

## GERINCFERDÜLÉS SZÜRÉSE MESTERSÉGES INTELLIGENCIÁVAL

Dr. Gulyás Gábor György PhD, Vitarex Stúdió Kft.

Kiss Attila Csaba, Vitarex Stúdió Kft.

Morvay Balázs Tibor, Budapesti Műszaki és Gazdaságtudományi Egyetem, Villamosmérnöki és Informatikai Kar, Automatizálási és Alkalmazott Informatikai Tanszék

Béres Bálint, Budapesti Műszaki és Gazdaságtudományi Egyetem, Villamosmérnöki és Informatikai Kar, Automatizálási és Alkalmazott Informatikai Tanszék

Várfalvi Marianna védőnő, MVSZSZ elnök

Dr. Rákóczi Ildikó PhD, főiskolai docens DE Egészségtudományi Kar

Kovács Edit, MSc, védőnő, MVSZSZ titkár

Dr. Papp Csaba PhD, egyetemi docens, DAEFI igazgató

Dr. Zsuga Judit, egyetem tanár, DE Általános Orvostudományi Kar, Pszichiátriai Tanszék

---

### Absztrakt

A gerincferdülés és egyéb mozgásszervi rendellenességek korai felismerése kritikus jelentőségű a hatékony kezelés és az érintettek életminőségének javítása szempontjából. A technológia lehetővé teszi az iskolavédőnők számára, hogy pontosabb diagnózist állítsanak fel, és időben javaslatokat tegyenek a szükséges beavatkozásokra. Jelen tanulmányban bemutatjuk a védőnők szerepét az iskolai egészségügyi szűrésben, és a Tartás Pajtás eszközt, ami az iskolai védőnői szűrés támogatására jött létre. Több védőnő bevonásával teszteltük valós környezetben ezt az eszközt, és elemeztük annak lehetőségeit és korlátait. A tanulmányban bemutatott eredmények az IML4E nemzetközi projekt keretében valósultak meg.

**Kulcsszavak:** gerincferdülés, mesterséges intelligencia, gépi látás, korai diagnózis, iskolavédőnő

---

### Bevezetés

Napjainkban a gerincbetegségek egyre jelentősebb népegészségügyi kihívás elé állítják mind a köznevelési, mind az egészségügyi szektort. A nemzetközi adatok aggasztóak, Ausztriában például a házi gyermekorvosi ellátásban minden 100 orvos-beteg találkozásból 5,8 (95% konfidencia intervallum (KI): 5,6-6,1) mozgásszervi panaszok miatt történik<sup>1</sup>. Az Amerikai Ortopédsebészeti társaság (American Association of Orthopaedic Surgeons) kimutatása szerint a 19 évnél fiatalabb gyerekek körében a mozgásszervi rendellenességek éves incidenciája eléri a 9,6 milliót<sup>2</sup>. A scoliosis a leggyakoribb, az idiopátiás scoliosis a leggyakoribb gyermekkori mozgásszervi rendellenesség<sup>3</sup>, a gerinc háromdimenziós deformitását eredményezve. Az

Amerikai Oktatási Minisztérium (American Department of Education) szerint hatmillió amerikai iskolás szenved scoliosisban<sup>4</sup>, Angliában kamaszkori idiopátiás scoliosis (10°-ot meghaladó görbület) prevalenciája a 10-16 éves korosztályban 2-3%. Összegezve megállapítható, hogy napjainkban a gyermekkori gerincdeformitások aggasztó mértéket öltöttek<sup>5</sup>. Az eltérés korai felismerése elengedhetetlen a kezelés mielőbbi megkezdése, illetve a progresszió lassítása végett<sup>6</sup>. A kórkép magas prevalencia mellett aluldiagnosztizált, illetve előfordul, hogy a diagnózis felállítása pontatlan<sup>7</sup>.

Az elmúlt évtizedek során a mesterséges intelligencia, különösen a gépi látás területe robbanásszerű fejlődésen ment keresztül, köszönhetően a nagy számítási kapacitású gyorsítókártyák elterjedésének, a rendelkezésre

álló nagy adatmennyiség elérhetőségének és a mélytanulásban történő előretörésnek. A mélytanulás, amely az emberi agy neuronjainak működését modellezi le, lehetővé teszi számunkra, hogy megközelítsük vagy akár meghaladjuk az emberi értelem korlátait bizonyos feladatokban, mint például a képfelismerés, a beszédfeldolgozás, és a természetes nyelvfeldolgozás. Ezen technológiák alkalmazása már most is jelentős előrelépéseket hozott számos iparágban, mint az egészségügy, az autóipar és a pénzügyi szolgáltatások. Különösen figyelemre méltóak a speciális mélytanulási modellek, amelyek az emberi testtartás elemzésére szolgálnak, képesek valós időben azonosítani az emberi test kulcspontjait, és széleskörű alkalmazásuk van a sportelemzéstől a fizioterápiáig és a kiterjesztett valóságig.

Jelen publikációban bemutatott munka az IML4E nemzetközi projekt<sup>8</sup> (Industrial Machine Learning for Enterprises, magyarul Ipari Gépi Tanulás Vállalatoknak), ITEA Eureka klaszter felhívás keretén belül valósult meg, német és finn partnerek bevonásával, nemzetközi együttműködés keretében. Az IML4E projekt célja az Európai KKV-k támogatása a gépi tanulás fejlesztésbe való bevezetésében, különös tekintettel az MLOps feladatok ellátásának hatékonyságára. A Vitarex Stúdió Szolgáltató Kft., a Budapesti Műszaki és Gazdaságtudományi Egyetem és a Debreceni Egyetem 2019-2.1.1-EUREKA-2020-00016 azonosítószámom nyújtott be pályázatot és kapott támogatást a Nemzeti Kutatási, Fejlesztési és Innovációs Hivaltól. A konzorcium munkájának keretét egy közös esettanulmány elkészítése határozza meg, egy olyan eszköz készítése, ami a végponton jelenlévő gépi látás segítségével támogatja a védőnők munkáját a gerincferdülési rendellenességek szűrése során. Az esettanulmány kiterjed az eszköz kifejlesztésére, az azt kiszolgáló adatkezelő rendszernek, modell hibakereső és javító megoldásnak, illetve az új modell verzió kiadásához szükséges háttérinfrastruktúrának a kialakítására.

## Módszer

Az alábbi fejezetben áttekintjük az alkalmazott módszertant.

## Védőnői szűrés az iskolában

A védőnői szolgálat több, mint százéves múltra tekint vissza, míg az iskolai védőnői szolgálat pedig közel fél évszázados múlttal bír.

## Az iskolavédőnői ellátás történeti, jogszabályi háttere

A védőnői szolgálat 1915-ben jött létre Stefánia Szövetség néven, fő célja az anyák és csecsemők védelme volt. Klebelsberg Kunó (1875-1932) kultúr- és tudománypolitikus egyik legjelentősebb alkotása a népiskolai program volt. A szegedi gyermekklinika alapkövetésénél 1926. október 5.-én ezt mondta: „A magyar gyermeket tehát nemcsak tanítani kell, hanem egészségét, életét óvni talán még nagyobb nemzeti kötelesség”<sup>9,10</sup>. Dr. Johan Béla (1889-1983) orvos, egészségpolitikus, államtitkár vezetésével jött létre a Zöldkeresztes Egészségvédelmi Szolgálat 1927-ben. A zöldkeresztes védőnői szolgálat 1930-1944-ig működött, amelynek tevékenységi köre már kiterjedt az iskolás korosztályokra is. Ettől kezdve a nevelési-oktatási intézményekben a védőnők szervezeten vettek részt az iskola-egészségügyi ellátásban<sup>11,12</sup>. A két védőnői szolgálat a II. Világháborút követően egyesült. A gyógyító – megelőző ellátás egységébe épített iskolaorvosi rendszer bevezetésére országosan a 21/1975. EüM. számú egészségügyi miniszteri utasítás megjelenése után került sor. „A közoktatásról szóló 1993. évi LXXIX. törvény megerősítette az iskola-egészségügyi jogszabály kiadását, amelyben a 11. § (1) bekezdésének d. pontja kimondta, hogy a tanuló joga, hogy rendszeres egészségügyi felügyeletben és ellátásban részesüljön.” A védőnői ellátásra vonatkozó jogszabály az 5/1995. számú NM. rendelet, amelyet a területi védőnői ellátásról szóló 49/2004. (V.21.) ESzCsM rendelet követett. Ez tartalmazza a területi védőnők köznevelési intézményi feladatait is, ugyanakkor a nagyobb tanulói létszámot ellátó intézményekben az iskola-egészségügyi, iskolavédőnői rendszer működéséhez az iskola-egészségügyi ellátásról szóló 26/1997. (IX. 3.) NM rendelet ad szabályozást. A kötelező egészségbiztosítás keretében igénybe vehető betegségek megelőzését és korai felismerését szolgáló egészségügyi szolgáltatásokról és a szűrővizsgálatok igazolásáról szóló 51/1997. (XII.

