doi：10.7499/j.issn.1008-8830.2504089

综述

机器学习在特定学习障碍的辅助诊断中的应用

赵浩[1,2,3,4]　梅淑岚[2]　王晶宇[3]　综述　　池霞[3,4]　审校

（1.西安外国语大学研究生院，陕西西安　710128；2.江苏省特种作业与康复机器人研究中心，江苏南京　211167；3.南京医科大学附属妇产医院/南京市妇幼保健院儿童保健科，江苏南京　210004；4.南京市发育行为医学重点实验室，江苏南京　210004）

［摘要］特定学习障碍（specific learning disorder, SLD）是儿童常见神经发育障碍，对其学业表现和生活质量产生显著影响。目前，SLD诊断主要依赖标准化测试和专业评估，过程复杂且耗时。多项研究表明，机器学习可通过分析测试分数、手写样本、眼动数据、神经影像数据及基因数据等多类数据，自动学习输入特征与输出标签的关联，实现高效预测，在SLD的早期筛查、辅助诊断及机制研究中展现出巨大潜力。该文综述了机器学习在SLD辅助诊断研究中的应用，并探讨其处理不同数据类型时的表现。

［中国当代儿科杂志，2025，27（11）：1420-1425］

［关键词］特定学习障碍；读写障碍；辅助诊断；机器学习

The application of machine learning in the auxiliary diagnosis of specific learning disorder

ZHAO Hao, MEI Shu-Lan, WANG Jing-Yu, CHI Xia. Department of Child Healthcare, The Affiliated Obstetrics and Gynaecology Hospital of Nanjing Medical University/Nanjing Women and Children's Healthcare Hospital, Nanjing 210004, China (Chi X, Email: xiachi.njmu@gmail.com)

Abstract: Specific learning disorder (SLD) is a common neurodevelopmental disorder in children that significantly affects academic performance and quality of life. At present, diagnosis mainly relies on standardized tests and professional evaluations, a process that is complex and time-consuming. Multiple studies have shown that machine learning can analyze diverse data, including test scores, handwriting samples, eye movement data, neuroimaging data, and genetic data, to automatically learn the relationships between input features and output labels and achieve efficient prediction. It shows great potential for early screening, auxiliary diagnosis, and research on underlying mechanisms in SLD. This article reviews the applications of machine learning in the auxiliary diagnosis of SLD and discusses its performance when handling different data types.

[Chinese Journal of Contemporary Pediatrics, 2025, 27(11): 1420-1425]

Key words: Specific learning disorder; Dyslexia; Auxiliary diagnosis; Machine learning

特定学习障碍（specific learning disorder, SLD）是一种影响个体学业表现的常见神经发育障碍。依据《精神障碍诊断与统计手册（第五版-修订版）》中SLD的分类标准，其主要包括读写障碍和计算障碍，其中读写障碍可进一步分为阅读障碍和书写障碍。SLD的诊断需通过标准化测试评估确认，即读写或计算水平显著低于同龄人的预期水平，且该表现不能归因于智力障碍、未矫正的感官异常、不良教育环境或其他神经发育障碍。流行病学调查显示，在不同语言和文化背景的学龄儿童中，全球SLD患病率为5%~15%[1]。SLD不仅严重影响患者的学业表现和生活质量，还给家

［收稿日期］2025-04-12；［接受日期］2025-09-16

［基金项目］2024年江苏省社会科学基金资助项目（24YYB010）；2023年江苏省科技计划专项（重点研发计划社会发展）资助项目（BE2023666）。

［作者简介］赵浩，男，博士，副教授。

［通信作者］池霞，女，博士，教授，主任医师。Email：xiachi.njmu@gmail.com。

庭带来沉重负担[2]。目前SLD的诊断主要依赖标准化测试和专业评估，过程复杂且耗时。同时，由于SLD在早期阶段症状表现多样，往往难以被及时识别，因此迫切需要开发更高效、更客观的诊断工具。

近年来，机器学习为SLD的辅助诊断提供了新方向[3]。该技术能够从复杂数据中自动提取关键特征，构建预测模型以实现早期识别，这不仅有助于提高SLD的诊断效率和准确性，还能为深入探索其神经机制和遗传基础提供支撑。本文将系统探讨机器学习在SLD辅助诊断中的应用，按数据类型（如测试分数、手写表现、眼动特征、神经影像及基因数据等）进行详细分析，以期为SLD研究提供更多理论支持和实践参考。

