Pregledni rad
UDK 376
DOI 10.53577/oot.8.2.5
Primljeno 22.10.2025.

Autori zadržavaju autorska prava i daju časopisu pravo prvog objavljivanja pod CC-BY 4.0 licencom koja dopušta drugima dijeljenje rada uz priznanje autorstva rada i početne objave u časopisu.

Uloga digitalnih tehnologija u multidisciplinarnoj podršci djeci s teškoćama u učenju: Pregled suradničkih modela

DORA DULEMBA [1], KORANA HORVATEK[1], BARBARA ULIČNIK[1]

[1] Fakultet za odgojne i obrazovne znanosti, Ul. cara Hadrijana 10, Osijek, Hrvatska, e-pošta: dora.dulemba23@gmail.com
[2] Fakultet za odgojne i obrazovne znanosti, Ul. cara Hadrijana 10, Osijek, Hrvatska, e-pošta:ko.horvatek@gmail.com
[3] Fakultet za odgojne i obrazovne znanosti, Ul. cara Hadrijana 10, Osijek, Hrvatska, e-pošta: barbaraulicnik@gmail.com
Kontakt autor: dora.dulemba23@gmail.com

Sažetak Ovaj rad predstavlja sustavni pregled literature (SLR) s ciljem analize načina na koje digitalne tehnologije podupiru multidisciplinarni pristup u radu s djecom s teškoćama u učenju. Iz početno identificiranih 156 publikacija, nakon višefazne selekcije prema PRISMA smjernicama uključeno je 28 metodološki relevantnih studija. Rezultati pokazuju da digitalne platforme i umjetna inteligencija unapređuju suradnju stručnjaka te omogućuju personalizirano planiranje i praćenje intervencija. Identificirane su specifične digitalne intervencije za djecu s disleksijom, disgrafijom i diskalkulijom, uključujući virtualnu stvarnost za razvoj jezičnih vještina, OCR sustave za procjenu rukopisa, te eye-tracking tehnologiju za rano prepoznavanje teškoća u čitanju. Analiza naglašava ključnu ulogu edukacijskog rehabilitatora u koordinaciji multidisciplinarnog tima kroz uporabu digitalnih alata koji omogućuju preciznije praćenje napretka i prilagodbu obrazovnih postupaka. Također, nalazi potvrđuju da digitalni sustavi za ranu detekciju teškoća, temeljeni na strojnom učenju i analitici obrazovnih podataka, značajno doprinose pravovremenim i učinkovitijim intervencijama. SLR ukazuje da integracija digitalnih tehnologija poboljšava dostupnost, individualizaciju i kvalitetu obrazovne podrške, ali i da njihova uspješna primjena zahtijeva stručnu interpretaciju, kontinuiranu edukaciju nastavnika i evaluaciju učinaka. Rad zaključuje da je daljnji razvoj digitalnih alata i modela suradnje među stručnjacima ključan za unapređenje inkluzivnog obrazovanja te za stvaranje održivih i učinkovitih praksi podrške djeci s teškoćama u učenju.

Ključne riječi: 1. digitalna podrška; 2. multidisciplinarnost; 3. teškoće u učenju; 4. suradnički modeli

The Role of Digital Technologies in Multidisciplinary Support for Children with Learning Difficulties: A review of collaborative models

DORA DULEMBA [1], KORANA HORVATEK[2], BARBARA ULIČNIK[3]

[1] Faculty of Education, Ul. cara Hadrijana 10, Osijek, Croatia,
e-mail:dora.dulemba23@gmail.com
[2] Faculty of Education, Ul. cara Hadrijana 10, Osijek, Croatia,
e-mail: ko.horvatek@gmail.com
[3] Faculty of Education, Ul. cara Hadrijana 10, Osijek, Croatia,
e-mail: barbaraulicnik@gmail.com
Contact author: dora.dulemba23@gmail.com

Abstract This systematic literature review (SLR) examines how digital technologies enhance multidisciplinary support for children with learning difficulties. Following a PRISMA-aligned selection process, 28 relevant studies were included from an initial pool of 156 publications. The findings show that digital platforms and artificial intelligence significantly improve collaboration among professionals and enable more precise, individualized planning of educational interventions. Key digital solutions identified in the review include virtual reality applications supporting language and reading skills in children with dyslexia, OCR-based handwriting assessment tools for dysgraphia, and eye-tracking systems that facilitate early detection of reading difficulties. The role of educational rehabilitators emerges as central in coordinating multidisciplinary teams through the use of digital tools that support continuous monitoring of progress and tailored instructional adjustments. Early identification technologies, particularly those based on machine learning and educational data analytics, are shown to contribute to timely and more effective interventions. Overall, the review indicates that digital technologies can substantially enhance accessibility, personalization, and quality of support for learners with difficulties. Their effective implementation, however, relies on professional expertise, ongoing training, and systematic evaluation. Further development of digital tools and collaborative models remains essential for advancing inclusive educational practice.

Keywords: 1. digital support; 2. multidisciplinarity; 3. learning difficulties; 4. collaborative model

1 Uvod

U suvremenim obrazovnim sustavima djeca s teškoćama u učenju, poput disleksije, disgrafije, diskalkulije i ADHD-a, predstavljaju skupinu učenika kojoj je nužna sustavna i ciljana podrška kako bi ostvarili svoje obrazovne potencijale. Multidisciplinarni pristup, koji uključuje suradnju učitelja, edukacijskih rehabilitatora, logopeda, psihologa i pedagoga, prepoznat je kao ključan za razvoj individualiziranih obrazovnih planova i osiguravanje inkluzivnog obrazovanja. U tom kontekstu sve se više ističe potreba za modelima podrške koji istodobno uzimaju u obzir organizaciju suradnje stručnjaka, primjenu specifičnih intervencija i praćenje obrazovnih ishoda.

Razvoj digitalnih tehnologija značajno je promijenio način na koji se multidisciplinarna podrška planira i provodi. Digitalne platforme, sustavi za razmjenu dokumentacije i komunikacijski alati omogućuju učinkovitiju koordinaciju rada različitih stručnjaka, kontinuirano praćenje napretka učenika te lakše usklađivanje obrazovnih i terapijskih intervencija. Istraživanja ukazuju da digitalno posredovani modeli suradnje mogu pridonijeti većoj transparentnosti procesa podrške i bržem donošenju odluka u stručnim timovima.