18.) NM rendelet tartalmazza az életkorhoz kötött szűrővizsgálatokat.

### A védőnői szűrővizsgálatok

A 3-18 éves korosztály, valamint a 18 év feletti, középfokú nappali rendszerű iskolai oktatásban résztvevők az egészségügyi alapellátás keretében szervezett iskola-egészségügyi, megelőző jellegű ellátásban részesülnek. Az óvodás korosztály szűrővizsgálatait a területileg illetékes védőnő és háziorvos végzi. Az iskola-egészségügyi feladatok ellátásában több szakterület összehangoltan vesz részt: az iskolát ellátó orvos, a védőnő, a fogorvos, helyenként pszichológus. A védőnő iskola-egészségügyi feladatai teljesítésekor együttműködik az iskolát ellátó orvossal, a tantestülettel, a szülői- és tanulói közösségekkel, ugyanakkor fontos önálló feladatai is vannak.

Az iskola-egészségügyi ellátásról szóló rendelet 3. sz. melléklete tartalmazza a védőnő által önállóan ellátandó feladatokat, többek között szűrővizsgálatok végzését a páros évfolyamokon (2, 4, 6, 8, 10, 12):

- a) a testmagasság, testtömeg, a testi fejlettség és tápláltsági állapot hazai standardok szerinti értékelése, a nemi fejlődés értékelése,
- b) a pszichés, motoros, mentális, szociális fejlődés és magatartásproblémák feltárása,
- c) érzékszervek működésének vizsgálata (látás, kancsalság, hallás) és a színlátás vizsgálata a 6. évfolyamban,
- d) mozgásszervek vizsgálata: különös tekintettel a lábstatikai problémákra és a gerinc-rendellenességekre,
- e) vérnyomásmérés,
- f) pajzsmirigy tapintásos vizsgálata a 4. évfolyamtól.

Mindezek kiegészítéseként fontos feladat az elvégzett feladatok dokumentációjának vezetése<sup>13,14,15</sup>.

Mindezek lehetővé teszik, hogy a védőnők bevonásával valósuljon meg a tervezett eszköz éles tesztelése. A projekt szempontjából a mozgásszervi szűrővizsgálatokat céloztuk meg különös tekintettel a gerinc-rendellenességekre. Az egészségügyi, így a védőnői szakterületeknek is

célja a szükséges vizsgálatok tudományos, népegészségügyi és módszertani alátámasztása, a gyermekek és tanulók egészségi állapotának minél objektívebb adatokkal, információkkal való rögzítése, állapotkövetése. Ehhez járul hozzá a vizsgálatok elvégzéshez folyamatosan fejlődő diagnosztikai eszközpark, valamint a szükséges informatikai háttér biztosítása. Az iskola-egészségügyi ellátásban korábban történt ugyan kezdeményezés mérőeszköz használatára a gerinc vizsgálatához, azonban általános bevezetésre nem került sor. Az utóbbi években az informatika, a digitális technológia, az orvos- és egészségtudományok robbanásszerű fejlődése felvetette újra annak szükségességét, hogy rendelkezünk olyan mérőeszközzel, amely a mozgásszervek vizsgálatát, különösen a gerinc és testtartás rendellenességeit objektivizálná. Tekintettel arra, hogy a szűrővizsgálatokat több korcsoportban, két évente akár több szakember végzi el, a vizsgálati eredmények és azok összehasonlítása biztonságosabbá válhat egy erre a célra fejlesztett digitális mérési rendszer és applikáció fejlesztésével. Az így előállított adattartalom az egyes ellátásokban, szűrési műveletekben a résztvevők közötti szakmai kommunikációt is megalapozottabbá, a kapott eredményeket biztonságosabbá teszik.

### Védőnői vizsgálati módszertan

Az iskola-egészségügyi ellátás során páros „index osztályok” tanulóinak vizsgálata során a mozgásszervi szűrések körébe tartoznak a következők (BNO besorolás megjelöléssel): tartási rendellenesség R.29.3, scoliosis M.41, M.Scheuermann M.42.0, chondropathiák M.91-92, lúdtalp M.21.4.

A mozgásszervi vizsgálat menete, az alkalmazás vizsgálati beállításánál figyelembe veendő testhelyzetek, mozdulatok a következők, illetve a vizsgálat menetét a Dr. Aszmann Anna által szerkesztett iskola-egészségügyi kézikönyv útmutatásai alapján állítottuk össze<sup>16</sup>:

1. A tanuló háttal áll a vizsgálatot végző személynek. Felső testén csak fehérmű van (ha elváltozást észlelünk, azt is leveszi). A vizsgáló megnézi, hogyan tartja magát, elsősorban a törzs-

kar háromszöget, a lapocka eltérést, illetve a gerinc görbületeket figyeli.

2. A vizsgáló megkéri a tanulót, hogy emelje fel mindkét karját a plafon felé nyújtózza. Megtekinti, hogy a tanuló tudja-e a hátizomzattal kompenzálni az esetleg addig látott elváltozást.

3. A tanuló nyújtott karral előrehajol a földig. Itt is a hátizom erősségét vizsgálja a védőnő (tudja-e kompenzálni izomzattal az elváltozást), illetve a bordapúp meglétét figyeli.

4. A vizsgáló megkéri a tanulót, hogy egyenesedjen vissza és karját engedje le a törzse mellé lazán, majd, hogy forduljon el az egyik oldalra (lábbal is). Csukott szemmel emelje fel mindkét karját vízszintesen és tartsa úgy 30 másodpercig (Matthias-féle teszt).

Amennyiben testtartásában változás következik be, pl. hátra dől, vagy a medence előre billen, tartáshibára, tartásgyengeségre gyanakodhatunk.

5. A tanuló leengedi mindkét karját a törzse mellé és a vizsgáló felé szembe fordul, így láthatók a medence esetleges elváltozásai, illetve a mellkas deformitások is.

Tartási rendellenességeknek 4 típusa van (hIV): hanyag tartás, lapos-, domború- és nyerges hát. Ezek a rendellenes tartás kategóriába tartozó izomeredetű problémák, tartási elváltozások. (Ide sorolható még a fokozott lumbális lordosis, mely a deréktáji fájdalom leggyakoribb kiváltó oka lehet.) A gerincrendellenességek közé tartozik a scoliosis, amelynek két típusa van: funkcionális (izomerősítéssel kompenzálható), valamint strukturális (izom erősítéssel már nem kompenzálható). A Scheuermann betegség az ékcsigolyák elváltozását, a chondropathiák az ízületi porcok elváltozását jelenti. A lúdtalp a lábboltozat hosszanti vagy keresztirányú elváltozásával jár. A szűrés szempontjából a nagyfokú domború hát kelthet gyanút, amely az alsó háti szakaszon látható.