1　机器学习模型

机器学习模型通常分为3类：监督学习、无监督学习和强化学习。监督学习在SLD研究中应用较为广泛，该方法通过对已标注标签的数据进行训练，建立输入特征与输出标签之间的映射模型，并将其应用于新数据实现标签预测[4]。其主要包括分类算法和回归算法。前者用于临床数据的分类，如判断儿童是否存在SLD；后者则用于连续型指标的预测，如预测参与者的阅读能力得分。

在SLD领域，无监督学习和强化学习的应用尚不广泛。无监督学习[5]通过对未标注数据进行自动分析，识别数据中潜在的模式或结构，尤其适用于标注成本高、标签获取困难的数据。强化学习[6]依托智能体与环境的交互，智能体基于当前状态选择行为，环境根据行为反馈奖励和新状态，智能体再据此不断调整策略，以实现累积奖励的最大化。此方法同样无须依赖预先标注的数据，在临床决策优化中展现出广阔的应用前景。无监督学习和强化学习在处理未标注数据及优化决策过程中的潜力，预示其未来在SLD临床应用中可能发挥重要作用。

2　算法选择

算法选择需综合考虑数据类型、样本量及任务目标等因素。支持向量机（support vector machine, SVM）和k近邻（k-nearest neighbor, KNN）在小样本数据集上表现突出。SVM通过将数据映射至高维空间，使类别间的区分度最大化，从而实现二分类；KNN则基于相似数据在特征空间中的邻近性，通过邻近样本预测新样本，其在分类任务中采用多数投票（取最高频类别标签），在回归任务中以KNN目标值的均值或加权均值作为预测结果。随机森林（random forest, RF）和自适应增强（AdaBoost）算法在大规模数据场景中具有显著优势。RF通过构建多个相互独立的决策树，采用投票机制确定最终分类结果；AdaBoost则通过迭代训练弱分类器并调整样本权重，聚焦错误样本，最终经加权投票提升预测精度。

近年来，神经网络（尤其是深度神经网络）在图像、音视频等多模态数据处理中应用广泛。与SVM或RF相比，前馈神经网络及多层前馈神经网络在数据预处理阶段对人工依赖度更低，且擅长通过多层抽象自动提取特征。在深度神经网络中，卷积神经网络（convolutional neural network, CNN）不仅适用于图像数据，还可将语音信号转化为频谱图进行处理；而递归神经网络（recurrent neural network, RNN）在捕捉语音（音频序列）与视频（图像序列）中的时序信息方面展现出优异性能。值得注意的是，CNN与RNN常被联合应用于语音及图像数据处理，以充分利用两类网络分别在空间特征和时序信息方面的提取能力。

3　机器学习在SLD数据中的应用

3.1　测试分数

机器学习可通过分析学业技能测试分数实现SLD的自动化评估，从而提高诊断效率。有研究使用非参数机器学习回归技术，对168名1~9年级学生的阅读和写作能力测试数据进行分析，探索了自动评估阅读和写作障碍的可行性[7]。另有研究运用RF算法分析伍德科克–约翰逊认知能力测试中的数学分数以识别计算障碍，模型准确率高达99.8%，显著提升了诊断效率[8]。

尽管学业技能测试通常始于小学阶段，但语言能力评估往往开展得更早。语言能力被认为是SLD的重要预测因素[9]，因此对其进行早期评估对SLD的早期识别具有重要意义。一项随访研究采用SVM算法对有家族性读写障碍史的幼儿在麦克阿瑟–贝茨语言交际发展量表（词汇与句子）中的测试分数进行分析，并预测其SLD风险，模型准确率为68%[10]。这表明机器学习可在儿童尚未开始学习阅读的早期阶段预测SLD风险，为早期干预

提供了可能。还有研究利用反向传播神经网络模型对汉语儿童的阅读相关认知技能测试分数进行分析，并预测读写障碍，模型总体准确率达94%，显著提高了汉语读写障碍的预测精度[11]。

