

Természetesnyelv-feldolgozás alkalmazása a betegelégedettség vizsgálatában

Application of natural language processing in the analysis of patient satisfaction

Czinkóczi Sándor¹

¹Dunaújvárosi Egyetem Társadalomtudományi Intézet

✉ czinkoczi@uniduna.hu

A betegek elégedettsége az egészségügyi szolgáltatások kiemelt minőségparamétere és egyben stratégiai célja is, amely a betegek elvárásai és a ténylegesen tapasztalt ellátás közötti különbséget tükrözi. Mérési módszertanként jellemzően betegelégedettségi kérdőíveket alkalmaznak az egyes egészségügyi intézmények a gyors adatfelvétel és statisztikai kiértékelés, valamint a tendenciakövetés érdekében. Azonban a kérdőíves felmérésnek számos korlátja van, ilyen például az alacsony válaszadási arány, torzítások, a valós idejű visszacsatolás hiánya, az elégedettségi skála nem kellő differenciáltsága. Napjaink robbanásszerűen fejlődő IT-technológiája, a mesterséges intelligencia (Artificial Intelligence, AI) már képes a természetes nyelvi feldolgozás (Natural Language Process, NLP) algoritmusával a kérdőívek Likert-skáláján mért betegelégedettségénél sokkal mélyebb elemzésre is. A természetes nyelvi feldolgozás lehetővé teszi a szabad szöveges betegvélemények elemzését. Ez a betegelégedettségi vizsgálatban kiemelt jelentőségű, tekintettel arra, hogy a betegek gyakran részletesebb és őszintébb visszajelzést adnak szöveges formában, mint strukturált kérdőívekben. Jelen tanulmány célja a természetes nyelvi feldolgozás módszertanának és gyakorlati alkalmazhatóságának bemutatása a betegelégedettségi vizsgálatban.

Kulcsszavak: betegelégedettség, természetes nyelvi feldolgozás, mesterséges intelligencia

Patient satisfaction represents a key quality indicator and strategic objective of healthcare services, reflecting the discrepancy between patients' expectations and the care they actually experience. As a measurement methodology, healthcare institutions typically employ patient satisfaction questionnaires to enable rapid data collection, statistical evaluation, and longitudinal trend analysis. However, questionnaire-based surveys present several limitations, including low response rates, various forms of bias, lack of real-time feedback, and insufficient granularity of satisfaction scales.

With the rapid advancement of contemporary information technologies, Artificial Intelligence (AI) – particularly Natural Language Processing (NLP) – now enables substantially deeper analysis than what can be achieved through Likert-scale questionnaire data alone. NLP techniques allow the analysis of free-text patient

feedback, which is of special significance in patient satisfaction research, given that patients frequently provide more detailed and candid insights in narrative responses than in structured survey instruments.

The aim of the present study is to demonstrate the methodological foundations and practical applicability of Natural Language Processing in the assessment of patient satisfaction.

Keywords: patient satisfaction, natural language processing, artificial intelligence

BEVEZETÉS

Egy egészségügyi intézmény szolgáltatásainak minőségét legjobban kifejező mutató és egyben legfontosabb stratégiai célja a betegek/páciensek elégedettsége. A szakirodalomban több definíciót is találunk a betegelégedettség meghatározására. A Linder-Pelz-féle definíció szerint a betegelégedettség a pozitív értékelések kombinációja az egészségügyi ellátás különböző aspektusaival kapcsolatban (például vizsgálatok, kezelés folyamata, ellátási terv vagy az egész egészségügyi rendszer) [1]. Pascoe szerint a betegelégedettség a beteg reakciója az egészségügyi ellátás jelentős aspektusaira, beleértve a kontextust, a folyamatot és az eredményt, amely magában foglalja az egyéni elvárásokhoz való viszonyítást és az érzelmi reakciót [2]. Batbaatar megközelítésében a betegelégedettség az egészségügyi szolgáltatásoknak a betegek szükségleteihez, elvárásaihoz és preferenciáihoz való megfelelését jelenti. A betegelégedettség az egészségügyi ellátás értékelésének eredménye, amely azon kognitív folyamaton alapul, hogy a beteg saját személyes szempontjait összeveti a ténylegesen igénybe vett ellátással [3]. Manzoor szerint a betegelégedettség annak mértékét fejezi ki, hogy a beteg milyen fokban elégedett az egészségügyi szolgáltatótól kapott ellátással. A betegelégedettség az egészségügyi intézmények teljesítményének és működési eredményességének egyik meghatározó indikátora [4].

A betegközpontú szemlélet és a betegelégedettség folyamatos növelése ma már valamennyi egészségügyi szolgáltató számára működési evidencia, kitűzött stratégiai cél. Megvalósításuk alapfeltétele, hogy rendelkezésre állnak-e a betegek visszajelzéseiből eredő, megfelelő minőségű és valid információk. Ennek hiányában nincs mód olyan intézkedések, beavatkozások tervezésére és végrehajtására,

amelyek érdemi hatást lennének képesek gyakorolni az egészségügyi szolgáltatási folyamatok minőségére és ezen keresztül a betegek elégedettségére.

Kulcskérdés, hogy milyen módon lehet a betegvisszajelzésekben kinyerni mindazon rejtett (tacit) információkat, amelyeket a páciens explicit módon nem definiált, de a szöveges vélemény mögötti attitűdből kiolvashatók, és a betegelégedettségrel kapcsolatos kérdésekre adott válaszokat befolyásolják. Tekintettel arra, hogy a több százezer szabad szövegű betegmegjegyzés manuális elemzése rendkívül erőforrásigényes feladat lenne, nagy segítség a mesterséges intelligencia természetesnyelv-feldolgozási technológiája. Jellemző alkalmazási területei: 1. témaosztályozás (hozzászólások témák szerinti osztályozása); 2. érzelmi elemzés (a hozzászólásban kifejezett érzelmek polaritásának kódolása, pozitív/negatív); 3. témamodellezés (annak meghatározása, hogy a hozzászólások tartalmazznak-e előre nem látható témákat).

A TERMÉSZETESNYELV-FELDOLGOZÁS AI-TECHNOLÓGIA A BETEGELÉGEDETTSÉGI VIZSGÁLATOKBAN

A természetesnyelv-feldolgozás (Natural Language Processing, NLP) a mesterséges intelligencia (Artificial Intelligence, AI) egyik legösszetettebb és legdinamikusabban fejlődő területe. Célja, hogy a számítógépek képesek legyenek az emberi nyelv megértésére, értelmezésére és előállítására. Az emberi nyelv nem csupán strukturált jelrendszer, hanem mélyen kontextusfüggő, kulturálisan beágyazott és gyakran többértelmű kommunikációs forma. Egy szó jelentése függhet a mondattól, a beszélő szándékától, a társadalmi kontextustól, sőt még a hanglejtéstől vagy hangsúlytól is. Ezért az NLP egyrészt technikai kihívás, másrészt interdiszciplináris terület is, amely a számítástechnikán túl a nyelvészet, a kognitív tudomány (pszichológia, idegtudomány, nyelvészet, filozófia) és a statisztika eredményeire is támaszkodik.