Istodobno, razvijen je broj specifičnih digitalnih intervencija usmjerenih na djecu s teškoćama u učenju. U literaturi se opisuju rješenja koja se oslanjaju na virtualnu stvarnost, prilagodljive obrazovne sustave, OCR tehnologiju za analizu rukopisa, eye-tracking sustave za praćenje čitanja te aplikacije za podršku vještinama čitanja, pisanja i računanja. Ta istraživanja pokazuju da pažljivo dizajnirane digitalne intervencije mogu unaprijediti motivaciju, točnost i brzinu učenja te omogućiti preciznije prilagodbe obrazovnih sadržaja pojedinim učenicima.

Važan aspekt multidisciplinarne podrške odnosi se na ulogu edukacijskog rehabilitatora i drugih stručnjaka koji koriste digitalne alate za planiranje, praćenje i evaluaciju intervencija. Stručnjaci imaju ključnu ulogu u interpretaciji podataka dobivenih digitalnim sustavima, odabiru primjerenih intervencija i koordiniranju suradnje unutar tima, gdje digitalne tehnologije djeluju kao podržavajući alat profesionalnom prosuđivanju.

Sve veća pozornost posvećuje se i ranom prepoznavanju teškoća u učenju uz pomoć digitalnih alata, primjerice kroz sustave za analizu čitanja, praćenje pogleda ili automatiziranu obradu pisanih produkata. Rani screening omogućuje pravovremeno uvođenje intervencija, što je povezano s boljim obrazovnim ishodima, smanjenjem školskog neuspjeha i poboljšanjem emocionalnog funkcioniranja učenika.

Unatoč broju pojedinačnih studija koje se bave digitalnim platformama, specifičnim intervencijama, ulogom stručnjaka i ranim prepoznavanjem teškoća, nedostaju sustavni pregledi koji integriraju sva ova područja u jedinstven konceptualni okvir.

Stoga je cilj ovog rada provesti sustavni pregled literature (SLR) o ulozi digitalnih tehnologija u multidisciplinarnoj podršci djeci s teškoćama u učenju, odgovarajući na sljedeća istraživačka pitanja: Kako digitalne platforme podržavaju multidisciplinarni pristup? Koje su specifične digitalne intervencije za djecu s disleksijom, disgrafijom i diskalkulijom? Kakva je uloga edukacijskog rehabilitatora u koordinaciji tima? Koliko rano prepoznavanje teškoća putem digitalnih alata utječe na obrazovne ishode?

Dosadašnja istraživanja ukazuju na razvoj digitalnih platformi koje podržavaju multidisciplinarnu suradnju stručnjaka (učitelja, edukacijskih rehabilitatora, logopeda i psihologa) kroz razmjenu dokumentacije, zajedničko praćenje napretka učenika i koordinaciju intervencija (Wagner i sur., 2020; MacKay-Lyons i sur., 2022) (istraživačko pitanje 1). Paralelno s time, razvijen je spektar specifičnih digitalnih intervencija za djecu s disleksijom (npr. VR i eye-tracking sustavi), disgrafijom (OCR analiza rukopisa) i diskalkulijom (prilagodljive matematičke aplikacije), koje poboljšavaju motivaciju i učne ishode (Minoofam i sur., 2022; Cibrian i sur., 2025; Mammarella i sur., 2016) (istraživačko pitanje 2). Uloga edukacijskog rehabilitatora i drugih stručnjaka ključna je u interpretaciji podataka iz digitalnih sustava, odabiru intervencija i vođenju tima, gdje tehnologija služi kao podržni alat profesionalnom prosuđivanju (Hurwitz, 2023; Hoic-Bozic i Mornar, 2015) (istraživačko pitanje 3). Konačno, rani screening teškoća putem digitalnih alata (analiza čitanja, praćenje pogleda, automatizirane procjene) omogućuje pravovremene intervencije povezane s boljim obrazovnim rezultatima (Gran Ekstrand i Benfatto, 2021; Kaisar, 2020) (istraživačko pitanje 4).

2 Pregled dosadašnjih istraživanja

Digitalne tehnologije i umjetna inteligencija sve više igraju ključnu ulogu u obrazovanju, osobito u kontekstu djece s teškoćama u učenju. Rajpurkar i sur. (2022) ukazuju na to kako umjetna inteligencija omogućava personalizaciju obrazovnog sadržaja i strategija, prepoznajući individualne izazove učenika u stvarnom vremenu. Korištenje tehnologija poput „recommender" sustava i aplikacija temeljenih na strojnim algoritmima pruža učiteljima alat za prilagodbu nastavnih metoda potrebama svakog učenika, čime se osigurava učinkovitija intervencija i podrška (Hoic-Bozic i sur., 2015). Osim toga, specifične tehnologije poput prepoznavanja rukopisa koriste se za dijagnosticiranje disgrafije kod djece, što omogućuje precizno prepoznavanje teškoća u pisanju i prilagodbu obrazovnih metoda (Drotár i Dobeš, 2020). „Eye-tracking" tehnologije, prema Yang (2024), pomažu u analizi problema s čitanjem, identificirajući specifične teškoće koje bi mogle ostati nezamijećene, a time omogućuju pravovremene intervencije. Nadalje, Gran Ekstrand i Benfatto

(2021) tvrde da tehnologije prepoznavanja govora mogu poboljšati proces evaluacije izgovora i omogućiti prilagodbu logopedskih metoda, što dovodi do boljih obrazovnih rezultata za djecu s govorno-jezičnim teškoćama. Također, tehnologije poput virtualne stvarnosti (VR) pokazale su se kao vrlo korisne za djecu s disleksijom. Minoofam i sur. (2022) dokazuju da VR može poboljšati percepciju jezika, dopuštajući djeci da se na interaktivan način angažiraju u učenju. Ova tehnologija omogućuje učenicima da vizualiziraju jezične koncepte na novi način, što im pomaže u boljoj integraciji informacija. Slični rezultati pokazuju i Cappadona i sur. (2023), koji ističu učinkovitost VR-a u smanjenju anksioznosti povezanih s učenjem, posebno u djece s disleksijom. Za djecu s disgrafijom i diskalkulijom, digitalni alati poput OCR (Optical Character Recognition) tehnologija pospješuju precizniju analizu rukopisa, dok interaktivni alati za matematičke koncepte pomažu djeci s diskalkulijom pri boljem razumijevanju vizualnih prikaza brojeva i matematičkih operacija (Cibrian i sur., 2025; Wagner i sur., 2020). Ovi alati pružaju personalizirane pristupe učenju i daju bolji uvid učiteljima u razumijevanju specifičnih teškoća svojih učenika.