3.2 手写数据

除学业技能测试分数外，书写表现评估也是评估SLD（尤其是写作障碍）的重要手段之一，机器学习为此提供了高效工具[12]。

手写数据通常包含两类特征：一类是手写特征，包括动态特征（如笔压力）、时间特征（如书写持续时间）[13]、运动学特征（如书写速度）[14]及从手写图像中提取的静态特征[15]；另一类是表达特征，即书面内容特征。现有研究多通过比较SVM、RF、AdaBoost和KNN等不同算法在相同手写特征数据集上的表现，选择最佳模型。Drotár等[16]、Kunhoth等[17]采用AdaBoost算法分析笔压力、书写速度、持续时间等手写数据，其SLD评估准确率分别为80%和80.8%，高于其他算法；Amini等[18]、Deschamps等[19]采用SVM算法分析手写数据，模型准确率均超过85%。其中Amini等的研究还发现，仅分析“空中特征”（笔未接触纸张时的轨迹数据）或“表面特征”（笔接触纸张时的轨迹数据）时，模型准确率分别为80.9%和71.4%，这提示“空中特征”与书写障碍的关联更密切，是重要的诊断信息来源。

随着机器学习技术的快速发展，近年来CNN和RNN等深度神经网络在手写数据分析中的应用逐渐增多。Bublin等[20]采用RNN中的长短期记忆网络模型分析手写数据，以预测系统性书写运动困难筛查（Systematic Screening for Motor Handwriting difficulties）量表得分。结果显示，该模型预测结果与专家评估高度一致（均方根误差小于1），可有效预测SLD风险。Kunhoth等[21]、Ramlan等[22]利用CNN提取手写特征并构建分类模型。Liu等[23]采用CNN从1 064名2~6年级儿童的10万份手写汉字图像中提取特征，通过位置编码捕捉字符排列顺序，结合长短期记忆网络模型捕捉时间序列特征，同时引入注意力机制使模型聚焦关键特征以捕捉字符间的复杂关系，最终模型SLD分类准确率达85.0%，展示了深度神经网络在复杂数据分析中的强大能力。目前研究多聚焦于手写特征，对书面表达特征的分析仍相对不足，未来可进一步深入探索该类特征，以提升SLD诊断的准确性。

3.3 眼动数据

读写障碍常伴随眼动异常，表现为在阅读过程中出现异常眼跳与注视[24-25]。阅读时眼球在单词和句子间的移动特征及注视稳定性等指标可作为读写障碍的潜在生物标志物。有研究通过记录参与者阅读文本时的眼动数据，提取眼跳幅度、注视持续时间等多项眼动特征，采用SVM、KNN、RF等多种机器学习算法分析，模型最高识别准确率达94%[26-27]。

多个基于阅读任务的眼动研究已证实机器学习在SLD诊断中的重要意义，而眼动数据在不同任务下的判别效能，决定了机器学习提取的眼动特征在诊断中的潜在价值[28-30]。El Hmimdi等[31]采用径向基函数核的SVM，对儿童观看发光二极管光源等非阅读任务下的眼动数据进行分析，仍能识别出SLD儿童。这表明，机器学习可在儿童尚未开始正式阅读的学龄前阶段预测SLD风险。

此外，机器学习还被用于分析儿童在绘画和游戏过程中的眼动数据，以区分SLD儿童与典型发育儿童。El Hmimdi等[32]采用SVM分析儿童在自由绘画过程中的眼动特征并构建模型，分类准确率超过90%。Piazzalunga等[33]采用高斯朴素贝叶斯（Gaussian Naive Bayes）、CatBoost、RF、SVM等多种算法，对绘画及游戏过程中的眼动数据进行分析，预测书写障碍发生风险的准确率达60%；该研究还利用SHAP（SHapley Additive exPlanations）解释器对关键输入特征进行分析，通过Shapley值量化每个特征对预测结果的贡献度，进一步证实了视知觉能力与书写障碍的关联。基于SHAP解释器的分析方法显著提升了模型的可解释性和可信度，为机器学习在SLD实际诊断中的应用提供了更坚实的支撑。

3.4 神经影像数据

利用机器学习分析神经影像数据，可深入探讨SLD的神经机制，并提升SLD诊断的效率。磁共振成像（magnetic resonance imaging, MRI）和脑电图（electroencephalography, EEG）是SLD研究中常用的神经影像技术。

MRI包括功能性MRI、结构性MRI和弥散张量成像，具有高空间分辨率和无创性优势，可识别与SLD相关的大脑结构和功能特征，如通过功能性MRI发现SLD患者的颞叶区域和白质体积存在异常。随着MRI数据的规模和复杂性增加，人工分析面临挑战，机器学习成为关键分析工具。有

