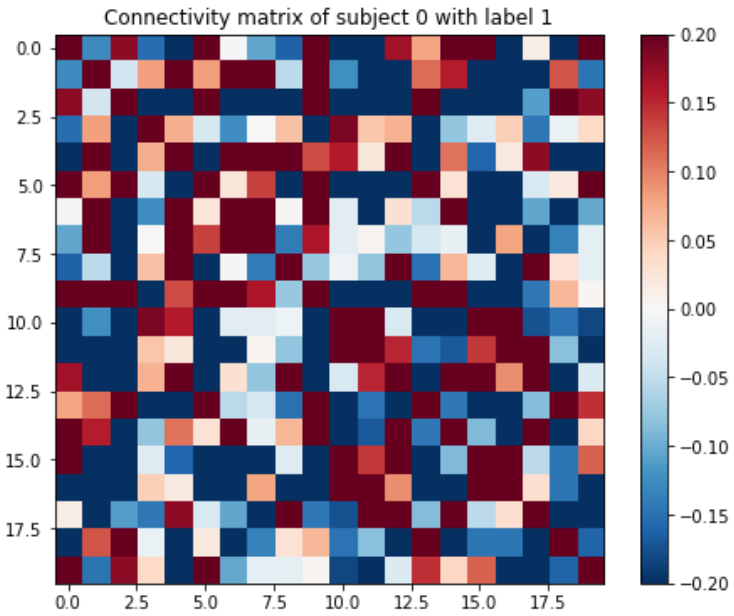


(b) 第二种情况

图11：一名确诊患有注意缺陷多动障碍（标签1）的受试者的20个脑区之间的连接矩阵，强度范围为 -20% 至 20%

通过独立成分分析，提取了20个成分，如图8(b)所示。进行了大量计算，将感兴趣区域的数量设定在15至40之间。分析得出的最佳数量为20。

因此，使用 [28] 中的组水平独立成分分析（CanICA）方法进行独立成分分析，以分析功能磁共振成像信号并去除这些噪声变量。根据 [29], , 静息态磁共振成像信号（血氧水平依赖信号）的处理对于识别感兴趣区域至关重要。默认模式网络（DMN）能有效体现注意缺陷多动障碍脑与典型发育脑之间的差异；借助独立成分分析，可以从磁共振成像[28-30]中高效识别感兴趣区域。通过识别感兴趣区域，可以大幅减少体素数量，仅保留激活体素来绘制

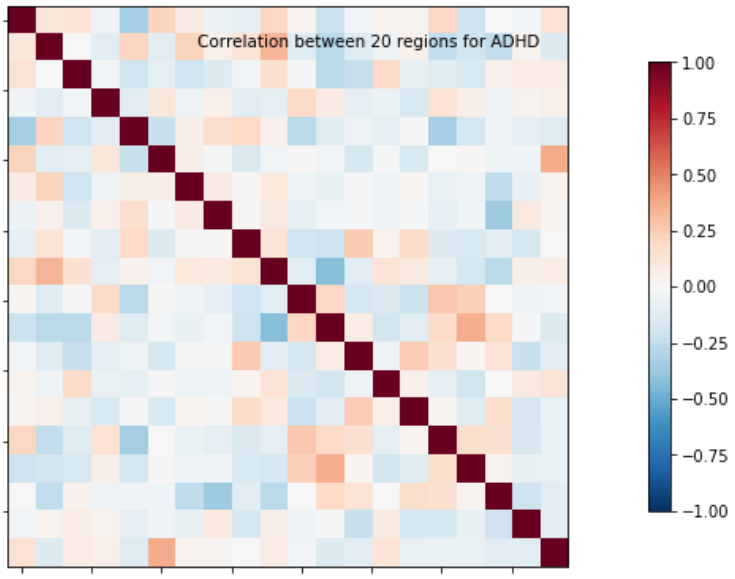


(a) 第一个案例

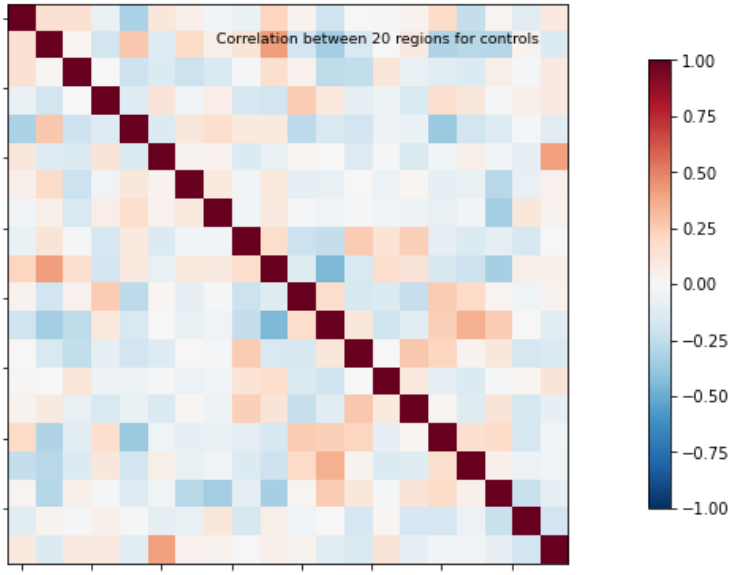


(b) 第二个案例

Fig图 12：所有受试者平均功能连接的相关矩阵 注意缺陷多动障碍组和典型发育对照组 受试者

功能连接图 [27-29]。移除非活动/含噪体素也能提高准确率。图8(a)展示了使用独立成分分析提取的成分对应的默认模式网络，其坐标取值为（x = 27，y = 44，z= 55）；图中以三幅图像分别呈现各坐标轴，直线的交点表示坐标位置。类似地，图8(b)展示了对数据集进行独立成分分析后提取的20个成分，并以（x = 2，y = -1，z = 20）作为参考坐标。

移除噪声体素并提取感兴趣区域后，使用类似图 9 所示的 fit_transform 方法获得了该数据的时间序列。进一步计算该时间序列后，可用于获得功能连接。

我们考虑了三种连接性度量来计算功能连接：相关、偏相关和切线。首先比较了这三种度量的准确率，发现“相关”和“切线”的准确率

相近且足够准确，如图10所示，因此后续采用“相关”。 [30-33] 的结果表明，与其他连接性度量相比，相关更适合作为连接性度量。此外，与随机网络相比，使用相关作为连接性度量构建的网络似乎具有更明显的聚类特征。为此，使用来自sklearn [34]库的StratifiedKFold分层交叉验证对数据进行分层，并使用连接性度量和线性支持向量分类器进行分类，以便进行比较。