### **A gépi látás alkalmazásának lehetőségei**

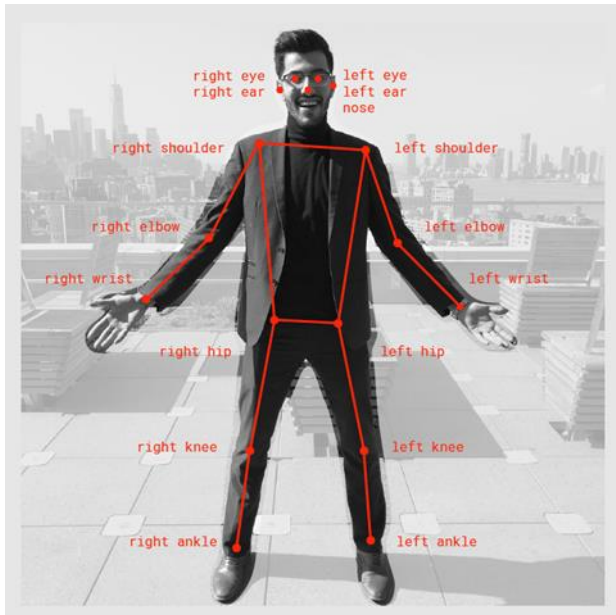
Az elmúlt évtizedekben a mesterséges intelligencia határozott fejlődésének lehettünk tanúi. A gépi látás a mesterséges intelligencia azon ágazata, amelybe a különféle intelligens kép- és videófeldolgozási eljárások tartoznak, mint például

a járművezetésben használt felismerő és elemző algoritmusok, az arcfelismerés vagy az orvosi képalkotás. Ezen a területen különösen robbanásszerű fejlődést tapasztalhatunk, többek között a nagy számítási kapacitású videokártyák elterjedésének, az interneten elérhető nagy adatnak és a mélytanulás fejlődésének<sup>17</sup> köszönhetően.

A mélytanulás lényegében az emberi agy működését utánozza, ahol az egyes neuronok összekapcsolódnak, és információkat továbbítanak. A mélytanulásban matematikai módszerekkel írjuk le a neuronhálózatok együttműködését, és ezzel tudjuk megközelítő módon utánozni (vagy egyes esetekben akár meghaladni) azokat a tevékenységeket, amelyekre korábban csak a természetes emberi intelligencia volt képes. Ezek a hálózatok, amelyek számos rétegből állnak, képesek összetett mintázatokat és összefüggéseket felfedezni nagy adathalmazokban, képekben, videókban. Ezek a módszerek különösen hatékonyak a képfelismerés, a beszédfeldolgozás, és a természetes nyelvfeldolgozás területén, ugyanis a mélytanulású neurális hálózatok képesek saját maguk tanulni és fejlődni egyszerűen úgy, hogy tanító adatokat mutatunk meg nekik. Az idő előrehaladtával így egyre pontosabb eredményeket képesek elérni, aminek általában a modell saját korlátjai szabnak határt. Ez a technológia jelentős potenciált rejt magában, és több iparágban, beleértve az egészségügyet, az autóipart és a pénzügyi szolgáltatásokat, már most is jelentős előre lépéseket eredményezett.

Vannak olyan speciális mélytanulási modellek, amelyek a testtartás elemzésére szolgálnak. Ezek a modellek képesek valós időben azonosítani és követni az emberi test kulcspontjait, mint például a végtagokat és az ízületeket. Ezek a modellek a mélytanulás rétegeit használva képesek a test különböző testpontjait pontosan felismerni. Egyes modellek komplex mozgássorozatok folytán és kihívást jelentő környezetben is képesek nagy pontossággal meghatározni ezeket. Alkalmazásuk széleskörű, kezdve a sportolók mozgásának elemzésétől a fizioterápiáig, valamint a számítógépes látás és a kiterjesztett valóság területén is kiemelkedően hasznosak. A lenti ábrán látható egy példa arra, hogy ezek a modellek

hogyan azonosítják be az egyes kulcspontokat, amely aztán a testtartás elemzésére felhasználható.



1. ábra. A PoseNet által megadott 17 kulcspont ábrázolása.<sup>18</sup>

A projekt indulásakor megvizsgáltuk az elérhető népszerűbb (és kellő támogatással, dokumentációval rendelkező) modelleket, amelyek közül a legkiemelkedőbb volt a PoseNet<sup>18</sup>, az OpenPose<sup>19</sup> és TRT\_Pose<sup>20</sup> (TensorRT Pose Estimation) rendszerek voltak. A PoseNet 17 testpontra ad egy kép alapján pozíció becslést. Főbb paramétereivel szabályozható a bemeneti kép feldolgozási felbontása (így aztán a végeredmény durvasága, pontossága) és a feldolgozás során alkalmazott mesterséges neurális rétegek száma (mivel mélytanulási hálóról van szó). Hasonlóan a PoseNet-hez, az OpenPose is kulcspontokat ad meg, azonban ennél a modellnél a kulcspontok száma is állítható 15, 18 és 25 között. Ezen túl szabályozható a feldolgozás pontossága is a felbontás állításával, illetve a magabiztossági küszöbérték meghatározásával. A TRT\_Pose rendszer szintén 18 kulcspontból álló testtartást határoz meg, s bár itt paramétereket nem választhatunk, használható a ResNet-18 és DenseNet121 modellekkel. Ezek a modellek alkalmasak lehetnek ún. edge computing megoldásokban, amikor a modellt nem egy dedikált számítógépen vagy a felhőben futtatják, hanem a végesszközön. Ez adatvédelmi

szempontból érzékeny felhasználási esetekben szokott fontos lenni.

## Eszközváltás

A projekt első feladata fejlesztési oldalról az volt, hogy döntést hozzunk, hogy a testtartás elemző számítógépes program milyen eszközön fusson. Az egyik kézenfekvő megoldás a mobilalkalmazás fejlesztése volt. A potenciális felhasználók döntő többsége már rendelkezik mobiltelefonnal és elmondható, hogy az IT iparág jelentős részét teszi ki a mobilfejlesztés. Ennek köszönhetően számos olyan technológia áll rendelkezésünkre, amely könnyűvé teszi a mobilfejlesztést, mesterséges intelligencia szempontjából is egyre több nagy teljesítményű, mobilra optimalizált MI modell és könyvtár jelenik meg.

Azonban mivel elég diverz a mobil eszközök piaca, számos operációs rendszerrel és verzióval, és egy mobilalkalmazás esetén fel kell készülni ennek ezeknek a támogatására, nehezen garantálható, hogy esetleges régebbi modellek rendelkeznek megfelelő erőforrásokkal a gerincvizsgálati program futtatásához. Továbbá, a projekt indulásakor, az akkori csúcsmobilokat leszámítva (amelyek Magyarországon egyáltalán nem is voltak elterjedtek), az elérhető modellek igen lassan futottak mobilon, jellemzően kb. egy vagy kevesebb FPS sebességgel.

A fejlesztett testtartás elemző programmal szemben támasztott elvárás, hogy hálózati kapcsolat nélkül is megfelelően tudjon működni, valamint, hogy lehetséges legyen a beépített gépi tanulási modell cseréje. Sőt, adatvédelmi szempontból az is kívánatos volt, hogy a kiértékelés közvetlenül az eszközön történjen. Ezekből a megszorításokból az következik, hogy a használt gépi tanulási modellt magán az eszközön kell tárolni és futtatni. Mobil készülékek esetén a nagyobb modellek futtatása, frissítése problémát jelent (pl. új alkalmazás verzió kiadása nélkül), így további lehetőségek után néztünk.

Alternatívaként az alkalmazást egy úgynevezett egykártyás számítógépre is fejleszthetjük, ami egyetlen nyomtatott áramkörti kártyából álló teljes számítógépet jelent. Ezek az eszközök kis méretűek, kis fogyasztásúak, viszonylag olcsók és

egy hagyományos számítógép funkcionalitásának nagy részével rendelkeznek. Ebben az esetben a fejlesztett alkalmazáson kívül a teljes operációs rendszert is testre szabhatjuk és az eltervezett működéshez optimalizálhatjuk. Hátránya viszont, hogy magát az eszközt, perifériáit, esetleges dobozolását (a „házát”) is biztosítani kell. Ezenkívül megoldást kell találni az eszköz fizikai védelmének biztosítására is.

A feladatra a legalkalmasabbnak az Nvidia Jetson Nano rendszere volt, amivel az rendelkezik GPU-szerű gépi tanulási műveleteket gyorsító hardverrel (amelyen 128 CUDA mag található), ez azonban a projekt első részében világszinten nem volt beszerezhető. Így egy kevésbé gyors, de népszerű hardverre esett a választásunk: az egykártyás Raspberry Pi 4-et választottuk az elérhetősége és költséghatékonysága miatt.

