

EKONOMIKA A MANAŽMENT

Vedecký časopis Fakulty podnikového manažmentu
Ekonomickej univerzity v Bratislave



ECONOMICS AND MANAGEMENT

Scientific Journal of the Faculty of Business Management,
Bratislava University of Economics and Business

Ročník XXIII.

Číslo 1

Rok 2026

ISSN 2454-1028

Predseda redakčnej rady

Dr. h. c. prof. Ing. Peter Markovič, PhD., DBA, Fakulta podnikového manažmentu EU v Bratislave, Slovenská republika

Redakčná rada

prof. Dr. Benjamin Beug, Hochschule 21, Buxtehude, Spolková republika Nemecko

doc. Ing. Hana Bohušová, Ph.D., AMBIS, a.s. Praha, Česká republika

prof. Dr. Gerard Lewis, Fakultät Wirtschaftswissenschaften, Hochschule für Technik und Wirtschaft Dresden, Spolková republika Nemecko

prof. Ing. Ivan Nový, CSc., Fakulta podnikohospodářská, Vysoká škola ekonomická v Praze, Česká republika

prof. Dr. rer. oec. habil. Volker Oppitz, Europäische Forschungs- und Arbeitsgemeinschaft (EFA e.V.), Spolková republika Nemecko

prof. Ing. Mária Režňáková, CSc., Fakulta podnikatelská, Vysoké učení technické v Brně, Česká republika

doc. Ing. Pavel Štrach, Ph.D. et Ph.D., ŠKODA AUTO vysoká škola, o.p.s., Česká republika

prof. DI Dr. Margarethe Überwimmer, Fachhochschule Oberösterreich, Steyr, Rakúsko

prof. Dr. Daniel Zorn, Hochschule für Wirtschaft und Umwelt Nürtingen-Geislingen, Spolková republika Nemecko

Adresa redakcie

Ekonomika a manažment, Vedecký časopis Fakulty podnikového manažmentu Ekonomickej univerzity v Bratislave, Dolnozemska 1/b, 852 35 Bratislava 5, Slovenská republika

<https://fpm.euba.sk/veda-a-vyskum/vedecky-casopis/ekonomika-a-manazment>

Výkonný redaktor

Ing. Katarína Grančičová, PhD., e-mail: katarina.grancicova@euba.sk ; tel.: +421 2 67 295 556

doc. Ing. Miroslav Tóth, PhD.; e-mail: miroslav.toth@euba.sk ; tel.: +421 2 67 295 562

Za textovú, jazykovú a grafickú úpravu jednotlivých príspevkov zodpovedajú autori. Príspevky prechádzajú recenzným konaním.

EKONOMIKA A MANAŽMENT

Vedecký časopis Fakulty podnikového manažmentu Ekonomickej univerzity v Bratislave zaregistrovaný na Ministerstve kultúry Slovenskej republiky dňa 26. júna 2003, evidenčné číslo 1577/08. ISSN 2454-1028 pridelené Národnou agentúrou ISSN, Univerzitná knižnica v Bratislave, Michalská 1, 814 17 Bratislava dňa 28. 4. 2017, č. j. 124/2017.

Časopis vychádza 3-krát ročne ako online recenzovaný open access vedecký časopis.

Vydavateľ

Nadácia Manažér, Dolnozemska cesta 1/b, 852 35 Bratislava, IČO 31812562.

Dátum vydania tohto čísla: 30. 04. 2026

ISSN 2454-1028



EKONOMIKA A MANAŽMENT

Ekonomická univerzita v Bratislave
Fakulta podnikového manažmentu

Ročník XXIII.