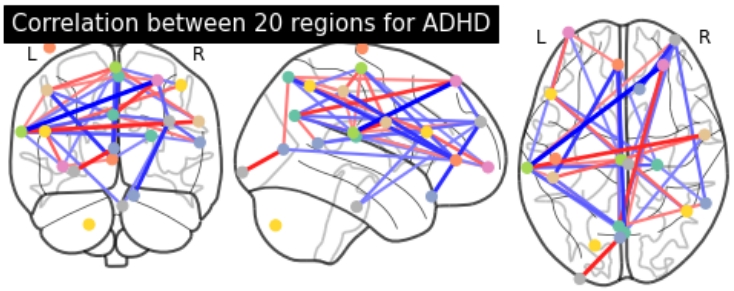


(a) 第一种情况

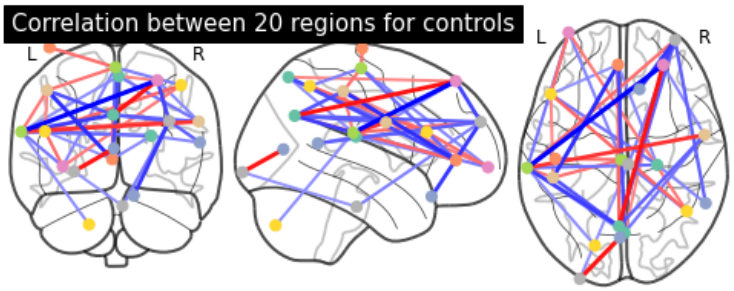


(b) 第二种情况

图13：以三维空间表示的 ADHD 与 TDC 受试者的平均功能连接组。在此图中，线条的颜色表示连接强度（参见图14）。

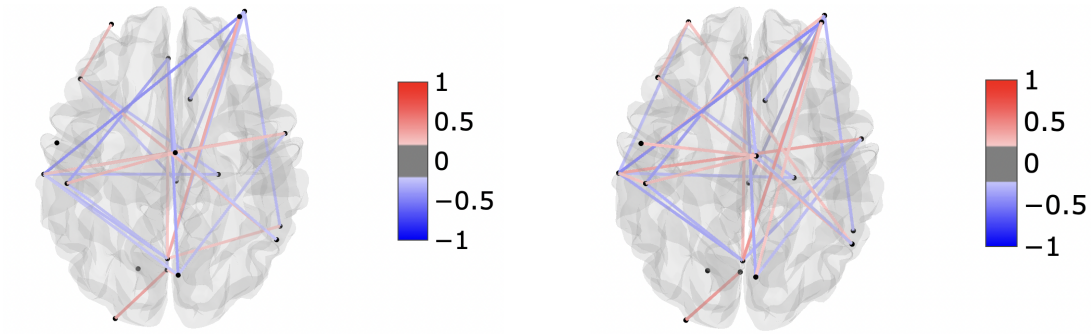


(a) 第一种情况　　(b) 第二种情况

图14：平均连接矩阵的功能连接图，以色阶显示20个脑区之间的连接强度，从而更直观地呈现 ADHD 与 TDC 受试者连接的密度。

获得感兴趣区域的时间序列后，使用相关性连接测量方法，以相关矩阵的形式测量功能连接。根据相关研究，功能连接是指体素或脑区之间的无向耦合强度，通常使用标准相关性测量方法计算[27-29]。功能连接图是对这些连接的表示。此外，功能连接还可以

用作预测模型的输入。图11 (a) 和 (b) 分别显示了无 ADHD 个体和 ADHD 个体的连接矩阵。

图12（a）和（b）分别为通过独立成分分析得到的20个脑区中，注意缺陷多动障碍组和典型发育对照组的平均功能连接平均相关矩阵。忽略对角线（某个脑区与自身的相关性始终为1）后，从图中看，各连接似乎没有太大差异。仅凭视觉很难区分这两幅图。因此，将这些连接绘制在脑图上，形成如图13所示的功能连接图。

将这些功能连接矩阵映射到脑图像上，其中每个节点代表一个感兴趣区域，边则代表各感兴趣区域之间时间同步的连接，并保留连接强度超过80%的连接，从而得到功能连接图或功能连接组。图13（a）展示了注意缺陷多动障碍确诊患者的平均连接图，其中包含20个感兴趣区域。图13（b）展示了这些感兴趣区域之间连接强度的比例尺，以供参考。

从图13（a）和（b）以及图14（a）和（b）可以看出，注意缺陷多动障碍组与典型发育对照组的功能连接图存在视觉差异。显而易见，注意缺陷多动障碍组的连接密度明显低于典型发育对照组。因此，这也表明可以利用功能连接区分注意缺陷多动障碍组和典型发育对照组，并将功能连接作为分类器的输入来预测注意缺陷多动障碍。此外，一些研究证明脑连接性是注意缺陷多动障碍诊断的生物标志物 [35,36]。

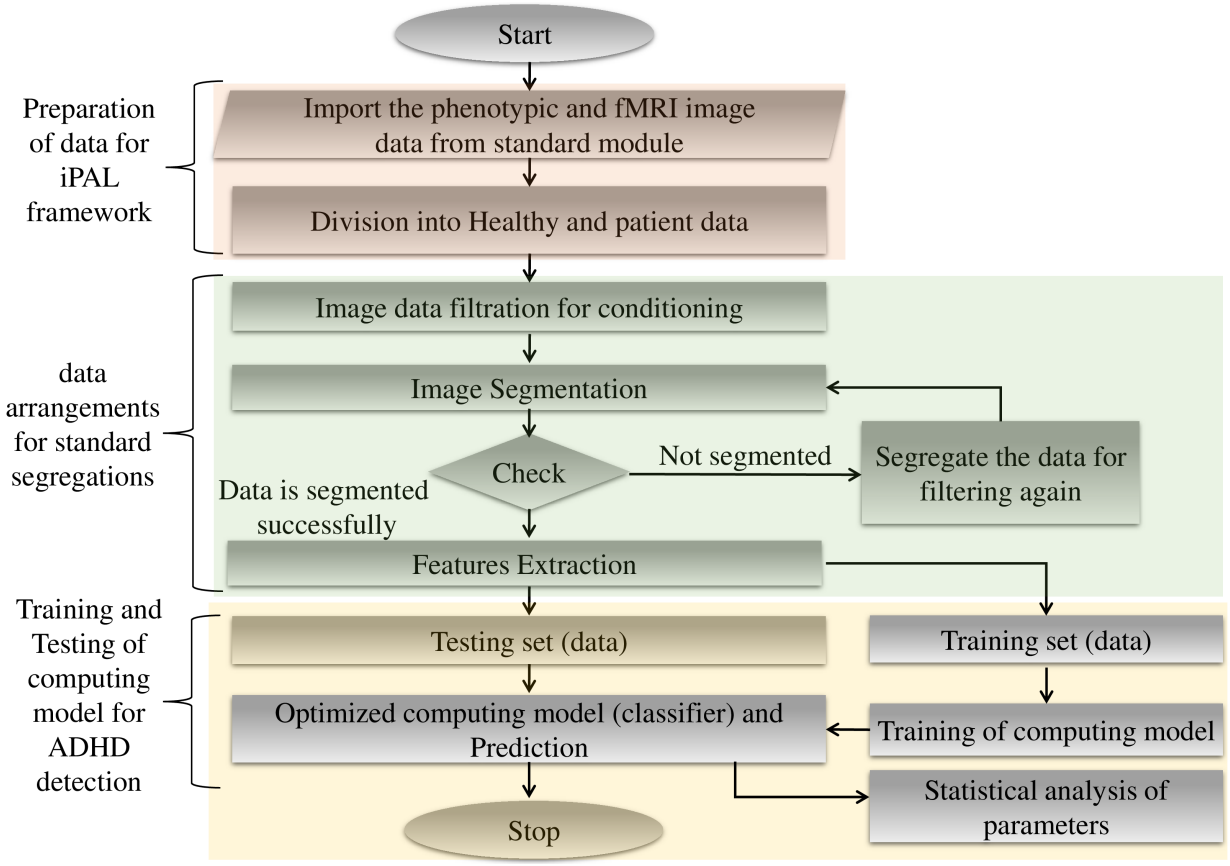


图15：自动化注意缺陷多动障碍诊断框架的处理步骤

### 5.4 注意缺陷多动障碍框架的分类

#### 5.4.1 表型数据集

大量分类器被广泛用于表型数据集和监督学习分类方法中，例如K近邻、逻辑回归、支持向量机、人工神经网络、随机森林、AdaBoost和决策树。监督学习是指已知分类结果，