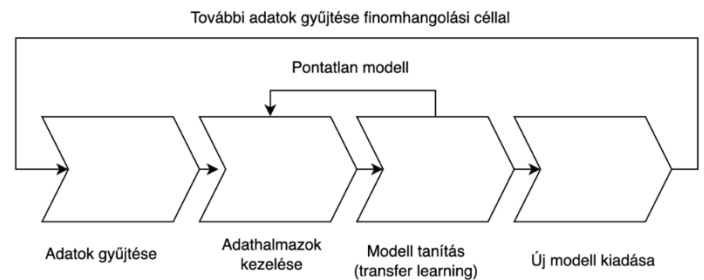
### Architektúra választás

A feladat során követelmény volt, hogy a kiválasztott modellt a beérkező adatok alapján tudjuk finomítani, és új verziók kiadásával a végfelhasználói élményt javítani tudjuk. Ehhez leginkább egy iteratív fejlesztési folyamatot követő architektúra illik, ami a mélytanulás területén gyakori. Az általunk választott főbb lépéseket a 2. ábrán lévő architektúra mutatja be. Az adatok gyűjtésének és kezelésének a megvalósítása a BME-é, a modell tanításnak és kiadásnak a megvalósítása a Vitarex feladata volt.

Az első lépésben az adatgyűjtés történik, ahol a képeket gyűjtjük össze és válogatjuk csoportokba különböző szempontok alapján a második lépésben, például hibatípusok szerint javító, illetve teszt adathalmazokba. Ez lehetővé teszi, hogy a modell tovább tanításával a rendszer pontosabban azonosítsa és korrigálja az egyes hibákat, mivel a képek csoportosítása elősegíti a specifikus jellemzők kiemelését a tanítási folyamat során.

A harmadik lépésben egy kiválasztott adathalmazt felhasználva tanítjuk tovább a modellt. A tanító algoritmusok a modell paramétereit finomhangolják, hogy a rendszer jobban kikerülje a hibákat és javítsa a teljesítményt. A tanítás eredményét validációs adathalmazon teszteljük,

ellenőrizve, hogy a modell általánosan is javult-e, illetve különösen a célzott hibatípusokra jobb eredményt tudtunk-e elérni. Új modell verziót akkor adunk ki, ha a modell teljesítménye megfelelőnek bizonyult. Ellenkező esetben szükséges újabb képek beszerzése, vagy további finomhangolás. Ez a fajta adaptív fejlesztési ciklus biztosítja, hogy a végső modell minél hatékonyabban teljesítsen a valós világban észlelt különféle helyzetekben.



2. ábra. Az általunk választott adatfeldolgozási architektúra. Az adatok gyűjtésének és kezelésének a megvalósítása a BME-é, a modell tanításnak és kiadásnak a megvalósítása a Vitarex feladata volt.

### Validálás

A validálás a Magyar Védőnők Szakmai Szövetségével együttműködésben történt. A validálásban résztvevő védőnők a Dél-pesti illetékességű kollegiális védőnői mentor javaslatára kerültek felkérésre. A validálásban összesen négy iskolavédőnő vett részt, a felmérések három budapesti kerület, 6 általános iskolájában zajlott. A védőnők felkészítését és az eszköz használatának betanítását a Vitarex Stúdió Kft. végezte. A tanulók bevonása a tanulók és szüleik tájékozott beleegyezését követően történt meg. A vizsgálatok az iskolák általános iskolák orvosi szobájában zajlottak. A védőnők több szempont szerint értékelték az eszköz használatát, a felhasználói élményt. Ezek a szempontok voltak: a helyiség alkalmassága, a fejlesztett eszköz működéséhez szükséges üzemállapot körülményei, az eszköz fizikai szempontjai, megbízhatósága.

## Eredmények

### A Tartás Pajtás eszköz bemutatása

A választott eszközre a Vitarex készítette el a Tartás Pajtás fantázianevű eszközt a gerincferdülés vizsgálására. A Tartás Pajtás egy egyedi kialakítású, kisméretű számítógép, amelynek saját tervezésű 3D nyomtatott háza van. Bekapcsolás után automatikusan indul el rajta a testtartás elemző program. Az eszköz segíti a védőnőt a testtartás vizsgálat lefolytatásában és a kamerája segítségével képes kielemezni, értékelni a tanulók testtartását, a készült képeket pedig el tudja menteni.

Az eszköz egy Raspberry Pi 4 (4gb vagy 8gb) egykártyás számítógépből, az ehhez megfelelő kamerából, 7" érintőképernyőből és egy USB-C típusú töltőből áll. A komponensek fizikai védelmét és integrációját egy 3D nyomtatott ház biztosítja, amelyet a Vitarex Stúdió Kft. tervezett. A ház úgy lett kialakítva, hogy a Raspberry Pi portjai szabadon maradtak, így az eszközre perifériák csatlakoztathatóak (külső képernyő, billentyűzet és egér), és így az eredmények mentése akár USB meghajtóra is történhet.



3. ábra: A Tartás Pajtás eszköz végső formájában. Szürke és fehér változatban készült a ház nyomtatása.

A testtartás elemző szoftver az MVSZSZ által meghatározott gerincvizsgálati protokoll alapján fut végig, ötlépéses vizsgálati eljárásrendet követve. A vizsgálat során a tanulók a képernyőn megjelenített specifikus instrukciók alapján helyezkednek el a kamera előtt, például „A tanuló felemeli mindkét karját, nyújtózva”. Ezt követően a védőnő képeket készít. A szoftver automatikusan

detektálja és megjeleníti a képeken az emberi alak kulcspontjait, lehetőséget adva a felhasználónak a pontok manuális korrekciójára. Az öt lépés során a rendszer folyamatosan kiszámítja és rögzíti a gerincferdülés esetleges eltérésének mértékét jelző adatokat. A vizsgálat befejeztével egy összegző felület jelenik meg, melyen a folyamat során készült képek és az analitikai eredmények egyaránt megjelennek.

A szoftveres megoldás több gépi tanulási modellt is alkalmaz. Az első modell képes az emberi alak kulcspontjainak koordinátáit meghatározni a képeken, míg további modellek a tanulók és a háttér, illetve a tanuló alakjának és kontúrjának szeparálására szolgálnak. Az ilyen típusú technológiák alkalmazása lehetővé teszi a vizsgálati folyamat automatizálását és a diagnosztikai pontosság növelését.

### Választott modell és szoftver architektúra

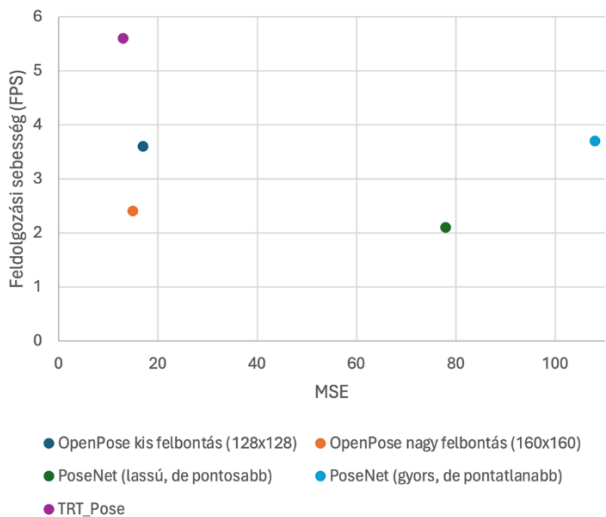
A modellek összehasonlítása során követett módszertanban két fő tényezőt vettünk alapul: a modellek sebességét és pontosságát. Hogy releváns környezetben kapjunk a sebességre vonatkozó mérési eredményeket, a méréseket Jetson Nano egykártyás számítógépen végeztük el. A pontosság meghatározására az átlagos négyzetes hibát számoltuk ki (Mean Squared Error, MSE). A modelleket különféle beállításokkal futtattuk (pl. bemeneti felbontás), hogy az általuk elérhető legszélesebb teljesítménytartományt el tudjuk érni.