Az NLP alapvetően két fő alrendszerre bontható: a természetes nyelv megértésére (Natural Language Understanding, NLU) és a természetes nyelv generálására (Natural Language Generation, NLG). Az NLU célja, hogy a gép képes legyen értelmezni a szöveg jelentését, felismerni a szándékot, az entitásokat és a kontextust. Ezzel szemben az NLG arra fókuszál, hogy a gép képes legyen az emberéhez hasonló, koherens és értelmes szöveget előállítani. A két terület szorosan összefügg, és a modern rendszerek gyakran mindkettőt integrálják, például egy chatbot esetében, amely először megérti a felhasználó kérdését, majd választ generál rá [5].

Egy szakirodalmi áttekintő tanulmány [6] 1969 és 2019 között publikált 60 kutatási dokumentumot vizsgált a betegélményt alakító tényezők megértése érdekében. A szerző arra a következtetésre jutott, hogy a betegek elégedettsége összetett téma, és további kutatásokra van szükség annak megértéséhez, hogy a beteg gondolatai és érzései hogyan befolyásolják az elégedettségét.

Brown és munkatársai kidolgozták a Klinikai Teljesítmény-visszajelzés Intervenciók Elméletét [7] annak érdekében, hogy elmagyarázzák, hogyan működik a betegvisszajelzés, és mi teszi sikeressé. A szerzők megállapították, hogy a visszajelzési folyamat magában foglalja a célkitűzést, az adatgyűjtést, a visszajelzés átadását, az értelmezést, az elfogadást és a viselkedés megváltoztatását.

Gupta és szerzőtársai tanulmányukban [8] a betegek visszajelzéseiben szereplő érzelemosztályozás kutatási terét elemezték. Megállapításuk szerint az érzelemosztályozási módszerek megbízhatósága és teljesítménye a gyűjtött visszajelzések minőségétől, pontosságától és formátumától függ. Ezért kulcsfontosságú a betegvisszajelzések adatgyűjtési mechanizmusainak tanulmányozása. A különböző bemeneti formák, például a felmérések, interjúk, kérdőívek és a közösségimédia-tartalmak különböző adattípusokat eredményeznek, amelyek eltérő előfeldolgozási és modellezési stratégiákat igényelnek.

A betegvisszajelzések mögötti érzelmek besorolására a kutatók jellemzően egy jól strukturált munkafolyamatot alkalmaznak, beépítve mind az emberi annotációt, mind a mesterséges intelligenciát. Ebben a folyamatban a mesterséges intelligencia alapvetően természetesnyelvi feldolgozást, gépi tanulást és mélytanulási technológiákat foglal magában.

A folyamat az alábbi lépésekből áll:

1. Betegvisszajelzések – különféle mechanizmusokon keresztül – összegyűjtése és adatbázisban való tárolása.
2. Előfeldolgozás végrehajtása a szöveges adatok szabványosítása érdekében, amely lehet
 - tokenizáció: a ChatGPT és hasonló modellek a szöveget nem betűnként, hanem tokenekre bontva dolgozzák fel. Egy token lehet egy szó, egy szórészlet vagy akár egy írásjel is;
 - szótagolás;
 - lemmatizáció: olyan nyelvtechnológiai eljárás, amelynek során egy szó szótári alakját (lemmáját) határozzuk meg. A folyamat során a ragozott, toldalékolt vagy képzett szóalakokat visszavezetjük az alapalakjukra, vagyis arra a formára, amely a szótárakban szerepel;
 - kisbetűs írás stb.
3. A szabványosított és feldolgozott szöveges adatok ezután két fő folyamaton mennek keresztül annak érdekében, hogy címkék vagy érzelmek generálódjanak az adatokhoz:
 - Hagyományos gépi tanulási algoritmusok: felügyelt, felügyelet nélküli, félig felügyelt.
 - A nagy nyelvi modellek közvetlenül konvertálják a szöveges adatokat, és hatékonyan generálják az érzelmeket.
4. A címkéket az annotátorok – olyan személyek (vagy ritkábban programok), akik adatokat (leggyakrabban szövegeket, képeket vagy hanganyagokat) címkékkel, megjegyzésekkel látják el, hogy azok feldolgozhatók legyenek például gépi tanulási rendszerek számára – ezután manuálisan ellenőrzik az Inter Annotator Agreement (IAA, annotátorok közötti egyetértés) segítségével. Azt mérik,

hogy több annotátor mennyire következetesen, egymással egyetértve címkézi ugyanazt az adatot, ezzel biztosítva az egységességet. Amikor emberek címkéznek adatokat (pl. egy megjegyzést „pozitívnak”, „semlegesnek” vagy „negatívnak” jelölnek), döntéseik eltérőek lehetnek a személyes értelmezés miatt. Az IAA azt méri, hogy több emberi címkéző mennyire következetesen ért egyet az adatok címkézésekor vagy osztályozásakor. A végső emberi ellenőrzés biztosítja a pontos érzelelemzést [8].

A gépi tanulás és a mesterséges intelligencia alkalmazása az egészségügyi intézményeknél nem újkeletű, azonban ezek a technológiák jellemzően még nem vesznek részt közvetlenül a betegellátásban és a kommunikációban. Az egyes funkcióikat nagyrészt szakértői felhasználásra tartják fenn a jelfeldolgozás, a prediktív analitika, az orvosi képelemzés és az orvostechnikai eszközök innovációi terén.

Khanbhai és munkatársai [9] tanulmányukban rámutattak, hogy a természetesnyelv-feldolgozás, valamint a gépi tanulás kifejezetten alkalmas a nem strukturált betegviszajelzések (pl. szabad szöveges válaszok) elemzésére.

A tanulmányban 19 darab 2000. január és 2019. december között íródott publikációt azonosítottak, amelyek különböző forrásokból (pl. online értékelések, strukturált kérdőívek) származó szöveges adatokat dolgoztak fel AI-technológiákkal. A kutatás szerint a szöveges módon rögzített adatok „gazdag információt” hordoznak a betegtapasztalatokról. Mindemellett az AI-alapú elemzések jelentősen képesek a feldolgozási és értelmezési módszerek hatékonyságát javítani, valamint a betegelégedettségi vizsgálatok pontosságát növelni. Különös tekintettel arra, hogy ezen információk kézi feldolgozása meglehetősen sok erőforrást (humán, idő, pénzügyi) igénylő folyamat lenne.