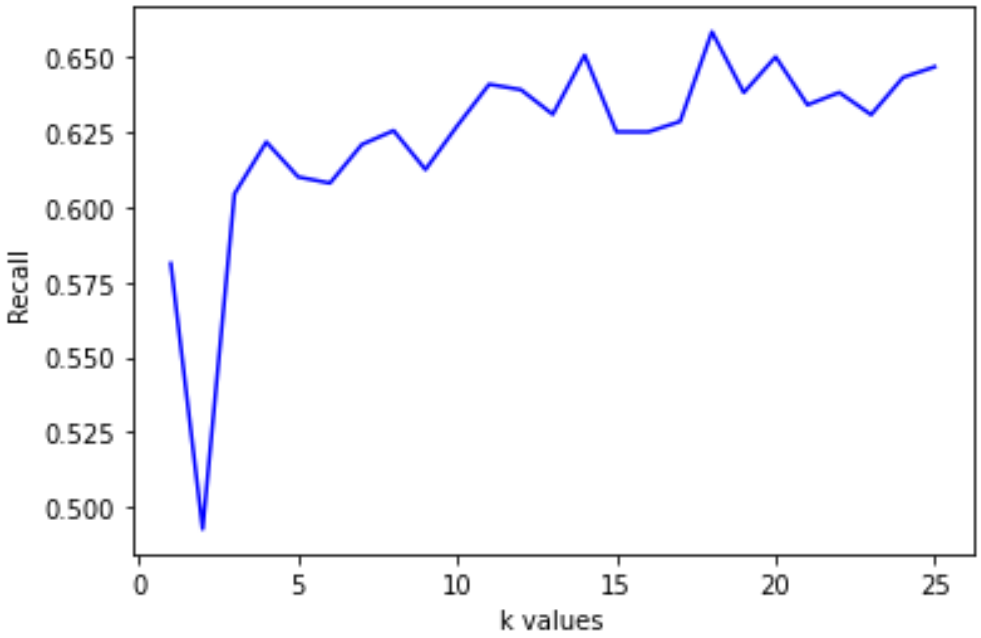


图16：K近邻中使用的K参数图

并利用从这些样本中学习得到的模型进行预测。逻辑回归是一种常用的监督分类算法，它会为用于预测个体类别的每个特征分配权重。当数据集线性可分时，该模型效果很好，因此并不特别适用于我们的表型数据集。数据采集站点及其用于测量ADHD [35, 36]的技术存在很大差异。自适应提升（AdaBoost）是最常用的强化算法之一，也是一种监督学习方法。它按照特定规则组合弱分类器，以构建稳健的分类器。AdaBoost会根据每次训练会话中的上一次整体分类结果以及所得准确率，确定每个样本的权重。K近邻是一种也用于分类问题的监督机器学习算法。顾名思义，KNN认为相似对象彼此距离较近。首先，算法会计算当前点与所选点之间的间距。然后将各距离相加并按升序排序，最后选取前K个条目作为最近邻，并进一步用于确定当前点的类别。本文按照 [37]中的描述使用支持向量机；在所使用的同类分类器中，它的准确率最高。SVM算法会在N维空间中寻找一个超平面，以对数据点进行分类。人工神经网络（ANN）是SVM的绝佳替代方案，因为其准确率与SVM非常接近。其多层神经网络适用于这种多样化的数据集。图15展示了处理来自不同站点的数据集时所采用的整体技术和流程。

#### 5.4.2 磁共振成像数据集

获得的磁共振成像数据集作为功能连接生物标志物，进一步用于诊断注意缺陷多动障碍。通过绘制相关矩阵并对注意缺陷多动障碍组和典型发育对照组进行比较可以观察到，两者在视觉上似乎非常相似。因此，需要进行全面评估，以区分注意缺陷多动障碍个体和典型发育对照组个体。观察发现，该数据集在线性上不可分，与最近邻无关，也不符合基于决策树的模式。使用神经网络进行分类似乎是一个潜在的候选方法，之后观察发现它是最合适的方法。

### 5.5 用于精准诊断的复杂模型训练

#### 5.5.1 表型数据集

首先，将从 [11]获取的表型数据集划分为分类特征和预测特征。随后，使用最小-最大缩放器对分类特征进行转换。此外，将505名受试者的数据按20%的比例划分为训练集和测试集。对这404名训练受试者的数据采用

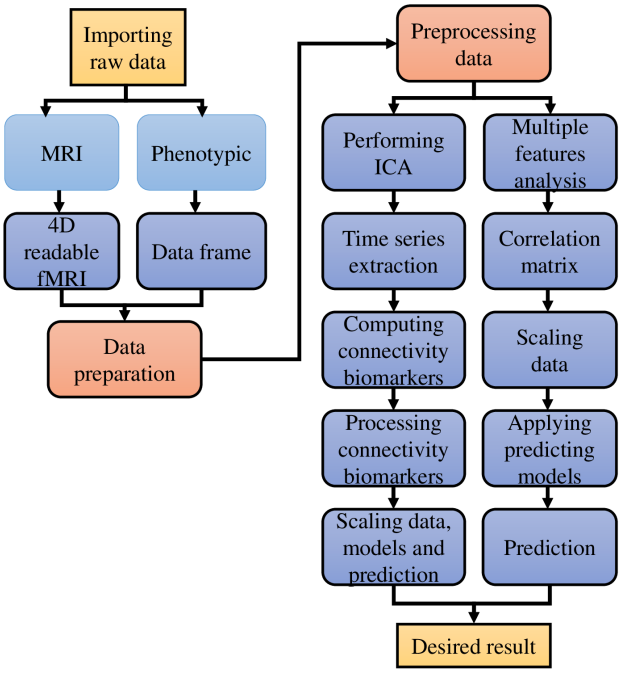


图17：所用方法的示意图

多种分类算法进行处理，并使用获得的模型对101名受试者进行预测。采用了多种分类算法，以确定最适合该数据集的分类器，包括逻辑回归、随机森林、AdaBoost、支持向量机、K近邻和神经网络。由于多_类别属于多项分布，线性回归使用交叉熵损失函数。使用的部分参数包括求解器“lbfgs”、容差1e-4以及最大迭代次数101。通过网格搜索确定随机森林的最佳参数，结果为“criterion”设为“entropy”，“max_features”设为“sqrt”，n_estimators设为1000。还对支持向量机进行了网格搜索，以估计最佳参数，结果为正则化参数100、伽马0.04，核函数为“rbf”。针对K参数从1到26的情况进行了K近邻分析，并在图16中观察到下图。