研究利用线性SVM分析结构性MRI和弥散张量成像数据，提取白质体积、各向异性分数、平均扩散率、轴向扩散率、径向扩散率等5种白质特征，实现了83.61%的读写障碍分类准确率[34]。

EEG技术因时间分辨率高、便携和非侵入性的特点，被广泛应用于SLD的功能研究，机器学习可通过分析EEG数据高效完成分类任务。有研究采用极限学习机分析儿童书写单词和非单词时的EEG信号，该模型区分读写能力正常者、有严重读写障碍者及读写有进步者的灵敏度和特异度分别为（0.92、0.87），（0.83、1），（0.91、0.96），整体准确率达89%[35]。Seshadri等[36]、Zaree等[37]的研究记录了儿童在视觉连续表现任务中的EEG信号，其SLD分类准确率分别高达96.7%和87.5%。

随着脑部网络规模（network size）的增大，表征不同脑区间相互作用的功能连接数量呈几何级增长。在这类高维稀疏数据场景中，线性支持向量机等机器学习模型的表现可能受限。因此，McNorgan[38]在通过MRI数据分析大脑功能连接模式时，采用多层前馈神经网络构建模型，对复杂模式进行最优的低维表征学习，以更好地处理大规模、高维度、非线性的复杂数据。该研究发现，阅读网络中负责正字法、语音及语义处理的区域，与阅读技能相关的功能连接会显著影响大脑的信息处理动态，进而调控个体的认知行为。CNN在MRI数据分析中的应用也取得了显著成果。Zahia等[39]、Tomaz Da Silva等[40]利用CNN分析MRI数据并开展读写障碍分类，模型准确率分别达72.73%和94.8%。同时，Tomaz Da Silva等的研究还采用网络可视化技术，生成的图像显示了对分类起关键作用的大脑区域，可帮助神经科学领域专家解读模型，为深入理解SLD的神经机制提供了重要参考。

3.5 基因数据

基因数据可为理解SLD的遗传基础及病因提供关键线索。基因数据通常具有高维度、大规模、高复杂度的特点，机器学习因其强大的特征选择与模式识别能力，成为识别SLD遗传生物标志物的重要方法。Lancaster等[41]利用一种名为弹性网络（Elastic Net）的机器学习模型，评估了多个基因（如*KIAA0319*和*DCDC2*）、人口变量及环境因素与阅读障碍的关系。结果表明，阅读障碍的发生是由多个基因共同作用的结果，同时也受人口统计学特征和环境的影响。弹性网络模型能够在高维数据中实现特征选择与正则化，有效减少模型的过拟合问题，为量化分析阅读障碍的复杂病因提供了可靠工具。

4 主要挑战与应对方向

4.1 数据质量与样本规模

机器学习模型有效性高度依赖数据规模与质量。但目前SLD研究数据集的样本量较少，质量参差不齐。不同研究中心的数据采集方法不一致、样本来源单一，数据中还可能存在潜在缺失值或噪声，这些因素均会影响模型普适性。未来可通过多中心协作整合不同数据集，扩大样本规模并提升数据质量，从而增强机器学习效能和模型稳健性。

4.2 数据多样性与复杂性

SLD研究涉及多种模态数据，尤其在全基因组数据的高维分析中，易引发模型过拟合的问题。机器学习在多模态数据融合方面的能力，为全面理解SLD复杂性提供可能，但也大幅增加模型训练难度和计算量[42]。对此，需不断优化算法，利用先进硬件和分布式计算资源，探索更具鲁棒性的特征选择和降维方法。

4.3 模型偏向与普适性

SLD的表现因语言、文化及教育背景不同存在差异，若模型在设计和训练阶段未充分考量这些因素，易对特定群体产生偏向性。未来机器学习研究需在训练数据构建与模型设计中充分纳入不同背景人群的信息，以确保诊断结果的普适性与公平性。

4.4 模型可解释性

机器学习模型的“黑箱”特性易引发质疑。因此，了解模型决策过程，提高模型透明性和可解释性至关重要。可解释性技术（如SHAP解释器、可视化分析）可助力揭示模型决策依据，未来应进一步探索可解释机器学习模型在SLD诊断中的应用。

5 总结

机器学习因其在多维度数据分析中的强大能力，在SLD诊断中具有广阔的应用前景。该技术可自动识别SLD相关特征，显著提高诊断效率与准确度，也为SLD的神经机制与遗传基础研究提