A tanulmány további érdekes megállapításai a gépi tanulás vonatkozásában az alábbiak:

- A minták azonosítása a rendelkezésre álló adatok minőségétől függ. A szövegosztályozásban vagy a hangulatalemzésben a megjegyzések sokfélesége befolyásolja a gépi előrejelzés/beclsés pontosságát. A nagyobb diverzitás csökkenti az ML-algoritmus azon képességét, hogy pontosan osztályozza a megjegyzést.
- Minden ML-algoritmust különböző szekvenciális szabályrendszerek vezérelnek a szemantikai vagy szintaktikai kapcsolatok osztályozására az adott szövegen belül. A szemantika a nyelvnek az a területe, amely a jelentéssel, a szavak, kifejezések és mondatok értelmével foglalkozik, míg a szintaktika a mondatok szerkezetével, a szavak nyelvtani kapcsolódásával foglalkozik. Bizonyos algoritmusok jobban illeszkedhetnek egyes adathalmazokhoz, mint másokhoz.
- Minél nagyobb a használt tanulóláma, annál nagyobb az algoritmusok pontossága a hasonló megjegyzések azonosításában a szélesebb adathalmazon belül, de az idő és az emberi kódolás tekintetében kompromisszumokra van szükség ahhoz, hogy a módszer erőforráshatékony legyen.

Shankar és Yip [10] egy integrált KDD (Knowledge Discovery in Databases) kutatási keretrendszer alkalmazott a szingapúri Alexandra Kórházban 2023-ban gyűjtött 126 134 betegviszajelzési bejegyzés elemzésére. Az adathalmaz 92 578 (73,4%) szabad szövegű megjegyzést tartalmazott, amely 1 568 932 tokent jelentett, átlagosan 16,9 szó hosszú megjegyzésekkel.

A kutatás eredménye alapján a hozzászólások 68,8%-a (63 685/92 578) pozitívnak, 25,4%-a (23 515/92 578) semlegesnek, 5,8%-a (5378/92 578) pedig negatívnak minősült. A témamodellőzés 10 különálló témát azonosított, beleértve a személyzet hozzáállását (9443/92 578, 10,2%), az egészségügyi személyzet szakmaiságát (9350/92 578, 10,1%), a kórházi környezetet (9258/92 578, 10,0%) és a várakozási időt (9258/92 578, 10,0%). Az aspektusalapú hangulatalemzés az ápolók hozzáállását (hangulati pontszám: 0,65), a személyzet segítőkészségét (0,61) és az orvosok szakértelmét (0,58) emelte ki a legpozitívabb szempontokként, míg a várakozási idő (-0,42) és a számlázás átláthatósága (-0,28) jelent meg a legnegatívabb szempontként.

A betegelégedettség AI-alapú analízisének hatására mérhetően javult az elégedettségi mutató, például 18%-kal nőtt a betegek várakozási idővel való elégedettsége. Következtetésük szerint tehát az AI nem csupán az elemzés fázisában hatásos, de a betegelégedettséget növelő fejlesztési intézkedések alapjául is szolgálhat.

Egy 2021-es kutatásban [11] gépi tanuláson alapuló természetesnyelv-feldolgozás segítségével 1048 betegmegjegyzést analizáltak hangulat szempontjából. 2016. augusztus és 2019. augusztus közötti időintervallumban 319 teljes térdízületiprotézis-beültetésen átesett beteg adatait összekapcsolták azon betegelégedettségi adatokkal, amelyek a betegmegjegyzéseket és a Press Ganey elégedettségi kérdőív adatait is tartalmazták. Dr. Press Rod Ganey statisztikus és felmérésmódszertani szakértő dolgozta ki az első felmérést a betegelégedettség tudományos mérésére és az egészségügyi ellátás javítására.

Az 1048 betegmegjegyzés 25%-a negatív, 58%-a pozitív, 8%-a vegyes és 9%-a semleges volt. A negatív megjegyzések két leggyakoribb témája a helyiség állapota (25%) és a nem hatékony kommunikáció (23%) volt. A negatív megjegyzéseket tevő betegek kisebb valószínűséggel ajánlották kórházi ellátásukat ismerőseiknek ($P < 0,001$). Érdekes megfigyelés, hogy nagyobb valószínűséggel tettek negatív megjegyzéseket ($P < 0,05$) azok a betegek, akik magasabb ASA score-ral (az Amerikai Aneszteziológusok Társaságának altatási kockázatbesoroló mutatója) rendelkeztek, illetve akik szkopolamin tapaszt kaptak.

A tanulmány következtetése, hogy a betegek elégedettsége nem feltétlenül helyettesíti a hagyományos objektív perioperatív mérési eredményeket, azonban az orvostudomány nem technikai aspektusainak javítására irányuló erőfeszítések továbbra is kulcsszerepet játszanak a betegközpontú ellátás biztosításában.

Doing-Harris és munkatársai [12] a Utah Egyetem Egészségügyi Rendszerétől származó (2014. január 1. és

2014. december 31. között generált) 51 234 Press Ganey betegelégedettségi választ elemeztek. Első lépésben kidolgoztak egy sémát a betegfelmérési válaszokból származó témák jellemzésére, és a sémákat egy annotációs vizsgálatmal validálták. Ezután két felügyelt osztályozót képeztek (egy szókincsalapú osztályozót és egy Naiv Bayes-osztályozót), hogy automatikusan címkézzék a válaszokat a sémából származó témákkal. A Bayes-tétel a Bayes-statisztika alapja, ahol a valószínűségeket nemcsak gyakorlati alapon, hanem információfrissítéseként kezelik. Ez lehetővé teszi az előzetes és a későbbi frissített valószínűségek közötti átmenetet. A „naiv” jelző onnan ered, hogy függetlenséget feltételez a bemeneti jellemzők között – ami ritkán igaz teljes mértékben, mégis jó eredményt ad sok gyakorlati feladatban. Ezután egy külön betanított osztályozó segítségével azonosították a betegek témákhoz tartozó érzelmi töltetét (pozitív, negatív, semleges). Végül LDA témamodelllezési módszert (Latent Dirichlet Allocation, egy olyan statisztikai modell, amely dokumentumokból rejtett témákat próbál felfedezni) alkalmaztak a negatív élményekhez kapcsolódó kifejezések klaszterezésére új témák definiálásához.

A kutatás annotációs rendszerének 28 témája közül a hét leggyakoribb az annotációk 63%-át tette ki: 1. időpontfoglalás; 2. időpontra való várakozás; 3. empátia; 4. tájékoztatás/magyarázat; 5. barátságosság; 6. rendelői környezet; 7. általános élmény/tapasztalat. Az érzelmek osztályozására vonatkozó F-pontszám 0,84 volt, a pontosság (precision) és a visszahívás (recall) harmonikus középértéke. Az F-pontszám azt méri, mennyire megbízható egy osztályozó abban, hogy helyes érzelmi kategóriába sorolja a példákat (precision); nem hagy ki olyan példákat, amelyek az adott érzelmehez tartoznak (recall). A negatív hozzászólások témáinak modellezésével alapvetően az időponthoz való hozzáféréssel, az időpontra való várakozással és az orvosnál töltött idővel kapcsolatos panaszokat tárták fel.