因此，K 的最佳取值为 18，其中包含来自多个类别的众多点，因此 K近邻无法作为可靠的分类器。在使用人工神经网络时，训练用的预测类别经独热编码器转换，以便用于神经网络。此外，我们构建了一个序列神经网络，输入规模为 13 维。该模型添加了五个全连接层，其维度和激活函数依次为 11 和“ReLU”、9 和“ReLU”、7 和“ReLU”、5 和“ReLU”，最后是 4 和“Sigmoid”。模型使用“categorical_crossentropy”作为损失函数，Adam 作为优化器，并以准确率作为评估指标进行编译。使用最多训练 100 轮的神经网络模型完成训练后，模型进行了预测，并将结果从独热编码格式转换回数组。

### 5.5.2 MRI数据集

由于组合模型必须分别处理功能磁共振成像和表型数据，因此在神经网络和支持向量机的训练与测试中使用相同的个体至关重要。因此，将功能磁共振成像和表型数据的特征及预测类别配对，然后按 70% 用于训练、30% 用于测试的比例划分为训练集和测试集，进而分别得到功能磁共振成像数据和表型数据的特征及预测类别。然而，在合并这些训练数据和测试数据之前，还需要对其进行缩放，以便用于模型训练。使用人工神经网络处理功能磁共振成像数据时，预测类别经独热编码器转换，以便用于神经网络。对于功能磁共振成像数据和表型数据，分别使用最小-最大缩放器处理其特征。还需注意，注意缺陷多动障碍的诊断被转换为二元形式，而表型文件中的注意缺陷多动障碍分为四种类型，如表1中 DX 所述。

使用功能连接作为连接性生物标志物所构建的相关矩阵，被用作我们神经网络的输入数据。我们构建了一个由全连接层组成的序列神经网络模型，其输入规模为 210 个神经元。模型使用了七个全连接层，其维度和激活函数分别为一百零五和

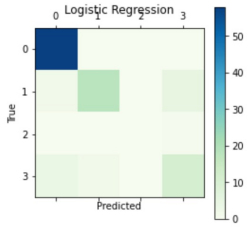


Accuracy Achieved for Logistic Regression: 86.13861386138613 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.91 | 1.00 | 0.95 | 58 |
| 1 | 0.90 | 0.72 | 0.80 | 25 |
| 2 | 0.00 | 0.00 | 0.00 | 1 |
| 3 | 0.65 | 0.65 | 0.65 | 17 |
| accuracy | | | 0.86 | 101 |
| macro avg | 0.61 | 0.59 | 0.60 | 101 |
| weighted avg | 0.85 | 0.86 | 0.85 | 101 |

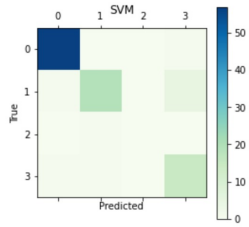


Accuracy Achieved for SVM: 90.0990099009901 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.97 | 0.98 | 0.97 | 58 |
| 1 | 0.90 | 0.76 | 0.83 | 25 |
| 2 | 0.00 | 0.00 | 0.00 | 1 |
| 3 | 0.71 | 0.88 | 0.79 | 17 |
| accuracy | | | 0.90 | 101 |
| macro avg | 0.65 | 0.66 | 0.65 | 101 |
| weighted avg | 0.90 | 0.90 | 0.90 | 101 |

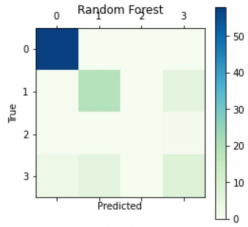


Accuracy Achieved for Random Forest: 84.15841584158416 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.95 | 1.00 | 0.97 | 58 |
| 1 | 0.76 | 0.76 | 0.76 | 25 |
| 2 | 0.00 | 0.00 | 0.00 | 1 |
| 3 | 0.53 | 0.47 | 0.50 | 17 |
| accuracy | | | 0.84 | 101 |
| macro avg | 0.56 | 0.56 | 0.56 | 101 |
| weighted avg | 0.82 | 0.84 | 0.83 | 101 |

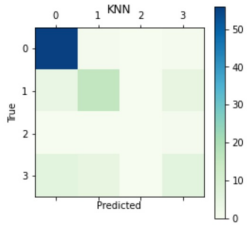


Accuracy Achieved for KNN: 77.22772277227723 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.85 | 0.97 | 0.90 | 58 |
| 1 | 0.73 | 0.64 | 0.68 | 25 |
| 2 | 0.00 | 0.00 | 0.00 | 1 |
| 3 | 0.46 | 0.35 | 0.40 | 17 |
| accuracy | | | 0.77 | 101 |
| macro avg | 0.51 | 0.49 | 0.50 | 101 |
| weighted avg | 0.74 | 0.77 | 0.75 | 101 |

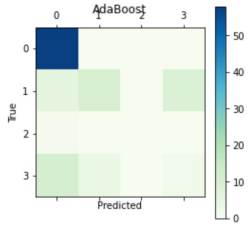


Accuracy Achieved for AdaBoost: 69.3069306930693 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.76 | 1.00 | 0.87 | 58 |
| 1 | 0.71 | 0.40 | 0.51 | 25 |
| 2 | 0.00 | 0.00 | 0.00 | 1 |
| 3 | 0.18 | 0.12 | 0.14 | 17 |
| accuracy | | | 0.69 | 101 |
| macro avg | 0.41 | 0.38 | 0.38 | 101 |
| weighted avg | 0.65 | 0.69 | 0.65 | 101 |

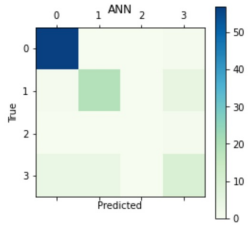


Accuracy Achieved for ANN: 85.14851485148515 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.92 | 1.00 | 0.96 | 58 |
| 1 | 0.78 | 0.84 | 0.81 | 25 |
| 2 | 0.00 | 0.00 | 0.00 | 1 |
| 3 | 0.64 | 0.41 | 0.50 | 17 |
| accuracy | | | 0.85 | 101 |
| macro avg | 0.58 | 0.56 | 0.57 | 101 |
| weighted avg | 0.83 | 0.85 | 0.83 | 101 |

图18：应用于表型数据的所有模型的混淆矩阵

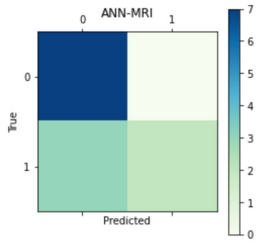


Accuracy Achieved for ANN-MRI: 75.0 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 0.70 | 1.00 | 0.82 | 7 |
| 1 | 1.00 | 0.40 | 0.57 | 5 |
| accuracy | | | 0.75 | 12 |
| macro avg | 0.85 | 0.70 | 0.70 | 12 |
| weighted avg | 0.82 | 0.75 | 0.72 | 12 |

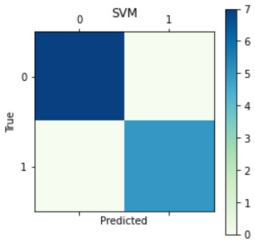


Accuracy Achieved for SVM: 100.0 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 1.00 | 1.00 | 1.00 | 7 |
| 1 | 1.00 | 1.00 | 1.00 | 5 |
| accuracy | | | 1.00 | 12 |
| macro avg | 1.00 | 1.00 | 1.00 | 12 |
| weighted avg | 1.00 | 1.00 | 1.00 | 12 |