A PoseNetnél néhány beállítás nem volt képes elegendő kulcspontot felismerni, ezért csak a legjobban működő konfigurációkat vettük figyelembe az összehasonlítás során. Az output stride nevű paraméterrel (lehetséges értékei: 8, 16, 32) a modell feldolgozási pontossága szabályozható, ahol a magasabb érték gyorsabb, de pontatlanabb feldolgozást eredményez. A multiplier paraméterrel (lehetséges értékei: 1.01, 1.0, 0.75 és 0.50) pedig a konvolúciós feldolgozási mélység szabályozható, ahol a magasabb érték pontosabb, de lassabb feldolgozáshoz vezet. Ennek megfelelően kétféle beállítást vizsgáltunk meg, gyors és pontatlan beállításnak az output

stride = 16 és multiplier = 0.5 értékekkel választottuk, az output stride = 32 és multiplier = 1.01 beállítások pedig a lassú, pontosabb futási eredményeket adják ki.

A többi rendszer modelljeinek szabályozására kevesebb paraméter áll rendelkezésre. Az OpenPose esetében a 25 kulcspontot számító modell bizonyult a leghatékonyabbnak. A tesztelésre kiválasztott Jetson Nano rendszeren néhány felbontásbeállításnál a teszt nem futott le a videómémória mérete miatt, ezért a 128x128 és a 160x160 felbontásokon teszteltük. A TRT\_Pose rendszer esetén a ResNet-18 modellel (18 réteg mély) használtuk, mert előzetes méréseink alapján ez adta a jobb eredményeket.

A 4. ábrán látható diagramon foglaljuk össze a modell összehasonlító mérési eredményeket. A legjobb eredményt a TRT\_Pose modell adta, ugyanis egyszerre a legnagyobb képfeldolgozási sebességet hozta, miközben a legkevesebb hibát produkálta. Az OpenPose modelljei is hasonlóan kevés hibával teljesítettek, azonban jelentősen kisebb képfeldolgozási sebesség mellett. A PoseNet mindkét kiértékelési szempont tekintetében elmaradt ezektől az eredményektől.



4. ábra. Különféle testtartás detektáló rendszerek modelljeinek összehasonlító méréseinek az eredménye. A legjobb eredményt a TRT\_Pose modell adta, ugyanis egyszerre a legnagyobb képfeldolgozási sebességet hozta, miközben a legkevesebb hibát produkálta<sup>21</sup>

A szoftverarchitektúra kialakításánál kiaknáztuk a teljes számítógépes platform által nyújtott

lehetőségeket, lehetővé téve egy integrált kliens-szerver architektúra megvalósítását egyetlen eszközön belül. Ebben a rendszerben a kliens komponens feladata a szerver felé irányuló kérések kezdeményezése, melyekre a szerver komplex számítások elvégzése után az eredménnyel válaszol. A kliens oldal ebben az esetben az alkalmazás felhasználói felületének megjelenítésére is szolgál, melynek implementációjához alapvető webes technológiákat alkalmaztunk, úgymint HTML, CSS és JavaScript. A szerver oldali implementációhoz a Python nyelvben írt Flask webkeretrendszert választottuk. Ennek egyszerűsége és sok előre beépített funkciója lehetővé teszi a gyors fejlesztést.

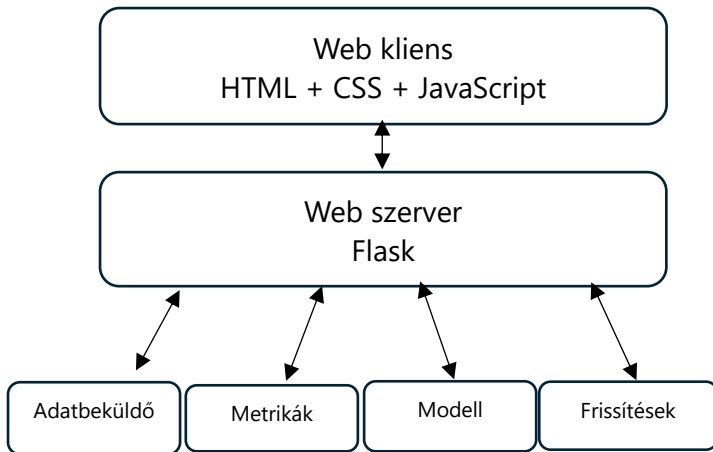
A szerver oldali logika moduláris struktúrát követ, ahol a különböző funkcionális egységeket elkülönítettük egymástól, ezáltal elősegítve a karbantarthatóságot és a kódbázis átláthatóságát. A modulokat a Flask-alapú központi komponens integrálja és használja.

A fontosabb modulok a következők:

- Adatbeküldő modul: felelős azért, hogy a vizsgálat során generált képeket anonimizált formában a kulcspontokkal együtt elküldje a modell további finomítására felhasználható formátumban.
- Metrika modul: az egyes vizsgálati lépésekhez kapcsolódó számításokat végzi, eredményül egy mutatószámot szolgáltatva, amely a testtartás helyességét számszerűsíti.
- Modell modul: gondoskodik a gépi tanulási modellek helyes működéséről és az esetleges modell frissítések menedzseléséről.
- Szoftverfrissítő modul: kezeli a szoftver frissítési folyamatát, biztosítva az alkalmazás naprakészességét.

Ezek a modulok együttesen alkotják a rendszer magját, biztosítva az alkalmazás zökkenőmentes működését és skálázhatóságát.





5. ábra: A testtartás elemző szoftver felépítése

Az eszköz bekapcsolásakor automatikusan elindul a webservert, valamint megnyílik egy webböngésző a megfelelő URL címmel, ahol látható az alkalmazás felhasználói felülete.

### Architektúra tapasztalatok

A tradicionális szoftverfejlesztés elengedhetetlen része a forráskód és hozzá tartozó állományok menedzselése, a szoftver teljes élettartama alatt, ami nagyrészt a forráskódok verziókezeléséből és tárolásukból áll. A szoftvereket többnyire csapatok írják, sokszor több vállalat emberei dolgoznak ugyanazokon a projekteken, vagy több független csapat dolgozik össze, akár több programozási nyelven, egyidőben. A párhuzamos fejlesztés, együttműködés és kódminőség fenntartása érdekében a verziókezelésen kívül szükség van olyan menedzsment elemekre is, mint pl. a kódellenőrzést elősegítő eszköz, automatizált tesztek, kód minőség ellenőrzés, automatikus hibakeresés stb.

A tradicionális szoftverek esetén ezekre a megoldandó problémákra a DevOps (Development Operations) terület kínál megoldásokat. A 2008 körül kialakult DevOps koncepció célja a szoftverfejlesztési és üzemeltetési folyamatok megkönnyítése és segítése. A mesterséges intelligenciát alkalmazó szoftverek menedzselése azonban talán még nehezebbnek mondható, hiszen a hagyományos összetevők mellett, a mesterséges intelligenciához kapcsolódó elemekből is áll, mint például a mentett modell, annak tanítási és tesztelési forráskódjai, a felhasznált adathalmazok, és ezek

különböző verziói. Ezen szoftverek életciklusának kezelése különböző kihívásokat jelent, és ennek következményeként sok ígéretes modell prototípus sosem jut el addig, hogy kiadják a felhasználók kezébe.

Kreuzberger és munkatársai<sup>22</sup> munkájukban összefoglalják a mesterséges intelligenciát tartalmazó projektek tulajdonságait. Munkájukban megállapítják, hogy a végfelhasználóhoz történő eljutás elmaradását legfőképp az okozza, hogy a szakmai közösség erőfeszítéseinek legnagyobb része a modellek továbbfejlesztésében merül ki, nem pedig azok skálázhatóságában és alkalmazhatóságában. A legfontosabb kérdés a mesterséges intelligenciával kapcsolatban a modell és az adatok verziókövetése. Egy ilyen projekt életciklusa alatt mind a modell, mind az adatok folyamatosan változhatnak.