A mesterséges intelligencia gyorsan integrálódott az egészségügybe, és javította például a diagnosztikai tevékenység pontosságát is. Azonban a mesterséges intelligencia által vezérelt klinikai eszközök széles körű elfogadottsága a betegek részéről még további megoldandó kérdéskör.

Ali Algrani [13] egy olyan mesterséges intelligenciával támogatott modellt (CareAssist-GPT) fejlesztett ki, amelynek célja a diagnosztikai pontosság és a betegélmény javítása valós idejű, érthető és empátikus kommunikáció révén. A CareAssist-GPT a mesterséges intelligencia által vezérelt diagnosztikai keretrendszer, amelyet a multimodális klinikai adatok (beleértve a röntgenfelvételeket, az életjeleket és a klinikai szövegeket) integrálására terveztek annak érdekében, hogy javítsák a diagnosztikai pontosságot, valamint a betegekkel való kommunikáció hatékonyságát. A modell jelentős javulást eredményezett a hagyományos diagnosztikai rendszerekhez képest: 95,8%-os diagnosztikai pontosság, 500 ms válaszidő, 9,3/10-es betegelégedettségi pontszám. A modell legfontosabb újítása, hogy egyidőben fókuszál a diagnosztikai teljesítményre és a betegközpontú kommunikációra. Ez az egyensúly lehetővé teszi a klinikusok szá-

mára, hogy a pontos diagnosztikai információk megszerzése érdekében a CareAssist-GPT-re támaszkodjanak, miközben nem terhelik túl a betegeket szakzsargonnal.

Egy 2023-ban végzett keresztmetszeti vizsgálatban [14] a kutatók egy neurális hálózaton alapuló NLP-modellt készítettek az interneten 1994 és 2020 között japán nyelven írt betegségblogok szöveges tartalmának felhasználásával. Körülbelül 20 millió mondatot nyertek ki 56 357 beteg által írt betegségblogokból, majd egy modellt készítettek a betegelégedettségi index (Patient Satisfaction Index, PSI) előrejelzésére regressziós megközelítéssel. A modell hatékonyságának értékelése után a PSI-t a rákbejelentés előtt és után is megbecsülték annak érdekében, hogy a rákdiagnózisok érzelmi hatását megvizsgálják 48 emlőrákos betegnél. A 169 mondatból álló tesztalalmaz segítségével értékelték az előrejelzett és a tényleges, emberek által címkézett PSI-értékek közötti korrelációt. A modell sikeresen számszerűsítette a betegek elégedettségét azáltal, hogy kiváló hatékonysággal detektálta a mondatokban található árnyalatokat (Spearman-féle korrelációs együttható $[\rho]=0,832$; négyzetes középérték hiba [RMSE] = 0,166; $P<.001$). A Spearman-féle rangkorrelációs együttható egy nemparaméteres statisztikai mérőszám, amely két változó közötti monoton kapcsolat erősségét és irányát mutatja meg. A Spearman-féle korrelációs együttható azt méri, hogy két változó értékei rangsoruk alapján mennyire mozognak együtt, míg a négyzetes középérték hiba (RMSE – Root Mean Squared Error) azt mutatja meg, hogy egy modell előrejelzései átlagosan mennyivel térnek el a valós értékektől, mégpedig négyzetes átlaggal súlyozva. A PSI szignifikánsan alacsonyabb volt a rákdiagnózis bejelentési időszakában, mint az azt megelőző kontrollidőszakban ($-0,057$, illetve $-0,012$; kétoldali $t_{47}=5,392$, $P<.001$), ami azt jelzi, hogy a modell képes számszerűsíteni a rákdiagnózis bejelentésével járó pszichológiai és érzelmi változásokat.

Lizée és szerzőtársai tanulmányukban [15] egy, a betegekkel kapcsolatba lépő mesterségesintelligencia-alapú orvosi ügynököt mutattak be. Ez egy olyan intelligens szoftver, amely orvosi információt tud megszerezni, keresni, magyarázni; páciensekkel kommunikálhat (chat, hang); adminisztrációt, dokumentációt automatizál; döntéstámogató funkciókat lát el (de nem hoz önálló döntéseket); képes adatokat integrálni (EESZT, EHR, laboradatok); akár orvoslátogatói jellegű feladatokat is végezhet: gyógyszerek ismertetése, információs anyagok generálása, tájékoztatás. Nem orvos, nem dönt helyette. Nem végez diagnózist emberi kontroll nélkül. Nem adhat terápiás utasítást. Az orvos munkáját támogatja, időt szabadít fel, információt rendszerez. Kifejlesztettek egy átfogó értékelési keretrendszert, amely szimulált beteginterakciókon keresztül integrálja a klinikai ismeretek értékelését, a valós kommunikációk elemzését és az automatizált tesztelést. Három héten keresztül véletlenszerű, kontrollált kísérletet végeztek, amelyben összehasonlították a betegek elégedettségét és az orvosi ügynökkel folytatott kommunikációk tapasztalatait, illetve a kizárólag az orvossal interakcióba lépő kontrollcsoport tapasztalatait. A kutatók megállapítása szerint az általános elégedettség és a

betegek által érzékelt kommunikációs egyértelműség magasabb volt az orvosi ügynökkel folytatott beszélgetések esetén, míg a kapott információkba vetett bizalom és az empátia érzékelése hasonló volt a két csoportnál. Kimutatták továbbá, hogy a betegek elkötelezettsége magasabb volt az orvosi ügynökkel folytatott kommunikációban, amit a betegek rövidebb válaszáideje igazolt.