3 Metodologija

Cilj ovog istraživanja bio je sustavno analizirati SLR metodom prema preporukama o korištenju višefaznog procesa za SLR. Istraživačka pitanja odabrana su na temelju prethodne ekspertne analize literature i trenutnih izazova u području digitalne podrške djeci s teškoćama u učenju, vodeći se važnošću multidisciplinarnog pristupa, potrebom za detaljnim prikazom digitalnih intervencija, definiranjem uloge edukacijskog rehabilitatora te ispitivanjem utjecaja ranog prepoznavanja teškoća na obrazovne ishode. Ovakav odabir pitanja usklađen je s preporučenim obrascima za SLR, a svaki segment tematizira ključne aspekte za razvoj inkluzivnog obrazovnog sustava. SLR se temeljio na sljedećim četirima istraživačkim pitanjima:

1. Kako digitalne platforme podržavaju multidisciplinarni pristup u radu s djecom s teškoćama u učenju?
2. Koje su specifične digitalne intervencije za djecu s disleksijom, disgrafijom i diskalkulijom?
3. Kakva je uloga edukacijskog rehabilitatora u koordinaciji multidisciplinarnog tima uz pomoć digitalnih tehnologija?
4. Koliko rano prepoznavanje teškoća kroz digitalne alate utječe na obrazovne ishode?

Sustavni pregled literature (SLR) proveden je prema preporukama priznatih metodologija (PRISMA, Kitchenham i Charters, 2007), s jasnom transparentnošću svih faza procesa. U prvom koraku, definiranjem istraživačkih pitanja i razvijanjem strategije pretraživanja, identificirano je 156 znanstvenih radova iz relevantnih baza podataka, uključujući Web of Science, Scopus i Google Scholar. Za potrebe pretraživanja korišten je sljedeći pretraživački upit na engleskom jeziku: ("digital support" OR "digital intervention" OR "multidisciplinary approach" OR "children with learning difficulties" OR "educational technology" OR "inclusive education") AND (dyslexia OR dysgraphia OR dyscalculia OR ADHD). Ovakav upit omogućio je ciljano dohvaćanje publikacija koje obrađuju tematske cjeline digitalne podrške, multidisciplinarnog pristupa i inkluzije djece s teškoćama u učenju u kontekstu suvremene obrazovne tehnologije. Sljedeća faza uključivala je temeljitu evaluaciju naslova, sažetaka i ključnih riječi te uklanjanje dupliciranih, nerelevantnih te metodološki neadekvatnih radova. Broj publikacija time je sužen na 84 članka koji su tematski i sadržajno odgovarali kriterijima uključenosti te pružali podatke usklađene s definiranom problematikom. Ova faza je ključna za izbjegavanje pristranosti i osiguravanje da su svi odabrani radovi visoke kvalitete. U završnoj, trećoj fazi provedena je detaljna analiza punog teksta odabranih radova uz primjenu uključujućih i isključujućih kriterija. Odbačeni su radovi koji ne pružaju jasne empirijske podatke o digitalnim intervencijama i multidisciplinarnim pristupima. Odabrano je 28 najrelevantnijih publikacija, koje su služile kao temelj za daljnju znanstvenu argumentaciju i analizu. Ova faza osigurava da integrirane publikacije odgovaraju na središnja istraživačka pitanja, usporedno razmatrajući metodološku snagu, empirijsku relevantnost i doprinos u kontekstu digitalne podrške djeci s teškoćama u učenju. Uključeni su istraživački radovi koji se bave temama primjene umjetne inteligencije, prilagodljivih sustava i digitalnih platformi u edukaciji djece s teškoćama u učenju. Pregledani su radovi koji pružaju empirijske podatke o učinkovitosti digitalnih alata u multidisciplinarnom radu stručnjaka, uključujući primjenu OCR sustava za prepoznavanje disgrafije i sustava za praćenje pokreta očiju za detekciju disleksije (Drotár i Dobeš, 2020; Gran Ekstrand i Benfatto, 2021). Dodatno, analizirani su podaci o implementaciji digitalnih metoda u obrazovnim institucijama te usporedba različitih pristupa digitalne podrške (McNamara i sur., 2017). Poseban naglasak stavljen je na sustave koji koriste prirodnu obradu jezika za analizu čitalačkih sposobnosti učenika (Spencer i Wagner, 2018). Korišteni su radovi koji istražuju ulogu gamifikacije u učenju i motivaciji učenika s teškoćama (Hamari i sur., 2014), kao i primjenu mobilnih aplikacija u poticanju samostalnog učenja (Pachler i sur., 2010).

Cijeli proces vodio se načelima transparentnosti, ponovljivosti i znanstvene rigoroznosti, osiguravajući pouzdanost zaključaka SLR-a te omogućujući jasno slaganje rezultata s najboljom dostupnom znanstvenom evidencijom.

4 Rezultati i rasprava

Analizirano je 28 publikacija, prikazanih u Tablici 1, koje ispunjavaju sve gore navedene kriterije i sadrže nalaze vezane uz multidisciplinarni pristup digitalne podrške djeci s teškoćama u učenju.

Tablica 1: SLR pregled odabranih radova

Autor(i), godina	Primjena IP	Povezani aspekti	Uzorak i kontekst	Glavni nalazi
Alcalde-Llergo i sur. (2023)	Rano prepoznavanje teškoća, specifične digitalne intervencije za disleksiju	Virtualna stvarnost za povećanje empatije prema učenicima s fonološkom disleksijom.	Djeca s disleksijom u osnovnim školama	VR tehnologija poboljšava razumijevanje i podršku učitelja za djecu s disleksijom.
Minoofam i sur. (2022)	Specifične digitalne intervencije za disleksiju	Adaptivni okvir za podučavanje učenika s disleksijom temeljen na učenju pojačanjima.	Djeca s disleksijom, uzorak 100 učenika	Digitalne platforme koriste adaptivne metode koje pružaju personalizirani pristup učenju disleksične djece.
Cibrian i sur. (2025)	Specifične digitalne intervencije za disgrafiju	OCR analiza rukopisa za dijagnosticiranje disgrafije.	Djeca s disgrafijom	OCR tehnologija omogućuje prepoznavanje disgrafije i može se koristiti u terapijskim intervencijama.
Narkhede i sur. (2024)	Specifične digitalne intervencije za disleksiju	Aplikacija za pomoć disleksičnim učenicima korištenjem TTS i klasifikacije teksta uz pomoć neuronskih mreža.	Učenici s disleksijom, 80 učenika	TTS aplikacije u kombinaciji s neuronskim mrežama poboljšavaju čitanje i razumijevanje teksta.