供了新思路。当前SLD研究中应用最多的为监督学习，未来研究可进一步结合无监督学习对未标注数据进行特征提取，并利用强化学习在交互式干预中制定个性化策略，从而拓展SLD研究的新领域。此外，模型的可解释性在医学应用场景中不容忽视，结合可视化工具或解释器展示模型的决策过程，将有助于增强医护人员和研究者对诊断结果的理解与信任。随着研究的进一步深入和机器学习技术的持续优化，机器学习必将在SLD的辅助诊断、干预效果监测及障碍机制探索等方面发挥更大作用，在为SLD患者带来福祉的同时，推动SLD研究不断迈向新高度。

作者贡献声明：赵浩负责论文选题、文献检索、论文撰写及修改；梅淑岚、王晶宇负责文献检索与撰写；池霞负责论文选题与审校。

利益冲突声明：所有作者声明无利益冲突。

［参　考　文　献］

[1] American Psychiatric Association. Diagnostic and Statistical Manual of Mental Disorders[M]. 5th ed. Washington, DC, USA: APA, 2022.

[2] National Center for Learning Disabilities. State of learning disabilities: navigating the transition to adulthood[EB/OL]. [2025-2-15]. https://ncld. org/understand-the-issues/state-of-ld-report/.

[3] Binson VA, Thomas S, Subramoniam M, et al. A review of machine learning algorithms for biomedical applications[J]. Ann Biomed Eng, 2024, 52(5): 1159-1183. PMID: 38383870. DOI: 10.1007/s10439-024-03459-3.

[4] Rashidi HH, Tran NK, Betts EV, et al. Artificial intelligence and machine learning in pathology: the present landscape of supervised methods[J]. Acad Pathol, 2019, 6: 2374289519873088. PMID: 31523704. PMCID: PMC6727099. DOI: 10.1177/2374289519873088.

[5] Eltouny K, Gomaa M, Liang X. Unsupervised learning methods for data-driven vibration-based structural health monitoring: a review[J]. Sensors (Basel), 2023, 23(6): 3290. PMID: 36992001. PMCID: PMC10058635. DOI: 10.3390/s23063290.

[6] Weltz J, Volfovsky A, Laber EB. Reinforcement learning methods in public health[J]. Clin Ther, 2022, 44(1): 139-154. PMID: 35058056. DOI: 10.1016/j.clinthera.2021.11.002.

[7] Iwabuchi M, Hirabayashi R, Nakamura K, et al. Machine learning based evaluation of reading and writing difficulties[J]. Stud Health Technol Inform, 2017, 242: 1001-1004. PMID: 28873918. DOI: 10.3233/978-1-61499-798-6-1001.

[8] Subramanyam A, Jyrwa S, Bansinghani JM, et al. Dyscalculia detection using machine learning[C]//Pattern Recognition and Machine Intelligence, Cham: Springer International Publishing, 2019: 111-120.

[9] Price KM, Wigg KG, Misener VL, et al. Language difficulties in school-age children with developmental dyslexia[J]. J Learn Disabil, 2022, 55(3): 200-212. PMID: 33890525. PMCID: PMC8996296. DOI: 10.1177/00222194211006207.

[10] Chen A, Wijnen F, Koster C, et al. Individualized early prediction of familial risk of dyslexia: a study of infant vocabulary development[J]. Front Psychol, 2017, 8: 156. PMID: 28270778. PMCID: PMC5318442. DOI: 10.3389/fpsyg.2017.00156.

[11] Wang R, Bi HY. A predictive model for Chinese children with developmental dyslexia: based on a genetic algorithm optimized back-propagation neural network[J]. Expert Syst Appl, 2022, 187: 115949. DOI: 10.1016/j.eswa.2021.115949.

[12] Danna J, Puyjarinet F, Jolly C. Tools and methods for diagnosing developmental dysgraphia in the digital age: a state of the art[J]. Children (Basel), 2023, 10(12): 1925. PMID: 38136127. PMCID: PMC10741997. DOI: 10.3390/children10121925.

[13] Rosenblum S, Dror G. Identifying developmental dysgraphia characteristics utilizing handwriting classification methods[J]. IEEE Trans Hum Mach Syst, 2017, 47(2): 293-298. DOI: 10.1109/THMS.2016.2628799.