Az orvosértékelő weboldalak (Physician Review Websites) hatása szignifikáns módon megnőtt az orvoslásban. Egy 2023-as tanulmányban [16] a Healthgrades nevű orvosértékelő weboldalon 1125, az Egyesült Államokban élő szemésszel kapcsolatban rögzített és ellenőrzött, mindösszesen 16 700 betegvéleményt elemeztek. A kvantitatív megfigyeléses vizsgálat során összefüggéseket azonosítottak az orvosok demográfiai adatai és a narratív (történeteszerű) vélemények hangulatanalízisének pontszámai, valamint a csillagos értékelések (az NLP területén egy olyan annotációs vagy címkézési módszer, amelyben szövegekhez pl. véleményekhez, kommentekhez numerikus értéket rendelnek, általában 1-től 5 csillagig) között, Student-féle t-próbák és ANOVA-tesztek segítségével. Az elemzés kimutatta, hogy az orvos személyiségét jellemző szavak (pl. „barátságos” és „törődő”) jobban növelték a pozitív értékelések valószínűségét, mint az orvos-beteg találkozás hatékonyságát leíró szavak (pl. „eredmények” és „hatékonyság”). A fiatalabb és férfi szemészek magasabb csillagos értékelést és érzelmi pontszámot kaptak. Az eredmények azt mutatták, hogy a „szemész kellemes személyiségét” és az „orvos-beteg találkozás hatékonyságát” leíró szavak befolyásolták a legpozitívabban, míg a „várakozást” vagy az „orvos kellemetlen személyiségét” leíró szavak befolyásolták a legnegatívabban a betegek véleményét. A legjobb értékelések olyan szavakat tartalmaztak, mint a „barátságos”, „törődő”, „kedves” és „kényelmes”, valamint az „eredmények”, „segítőkész” és „hatékony”. A legrosszabb értékelések olyan szavakat tartalmaztak, mint a „durva”, „szakszerűtlen”, „arrogáns” és „leereszkedő”, valamint a „várakozó” és „sietős”.

Kulcskérdés, hogy az AI-alapú kérdőívek mennyiben képesek kiváltani vagy kiegészíteni a klasszikus kérdőíves módszereket. M. van Buchem és munkatársai [17] egy olyan új, mesterséges intelligenciával támogatott, nyitott végű kér-

dőívől álló, betegvisszajelzés-alapú tapasztalatmérési eszközt (Artificial Intelligence-Patient Reported Experience Measure, AI-PREM) fejlesztettek ki, amely a válaszokat értelemezés és témamodellelés segítségével analizálja.

A végső AI-PREM öt nyitott kérdésből állt, amelyek a kapott tájékoztatásra, a személyes megközelítésre, az egészségügyi szakemberek közötti együttműködésre, az ellátás megszervezésére és egyéb tapasztalatokra vonatkoztak. A kutatók a Picker Intézet példáival egészítették ki a kérdéseket:

1. kérdés: Milyen volt a kapott információ? (prognózis, a lehetséges vizsgálatok, kezelések)
2. kérdés: Milyen volt a személyes megközelítés? (közös döntéshozatal, a preferenciák meghallgatása, érzelmi támogatás)
3. kérdés: Milyen volt az együttműködés az egészségügyi szakemberek között? (ne legyenek eltérő tanácsok, ne kelljen többször elmesélnie a történetét, kapcsolatfelvétel a háziorvossal vagy más kórházakkal)
4. kérdés: Milyen volt az ellátásszervezés hatékonysága? (időpontfoglalás, időpontok összevonása egy napon, telefonos elérhetőség)
5. kérdés: Mit szeretne még megosztani a tapasztalatairól?

Összesen 867 vesztibuláris schwannomás betegből 536 töltötte ki az AI-PREM- és a PEM- kérdőíveket, ami 62%-os válaszadási arányt eredményezett. A PEM-pontszám (Patient Experience Measure score) egy kvantitatív mutató, amely a betegek egészségügyi ellátással kapcsolatos tapasztalatait fejezi ki, gyakran szöveges visszajelzések Natural Language Processing-alapú elemzésével előállítva. Két beteget kizártak, mert diagnózisuk a vesztibuláris schwannomáról meningeomára változott, ami egy másik ellátási folyamatban való kezelést tett szükségessé. Így 534 kérdőív párt maradt az elemzéshez. A betegek válaszainak medián hossza két szó volt, az interkvartilis tartomány 1 és 11 szó között volt. A maximális válasz hossz 192 szó volt.

A kutatás eredménye, hogy amíg az 1-3. kérdések szignifikáns különbséget mutattak a PEM-pontszámokban a pozitív és negatív válaszok között, addig a 4. kérdésnél ez nem volt kimutatható, lásd 1. táblázat.

	Kérdés	Páciensek száma N (%)	Kérdések átlagos PEM-pontszáma 1-10-ig ($\mu \pm sd$)
1.	Pozitív	359 (67.2%)	9.7 \pm 0.9
	Negatív	26 (4.9%)	8.1 \pm 2.4**
2.	Pozitív	360 (67.4%)	9.7 \pm 0.7
	Negatív	31 (5.8%)	7.7 \pm 2.6**
3.	Pozitív	325 (60.9%)	9.6 \pm 1.1
	Negatív	40 (7.5%)	8.3 \pm 1.8*
4.	Pozitív	343 (64.2%)	6.9 \pm 1.7
	Negatív	39 (7.3%)	6.4 \pm 2.0
5.	Pozitív	121 (22.7%)	
	Negatív	35 (6.6%)	

A kétmintás független t-próbához tartozó p-érték: * = $p < 0,001$, ** = $p < 0,0001$.

1. táblázat
A PEM-pontszámok az egyes kérdésekre (forrás: [17])

Érdekes kérdés, hogy jelenleg mire használják az egészségügyi intézmények a mesterséges intelligencia természetesnyelv-feldolgozási technikáját.

Feizollah és munkatársai által elvégzett [18] hatókörfelmérés azt vizsgálta, hogy az egyes egészségügyi szolgáltató intézményeknél milyen módon alkalmazzák az NLP-technikákat a strukturálatlan betegvisszajelzések elemzésére, különös tekintettel a klinikai folyamatokra gyakorolt hatásokra. 2024 februárjában a következő adatbázisokban hajtottak végre keresést (dátumkorlátozás nélkül): MEDLINE, Embase, CINAHL, Cochrane Reviews Database és Google Scholar. A jogosultsági kritériumok közé tartoztak azok az angol nyelvű tanulmányok, amelyek azonosítható egészségügyi intézmények vonatkozásában alkalmaztak NLP-technikákat a strukturálatlan betegvisszajelzések elemzésére. Kizárták azokat a vizsgálatokat, amelyeknél kizárólag emberek végeztek kódolást, vagy ha az NLP-t strukturált visszajelzésekre vagy nem beteg által generált tartalmakra alkalmazták. A kinyert adatokat narratív módon szintetizálták az egészségügyi ellátási környezetre, az NLP-módszerekre, és a klinikai alkalmazásokra vonatkozóan. 4017 rekordból 52 vizsgálat felelt meg a beválasztási kritériumoknak. A bevont vizsgálatokban három NLP-technikát azonosítottak: a hangulatelemzést (n=32), a témamodellezést (n=15) és a szövegosztályozást (n=7).

A kutatás eredménye, hogy az egyes egészségügyi szolgáltató intézmények a hangulatelemzést a beteghangulat és az egészségügyi szolgáltató jellemzői közötti összefüggések feltárására, az érzelmi válaszok időbeli nyomon követésére, valamint az egészségügyi ellátás fejlesztésére alkalmas területek azonosítására alkalmazták. A témamodellezést elsősorban a betegvisszajelzésekben található látens témák feltárására, a betegélmények (különböző egészségügyi környezetekben való) összehasonlítására alkalmazták. A szövegosztályozást a betegvisszajelzések előre meghatározott témákba való kategorizálására használták.