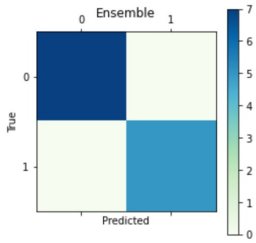


Accuracy Achieved for Ensemble: 100.0 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0 | 1.00 | 1.00 | 1.00 | 7 |
| 1 | 1.00 | 1.00 | 1.00 | 5 |
| accuracy | | | 1.00 | 12 |
| macro avg | 1.00 | 1.00 | 1.00 | 12 |
| weighted avg | 1.00 | 1.00 | 1.00 | 12 |

图19：应用于 nilearn 数据集的算法的混淆矩阵

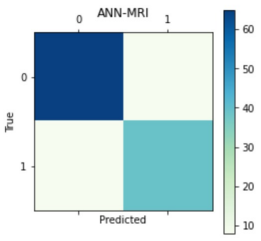


Accuracy Achieved for ANN-MRI: 86.66666666666667 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0.0 | 0.89 | 0.89 | 0.89 | 73 |
| 1.0 | 0.83 | 0.83 | 0.83 | 47 |
| accuracy | | | 0.87 | 120 |
| macro avg | 0.86 | 0.86 | 0.86 | 120 |
| weighted avg | 0.87 | 0.87 | 0.87 | 120 |

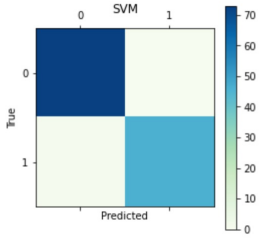


Accuracy Achieved for SVM: 99.16666666666667 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0.0 | 0.99 | 1.00 | 0.99 | 73 |
| 1.0 | 1.00 | 0.98 | 0.99 | 47 |
| accuracy | | | 0.99 | 120 |
| macro avg | 0.99 | 0.99 | 0.99 | 120 |
| weighted avg | 0.99 | 0.99 | 0.99 | 120 |

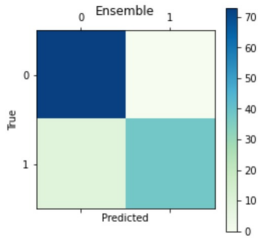


Accuracy Achieved for Ensemble: 92.5 %

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| 0.0 | 0.89 | 1.00 | 0.94 | 73 |
| 1.0 | 1.00 | 0.81 | 0.89 | 47 |
| accuracy | | | 0.93 | 120 |
| macro avg | 0.95 | 0.90 | 0.92 | 120 |
| weighted avg | 0.93 | 0.93 | 0.92 | 120 |

图20：应用于NITRC数据集的算法混淆矩阵

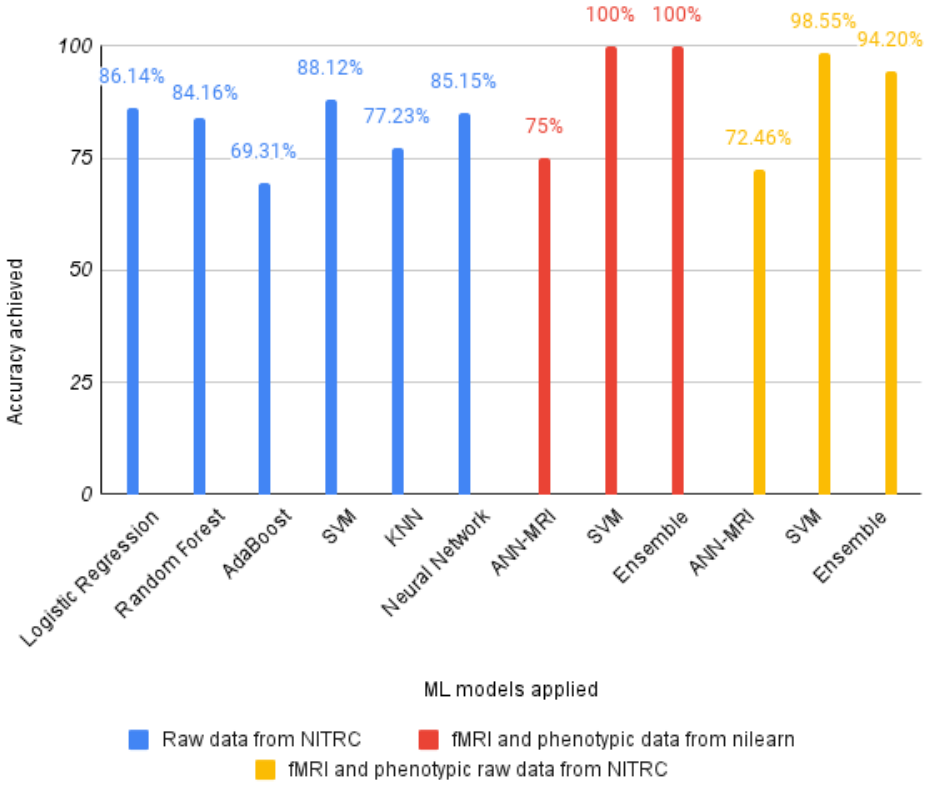


图2　　1：不同机器学习模型应用于不同数据集时所取得的准确率比较

‘relu’、五十二，‘relu’、二十六，‘relu’、十三，‘relu’、六，‘relu’、三，最后是二和‘sigmoid’。模型使用‘categorical_crossentropy’作为损失函数，使用 adam 作为优化器，并以准确率作为评估指标。神经网络模型经过训练轮次上限为一百的训练后，进行预测，并将结果从独热编码格式转换回数组。表型数据使用支持向量机处理。由于目的是将所得结果用于集成，因此使用网格搜索优化支持向量机，以预测最合适的参数。正则化参数设为一千，伽马设为 0.05，核函数设为‘径向基函数’。随后，模型进一步使用解压所得的缩放数据进行训练，以获得预测结果。图17中的流程图展示了用于处理结果的各种方法。对这些个体的表型数据进行处理，以便与功能磁共振成像结合，用于集成 ADHD 分类。功能性磁共振成像数据使用神经网络处理，表型数据则使用支持向量机处理。将两者集成后，便可根据个体的功能磁共振成像和表型数据，得出对 ADHD 的诊断预测。调整权重可体现各参数的影响程度。在测试中，两个参数采用相同的权重。由于预测类别为二元类别，因此将功能磁共振成像和表型分类结果分别乘以相应权重，再相加。阈值 0.5 用于确定预测类别。若总和小于或等于阈值，则归为类别 0；若总和大于该阈值，则归为类别 1。所得结果随后用于显示混淆矩阵及其他相关可视化内容。

## 6 精确框架验证与结果分析

使用多种机器学习算法对表型数据集进行分类。逻辑回归的准确率为 86.13%，随机森林为 84.15%，AdaBoost 为 69.30%，支持向量机为 90.09%，K 近邻为 77.27%，人工神经网络为 85.14%。图18展示了详细分析。基于来自 nilearn 的 39 个个体的数据集诊断注意缺陷多动障碍时，人工神经网络在功能磁共振成像数据上的准确率为 75%，支持向量机在表型数据上的准确率为 100%，结合这两个分类器时准确率也为 100%。图19展示了详细分析。基于来自 NITRC 的 400 个个体的数据集诊断注意缺陷多动障碍时，人工神经网络在功能磁共振成像数据上的准确率为 86.67%，支持向量机在表型数据上的准确率为 99.16%，结合这两个分类器时准确率为 92.5%。图20展示了详细分析。