Ahhoz, hogy támogassuk a reprodukálható kísérleteket, és romló teljesítmény esetén vissza tudjunk térni egy korábbi verzióhoz, ezeket az említett adatokat mind verziókezelni kell. Jelen munkánkban erre a célra a DVC (Data Version Control) eszközt használtuk. Ez egy nyílt forráskódú eszköz, mely lehetővé teszi akár nagyméretű fájlok hatékony verziókezelését is, melyeket a standard verziókövető rendszerek nem. Nagyméretű fájlok voltak például a modell tanítóadatai és a beérkezett, használatból eredő adatok, ezek mentését periodikusan végeztük el, amikor úgy véltük, elegendő változás történt az adatokban, ami indokolja egy új verzió létrehozását. Fontos továbbá megemlíteni, hogy a DVC hatékonyan illeszkedett a meglévő, Git alapú szoftver verziókezelő munkafolyamatunkhoz.

Az MLOps (Machine Learning Operations) egy átfogó megközelítés a gépi tanulási modellek életciklusának szisztematikus és hatékony kezelésére<sup>23</sup>. Ez a folyamat magában foglalja a modell tanítást, mely az adatokon alapuló prediktív képességek kialakítását célozza meg, valamint a tanított modell kiértékelését, mely a teljesítményének mélyreható vizsgálatát és validálását jelenti. Az MLOps keretrendszer továbbá biztosítja a modell szállítást, azaz a modell integrálását a végfelhasználói alkalmazásokba.

A projekt résztvevői az MLOps elveinek megfelelően megvalósítottak egy háttérinfrastruktúrát (a korábbi architektúrának megfelelően), amelynek segítségével hatékonyan kezelhető az alkalmazásba beépített kulcsfont elemző modell életciklusa. Ennek a rendszernek a megvalósítása során felhasználtuk az MLflow<sup>24</sup> nyílt forráskódú könyvtárat, amely eszközöket biztosít a modellek összehasonlítására, tárolására és szállítására. Ez rá tud épülni a DVC adatverzió kezelő rendszer működésére.

Kifejlesztettünk egy automatizált folyamatot a testtartás elemző programban alkalmazott kulcsfont-detektáló modell frissítésére. Ennek során a háttérinfrastruktúra segítségével újonnan létrehozott modell verziókat Github Release formájában tesszük közzé, ami egy interneten keresztül hozzáférhető tárolónak felel meg. Maga az alkalmazás rendszeres időnként összehasonlítja, hogy a jelenleg használt modell verziója megegyezik-e a legfrissebb elérhető verzióval. Amennyiben eltérést tapasztal, akkor az alkalmazás automatikusan letölti a frissebb modell verziót és lecseréli arra az aktuálisan használt modellt. Így a továbbiakban már az újabb modellt használja majd a program.

A teljes szoftverfrissítés is hasonló elven működik. Ilyenkor viszont a frissítés végén újraindul az eszköz, hogy a friss szoftver változat el tudjon indulni. Ezeknek a fejlesztésnek köszönhetően szerzett tapasztalatok jelentős tudásbázist jelentenek az MLOps területén. Ezeknek az ismereteknek a segítségével pedig a jövőben jóval könnyebben és hatékonyabban tudjuk majd elvégezni a gépi tanulási modellekhez kapcsolódó fejlesztési munkákat.

## **Validálás deskriptív eredményei**

### **A validálás körülményei**

Az eszközfejlesztés és validálás célja a tanulók iskola-egészségügyi ellátásában, hogy a mozgásszervi eltérések (gerinc és egyéb tartási rendellenességek) rendszeres, preventív célú szűrővizsgálata kiegészüljön és pontosabbá váljon az eddigi megtekintésen alapuló leletezéshez

képest. Az iskolavédőnö számára a cél az eszközös vizsgálat alkalmazása, az eszköz használatával, a vizsgált személyekkel való együttműködés tapasztalatainak rögzítése, értékelése. A validálási folyamathoz és annak értékeléséhez a projekt védőnöi szakértői és a fejlesztő csoport szakmai módszertani szempontrendszerrel állították össze.

A validálási folyamat elsődleges célcsoportja az iskolavédőnök voltak, másodlagos célcsoport 8-14 év közötti tanulók. A validálás helyszínéül a Budapest Főváros 6 nevelési és oktatási intézménye, iskola-egészségügyi rendelő, az időszaka a 2023. május hónap.

A validálás mind a 6 helyszínen és mind a 4 tesztelő védőnök által a tervezettek szerint szabályosan történt, a tesztelés mennyiségének célindikátora 10 tanuló/védőnök volt, összesen 39 fő tanuló vett tényleges részt a tesztelésben.

A program kipróbálásának előfeltételei magukban foglalják az iskolavédőnök munkáltatójának tájékoztatását és a részvételükhöz szükséges engedélyezési nyilatkozat beszerzését. Emellett szükséges az érintett nevelési-oktatási intézmény igazgatójának részletes tájékoztatása a programról, beleértve annak céljait, tartalmát, valamint az iskolavédőnök, a szülők és a tanulók ebben betöltött szerepét. Fontos az adatvédelmi és egészségügyi protokollokról szóló tájékoztatók elkészítése és a szülők beleegyező nyilatkozatának megszerzése is. A programban részt venni kívánó iskolavédőnöknek nyilatkozniuk kell részvételi szándékukról és megértésükről a készülék használatával és a tesztelési folyamattal kapcsolatban. A teszteléshez továbbá szükséges az érintett védőnök munkáltatóinak és az intézmények vezetőinek hivatalos tájékoztatása és együttműködésük elnyerése. A tanulók kiválasztása után részletes tájékoztatókat és beleegyező nyilatkozatokat kell kiadni a szülőknek és a tanulóknak, akiket szóbeli tájékoztatással is ellátnak a vizsgálat részleteiről, céljáról, az adatvédelemről és az adatok anonim továbbításáról. A kipróbálás maga az intézmény hivatalos helyiségében, önkéntes alapon, tanórán kívüli időben, beleegyező nyilatkozattal rendelkező tanulók bevonásával történik.

Szempontok		1. VN	2. VN	3. VN	4. VN
Üzemállapot körülményei	Internet beállítása	50%	0%	50%	100%
	Tápellátás	Rövidnek bizonyult a kábel, a készülék jelzett alacsony feszültség problémát			
	Kamera hűz-e	Nem	10-15°	Jobbra	Nem
	Fókusz megfelelő	Igen	Néha	Igen	Igen
	Homályos kép	Nem	Fényfüggő	Igen	Nem
Megvilágítás elégséges-e a működtetéshez?	Igen	fényfüggő	Igen	Igen	
Eszköz fizikai szemp.	Mérete megfelelő-e	Igen	Igen	Igen	Igen
	Tömege megfelelő-e	Igen	Igen	Igen	Igen
	Stabilitása megfelelő-e	Igen	Igen	Igen	Igen
	Funkciós elemek felismerhetősége	Igen	Asztali ikon	Igen	Igen
	Ki-be kapcsolás rendben működött	Igen	Igen	Igen	Igen
Környezet	Távolság a tanulótól	1,5m	Változó	2m	2m
	Használati magasság	1,3m	0,7m	0,8m	0,75m
	Magasság állítás hiányzott?	Minden résztvevő egyöntetűen hiányolta			
	Fényviszonyok a szobában	OK	Csak naps időben, vagy lámpával	OK	Lámpával
Felhasználói élmény	Felhasználói felület	-	Könnyen	Könnyen	Könnyen
	Sebesség (várakozás kirajzolásra)	Megfelelő	Fényfüggő	Megfelelő	Megfelelő
	Kulcspontok javíthatósága	Nem volt szükséges	Megfelelő	Megfelelő, de hozzáadás is kellene	Igen
	Összegző felület érthető, átláthatóság	Megfelelő	Megfelelő	Megfelelő	Megfelelő
	Mutatószám megjelenik a képeken	Igen	Igen	Igen	Néha elmaradt
Összegző felület értékelése	-	-	Néha lassú betöltés	Néha kimaradt	
Megbízhatóság	Kulcspontok helyesek voltak?	Változóak a tapasztalatok, többnyire igen, de néha kihagyta a program			
	Mutatószám megfelelő volt?	Változó	Nem mindig	Nem	Igen
	Alkalmazás hibát tapasztalt	Nem	Igen	Igen	Igen
	Javítható volt a hiba?	-	Igen	Igen	Igen
	Hibajelentés sikerült?	Igen	Igen	Nem	Igen

1. táblázat. A védőnői felmérés eredményeit deskriptív módon összefoglaló táblázat.