AZ NLP A GYAKORLATBAN

Adekvát kérdésként merül fel, hogy a jelenlegi AI-technológia milyen szintű elemzésre képes a szabad szövegű betegvisszajelzések tekintetében. Az elemzéshez egy fővárosi szakrendelő fizioterápia/gyógytorna szakrendeléseire vonatkozó betegelégedettségi kérdőíveinek szabad szövegezésű részéből gyűjtöttem ki a betegvisszajelzéseket (szöveghű idézetként).

Az elemzéshez a Microsoft 365 Copilot AI-alkalmazásba töltöttem be a szöveges megjegyzéseket: 1567 szó, 9991 karakter (szóköz nélkül).

A természetesnyelv-elemzéshez az alábbi utasítást adtam meg:

Az alábbi betegvisszajelzések alapján készíts egy komplex természetes nyelvi feldolgozás (NLP) mélyanalízist.

Microsoft 365 Copilot elvégezte az NLP-elemzést az alábbi eredménnyel.

MÉLY NLP ANALÍZIS – TELJES KORPUSZ (GYÓGYTORNA + FIZIKOTERÁPIA)

Az elemzést 7 rétegben mutatom be:

1. Lexikai frekvencia mintázatok
2. Szemantikai térkép és fogalomhalmazok
3. Téma koherencia (topic coherence) és rejtett témastruktúra
4. Diskurzív azaz gondolati mintázatok és narratív struktúrák
5. Pragmatikai és attitűdmintázatok
6. Érzelmi és pszichológiai mélyelemzés (sentiment, affective load)
7. Kognitív nyelvészeti metaelemzés: mit „mond” a korpusz a betegek igényeiről?

1. LEXIKAI FREKVENCIA ÉS KULCSKIFEJEZÉSEK

A korpusz domináns szavai három nagy csoportba tömörülnek:

A. Ellátás + személyzet (pozitív tömb)

- kedves
- segítőkész
- gyógytornász
- odaadás
- elégedett
- udvarias
- figyelmes

Nyelvi mintázat: a személyzetre vonatkozó kifejezések magasan pozitív polaritású mellékevek, melyek sokszor fokozással jelennek meg („rendkívül”, „nagyon”, „kiváló”).
→ Erős pragmatikai háló: bizalom, szeretet, hála.

B. Infrastruktúra + tárgyi feltételek (negatív tömb)

- kicsi, szűk, zsúfolt
- szellőzés, huzat, levegőtlen
- öltöző, padló, tisztaság
- elavult gépek, kevés gép
- higiénia, kendő, lepedő

Nyelvi mintázat:

→ túlsúlyban negatív attribútumok: zsúfolt, rossz, kevés, nem megoldott, elavult

→ gyakran fizikai diszkomfort leírásai („hideg”, „szagok”, „huzat”).

C. Szervezési problémák (kevert polaritás)

- időpont
- várakozás
- csúszás
- adminisztráció
- tájékoztatás hiánya

Ez a csoport procedurális elégedetlenséget mutat, de gyakran keveredik a személyzet dicséretével, ami azt jelzi:

→ A rendszer rossz, de az emberek jók.
Ez a magyar egészségügyben gyakori diskurzív minta.

2. SZEMANTIKAI TÉRKÉP – 5 FŐ FOGALOMHALMAZ

A teljes korpuszt szemantikai klaszterekkel vizsgálva:

1. Szakmai emberi minőség – „pozitív humán mag”

- kedvesek
- türelmesek
- szakértők
- odaadók

Ez a legerősebb, legkoherensebb, leggyakrabban ismétlődő „value cluster”.

2. Fizikai környezet – „negatív infrastruktúra”

- öltöző, szellőzés, helyszűke
- higiéniai eszközök hiánya
- gépek elavultsága

3. Rendszerszintű működés – „szervezetlenség”

- időpontkezelés
- várakozás
- túlterheltség
- adminisztráció

4. Terápiás igények – „funkcionális elvárások”

- hosszabb idő
- több eszköz
- több terem
- gyakoriság növelése

5. Betegtájékoztatás – „információs deficit”

- otthoni torna
- kezelési célok
- folyosói tájékoztatás hiánya

Ezek erős coherence score-t mutatnak (0,41–0,53 becsült LDA-témakoherenciával).

3. REJTETT TÉMASTRUKTÚRA (LDA-ÉRTELMEZÉS)

Az automatikusan generált 6 téma mögött valójában három makrotéma húzódik:

Makrotéma A: Emberi tényezők (kivételesen pozitív)

A személyzet minden dimenzióban felülmúlja a rendszer működését.

Mikrojellemzők:

- empátia
- szakmai kompetencia
- személyre szabott figyelem
- bizalomépítő kommunikáció

→ Ez a „rendszer ellensúlyozása” a korpuszban.

Makrotéma B: Fizikai higiéniai infrastruktúra (kritikusan negatív)

Ez a legnagyobb negatív tömb.

Mikrojellemzők:

- szellőzés, huzat, levegőhiány
- öltözők elégtelensége
- padló, szagok, higiéniai protokoll
- eszközök és gépek elavultsága

→ A diskurzusban a „rossz fizikai környezet” traumatizáló hatásként jelenik meg:

„nem jó érzés ide jönni”, „gusztustalan”, „nem elfogadható”.

Makrotéma C: Szervezés és időgazdálkodás (rendszerszintű probléma)

Mikrojellemzők:

- időpontcsúszás
- kevés gép → torlódás
- adminisztráció túlterheli a személyzetet
- betegek életritmusával nem kompatibilis rendszer

→ A leggyakrabban felmerülő panasz: „mindig később hívnak be”

4. DISKURZÍV MINTÁZATOK – HOGYAN BESZÉLNEK A BETEGEK?

A korpuszban három diskurzústípus váltakozik:

1. „Háladiskurzus” – erős pozitív emocionális töltettel

Ez a legerősebb diskurzív stílus.

Jellemző formák:

- „Köszönöm”
- „Hálás vagyok”
- „Megköszönöm azt a lelkiismeretes munkát...”

A mondatok 20–25%-a kifejezetten hála.

2. „Panasz diskurzus” – racionális, gyakran tényközlő

Jellemző mondatformák:

- „Kevés a hely...”
- „Nem lehet megmosakodni...”
- „Zavaró, hogy...”
- „A wc-ben nincs papír...”

Érdekes megfigyelés: a panaszok 80%-a infrastruktúra/higiénia jellegű, nem személyzetkritika.

3. „Javasló diskurzus” – konstruktív, ajánló jellegű

Jellemző kifejezések:

- „Célszerű lenne...”
- „Javaslom, hogy...”
- „Sokat segítene, ha...”