人们一直尝试基于个体的静息态功能磁共振成像或表型数据，或两者兼用，开发多种二分类器和多分类器，以诊断和分类注意缺陷多动障碍。在研究当前技术进展后，我们尝试运用多种技术进一步推进诊断，并发现了许多令人振奋的发现以及研究发展中亟待改进的关键领域。因此，我们开始利用 ADHD-200 竞赛期间由 NITRC 提供的个体表型数据进行注意缺陷多动障碍分类。最终，我们使用支持向量机对整合数据进行分类，取得了 90.09% 的准确率；如果将数据划分为不同部分，准确率还有望进一步提高。然而，经过对这些数据的详细分析，我们发现，分类结果会因数据来源以及各种参数的计算方法不同而存在巨大差异。此外，这也使我们确信，这些数据不足以用于医学应用和临床目的。

因此，我们研究了磁共振成像，希望它能为我们提供一个一致的评估平台，以准确诊断注意缺陷多动障碍。查看 nilearn 库提供的静息态功能磁共振成像数据后，我们开始改进现有工作，采用更好的神经网络，基于这些静息态功能磁共振成像数据诊断注意缺陷多动障碍，并成功达到 75% 的准确率。接下来的任务是将基于静息态功能磁共振成像的诊断与基于表型数据的分类相结合，以便在医疗和临床领域的应用中取得最佳结果。借助支持向量机，我们取得了惊人的 100% 准确率；由于神经网络能够准确预测非注意缺陷多动障碍病例，采用等权重集成后，准确率也达到 100%。然而，当时的 nilearn 库（版本为 nilearn-0.7.1）仅包含 40 个个体的数据，因此仍需在更大规模的应用中验证。为此，我们将从 NITRC 获取的静息态功能磁共振成像和表型数据私下托管于云端，并编写脚本自动处理数据，以便用于更多个体。我们成功托管了 824 个个体的数据，剔除不一致的数据后，数量减少至 400 个。基于功能磁共振成像的神经网络准确率为 86.67%，基于表型数据的支持向量机准确率为 99.16%；两者以相同权重参与集成后，准确率为 92.5%。图21展示了前文提及的所有分类模型所达到的准确率对比 [38]。图21描述：蓝色分类器基于包含 505 个个体的表型数据集。这六种分类器分别为逻辑回归、随机森林、自适应提升、支持向量机、K近邻和人工神经网络。红色分类器基于从 nilearn 库获取的、包含 39 个个体的数据集。黄色分类器基于从 NITRC 数据集获取的、包含 400 个个体的数据集。对于这两种颜色，ANN-MRI 表示基于功能性磁共振成像数据的人工神经网络，SVM 表示基于表型数据的支持向量机，而 Ensemble 表示结合两种数据进行的分类。

表 2：iPAL 与现有研究的比较

| 研究 | 数据集 | 受试者 | 特征 | 分类器 | 准确率（%） | 精确率（%） | F-1 |
|---|---|---|---|---|---|---|---|
| Khare 等人[39] | EEG | 61 | VHERS | ELM-SIG | 99 | 100 | 99 |
| Tenev 等人[40] | EEG | 67 | FFT | SVM | 82.3 | - | - |
| Moghaddari 等人[41] | EEG | 31 | 节律与卷积神经网络 | CNN | 98.48 | - | 98.49 |
| Snyder 等人[42] | EEG | 97 | 平均功率 | - | 89 | 87 | - |
| Karimu 等人[43] | CWT | 20 | 小波尺度图 | MEFM | 99 | 98 | - |
| Boroujeni 等人[44] | EEG | 50 | FD、CD、EN | SVM | 96 | 98 | - |
| 提出的 iPAL | 表型<br>与功能磁<br>共振成像 | 400<br>400 | 平均FD、DVARS<br>均方根帧<br>位移 | 集成 | 100 | 99 | 99 |

## 7 当前研究的结论与未来方向

在对注意缺陷多动障碍进行计算机辅助诊断之前，我们收集了多个脑区的数据，并在研究框架分析过程中考虑了各种改进因素。这将有助于其在现实世界中的医疗和临床应用。不同网站提供的数据以及用于计算各种参数的测量方法之间存在巨大差异。相比之下，基于表型数据的预测更为准确。所提出的研究范式证实，如果功能磁共振成像数据的噪声极少，且参数测量采用统一技术，那么利用功能磁共振成像能够揭示其与注意缺陷多动障碍之间的重要关联。与此同时，表型数据在诊断注意缺陷多动障碍方面表现更佳。大规模数据能够为我们提供有意义的见解，并在数据充足时呈现各种测量指标之间的关系。因此，需要采用合适的标准，以实现更好的诊断。

根据目前的总结性研究，显然，精准诊断对于减轻注意缺陷多动障碍的影响至关重要。因此，有必要设计或构建一种范式，以便利用当前方法实现自动诊断，从而精准检测病情。偏远地区的患者也将有望获得诊断。未来计划开发一种智能框架，优化时间安排，同步完成患者数据收集、自动诊断和为个体提供治疗等所有流程。这样一来，患者便能获得更优质、可靠且不间断的治疗。这种医疗护理模式将有助于降低患者的治疗成本。人们也会更加关注此类疾病，并在获得频繁的解决方案后，更擅长进行自我诊断。

## 参考文献


[1] J. Berrezueta-Guzman、V. E. Robles-Bykbaev、I. Pau、F. Pesántez-Avilés 和 M. -L. Martín-Ruiz，《ADHD护理中的机器人技术：文献综述》，载于 IEEE Access，第 10 卷，第 608–625 页，2022 年。doi：10.1109/AC- CESS.2021.3137082。

[2] Y. Gu、S. Miao、J. Yang 和 X. Li，《基于 fNIRS 信号多视图特征融合的 ADHD儿童识别》，发表于 IEEE Sensors Journal，第 22 卷第 13 期，第 13536-13543 页，2022 年 7 月 1 日。doi: 10.1109/JSEN.2022.3168488。

[3] S. Pei、C. Wang、S. Cao 和 Z. Lv，《基于 fMRI 的功能连接数据增强及其在跨站点ADHD分类中的应用》，发表于 IEEE Transactions on Instrumentation and Measurement，第 72 卷，第 1-15 页，2023 年，文章编号 2501015。doi: 10.1109/TIM.2022.3232670。

[4] Ankrah、Elizabeth A. 等，《我、我的健康和我的手表：患有 ADHD 的儿童如何理解智能手表健康数据》。ACM TransactionsonComputer-Human Interaction（2022）。

[5] Tavakoulnia、Arya 等人。《设计一款可穿戴技术应用，以提升 ADHD 儿童的执行功能》。2019年 ACM 普适计算与泛在计算国际联合会议附属论文集及 2019年 ACM 可穿戴计算国际研讨会论文集。2019年。

[6]“流行病学”，https://adhd-institute.com/burden-of-adhd/epidemiology/，2021年3月。

[7] R. Bansal、L. H. Staib、D. Xu、H. Zhu 和 B. S. Peterson，“利用二维流形上的高斯随机场对脑表面进行统计分析”，IEEE 医学成像汇刊，第 26 卷，第 1 期，第 46–57 页，2007年。