[14] Zvoncak V, Mekyska J, Safarova K, et al. New approach of dysgraphic handwriting analysis based on the tunable Q-factor wavelet transform[C]//2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO). Piscataway, NJ, USA: IEEE, 2019: 289-294.

[15] Devillaine L, Lambert R, Boutet J, et al. Analysis of graphomotor tests with machine learning algorithms for an early and universal pre-diagnosis of dysgraphia[J]. Sensors (Basel), 2021, 21(21): 7026. PMID: 34770333. PMCID: PMC8588387. DOI: 10.3390/s21217026.

[16] Drotár P, Dobeš M. Dysgraphia detection through machine learning[J]. Sci Rep, 2020, 10(1): 21541. PMID: 33299092. PMCID: PMC7725992. DOI: 10.1038/s41598-020-78611-9.

[17] Kunhoth J, Al Maadeed S, Saleh M, et al. Exploration and analysis of on-surface and in-air handwriting attributes to improve dysgraphia disorder diagnosis in children based on machine learning methods[J]. Biomed Signal Process Control, 2023, 83: 104715. DOI: 10.1016/j.bspc.2023.104715.

[18] Amini M, Targhi AT, Hosseinzadeh M, et al. The impact of in-air features on the diagnosis of developmental dysgraphia[J]. J Intell Fuzzy Syst, 2023, 44(1): 1413-1424. DOI: 10.3233/JIFS-221708.

[19] Deschamps L, Devillaine L, Gaffet C, et al. Development of a pre-diagnosis tool based on machine learning algorithms on the BHK test to improve the diagnosis of dysgraphia[J]. Adv Artif Intell Mach Learn, 2021, 1(2): 114-135. DOI: 10.54364/AAIML.2021.1108.

[20] Bublin M, Werner F, Kerschbaumer A, et al. Handwriting evaluation using deep learning with SensoGrip[J]. Sensors

(Basel), 2023, 23(11): 5215. PMID: 37299942. PMCID: PMC10255959. DOI: 10.3390/s23115215.

[21] Kunhoth J, Al Maadeed S, Saleh M, et al. CNN feature and classifier fusion on novel transformed image dataset for dysgraphia diagnosis in children[J]. Expert Syst Appl, 2023, 231: 120740. DOI: 10.1016/j.eswa.2023.120740.

[22] Ramlan SA, Isa IS, Osman MK, et al. Comparing CNN-based architectures for dysgraphia handwriting classification performance[J]. Pertanika J Sci Technol, 2024, 32(5): 2013-2032. DOI: 10.47836/pjst.32.5.05.

[23] Liu HW, Wang S, Tong SX. DysDiTect: dyslexia identification using CNN-positional-LSTM-attention modeling with Chinese dictation task[J]. Brain Sci, 2024, 14(5): 444. PMID: 38790423. PMCID: PMC11118011. DOI: 10.3390/brainsci14050444.

[24] Macambira YKDS, Barbosa JVDS, Queiroga BM, et al. Ocular findings from otoneurological examinations in children with and without dyslexia: a systematic review with meta-analysis[J]. Braz J Otorhinolaryngol, 2022, 88Suppl 3(Suppl 3): S192-S201. PMID: 35094959. PMCID: PMC9760992. DOI: 10.1016/j.bjorl.2021.10.006.

[25] Weiss B, Nárai Á, Vidnyánszky Z. Lateralization of early orthographic processing during natural reading is impaired in developmental dyslexia[J]. Neuroimage, 2022, 258: 119383. PMID: 35709947. DOI: 10.1016/j.neuroimage.2022.119383.

[26] Vajs I, Ković V, Papić T, et al. Spatiotemporal eye-tracking feature set for improved recognition of dyslexic reading patterns in children[J]. Sensors (Basel), 2022, 22(13): 4900. PMID: 35808394. PMCID: PMC9269601. DOI: 10.3390/s22134900.

[27] Vajs I, Papić T, Ković V, et al. Accessible dyslexia detection with real-time reading feedback through robust interpretable eye-tracking features[J]. Brain Sci, 2023, 13(3): 405. PMID: 36979215. PMCID: PMC10046816. DOI: 10.3390/brainsci13030405.

[28] Appadurai JP, Bhargavi R. Eye movement feature set and predictive model for dyslexia: feature set and predictive model for dyslexia[J]. Int J Cogn Inform Nat Intell, 2021, 15(4): 1-22. DOI: 10.4018/IJCINI.20211001.oa28.