Autor(i), godina	Primjena IP	Povezani aspekti	Uzorak i kontekst	Glavni nalazi
Bourkoukou i El Bachari (2016)	Digitalne platforme, personalizacija obrazovanja	Personalizacija učenja temeljenog na suradničkom filtriranju i preferencijama učenika.	Srednjoškolci	Personalizirane obrazovne platforme omogućuju bolje prilagodbu sadržaja za djecu s različitim potrebama.
Cappadona i sur. (2023)	Specifične digitalne intervencije za disleksiju, virtualna stvarnost	Intervencija govora pomoću VR sustava u djece s jezičnim poremećajima.	Djeca s jezičnim poremećajima	Virtualna stvarnost poboljšava izgovor i govor djece s jezičnim teškoćama.
Drotár i Dobeš (2020)	Strojno učenje za detekciju disgrafije	Digitalna podrška u ranom otkrivanju disgrafije kroz analizu rukopisa djece različite dobi, spola i dominatne ruke.	Djeca s i bez disgrafije	Strojno učenje omogućava detekciju disgrafije s točnošću od gotovo 80%
Gran Ekstrand, i Benfatto (2021)	Specifične digitalne intervencije za disleksiju	Korištenje eye-tracking tehnologije za prepoznavanje teškoća u čitanju.	Djeca s disleksijom	Eye-tracking tehnologija može prepoznati specifične teškoće u čitanju i pomoći u terapiji.
Häikiö i Luotojärvi (2022)	Specifične digitalne intervencije za disleksiju	Utjecaj razdvajanja slogova na čitanje novih riječi kod djece.	Djeca s disleksijom	Razdvajanje slogova uz pomoć digitalnih alata poboljšava čitanje kod djece s disleksijom.
Hoic-Bozic i Mornar (2015)	Digitalne platforme	Korištenje recommender sustava i Web 2.0 alata za poboljšanje modela miješanog učenja.	Studenti, 50 sudionika	Recommender sustavi mogu personalizirati iskustvo učenika i pomoći u učenju djece s teškoćama.
Hurwitz (2023)	Uloga edukacijskog rehabilitatora, digitalne tehnologije u podršci	Dizajn i utjecaj asistivnih tehnologija za djecu s teškoćama.	Djeca s teškoćama, specijalisti	Asistivne tehnologije poboljšavaju pristup obrazovanju i povećavaju samostalnost djece s teškoćama.

Autor(i), godina	Primjena IP	Povezani aspekti	Uzorak i kontekst	Glavni nalazi
Ismail i Jaafar (2014)	Specifične digitalne intervencije za disleksiju	Značajke prikaza teksta za djecu s disleksijom.	Djeca s disleksijom, 60 učenika	Promjena tipografije i boje teksta putem digitalnih alata može poboljšati čitanje kod djece s disleksijom.
Kavanagh i sur. (2017)	Specifične digitalne intervencije za disleksiju	Pregled primjene virtualne stvarnosti u obrazovanju, s naglaskom na djecu s teškoćama u učenju.	Nema specifičnog uzorka	Virtualna stvarnost može pružiti prilagodljive i poticajne obrazovne alate za djecu s teškoćama u učenju.
Kaisar (2020)	Rano prepoznavanje teškoća	Detekcija disleksije korištenjem tehnika strojnog učenja.	Djeca, 100 učenika	Tehnike strojnog učenja mogu pomoći u ranoj detekciji disleksije, čime se omogućuje pravovremena intervencija.
Kuster i sur. (2018)	Specifične digitalne intervencije za disleksiju	Utjecaj fontova za disleksiju na čitanje kod djece s disleksijom.	Djeca s disleksijom	Korištenje specijaliziranih fontova za disleksiju može poboljšati brzinu i točnost čitanja.
Mammarella i sur. (2016)	Specifične digitalne intervencije za diskalkuliju	Istraživanje alata za matematičke teškoće kod djece s diskalkulijom.	Djeca s diskalkulijom	Digitalne aplikacije za matematičke teškoće pomažu djeci s diskalkulijom u učenju osnovnih matematičkih vještina.
MacKay-Lyons i sur. (2022)	Uloga edukacijskog rehabilitatora, personalizacija obrazovanja	Uloga učitelja u personaliziranom obrazovanju koristeći digitalne tehnologije.	Učitelji, 50 učitelja	Učitelji igraju ključnu ulogu u implementaciji digitalnih alata za personaliziranu podršku djeci s teškoćama.

Autor(i), godina	Primjena IP	Povezani aspekti	Uzorak i kontekst	Glavni nalazi
Melby-Lervåg i sur. (2012)	Specifične digitalne intervencije za disleksiju	Uloga fonoloških vještina u razvoju disleksije i kako digitalne tehnologije mogu pomoći.	Djeca s disleksijom	Fonološke vještine imaju ključnu ulogu u prevenciji disleksije, a digitalni alati mogu pomoći u njihovu razvoju.
John i Renumol (2018)	Specifične digitalne intervencije za disgrafiju	Upotreba digitalnih alata za poboljšanje pisanja i motoričkih vještina kod djece s disgrafijom.	Djeca s disgrafijom	Digitalni alati mogu poboljšati motoričke vještine i olakšati proces pisanja kod djece s disgrafijom.
Üstün i sur. (2021)	Specifične digitalne intervencije za diskalkuliju	Korištenje alata za pomoć djeci s matematičkim teškoćama.	Djeca s diskalkulijom	Alati za matematičke teškoće olakšavaju djeci s diskalkulijom bolje razumijevanje i rješavanje matematičkih zadataka.
Pugliatti i sur. (2020)	Specifične digitalne intervencije za disleksiju	Primjena digitalnih rješenja u terapiji disleksije, uključujući igre i aplikacije.	Djeca s disleksijom	Digitalna rješenja, uključujući igre i aplikacije, čine terapiju disleksije interaktivnijom i učinkovitijom.
Silva i Costa (2018)	Rano prepoznavanje teškoća	Razvoj sustava za rano prepoznavanje disleksije temeljenog na analizama podataka.	Djeca, 200 učenika	Sustavi za rano prepoznavanje disleksije temeljeni na podacima mogu značajno unaprijediti detekciju i intervenciju.
Hall i sur. (2013)	Specifične digitalne intervencije za disleksiju	Uloga neuroloških procesa u razumijevanju i ispravljanju disleksije pomoću digitalnih intervencija.	Nema specifičnog uzorka	Neurološki procesi igraju ključnu ulogu u razumijevanju disleksije, a digitalne intervencije mogu olakšati terapiju.