[8] L. Shao、Y. You、H. Du 和 D. Fu，“基于 fMRI 数据和多目标优化的 ADHD 分类”，《生物医学中的计算机方法与程序》，第 196 卷，文章编号 105676，2020年。

[9]A. Kushwaha，“使用机器学习预测注意缺陷多动障碍”，International Journal of Advanced Trends in Computer Science and Engineering，第 9 卷，第 5296–5302 页，2020年 08 月。[10] P. Bellec、C. Chu、F. Chouinard-Decorte、Y. Benhajali、D. S. Margulies 和 R. C. Craddock，“神经局ADHD-200预处理数据库”，《神经影像》，第 144 卷，第 275–286 页，2017年。[11] Mennes 等，“ADHD-200样本”，https://fcon_1000.projects.nitrc.org/indi/adhd200/。[12] H. RaviPrakash、A. Watane、S. Jambawalikar 和 U. Bagci，“用于功能性脑连接的深度学习：我们已经做到这一步了吗？”《用于医学成像和临床信息学的深度学习与卷积神经网络》，第 347–365 页，2019年。[13] A. Riaz、E. Alonso 和 G. Slabaugh，“基于 fMRI 的 ADHD 分类表型整合框架”，载于 International Conference on Image Analysis and Recognition。Springer，2016年，第 217–225 页。[14] M. N. I. Qureshi、B. Min、H. J. Jo 和 B. Lee，“使用递归特征消除和分层极限学习机对 ADHD亚型进行鉴别诊断的多类别分类：结构磁共振成像研究”，《公共科学图书馆·综合》，第 11 卷，第 8 期，文章编号 e0160697，2016年，第 22–25 页。[15] N. Sethu 和 R. Vyas，“ADHD预测中机器学习方法概述”，载于《生物工程进展》。Springer，2020年，第 51–71 页。[16] M. Chen、H. Li、J. Wang、J. R. Dillman、N. A. Parikh 和 L. He，“用于分析多尺度功能性脑连接组数据以检测注意缺陷多动障碍的多通道深度神经网络模型”，Radiology: Artificial Intelligence，第 2 卷，第 1 期，2019年。[17] V. Pereira-Sanchez 和 F. X. Castellanos，“注意缺陷/多动障碍的神经影像学”，《精神病学当前观点》，第 34 卷，第 2 期，第 105 页，2021年。[18] I. Elujide、S. G. Fashoto、B. Fashoto、E. Mbunge、S. O. Folorunso 和 J. O. Olamijuwon，“深度学习和机器学习技术在精神病性障碍多标签分类中的应用”，《医学信息学解锁》，第 23 卷，文章编号 100545，2021年。[19] S. Itani、F. Lecron 和 P. Fortemps，“多中心医学数据的多层分类框架：在 ADHD-200数据集中的应用”，《应用专家系统》，第 91 卷，第 36–45 页，2018年。[20] G. Tostaeva，“使用神经网络对 fMRI 数据进行功能连接分类”，
h
t
t
ps://to
wardsdatascience.com/using-neural-networks-for-a-functional-connectivity-classification-of-fmridata-ff0999057bc6，2019年 12 月。[21]A. Abraham、F. Pedregosa、M. Eickenberg、P. Gervais、A. Mueller、J. Kossaifi、A. Gramfort、B. Thirion 和 G. Varoquaux，“使用 Scikit-learn 进行神经影像学机器学习”，《神经信息学前沿》，第 8 卷，文章编号 14，2014年。[22] Y. Du、Z. Fu 和 V. D. Calhoun，“使用功能连接对脑部疾病进行分类和预测：前景可期，但挑战重重”，《神经科学前沿》，第 12 卷，文章编号 525，2018年。[23]A. M. Mowinckel、D. Alnæs、M. L. Pedersen、S. Ziegler、M. Fredriksen、T. Kaufmann、E. Sonuga-Barke、T. Endestad、L. T. Westlye 和 G. Biele，“默认模式变异性增加与任务表现下降有关，且在患有 ADHD 的成年人中显而易见”，《神经影像：临床》，第 16 卷，第 369–382 页，2017年。[24] F. Pedregosa、G. Varoquaux、A. Gramfort、V. Michel、B. Thirion、O. Grisel、M. Blondel、P. Prettenhofer、R. Weiss 等，“Scikit-learn：Python 中的机器学习”，《机器学习研究杂志》，第 12 卷，第 2825–2830 页，2011年。[25]D. Tomasi 和 N. D. Volkow，“注意缺陷/多动障碍儿童的异常功能连接”，《生物精神病学》，第 71 卷，第 5 期，第 443–450 页，2012年。[26] G. Varoquaux、S. Sadaghiani、P. Pinel、A. Kleinschmidt、J.-B. Poline 和 B. Thirion，“用于 fMRI 数据集稳定多被试 ICA 的组模型”，《神经影像》，第 51 卷，第 1 期，第 288–299 页，2010年。[27] H. Yang、Q.-Z. Wu、L.-T. Guo、Q.-Q. Li、X.-Y. Long、X.-Q. Huang、R. C. Chan 和 Q.-Y. Gong，“未接受药物治疗的 ADHD 儿童异常自发性脑活动：一项静息态 fMRI 研究”，《神经科学快报》，第 502 卷，第 2 期，第 89–93 页，2011年。[28]Abraham, A., Pedregosa, F., Eickenberg, M., Gervais, P., Mueller, A., Kossaifi, J., Gramfort, A., Thirion, B., & Varoquaux, G.（2014）。使用 Scikit-learn 进行神经影像学机器学习。《神经信息学前沿》，8。https://doi.org/10.3389/fninf.2014.00014。