## Az eredmények bemutatása

Az eredmények feldolgozásához a következő, védőnői dokumentációból származó anonimizált tanulói adatokat gyűjtöttük (későbbi feldolgozáshoz): életkor; évfolyam; általános egészségi állapot: gerinc, testtartás, mozgásszervi jellemzők az anamnézisben, korábbi vizsgálatban; gyógytestnevelésben részesül-e; mozgásszervi terápiában részesül-e.

## Összegzés

Összességében elmondhatjuk, hogy a tesztelés végző védőnők reális képet és értékelést adtak a készülék technikai és szakmai használhatóságáról. Alapos, részletes műszaki és szakmai értékelést adtak, az eszközről, a védőnői vizsgálati módszertani elvárásoknak való megfeleléséről számszerűsített adatokkal alátámasztva. A tesztelésre rendelkezésre álló tanítási év kiválasztott időszakában a tervezett 40 tanulóból

valóban megvizsgált tanulók számát 39 fővel teljesítették.

A fejlesztett tanulói testtartást elemző készüléket további korrekciók, finomítások után az iskolavédőnői munkában hasznos eszköznek ítélik meg. A digitális adatjellege miatt a kapott vizsgálati adatsort javasolják a védőnői informatikai programokhoz, valamint az EESZT-hez csatlakoztatni a háziorvosi, házi gyermekorvosi, iskolaorvosi és ortopéd szakorvosi ellátások számára, további felhasználásra. Alkalmasnak találják mért adatokkal alátámasztva az alapszűrési megállapításokat a védőnői leletekhez csatolásra, és az orvosi, szakorvosi ellátás, további vizsgálathoz küldés alátámasztására, megalapozására.

A vizsgálati tesztelés további hozzáadott értékei a kapott észrevételek és verbális kommunikáció megállapításai alapján, a szülők és tanulók érdeklődését felkeltette, együttműködési készségüket növelte. A védőnői kompetenciák az eszközhasználattal bővültek, a védőnők szakmai megítélése, presztízse és szakmai önfejlődésük megítélése is pozitívan változott, hivatástudatuk erősödött. Fejlődött a vizsgálatban részt vett védőnők digitális eszközhasználati készsége, kreatív helyzetfelismerése és megoldókészsége. Jó együttműködő partnerei voltak a műszaki-informatikai fejlesztő teamnek.

## Megbeszélés

A fejlesztéssel kapcsolatos eredmények elhelyezése a nemzetközi irodalomban.

## A testtartás elemzés eredményei

Informatikai szempontból a kapott felhasználói visszajelzések és a modell korlátjainak elemzése több fejlesztési lehetőséget tárt fel. A felhasználók igényelték a hosszabb töltőkábel biztosítását, valamint az Eduroam hálózathoz való csatlakozás problémáinak orvoslását. A rossz fényviszonyokhoz való alkalmazkodás, a pendrive-ra mentés lehetősége és egy kikapcsoló gomb hozzáadása szintén érthető, kezelhetőséget segítő igényekként merültek fel. A felhasználók értékelnék a magasság állítási lehetőséget, bár

annak megvalósítása kihívást jelenthet. Felmerült továbbá a szállítás közbeni tárolás szükségessége, hogy az eszköz véletlen ne sérüljön meg ilyen esetben sem. Ehhez jó lenne az eszkozhöz egy állvány a pozicionáláshoz (a kábelezési kihívások megoldása mellett), illetve, ha a kamera (például fókusza) állítható lenne.

A visszajelzések szerint az eszköz működése elégtelen, ha nem áll rendelkezésre elegendő természetes fény (alagsori helyiségekben vagy későbbi időpontokban), vagy nincs megfelelően megvilágítva a vizsgált személy. Ezekben az esetekben rendszeresen előfordultak a kulcspont érzékelés hibái (pontatlanság, vagy hiányzó kulcspont), így ezt a lépést meg kellett ismételni és korrigálni kellett. Emellett további vizsgálatok tárgyát kell képeznie a gépi látási algoritmusok általános pontossága, illetve azok továbbfejlesztési lehetőségei.

## Értékelés orvosi oldalról

A jelen fejlesztés eredményeként a gépi tanulás és a mesterséges intelligencia eszköztárával egy fizikai végponton futó alkalmazás készült, ami rutin klinikai körülmények között használható és lehetővé teszi a testtartás rendellenességeinek pontos, kvantitatív elemzését és longitudinális követését.

A védőnők szubjektív megítélése az eszköz hasznosságáról többrétű volt. Felvetették, a lapockák csúcsainak hozzáadását a kulcspontokhoz, mert szerintük azon a területen jelentősebb eltérések vannak: szűréskor figyelik, hogy a lapocka csúcsai mennyire esnek egy vízszintes vonalba. Volt, aki szerint egyelőre szabad szememmel jobban látják az eltérést, mint az eszközzel, de ez lehet, hogy ez csak a kamerabeállítási problémák, és a gyakorlat hiánya miatt van. Más valaki szerint az elkészített felvételek után a kiértékelés nehezen volt használható, de megállapította, hogy a készülék használata a dokumentálást segítheti, mert visszakereshető lesz az adott tanulóról készített felvétel. Egy másik védőnő szerint a fizikális vizsgálat eredményei megfeleltek az eszköz eredményeivel kapott eredményeknek, pontosan látta a testtartás hibáit, sőt a két vizsgálati forma

együtt nagyon pontos eredményt ad. Ez a vizsgáló felvetette, hogy az orthopéd szakorvosi diagnózist is segíthetné a mesterséges intelligenciával augmentált kép alapú dokumentáció. Az eszköznek a jövőbeli helyét, hasznosságát (a hibák elhárítása után) egy védőnő se kérdőjelezte meg, amennyiben az eszköz használata gyorsabbá válik, így nem lassítja a vizsgálatokat. A felület intuitív, egyszerű használatáról valamennyien egyöntetűen pozitívan nyilatkoztak.

A négy védőnőből három javasolja általános szűrővizsgálati segédeszközként az eszköz általános használatát attól függően, mennyi időt vesz igénybe használata, illetve hosszabb távon hogyan tudják a teremben elhelyezni, úgy, ne akadályozza többi eszközös vizsgálatot (látásvizsgálat) a védőnői munka során. Végezetül az egészségügyi ellátás folyamatosságának biztosítása végett megfontolandó a rendszer által generált adatok integrálása az EESZT-be. Ezáltal a képi diagnosztikai dokumentumok elérhetővé válnak a szakellátásban.

### Limitációk

Az alkalmazás lehetséges társadalmi hatásának legnagyobb korlátját a terjeszthetősége jelenti. Bár egy Raspberry Pi alapú eszköz egy rendkívül rugalmas és költséghatékony megoldás lehet prototípusok készítésére és speciális feladatokra, a széles körű elterjedését akadályozhatja a beszerzési költsége. Ezzel szemben, ha ugyanazt az alkalmazást mobiltelefonokra fejlesztik ki, az jelentősen növelheti a terjeszthetőséget és elérhetőséget, hiszen mobiltelefonja szinte a társadalom valamennyi tagjának van, lehetővé téve, hogy az alkalmazás sokkal több emberhez jusson el könnyebben és gyorsabban.

Az egyes telefonok teljesítménye jelentősen eltérhet, és egy jelentős hányaduk ma sem alkalmas olyan alkalmazások futtatására, amelyek gépi tanulást alkalmaznak. Ezért az ilyen, számításnehéz funkciókat – megfelelő adatvédelmi és biztonsági technikai intézkedések bevonásával – delegálni lehetne webes vagy felhős alkalmazásokba. Ennek további előnye lenne, hogy az alkalmazás frissítése nélkül ki lehetne adni új gépi tanulási modell verziókat. Hátránya azonban, hogy a képeknek el kell hagyniuk a kiértékeléshez

a készüléket, s ezért is lennének szükségesek az adatvédelmi intézkedések.