Autor(i), godina	Primjena IP	Povezani aspekti	Uzorak i kontekst	Glavni nalazi
Comber i Nixon (2009)	Specifične digitalne intervencije za disleksiju	Tehnologije za čitanje i pisanje koje pomažu djeci s disleksijom, uključujući interaktivne platforme.	Djeca s disleksijom	Interaktivne digitalne platforme mogu značajno poboljšati čitanje i pisanje kod djece s disleksijom.
Heß i sur. (2024)	Digitalne platforme	Kreiranje digitalnih obrazovnih alata za djecu s različitim teškoćama u učenju.	Djeca s različitim teškoćama	Digitalni obrazovni alati podržavaju fleksibilno učenje, prilagodljivo djeci s različitim potrebama.
Tobolcea i Danubianu (2010)	Specifične digitalne intervencije za disgrafiju	Razvoj računalnih alata koji pomažu u analizi i liječenju disgrafije kod djece.	Djeca s disgrafijom	Računalni alati za analizu disgrafije poboljšavaju dijagnostiku i liječenje ovog poremećaja.
Borhan i sur. (2018)	Specifične digitalne intervencije za disleksiju	Korištenje aplikacija i interaktivnih platformi za podršku učenju djece s disleksijom.	Djeca s disleksijom	Aplikacije i interaktivne platforme pružaju visoko personalizirane metode učenja za djecu s disleksijom.
Benavides-Varela i sur. (2020)	Specifične digitalne intervencije za diskalkuliju	Razvoj alata za djecu s matematičkim teškoćama temeljenih na digitalnim tehnologijama.	Djeca s diskalkulijom	Digitalni alati za djecu s diskalkulijom pomažu u savladavanju osnovnih matematičkih vještina kroz interaktivne zadatke.

Izvor: autori.

Tablica 1 daje uvid u dosadašnja istraživanja digitalne podrške djeci sa specifičnim teškoćama u učenju, razvrstana prema istraživačkim pitanjima. U području specifičnih intervencija za disleksiju ističu se, primjerice, radovi Alcalde-Llergo i sur. (2023), Minoofam i sur. (2022), Ismail i Jaafar (2014), Kavanagh i sur. (2017), Kuster i sur. (2018), Melby-Lervåg i sur. (2012), Hall i sur. (2013), Comber i Nixon (2009), Borhan sur. (2018), Pugliatti i sur. (2020), Narkhede i sur. (2024) i Häikiö i Luotojärvi (2022), koji ispituju različite oblike digitalnih rješenja za poticanje čitanja i jezičnog razvoja. U domeni disgrafije ističu se radovi Cibrian i sur. (2025), John i Renumol (2018), Drotár i Dobeš (2020) i Tobolcea i Danubianu (2010), dok se diskalkulijom bave Mammarella i sur. (2016), Üstün i sur. (2021), Wagner i sur. (2020) i Benavides-Varela i sur. (2020). Takva raspodjela potvrđuje široku lepezu tehnoloških rješenja, uključujući virtualnu stvarnost (Alcalde-Llergo i sur., 2023; Minoofam i sur., 2022), OCR tehnologiju (Cibrian i sur., 2025; Drotar i Dobeš, 2020), eye-tracking sustave (Gran Ekstrand i Benfatto, 2021) te specijalizirane matematičke alate (Mammarella i sur., 2016; Wagner i sur., 2020).

Metodološki gledano, u uzorku se nalaze eksperimentalna istraživanja (npr. Minoofam i sur., 2022; Narkhede i sur., 2024; Mammarella i sur., 2016), kvantitativne i kvalitativne studije (npr. Cibrian i sur., 2025; Hurwitz, 2023; Heß i sur., 2024) te pregledni radovi (npr. Kavanagh i sur., 2017; Hall i sur., 2013). Eksperimentalni radovi često uključuju uzorke djece s teškoćama, što omogućuje empirijsku provjeru učinka tehnologija poput VR-a, TTS sustava ili gamificiranih aplikacija (Minoofam i sur., 2022; Borhan sur., 2018; Pugliatti i sur., 2020). Kvalitativne studije, poput Hurwitza (2023) i MacKay-Lyons i sur. (2022), temelje se na iskustvima stručnjaka i nastavnika, dok radovi poput Sharplesa i sur. (2019) dodatno tematiziraju implementaciju digitalnih alata u svakodnevnoj praksi. Većina istraživanja provodi se u školskim ili terapijskim okruženjima, s uzorcima djece s disleksijom, disgrafijom ili diskalkulijom te stručnjaka koji s njima rade, što nalazima daje jasnu primjenjivost u obrazovnom kontekstu.

Što se tiče odgovora na istraživačka pitanja, oni slijede u nastavku.

1. DIGITALNE PLATFORME I MULTIDISCIPLINARNI PRISTUP (IP1)

Na istraživačko pitanje o ulozi digitalnih platformi u podršci multidisciplinarnom pristupu izravno se odnosi više radova u Tablici 1, uključujući Bourkoukou i El Bachari (2016), Hoic-Bozic i Mornar (2015), Heß i sur. (2024), Rajpurkar i sur. (2022), Wagner i sur. (2020) i MacKay-Lyons i sur. (2022). Bourkoukou i El Bachari (2016) opisuju personalizirane obrazovne platforme temeljene na suradničkom filtriranju, dok Hoic-Bozic i Mornar (2015) analiziraju recommender sustave i Web 2.0 alate za

podršku suradničkom i miješanom učenju. Heß i sur. (2024) i Wagner i sur. (2020) naglašavaju da digitalni sustavi olakšavaju razmjenu podataka i planiranje intervencija u timovima koji rade s djecom s teškoćama, a MacKay-Lyons i sur. (2022) prikazuju kako učitelji koriste digitalne alate u personaliziranom obrazovanju. Zajednički nalazi ovih studija ukazuju na to da digitalne platforme olakšavaju komunikaciju i koordinaciju među stručnjacima, ali i pružaju strukturirane formate za planiranje i praćenje podrške.

2. SPECIFIČNE DIGITALNE INTERVENCIJE (IP2)

Drugo istraživačko pitanje pokriveno je najvećim brojem radova u Tablici 1. U području disleksije, radovi Alcalde-Llergo i sur. (2023), Minoofam i sur. (2022), Ismail i Jaafar (2014), Kavanagh i sur. (2017), Kuster i sur. (2018), Melby-Lervåg i sur. (2012), Hall i sur. (2013), Comber i Nixon (2009), Borhan sur. (2018), Pugliatti i sur. (2020), Narkhede i sur. (2024) i Häikiö i Luotojärvi, T. (2022) istražuju različite oblike digitalnih intervencija, od promjene tipografije i prikaza teksta, preko VR okruženja, do interaktivnih aplikacija za čitanje. Za disgrafiju su ključni radovi Cibrian i sur. (2025), John i Renumol (2018), Drotár i Dobeš (2020) i Tobolcea i Danubianu (2010), koji analiziraju OCR i računalne alate za procjenu i poboljšanje rukopisnih vještina. U području diskalkulije ističu se Mammarella i sur. (2016), Üstün i sur. (2021), Wagner i sur. (2020) i Benavides-Varela i sur. (2020), koji opisuju matematičke aplikacije i digitalne alate dizajnirane za potporu učenju osnovnih matematičkih pojmova. Ovi radovi zajednički potvrđuju da su specifične digitalne intervencije usmjerene na različite aspekte učenja i mogu biti prilagođene profilu teškoća.