[29] L. E. Johnson 和 J. M. Conrad，“用于治疗和诊断注意缺陷多动障碍的技术综述”，载于第九届 IEEE 年度普适计算、电子与移动通信会议（UEMCON）。IEEE，2018年，第 819–824 页。[30] B. Sorger 和 R. Goebel，“第 21 章——用于脑机接口的实时功能磁共振成像”，载于《脑机接口》，《临床神经病学手册》系列，N. F. Ramsey 和 J. del R. Millán 编。爱思唯尔，2020年，第 168 卷，第 289–302 页。[31] S. A. Huettel，“功能磁共振成像（fMRI）”，载于《光谱学与光谱测定百科全书》第二版，J. C. Lindon 编。牛津：学术出版社，2010年，第 741–748 页。[32] E. B. Johnson 和 S. Gregory，“第 6 章——亨廷顿病：亨廷顿病的脑成像”，载于《脑成像》，《分子生物学与转化科学进展》系列，2019年，第 165 卷，第 321–369 页。[33] A. Zalesky、A. Fornito 和 E. Bullmore，“关于使用相关性衡量网络连接”，《神经影像》，第 60 卷，第 4 期，第 2096–2106 页，2012年。[34] F. Pedregosa、G. Varoquaux、A. Gramfort、V. Michel、B. Thirion、O. Grisel、M. Blondel、P. Prettenhofer、R. Weiss、V. Dubourg、J. Vanderplas、A. Passos、D. Cournapeau、M. Brucher、M. Perrot 和 E. Duchesnay，“Scikit-learn：Python 机器学习”，《机器学习研究杂志》，第 12 卷，第 2825–2830 页，2011年。[35] C. McNorgan、C. Judson、D. Handzlik 和 J. G. Holden，“通过识别共同的诊断性任务相关功能连接，关联注意缺陷多动障碍与行为评估”，《生理学前沿》，第 11 卷，第 1595 页，2020年。[36] H. Zhang、Y. Zhao、W. Cao、D. Cui、Q. Jiao、W. Lu、H. Li 和 J. Qiu，“通过独立成分分析揭示注意缺陷多动障碍患者静息态网络中的异常功能连接”，《BMC 神经科学》，第 21 卷，第 1 期，第 1–11 页，2020年。[37] S. Itani、M. Rossignol、F. Lecron 和 P. Fortemps，“面向辅助诊断的可解释机器学习模型：注意缺陷多动障碍案例研究”，《公共科学图书馆·综合》，第 14 卷，第 4 期，e0215720 页，2019年。[38] Sharma、Yogesh 和 Bikesh Kumar Singh。“使用多变量经验模态脑电分解方法检测儿童注意缺陷多动障碍：一项全面的分析研究。”《应用专家系统》213（2023）：119219。[39] S. K. Khare、N. B. Gaikwad 和 V. Bajaj，“VHERS：一种用于自动检测注意缺陷多动障碍的全新变分模态分解与希尔伯特变换脑电节律分离方法”，载于 IEEE Transactions on Instrumentation and Measurement，第 71 卷，第 1–10 页，2022，文章编号 4008310。doi：10.1109/TIM.2022.3204076。[40]Tenev、Aleksandar 等。“成年注意缺陷多动障碍患者的分类机器学习方法。”《国际心理生理学杂志》93.1（2014）：162–166。[41] Moghaddari、Majid、Mina Zolfy Lighvan 和 Sebelan Danishvar。“基于连续心理任务脑电的卷积神经网络儿童注意缺陷多动障碍诊断。”《生物医学中的计算机方法与程序》197（2020）：105738。[42] Snyder、Steven M. 等。“脑电生物标志物与临床医生的注意缺陷多动障碍评估相结合。”《脑与行为》5.4（2015）：e00330。[43]Yaghoobi Karimu、Reza 和 Sassan Azadi。“使用专家模糊模型混合诊断注意缺陷多动障碍。”《国际模糊系统杂志》20.4（2018）：1282–1296。[44] Boroujeni、Yasaman Kiani、Ali Asghar Rastegari 和 Hamed Khodadadi。“通过脑电信号的非线性分析诊断注意缺陷多动障碍。”《IET 系统生物学》13.5（2019）：260–266。

## 作者简介



**AbhishekSharma** 毕业于印度瓜廖尔的 Jiwaji University，获电子工程学士学位；后于意大利热那亚大学获嵌入式系统博士学位。目前，他在印度斋浦尔的 LNM信息技术学院电子与通信工程系担任助理教授。他还是 IEEE、计算机学会和消费电子学会的成员，印度技术教育学会终身会员，以及印度高级计算学会终身会员。在现任职的院校，他负责协调 ARM大学合作伙伴计划，同时也是 LNM智能技术中心（L-CST）的中心负责人。他的研究兴趣包括实时系统和嵌入式系统。



**Arpit Jain**目前是LNM信息技术学院预毕业年级的学生，正在攻读计算机科学与工程工学学士学位。他目前担任MWEP（Sankalp俱乐部）的导师，曾任协调员，也是Phoenix俱乐部（机器人学）、天文学俱乐部和谷歌开发者小组（GDG勒克瑙）的高级成员。目前，他在VMware印度私人有限公司实习。本文是他在神经影像学和注意缺陷多动障碍领域的首项重要成果。他的主要研究领域包括机器学习、人工智能、社会网络分析、数据库管理、无线传感器网络、片上网络、图像处理和软件开发工程。



**ShubhangiSharma** 目前是LNM信息技术学院预毕业年级的学生，正在攻读电子与通信工程工学学士学位。本文是她在机器学习和神经影像学领域的首项重要成果。她的兴趣领域包括机器学习、人工智能、物联网、嵌入式系统和软件开发。



**Ashutosh Gupta** 目前是 LNM信息技术学院（位于印度斋浦尔）计算机科学与工程专业的本科生，正处于倒数第二学年。本文是他在神经影像学和数据科学领域发表的第一篇论文。他的兴趣领域包括机器学习、软件开发、机器学习和软件开发中的设计策略，以及数据科学研究。



**Prateek Jain** （M’18）于2010年获得印度 Jiwaji University 电子工程学士学位，并获得瓜廖尔ITM大学硕士学位。他在斋浦尔马拉维亚国家理工学院获得博士学位。2016年至2020年间，他获得了人力资源开发部奖学金。他曾任职于VIT安得拉邦大学电子工程学院（SENSE）。目前，他是印度艾哈迈达巴德尼尔玛大学的助理教授。他目前的研究兴趣包括实时系统设计、低功耗超大规模集成电路设计、生物医学系统和仪器仪表。他是25篇同行评审论文的作者，并定期为12种期刊和10场会议审稿。他曾在知名大学的技术项目中担任主讲人。



**Saraju P. Mohanty** （IEEE高级会员）于1995年获得布巴内斯瓦尔奥里萨农业与技术大学电气工程荣誉学士学位，1999年获得班加罗尔印度科学研究所系统科学与自动化硕士学位，并于2003年获得坦帕南佛罗里达大学计算机科学与工程博士学位。他现任北德克萨斯大学教授。他的研究方向是“智能电子系统”，相关研究获得了国家科学基金会（NSF）、半导体研究公司（SRC）、美国空军、印美科学技术论坛和使命创新的资助。他已发表450篇研究论文、出版5本书，并拥有9项已授权或申请中的专利。他在谷歌学术上的h指数为48，i10指数为209，引用次数达10,500次。他被视为智慧城市技术领域具有远见的研究者，其研究涉及安全、能量感知以及集成人工智能/机器学习的智能组件。他提出了安全

他于2004年设计了数字相机（SDC），其内置安全特征采用硬件辅助安全（HAS）或安全设计（SbD）原则设计。他因设计出2004年的首款数字水印芯片和2006年的首款低功耗数字水印芯片而广受认可。他曾获得16项最佳论文奖、2020年的富布赖特专家奖、2020年的IEEE消费电子学会杰出服务奖、2018年的IEEE-CS- TCVLSI杰出领导力奖，以及2016年物理科学与数学类最佳教科书PROSE奖。他曾在多个国际会议上发表18场主题演讲，并参与14场专题讨论。他一直担任多份经过同行评审的国际汇刊和期刊的编委会成员，包括IEEE大数据汇刊（TBD）、IEEE集成电路与系统计算机辅助设计汇刊（TCAD）、IEEE消费电子汇刊（TCE）以及ACM计算系统新兴技术期刊（JETC）。2016—2021年，他担任《IEEE消费电子杂志》（MCE）主编（EiC）。2014—2018年，他担任IEEE计算机学会（IEEE-CS）超大规模集成技术委员会（TCVLSI）主席；2019—2021年，他担任IEEE消费电子学会理事会成员。他还在多个国际会议的指导委员会、组织委员会和程序委员会任职。他担任IEEE智能电子系统国际研讨会（IEEE-iSES）、IEEE-CS超大规模集成电路研讨会（ISVLSI）以及OITS国际信息技术会议（OCIT）指导委员会主席或副主席。他指导过3名博士后研究人员，并指导完成14篇博士学位论文、26篇硕士学位论文和18个本科生项目。