[29] Jothi Prabha A, Bhargavi R. Predictive model for dyslexia from fixations and saccadic eye movement events[J]. Comput Methods Programs Biomed, 2020, 195: 105538. PMID: 32526535. DOI: 10.1016/j.cmpb.2020.105538.

[30] JothiPrabha A, Bhargavi R, Deepa Rani BV. Prediction of dyslexia severity levels from fixation and saccadic eye movement using machine learning[J]. Biomed Signal Process Control, 2023, 79, Part 1: 104094. DOI: 10.1016/j.bspc.2022.104094.

[31] El Hmimdi AE, Ward LM, Palpanas T, et al. Predicting dyslexia and reading speed in adolescents from eye movements in reading and non-reading tasks: a machine learning approach[J]. Brain Sci, 2021, 11(10): 1337. PMID: 34679400. PMCID: PMC8534067. DOI: 10.3390/brainsci11101337.

[32] El Hmimdi AE, Ward LM, Palpanas T, et al. Predicting dyslexia in adolescents from eye movements during free painting viewing [J]. Brain Sci, 2022, 12(8): 1031. PMID: 36009094. PMCID: PMC9405842. DOI: 10.3390/brainsci12081031.

[33] Piazzalunga C, Dui LG, Termine C, et al. Investigating visual perception impairments through serious games and eye tracking to anticipate handwriting difficulties[J]. Sensors (Basel), 2023, 23(4): 1765. PMID: 36850364. PMCID: PMC9958538. DOI: 10.3390/s23041765.

[34] Cui Z, Xia Z, Su M, et al. Disrupted white matter connectivity underlying developmental dyslexia: a machine learning approach [J]. Hum Brain Mapp, 2016, 37(4): 1443-1458. PMID: 26787263. PMCID: PMC6867308. DOI: 10.1002/hbm.23112.

[35] Zainuddin AZA, Mansor W, Lee KY, et al. Comparison of extreme learning machine and K-nearest neighbour performance in classifying EEG signal of normal, poor and capable dyslexic children[C]//2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Piscataway, NJ, USA: IEEE, 2019: 4513-4516.

[36] Seshadri NPG, Singh BK, Pachori RB. EEG based functional brain network analysis and classification of dyslexic children during sustained attention task[J]. IEEE Trans Neural Syst Rehabil Eng, 2023, 31: 4672-4682. PMID: 37988207. DOI: 10.1109/TNSRE.2023.3335806.

[37] Zaree M, Mohebbi M, Rostami R. An ensemble-based machine learning technique for dyslexia detection during a visual continuous performance task[J]. Biomed Signal Process Control, 2023, 86, Part B: 105224. DOI: 10.1016/j.bspc.2023.105224.

[38] McNorgan C. The connectivity fingerprints of highly-skilled and disordered reading persist across cognitive domains[J]. Front Comput Neurosci, 2021, 15: 590093. PMID: 33643016. PMCID: PMC7907163. DOI: 10.3389/fncom.2021.590093.

[39] Zahia S, Garcia-Zapirain B, Saralegui I, et al. Dyslexia detection using 3D convolutional neural networks and functional magnetic resonance imaging[J]. Comput Methods Programs Biomed, 2020, 197: 105726. PMID: 32916543. DOI: 10.1016/j.cmpb.2020.105726.

[40] Tomaz Da Silva L, Esper NB, Ruiz DD, et al. Visual explanation for identification of the brain bases for developmental dyslexia on fMRI data[J]. Front Comput Neurosci, 2021, 15: 594659. PMID: 34566613. PMCID: PMC8458961. DOI: 10.3389/fncom.2021.594659.

[41] Lancaster HS, Liu X, Dinu V, et al. Identifying interactive biological pathways associated with reading disability[J]. Brain Behav, 2020, 10(8): e01735. PMID: 32596987. PMCID: PMC7428467. DOI: 10.1002/brb3.1735.

[42] Zhong S, Song S, Tang T, et al. DYPA: a machine learning dyslexia prescreening mobile application for Chinese children [J]. Proc ACM Interact Mob Wearable Ubiquitous Technol, 2023, 7(3): 143. DOI: 10.1145/3610908.

（本文编辑：杨丹）

（版权所有©2025 中国当代儿科杂志）