3. ULOGA EDUKACIJSKOG REHABILITATORA I DRUGIH STRUČNJAKA (IP3)

Na treće istraživačko pitanje, o ulozi edukacijskog rehabilitatora u koordinaciji multidisciplinarnog tima uz pomoć digitalnih tehnologija, nadovezuju se radovi Hurwitza (2023), MacKay-Lyons i sur. (2022), Wagner i sur. (2020) i Heß i sur. (2024) uključeni u Tablicu 1. Hurwitz (2023) analizira ulogu stručnjaka u dizajnu i primjeni asistivnih tehnologija, naglašavajući važnost njihove stručne procjene pri odabiru i prilagodbi alata. MacKay-Lyons i sur. (2022) prikazuju kako učitelji koriste digitalne tehnologije za personalizaciju nastave, dok Wagner i sur. (2020) i Heß i sur. (2024) opisuju modele suradnje u kojima edukacijski rehabilitatori i ostali stručnjaci koriste digitalne sustave za planiranje, praćenje i evaluaciju intervencija. Nalazi ovih istraživanja zajednički upućuju na to da je uloga edukacijskog rehabilitatora centralna u interpretaciji digitalnih podataka i koordinaciji timskog rada.

4. RANO PREPOZNAVANJE TEŠKOĆA (IP4)

Četvrto istraživačko pitanje, o ranom prepoznavanju teškoća putem digitalnih alata i utjecaju na obrazovne ishode, pokriveno je radovima Gran Ekstrand i Benfatto (2021), Kaisar (2020), Silva i Costa (2018), Drotár i Dobeš (2020), Alcalde-Llergo i sur. (2023) i Borhan sur. (2018) iz Tablice 1. Gran Ekstrand i Benfatto (2021) prikazuju primjenu eye-tracking tehnologije u identifikaciji teškoća u čitanju, dok Kaisar (2020) i Silva i Costa (2018) analiziraju sustave strojnog učenja za ranu detekciju disleksije. Drotár i Dobeš (2020) usmjeravaju se na analizu rukopisa za prepoznavanje disgrafije, a Borhan sur. (2018) i Alcalde-Llergo i sur. (2023) ukazuju na potencijal digitalnih sustava i VR okruženja u ranom prepoznavanju i ublažavanju teškoća. Ti radovi zajedno potvrđuju da digitalni alati mogu služiti kao učinkoviti screeening instrumenti koji omogućuju pravodobno usmjeravanje podrške.

Digitalne platforme poboljšavaju multidisciplinarnu koordinaciju (IP1)

Rezultati pokazuju da digitalne platforme (Bourkoukou i El Bachari, 2016; Hoic-Bozic i Mornar, 2015; Wagner i sur., 2020) olakšavaju razmjenu podataka i koordinaciju između stručnjaka, što odgovara nedavnim pregledima o inkluzivnim digitalnim platformama koje smanjuju administrativno opterećenje za 30-40% u timovima (Rajpurkar i sur., 2022; Wyeth i sur., 2023). Međutim, nedostatak standardiziranih platformi ograničava širu primjenu u hrvatskom kontekstu gdje su e-dnevnici još uvijek fragmentirani, slično izazovima u EU zemljama (UNESCO, 2025).

Specifične intervencije dokazano djeluju (IP2)

Digitalne intervencije za disleksiju (Minoofam i sur., 2022; Gran Ekstrand i Benfatto, 2021), disgrafiju (Cibrian i sur., 2025) i diskalkuliju (Mammarella i sur., 2016) postižu konkretne učinke poput 80% točnosti dijagnostike i 25% veće motivacije, što potvrđuju recentne sustavni pregledi o AI alatima za specifične teškoće (Cheung i Slavin, 2013; Bhushan, 2024; Han, 2025). Ključno je prilagoditi ih lokalnim jezicima i kurikulumima za veću pristupačnost, kao što predlažu EU smjernice za inkluzivne tehnologije.

Stručnjaci ključni u implementaciji (IP3)

Edukacijski rehabilitatori imaju centralnu ulogu u interpretaciji digitalnih podataka (Hurwitz, 2023; MacKay-Lyons i sur., 2022), slažući se s naglaskom da tehnologija podržava, ali ne zamjenjuje profesionalno prosuđivanje (Hoic-Bozic i Mornar, 2015; van Calis, 2025). Nedostaje sistematska obuka za korištenje ovih alata u inkluzivnim timovima, što ograničava njihovu učinkovitost, posebno u kontekstu suradnje s roditeljima i školama (Early Childhood Australia, 2025).

Rano prepoznavanje sprječava kumulaciju problema (IP4)

Eye-tracking i ML algoritmi (Gran Ekstrand i Benfatto, 2021; Kaisar, 2020) omogućuju ranu detekciju, povezanu sa smanjenjem školskog neuspjeha za 15-20% (Snowling i sur., 2020; Patel i sur., 2025). Ovo ima posebnu važnost u Hrvatskoj gdje se screening često provodi kasno, što rezultira nepotrebnim neuspjesima učenika, dok AI screening alati pokazuju potencijal za ranu intervenciju (Khan i sur., 2023).

Nalazi potvrđuju integrirani model gdje platforme (IP1), intervencije (IP2), stručnjaci (IP3) i screening (IP4) čine cjelovitu podršku, ali ukazuju na potrebu za longitudinalnim istraživanjima i lokalnom adaptacijom alata za inkluzivno obrazovanje (Alonso-García i sur., 2024; EU CERV, 2025).

5 Zaključak

Sustavni pregled literature proveden u ovom radu potvrđuje da digitalne tehnologije imaju ključnu ulogu u unapređenju multidisciplinarnog pristupa podršci djeci s teškoćama u učenju. Digitalne platforme, umjetna inteligencija, virtualna stvarnost, OCR sustavi i eye-tracking tehnologije omogućuju preciznije prepoznavanje specifičnih teškoća, učinkovitiju komunikaciju među stručnjacima i personalizirane intervencije u stvarnom vremenu. Nalazi pokazuju da digitalna rješenja poboljšavaju dijagnostičku točnost i omogućuju oblikovanje dinamičnih obrazovnih iskustava prilagođenih jedinstvenim potrebama svakog učenika.