A testtartás és testmozgás vizsgálatának terén jelenleg is fontos előrehaladások vannak a minél pontosabb csontváz alapú modellezés rekonstruálásában<sup>25</sup>. A projekt során alkalmazott modellekkel lehetőség van mind a képeken jelenlevő emberek testtartásának modellezésére egy, illetve több szereplő esetén, valamint videó alapú elemzésre is, ahol lehetséges az egyes testrészekhez rendelt kulcspontok mozgás követésével is, amely komplexebb vizsgálati formák megvalósításának is nyújthat tere. Ezen kívül csontváz alapú vizsgálatnál fejlesztések folynak, hogy kétdimenziós kép alapján lehetőség legyen háromdimenziós testhelyzet megállapítására is<sup>26,27</sup>. Továbbá, a képalapú vizsgálatokban jelentős fejlesztések folynak a testhelyzet alapú osztályozás terén, ahol a modellünk képes a helyes, illetve helytelen testtartások automatikus osztályozására<sup>28</sup>.

A csontváz alapú modellezés azonban nem megfelelő fiziológiai vizsgálatok megvalósításához, ahol a teljes test megfigyelése szükséges, jelenleg is fejlesztések folynak az olyan modellek megalkotásában, amely teljes testi háromdimenziós modell megalkotására képes<sup>29</sup>. Ebben a modell a teljes testhez generálódik, amely segítségével az egyes testrészek helyzetet, illetve mozgását teljes kiterjedésükben meg lehet valósítani. Ez alapján már nem csak a testtartás és -mozgás modellezhető, hanem lehetőség nyílik, a különböző környezettel való interakciók fizikai modellezésre is<sup>30</sup>.

Az eszköz orvosi gyakorlatban való elterjedésének limitációja lehet, ha limitált a hozzáférés az eszköz által generált adatokhoz, illetve az eszközök kezelőfelülete nem elég felhasználóbarát.

### Konklúzió

Az elmúlt években a gerincferdülés és más mozgásszervi rendellenességek korai felismerése és kezelése érdekében jelentős fejlődés történt a mesterséges intelligencia (MI) és a gépi látás alkalmazásában. Az IML4E projekt keretében fejlesztett Tartás Pajtás eszköz gépi tanulási algoritmusokkal képes segíteni az iskolavédőnők

munkáját a gerincferdülés szűrése során, illetve a szűrések dokumentálásában. Összefoglalva, a Tartás Pajtás demonstrálja a mesterséges intelligencia és gépi látás alkalmazásának potenciálját a gyermekkori gerincferdülés és más mozgásszervi rendellenességek korai felismerésében. Mindazonáltal felhívja a figyelmet a gépi látás kihívásaira is, mint például az eszköz állíthatóságának, a modellek pontosításának, illetve az alkalmazott gépi látási algoritmusok pontosságának szükségessége; mindezeket a Tartás Pajtás következő verziójában érdemes lesz javítani. A projekt eredményei pozitív hatást gyakorolhatnak a korai diagnózisra, a kezelés hatékonyságára és a gyermekek életminőségére. Bár ehhez további fejlesztések szükségesek, a további kutatások és fejlesztések várhatóan tovább bővítik ezeket a lehetőségeket, elősegítve ezzel a technológia széles körű alkalmazását az egészségügyi ellátásban.

## IRODALOM

1. Henschke N, Harrison C, McKay D, et al. *Musculoskeletal conditions in children and adolescents managed in Australian primary care.* *BMC Musculoskelet Disord.* 2014;15:164.
2. American Academy of Orthopaedic Surgeons. *Children and Musculoskeletal Health. Position Statement 1170.* 2011. Available from: <https://www.aaos.org/uploadedFiles/1170%20Children%20and%20Musculoskeletal%20Health.pdf>
3. Vajickova J. *Effect of dynamic sitting position in school.* *Rehabilitacia.* 2005;42(3):155-60.
4. Sudo H, Kokabu T, Abe Y, et al. *Automated noninvasive detection of idiopathic scoliosis in children and adolescents: A principle validation study.* *Sci Rep.* 2018;8(1):17714.
5. California Department of Education Sacramento. *Standards for scoliosis screening in California public school.* 2007. Available from: <https://www.cde.ca.gov/ls/he/hn/document/s/scoliosisscreening.pdf>
6. Mitova S. *Frequency and prevalence of postural disorders and spinal deformities in children in primary school.* *Res Kinesiol.* 2015;43(1):21-4.
7. Skrabanek P, McCormick J. *Follies and Fallacies in Medicine.* 3rd ed. Eastbourne (UK): Tarragon Press; 1998. p. 68. Available from: <https://www.pdfdrive.com/follies-and-fallacies-in-medicine-e19468111.html>
8. *Industrial Grade Machine Learning for Enterprises.* Available from: <https://iml4e.org>
9. Lukánszky B, Németh A. *Neveléstörténet.* Budapest: Nemzeti Tankönyvkiadó Rt.; 1996.
10. Klebelsberg Kúnó élete és munkássága. Available from: <https://edu.ek.szte.hu/klebelsberg-kuno-elete-es-munkassaga/klebelsberg-mint-allamferfi-es-kulturpolitikus/>
11. Szeles V, Lukáts Á, Székely L. *A magyar iskola-egészségügy története a jogforrások tükrében.* *Budapesti Közegészségügy.* 1998;30(3).
12. Szelesné Kupi V. *Az iskola-egészségügy jogforrásai I.-II. Egészségnevelés.* 1996;37.
13. 26/1997. (IX. 3.) NM rendelet az iskola-egészségügyi ellátásról. Available from: <https://net.jogtar.hu/jogszabaly?docid=99700026.nm>
14. 49/2004. (V. 21.) ESzCsM rendelet a területi védőnői ellátásról. Available from: <https://net.jogtar.hu/jogszabaly?docid=a0400049.esc>
15. 51/1997. (XII. 18.) NM rendelet a kötelező egészségbiztosítás keretében igénybe vehető betegségek megelőzését és korai felismerését szolgáló egészségügyi szolgáltatásokról és a szűrővizsgálatok igazolásáról. Available from: <https://net.jogtar.hu/jogszabaly?docid=99700051.nm>
16. Aszmann A, Bihari Á, Vekerdy Zs, et al. *Egészségvédelem a közoktatásban.* 2005.
17. Krizhevsky A, Sutskever I, Hinton GE. *ImageNet Classification with Deep Convolutional Neural Networks.* 2012.
18. *Real-time Human Pose Estimation in the Browser with TensorFlow.js.* Available from: <https://blog.tensorflow.org/2018/05/real-time-human-pose-estimation-in.html>
19. OpenPose. Available from: <https://github.com/CMU-Perceptual-Computing-Lab/openpose>
20. trt\_pose. Available from: [https://github.com/NVIDIA-AI-IOT/trt\\_pose](https://github.com/NVIDIA-AI-IOT/trt_pose)
21. Várhidi B. *Testtartás-elemző eszköz készítése deep learning alapon.* Szakdolgozat. 2020.
22. Kreuzberger D, Kühl N, Hirschl S. *Machine learning operations (mlops): Overview, definition, and architecture.* *IEEE Access.* 2023.
23. *MLOps: Continuous delivery and automation pipelines in machine learning.* Available from: <https://cloud.google.com/architecture/mlops-continuous-delivery-and-automation-pipelines-in-machine-learning>
24. MLFlow. Available from: <https://mlflow.org/>

25. Zheng C, Wu W, Chen C, et al. *Deep Learning-based Human Pose Estimation: A Survey*. *ACM Comput Surv*. 2023;56(1):11.
26. Tripathi S, Müller L, Huang CHP, et al. *3D human pose estimation via intuitive physics*. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023. p. 4713-25.
27. Gong J, Foo LG, Fan Z, et al. *Diffpose: Toward more reliable 3d pose estimation*. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023. p. 13041-51.
28. Yang S, Feng Z, Wang Z, et al. *Detecting and grouping keypoints for i-person pose estimation using instance-aware attention*. *Pattern Recognit*. 2023;136:109232.
29. Dai Y, Lin Y, Lin X, et al. *Sloper4d: A scene-aware dataset for global 4d human pose estimation in urban environments*. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023. p. 682-92.
30. Stern L, Roshan Fekr A. *In-Bed Posture Classification Using Deep Neural Network*. *Sensors*. 2023;23(5):2430.