Ez a diskurzus stratégiai szempontból kiemelt jelentőségű:

→ a betegek fejlesztési ötletekben gondolkodnak, aktív partnerek.

5. PRAGMATIKAI ÉS ATTITÚDMINTÁZATOK

A korpuszban megtalálhatók:

Pozitív pragmatikai aktusok

- dicséret
- hála
- elismerés
- tapintatos javaslat

Negatív pragmatikai aktusok

- panasz
- kifogás
- sürgetés
- felháborodás (ritkább, de jelen van „gusztustalan”, „elfogadhatatlan”)

Attitűdstruktúra:

A betegek attitűdje kettős:

- pozitív érzelmi lojalitás a személyzet felé
- negatív értékelés a rendszer és az infrastruktúra felé

Ez rendkívül tipikus a magyar ellátórendszerben.

6. ÉRZELMI ÉS PSZICHOLÓGIAI MÉLYELEMZÉS

A sentiment-mátrix alapján (zöld–piros skála):

Pozitív érzelmi klaszterek

- hála, bizalom
- megnyugvás, elfogadás („sokat javultam”, „jól foglalkoznak velem”)
- optimizmus („csak így tovább”, „jó légkör van”)

Negatív érzelmi klaszterek

- undor (higiénia kapcsán)
- frusztráció (várakozás, időpontcsúszás)
- diszkomfort (szellőzés, öltöző)
- félelem (felfázás, huzat reumás betegeknek)

A corpus érzelmi töltete:

- 55% pozitív
- 35% negatív
- 10% semleges

Ez kiegyensúlyozott, de a negatív érzelmek erősebben koncentrálnak egy témára:

→ infrastruktúra és higiénia.

7. KOGNITÍV NYELVÉSZETI METAELMÉZÉS – MIT MOND A SZÖVEG A BETEGEK VALÓS SZÜKSÉGLETEIRŐL?

A szövegek mögött három alapvető emberi szükséglet rajzolódik ki:

1. Biztonság (higiénia, fizikai komfort) → „Legyen tiszta, legyen levegő, legyen hely.”

Ez a legfontosabb, és jelenleg a legrosszabbul teljesítő.

2. Tisztelet és figyelem → „Halljanak meg minket.”

A személyzet ezt maximálisan teljesíti, ezért ilyen sok a dicséret.

3. Kontroll és kiszámíthatóság → „Tudjam, mikor kerülök sorra, és mi történik velem.”

Ez jelenleg csak részben teljesül szervezési problémák miatt.

ÖSSZEFOGLALÓ:

MI A MÉLY NLP ELEMZÉS KONKLÚZIÓJA?

A rendszer emberközpontú és kiváló szakmai minőségű, de infrastruktúrája, higiénijája és szervezetsége erősen alul-teljesít.

A betegek kommunikációs mintái:

- dicséretkultúra erős;
- panaszok strukturáltak és tárgyyszerűek;
- javaslatok reálisak, megvalósíthatók;
- a bizalom magas, a szervezet ezt tökére válthatná.

Az elemzés alapján megállapítható, hogy a mesterséges intelligencia – a hangulatelemzés, témamodellezés és a szövegosztályozás kritériumait figyelembe véve – képes a szöveges betegvisszajelzések analizésére és olyan rejtett információk feltárására, amelyek a betegek véleményének hátterében húzódnak meg (pl. érzelmek, hangulat, értékek, motivációk stb.). Az NLP hozzásegíti az egészségügyi intézmények vezetését ahhoz, hogy jobban megértsék a betegek elégedettségének/elégedetlenségének mélyebb hátterét. Mindez lehetővé teszi a betegek elégedettségének növelésére és az egészségügyi szolgáltatások minőségfejlesztésére irányuló hatékonyabb intézkedések kidolgozását.

ÖSSZEGRZÉS, JÖVŐBENI FEJLESZTÉSI LEHETŐSÉGEK

A betegközpontú szemlélet és a betegelégedettség folyamatos növelése ma már valamennyi egészségügyi szolgáltató számára működési evidencia, kitűzött stratégiai cél. Megvalósításuk alapfeltétele, hogy rendelkezésre állnak-e a betegek visszajelzéseiből eredő, megfelelő minőségű és valid információk. Ennek hiányában nincs mód olyan intézkedések, beavatkozások tervezésére és végrehajtására, amelyek érdemi hatást lennének képesek gyakorolni az

egészségügyi szolgáltatási folyamatok minőségére és ezen keresztül a betegek elégedettségére.

Az utóbbi évek kutatásai visszaigazolták, hogy a mesterséges intelligencia legújabb technológiai (természetesnyelv-feldolgozás, mélytanulás, gépi tanulás) alkalmasak a beteg-visszajelzések mögötti érzelmi töltetek és motivációs tényezők analizálására. Ezen keresztül az egészségügyi szolgáltató intézmény olyan, a betegek tacit (rejtett) véleményét feltáró információkhoz jut, amelyek alapján a betegelégedettséget érdemben javítani képes fejlesztési intézkedések definiálhatóak.

A kutatók az NLP jövőbeni fejlesztési lehetőségeit az alábbiak szerint határozták meg:

- Az orvosi korpuszokon (kórtörténetek, diagnoszticai leírások, tudományos publikációk és szakcikkek, gyógyszerleírások, egészségügyi irányelvek, orvosi tankönyvi szövegek) betanított speciális nyelvi modellek fejlesztése az összetett terminológia jobb értelmezése érdekében.
- Az érzelemfelismerés integrálása az empatikus kommunikáció fokozása érdekében, valamint további adatforrások (pl. genomikai adatok) kórtörténeti és életmódbeli tényezők beépítése a mind inkább személyre szabott diagnosztika érdekében.
- A számítási teljesítmény optimalizálására való összpontosítás olyan technikák segítségével, mint a modellkvantálás és a felhőalapú következtetési megoldások telepítése, amelyek a rendszert könnyebben hozzáférhetővé teszik az erőforrás-korlátozott egészségügyi környezetek számára. A modellkvantálás (model quantization) egy olyan eljárás a gépi tanulásban, amelynek célja, hogy egy neurális háló memória- és számításiigénye csökkenjen anélkül, hogy a pontossága jelentősen

romlana. Előnyei: gyorsabb végrehajtás, kevesebb memóriaigény, energiatakarékosság. Lehetővé teszi nagy modellek futtatását gyengébb gépeken. Például egy modell súlya FP32-ben 32 bit, INT8 formában csak 8 bit.