Uloga edukacijskog rehabilitatora unutar digitalno posredovanog multidisciplinarnog okruženja dodatno dobiva na važnosti. Stručnjaci imaju mogućnost kontinuiranog praćenja napretka, preciznijeg planiranja intervencija i učinkovitije koordinacije s ostalim članovima tima. Takva suradnja rezultira većom dosljednošću i kvalitetom podrške, što izravno pridonosi boljim obrazovnim ishodima djece.

Rana detekcija teškoća, potpomognuta algoritmima strojnog učenja i sustavima za analizu jezičnih, čitalačkih i motoričkih vještina, pokazuje se kao jedan od naj-

snažnijih prediktora kasnijeg uspjeha intervencija. Pravovremeno prepoznavanje obrazovnih rizika omogućuje brzu primjenu ciljano usmjerenih metoda koje mogu značajno ublažiti dugoročne posljedice teškoća u učenju.

Iako rezultati ukazuju na izniman potencijal digitalnih tehnologija, važno je naglasiti da se njihova učinkovitost ne smije promatrati odvojeno od pedagoške ekspertize i profesionalnog prosuđivanja. Optimalni ishodi postižu se tek kada se tehnološka rješenja integriraju u refleksivnu, stručno vođenu praksu koja uzima u obzir individualne razlike, emocionalne potrebe i socijalni kontekst djeteta. Stoga je nužno kontinuirano ulagati u edukaciju stručnjaka, razvoj institucionalne infrastrukture i sustavno praćenje učinkovitosti implementiranih digitalnih alata.

Buduća istraživanja trebala bi se usmjeriti na dugoročne učinke digitalnih intervencija, njihovu primjenjivost u različitim obrazovnim kontekstima te razvoj standardiziranih protokola za multidisciplinarnu suradnju u digitalnom okruženju. Posebna pažnja treba se posvetiti uključivanju obitelji i samih učenika u planiranje digitalne podrške, čime se podiže razina autonomije i motivacije djece s teškoćama u učenju.

Zaključno, digitalne tehnologije ne zamjenjuju ljudski rad niti stručnost, ali mijenjaju način na koji stručnjaci surađuju, donose odluke i oblikuju obrazovne intervencije. Njihova promišljena i integrirana primjena predstavlja važan iskorak prema inkluzivnom obrazovnom sustavu koji uistinu odgovara potrebama svakog djeteta.

Izjava o sukobu interesa

Autori izjavljuju da nema potencijalnih sukoba interesa u vezi s istraživanjem, autorstvom i/ili objavljivanjem ovog članka.

Literatura

Alcalde-Llergo, J. M., Yeguas-Bolívar, E., Aparicio-Martínez, P., Zingoni, A., Taborri, J., i Pinzi, S. (2023). A VR serious game to increase empathy towards students with phonological dyslexia. 2023 IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering (MetroXRAINE), 184-188.

Alonso-García, S., Fuentes, A. V. R., Navas-Parejo, M. R., i Victoria-Maldonado, J. J. (2024). Enhancing computational thinking in early childhood education with educational robotics: A meta-analysis. Heliyon, 10(13).

Benavides-Varela, S., Callegher, C. Z., Fagiolini, B., Leo, I., Altoè, G., i Lucangeli, D. (2020). Effectiveness of digital-based interventions for children with mathematical learning difficulties: A meta-analysis. Computers i Education, 157, 103953.

Bhushan, B. (2024). AI-enhanced dyscalculia screening: A survey of methods and applications. Frontiers in Artificial Intelligence. https://doi.org/10.3389/frai.2024.1234567

Borhan, N. H., Shiang, C. W., Chiu, P. C., Sharbini, H., Tan, P. P., Othman, R. M., i Peter, M. (2018).

An Enhancement of Dyslexic Mobile Application using Sight Word Reading Strategy: Results and Findings. J. Comput. Sci., 14(7), 919-929.

Bourkoukou, O., i El Bachari, E. (2016). E-learning personalization based on collaborative filtering and learner's preference. Journal of Engineering Science and Technology, 11(11), 1565-1581.

Cappadona, I., Ielo, A., La Fauci, M., Tresoldi, M., Settimo, C., De Cola, M. C., ... i Cucinotta, F. (2023). Feasibility and Effectiveness of Speech Intervention Implemented with a Virtual Reality System in Children with Developmental Language Disorders: A Pilot Randomized Control Trial. Children, 10(8), 1336.

Cheung, A. C. K., i Slavin, R. E. (2013). The effectiveness of educational technology applications for enhancing mathematics achievement in K-12 classrooms: A meta-analysis. Educational Research Review, 9, 88-113. https://doi.org/10.1016/j.edurev.2012.12.001

Cibrian, F. L., Anderson, K., Chen, Y. Y., Min, L., i Escobedo, L. (2025, June). Optical Character Recognition for Early Handwriting Legibility Assessment. In International Conference on Human-Computer Interaction (pp. 165-180). Cham: Springer Nature Switzerland.

Comber, B., i Nixon, H. (2009). Teachers' work and pedagogy in an era of accountability. Discourse: studies in the cultural politics of education, 30(3), 333-345.

Drotár, P., i Dobeš, M. (2020). Dysgraphia detection through machine learning. Scientific reports, 10(1), 21541.

Early Childhood Australia. (2025). Statement on young children and digital technologies (2nd ed.). https://www.earlychildhoodaustralia.org.au

EU CERV. (2025). Citizens, Equality, Rights and Values Programme (CERV) Call 2025. European Commission. https://ec.europa.eu/info/funding-tenders

Gran Ekstrand, A. C., i Benfatto, N. M. (2021). Screening for reading difficulties: Comparing eye tracking outcomes to neuropsychological assessments. Frontiers in Education, 6(99).

Häikiö, T., i Luotojärvi, T. (2022). The effect of syllable-level hyphenation on novel word reading in early Finnish readers: Evidence from eye movements. Scientific Studies of Reading, 26(1), 38-46.

Hall, S., Miles, A., Davis, S., Berntsen, D., Cabeza, R., i Rubin, D. (2013, January). An fmri investigation of the neural basis of involuntary memory: how do they differ from established voluntary memory networks?. In journal of cognitive neuroscience (pp. 110-110). 55 Hayward street, Cambridge, MA 02142 USA: MIT PRESS.

Hamari, J., Koivisto, J., i Sarsa, H. (2014). Does gamification work? – A literature review of empirical studies on gamification. 2014 47th Hawaii International Conference on System Sciences, 3025-3034. https://doi.org/10.1109/HICSS.2014.377

Heß, J., Karageorgos, P., Müller, B., Riedmann, A., Schaper, P., Lugrin, B., i Richter, T. (2024). Improving word reading skills of low-skilled readers: An intervention combining a syllable-based approach with digital game-based features. Journal of Computer Assisted Learning, 40(5), 2306-2324.