- Ahogy az egészségügy mesterségesintelligencia-területe egyre jobban fejlődik, a nyelvi modellezés, az érzelmi intelligencia, a magyarázhatóság, a skálázhatóság és az etikus telepítés terén végzett folyamatos munka kulcsfontosságú lesz a hozzáférhető, megbízható és emberközpontú AI-diagnosztika új korszakának megvalósításához [10].
- A jövőben a visszajelzési rendszereket úgy kell megtervezni, hogy több platformon (pl. mobilalkalmazásokon, weboldalakon, sms-ben, személyes interjúkon és hangbevitelen) is működjenek, annak érdekében, hogy növeljék a különböző betegpopulációk részvételét.
- A visszajelzésgyűjtés hatókörének bővítése érdekében a családtagok számára is lehetővé kell tenni, hogy visszajelzést küldjenek az idős vagy kritikus állapotú betegek nevében.
- A betegvisszajelzések gyűjtésének és elemzésének folyamatát automatizálni kell az NLP és a mesterséges intelligencia eszközeinek használatával annak érdekében, hogy csökkentjük a manuális adatfeldolgozási terheket, és elemezhetővé váljon a nagy mennyiségű adat.
- A hangulelemzési modellek általánosíthatóságának és robusztusságának javítása érdekében a jövőbeni fejlesztéseknek a nagy méretű, reprezentatív adatbázisok gondozására és megosztására kell összpontosítani.
- Az azonosított és analizált visszajelzéseket közvetlenül a minőségfejlesztési programokba, a teljesítményértékelésekbe és a stratégiai tervezésbe kell beépíteni [14].

IRODALMI HIVATKOZÁSOK

- [1] Linder-Pelz SU: Toward a theory of patient satisfaction; Soc Sci Med; 1982.; 16(5): 577-582. DOI: 10.1016/0277-9536(82)90311-2
- [2] C.Pascoe G: Patient satisfaction in primary health care: A literature review and analysis; Evaluation and Program Planning; 1983.; 6(3-4): 185-210. DOI: 10.1016/0149-7189(83)90002-2
- [3] Batbaatar E, Dorjdagva J, Luvsannyam et al.: Determinants of patient satisfaction: A systematic review. Perspectives in Public Health; 2017.; 137(2): 89–101. DOI: 10.1177/1757913916634136
- [4] Manzoor F, Wei L, Hussain A et al.: Patient satisfaction with health care services: An application of physician's behavior as a moderator; International Journal of Environmental Research and Public Health; 2019.; 16(18): 3318. DOI: 10.3390/ijerph16183318
- [5] <https://www.deeplearning.ai/resources/natural-language-processing/>
- [6] Kalaja R: Determinants of Patient Satisfaction with Health Care: A Literature Review; European Journal of Natural Sciences and Medicine, vol. 6, pp. 43–54, May 2023. DOI: 10.2478/ejnsm-2023-0005
- [7] Brown B et al.: Clinical Performance Feedback Intervention Theory (CP-FIT): A New Theory for Designing, Implementing and Evaluating Feedback in Health Care Based on a Systematic Review and Meta-synthesis of Qualitative Research; Implementation Science, vol. 14, no. 1, pp. 1–20, 2019. DOI: 10.1186/s13012-019-0883-5
- [8] Gupta Ay, Gupta An, Bansal D and Khushi: From Surveys To Sentiment: A Review Of patient Feedback Collection And Analysis methods; Jordanian Journal of Computers and Information Technology (JJCIT), Vol. 11, No. 03, September 2025. DOI: 10.5455/jjcit.71-1747299718

- [9] Khanbhai M, Anyadi P, Symons J et al.: Applying natural language processing and machine learning techniques to patient experience feedback: a systematic review; *BMJ Health Care Inform* 2021.; DOI: 10.1136/bmjhci-2020-100262
- [10] Shankar R, Yip A: MBBS: Transforming Patient Feedback Into Actionable Insights Through Natural Language Processing: Knowledge Discovery and Action Research Study; *JMIR Form Res* 2025. vol. 9. p. 1. DOI: 10.2196/69699
- [11] Bovonratwet P, Shen TS, Islam W et al.: Natural Language Processing of Patient-Experience Comments After Primary Total Knee Arthroplasty; *The Journal of Arthroplasty* 36 (2021) 927-934, DOI: 10.1016/j.arth.2020.09.055
- [12] Doing-Harris K, Mowery DL, Daniels C et al.: Understanding patient satisfaction with received healthcare services: A natural language processing approach; *AMIA Annu Symp Proc.* 2017 Feb 10:2016:524-533. eCollection 2016. PMID: 28269848 PMID: PMC5333198
- [13] Algarni A: CareAssist GPT improves patient user experience with a patient centered approach to computer aided diagnosis; *Scientific Reports*, 2025. 15:22727 DOI: 10.1038/s41598-025-01518-w
- [14] Matsuda Sh, Ohtomo T, Okuyama M et al.: Estimating Patient Satisfaction Through a Language Processing Model: Model Development and Evaluation; *JMIR Form Res*; 2023. vol. 7. p. 1, DOI: 10.2196/48534
- [15] Lizée A, Beaucoté P-A, Whitbeck J et al.: Conversational medical AI: Ready for practice; DOI: 10.48550/arXiv.2411.12808; 2025
- [16] Jo JJ, Cheng CP, Ying S and Chelnis JG: Physician Review Websites: Understanding Patient Satisfaction with Ophthalmologists Using Natural Language Processing; *Journal of Ophthalmology* Volume 2023, Article ID 4762460, 7 p. DOI: 10.1155/2023/4762460
- [17] van Buchem MM, Neve OM, Kant IMJ et al.: Analyzing patient experiences using natural language processing: development and validation of the artificial intelligence patient reported experience measure (AI-PREM); *BMC Medical Informatics and Decision Making* 2022. 22:183; DOI: 10.1186/s12911-022-01923-5
- [18] Feizollah A, Lin C-Y, O'Malley L et al.: The Use of Natural Language Processing to Interpret Unstructured Patient Feedback on Health Services: Scoping Review. *J Med Internet Res* 2025. vol. 27; DOI: 10.2196/72853

A SZERZŐ BEMUTATÁSA



Székely Sándor közgazdász, szervezetfejlesztési és egészségügyi menedzsment szakember 2000-ben a Pécsi Tudományegyetemen, 2004-ben a Budapesti Műszaki és Gazdaságtudományi Egyetemen diplomázott, 2013-ban a Pécsi Tudományegyetemen PhD-fokozatot szerzett. Pályája során a minőségirányítás, a szervezetfejlesztés, a

felsőoktatás és az egészségügyi intézményvezetés területén dolgozott. Vezetőként és szakértőként jelentős szerepet vállalt többek között a Zuglói Egészségügyi Szolgálat és a Bajcsy-Zsilinszky Kórház fejlesztési projektjeiben. Oktatóként, kutatóként és szerzőként is aktív, számos tanulmány és szakkönyv fűződik a nevéhez. Jelenleg a Dunaújvárosi Egyetem Társadalomtudományi Intézetének egyetemi adjunktusa.