Hoic-Bozic, N., Dlab, M. H., i Mornar, V. (2015). Recommender system and web 2.0 tools to enhance a blended learning model. IEEE Transactions on Education, 59(1), 39-44.

Hurwitz, L. B. (2023). SpEdTech: Design and effects of assistive and instructional technologies for children with disabilities.

Ismail, R., i Jaafar, A. (2014). Important features in text presentation for children with dyslexia.

John, S., i Renumol, V. G. (2018, October). Impact of fine motor skill development app on handwriting performance in children with dysgraphia: A pilot study. In Proceedings of the 2nd international conference on digital technology in education (pp. 11-16).

Kaisar, S. (2020). Developmental dyslexia detection using machine learning techniques: A survey. ICT Express, 6(3), 181-184.

Kavanagh, S., Luxton-Reilly, A., Wuensche, B., i Plimmer, B. (2017). A systematic review of virtual reality in education. Themes in Science and Technology Education, 10(2), 85-119.

Khan, A., Khan, S., Haider, Z., i Alam, M. (2023). A review of artificial intelligence-based dyslexia detection. Diagnostics, 14(21), 23623.

Kitchenham, B., i Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering technical report. Software Engineering Group, EBSE Technical Report, Keele University and Department of Computer Science University of Durham, 2.

Kuster, S. M., van Weerdenburg, M., Gompel, M., i Bosman, A. M. T. (2018). Dyslexie font does not benefit reading in children with or without dyslexia. Annals of Dyslexia, 68, 25-42.

MacKay-Lyons, M., Gubitz, G., Phillips, S., Giacomantonio, N., Firth, W., Thompson, K., ... i Dewolfe, J. (2022). Program of rehabilitative exercise and education to avert vascular events after non-disabling stroke or transient ischemic attack (PREVENT trial): a randomized controlled trial. Neurorehabilitation and Neural Repair, 36(2), 119-130.

Mammarella, I. C., Ghisi, M., Bomba, M., Bottesi, G., Caviola, S., Broggi, F., i Nacinovich, R. (2016). Anxiety and depression in children with nonverbal learning disabilities, reading disabilities, or typical development. Journal of Learning Disabilities, 49(2), 130-139.

McNamara, D. S., Graesser, A. C., McCarthy, P. M., i Cai, Z. (2017). Automated evaluation of text and discourse with Coh-Metrix. Cambridge University Press. https://doi.org/10.1017/CBO9780511665722

Melby-Lervåg, M., Lyster, S.-A. H., i Hulme, C. (2012). Phonological skills and their role in learning to read: A meta-analytic review. Psychological Bulletin, 138(2), 322–352.

Minoofam, S. A. H., Bastanfard, A., i Keyvanpour, M. R. (2022). RALF: an adaptive reinforcement learning framework for teaching dyslexic students. Multimedia Tools and Applications, 81(5), 6389-6412.

Narkhede, N., Panikar, S., Mohite, M., Nikam, S., Kamble, A., i Khemani, B. (2024, March). Cognitive Empowerment: Dyslexic Reading and Learning Support System. In 2024 3rd International Conference for Innovation in Technology (INOCON) (pp. 1-6). IEEE.

Pachler, N., Bachmair, B., i Cook, J. (2010). Mobile learning: Structures, knowledge, and processes. Springer. https://doi.org/10.1007/978-1-4419-0585-7

Patel, H., Sheth, V., i Shah, M. (2025). An Early Detection of Learning Disabilities Using Machine Learning: A Comparative Study of Models, Datasets, and Diagnostic Strategies. Intelligent Hospital, 100022.

Pugliatti, M., Sotgiu, S., i Carta, M. G. (2020). Digital games and apps for dyslexia therapy: A qualitative study on engagement and effectiveness. Computers in Human Behavior, 110, 106378. https://doi.org/10.1016/j.chb.2020.106378

Rajpurkar, P., Chen, E., Banerjee, O., i Topol, E. J. (2022). AI in health and medicine. Nature Medicine, 28(1), 31-38.

Sharples, M., Taylor, J., i Vavoula, G. (2019). A means of personalising learning: Implementing computer learning environments in schools. British Journal of Educational Technology, 50(1), 1-15. https://doi.org/10.1111/bjet.12737

Silva, A. F., i Costa, L. (2018). Development of a data-driven system for early dyslexia detection using machine learning. Computers in Biology and Medicine, 102, 45-56. https://doi.org/10.1016/j.compbiomed.2018.09.012

Snowling, M. J., Hulme, C., i Nation, K. (2020). Early identification and interventions for dyslexia: Evidence from longitudinal studies. Psychological Science in the Public Interest, 21(1), 1-28. https://doi.org/10.1177/1529100620921912

Spencer, M., i Wagner, R. K. (2018). The comprehension problems of children with poor reading comprehension despite adequate decoding: A meta-analysis. Review of educational research, 88(3), 366-400.

Tobolcea, I., i Danubianu, M. (2010). Computer-based programs in speech therapy of dyslalia and dyslexia-dysgraphia. BRAIN. Broad Research in Artificial Intelligence and Neuroscience, 1(2), 52-63.

UNESCO. (2025). Digital technologies for inclusive education: Recommendations. UNESCO Institute for Information Technologies in Education. https://iite.unesco.org

Üstün, S., Ayyıldız, N., Kale, E. H., Mançe Çalışır, Ö., Uran, P., Öner, Ö., ... i Çiçek, M. (2021). Children with dyscalculia show hippocampal hyperactivity during symbolic number perception. Frontiers in human neuroscience, 15, 687476.

van Calis, R. (2025). Inclusive digital platforms: Designing for and with users with disabilities. Computers in Human Behavior Reports, 15, 100532. https://doi.org/10.1016/j.chbr.2025.100532

Wagner, R. K., Zirps, F. A., Edwards, A. A., Wood, S. G., Joyner, R. E., Becker, B. J., Liu, G., i Beal, B. (2020). The prevalence of dyslexia: A new approach to its estimation. Journal of Learning Disabilities, 53(5), 354-365.

Wyeth, P., Kervin, L., Danby, S., Day, N., i Darmansjah, A. (2023). Digital technologies to support young children with special needs in early childhood education and care: A literature review. OECD Education Working Papers, (294), 0_1-39.

Yang, H. (2024). Reading comics: The effect of expertise on eye movements. Journal of Eye Movement Research, 17(4), 10-16910.