Číslo 1

Rok 2026

Autori príspevkov (Authors of Contributions)

Pavol Andrejovský

Bratislava University of Economics and Business, Faculty of Business Economics with seat in Košice, Department of Commercial Entrepreneurship, Tajovského 13, 041 30 Košice, Slovak Republic

e-mail: pavol.andrejovsky@euba.sk

Author's share: 10 %

Peter Bahna

Bratislava University of Economics and Business, Faculty of Business Management, Department of Information management, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak republic

e-mail: peter.bahna@euba.sk

Author's share: 100 %

Katarína Čulková

Technical university in Košice, Faculty of Mining, Ecology, Process Control and Geotechnologies, Institute of Earth Resources, Letná č. 1/9, 042 00 Košice-Sever, Slovak Republic

e-mail: katarina.culkova@tuke.sk

Author's share: 20 %

Zuzana Hajduová

Bratislava University of Economics and Business, Faculty of Business Management, Department of Business Finance, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak Republic

e-mail: zuzana.hajduova@euba.sk

Author's share: 10 %

Peter Markovič

Bratislava University of Economics and Business, Faculty of Business Management, Department of Business Finance, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak Republic

e-mail: peter.markovic@euba.sk

Author's share: 10 %

Samuel Mihalčín

Bratislava University of Economics and Business, Faculty of Business Management, Department of Management, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak Republic

e-mail: samuel.mihalcin@euba.sk

Author's share: 50 %

Juraj Mišún

Bratislava University of Economics and Business, Faculty of Business Management, Department of Management, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak Republic

e-mail: juraj.misun@euba.sk

Author's share: 50 %

Maksym Mykhei

Technical university in Košice, Faculty of Mining, Ecology, Process Control and Geotechnologies, Institute of Earth Resources, Letná č. 1/9, 042 00 Košice-Sever, Slovak Republic

e-mail: maksym.mykhei@tuke.sk

Author's share: 20 %

Laura Oltmanns

Bratislava University of Economics and Business, Faculty of Business Management, Department of Information management, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak republic

e-mail: laura.oltmanns@euba.sk

Author's share: 100 %

Henrieta Pavolová

Technical university in Košice, Faculty of Mining, Ecology, Process Control and Geotechnologies, Institute of Earth Resources, Letná č. 1/9, 042 00 Košice-Sever, Slovak Republic

e-mail: henrieta.pavolova@tuke.sk

Author's share: 20 %

Anna Tabišová

Technical university in Košice, Faculty of Mining, Ecology, Process Control and Geotechnologies, Institute of Earth Resources, Letná č. 1/9, 042 00 Košice-Sever, Slovak Republic

e-mail: anna.tabisova@tuke.sk

Author's share: 20 %

Ivana Tkáčová

Technical university in Košice, Faculty of Mining, Ecology, Process Control and Geotechnologies, Institute of Earth Resources, Letná č. 1/9, 042 00 Košice-Sever, Slovak Republic

e-mail: ivana.tkacova@tuke.sk

Author's share: 20 %

Murat Tetik

Bratislava University of Economics and Business, Faculty of Business Management, Department of Business Finance, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak Republic

e-mail: murat.tetik@euba.sk

Author's share: 80 %

Roman Tranzík

Bratislava University of Economics and Business, Faculty of Business Management, Department of Information management, Dolnozemska cesta 1/b, 852 35 Bratislava, Slovak republic

e-mail: roman.tranzik@euba.sk

Author's share: 90 %

OBSAH (CONTENTS)

VEDECKÉ PRÍSPEVKY (SCIENTIFIC CONTRIBUTIONS)

- Peter Bahna** 9
AI trust a AI anxiety v manažmente zdravotnej starostlivosti: systematický prehľad determinantov, mechanizmov a organizačných implikácií / *AI trust and AI anxiety in healthcare management: a systematic review of determinants, mechanisms, and organizational implications*
- Maksym Mykhei, Katarína Čulková, Henrieta Pavolová, Anna Tabišová, Ivana Tkáčová** 21
Clean Energy Investment Growth, Grid Adequacy, and Regional Concentration: Evidence from Global Investment Trends (2015–2024)
- Laura Oltmanns** 41
Das regulatorische Umfeld für nachhaltige Logistik in der Europäischen Union: Auswirkungen des Green Deal, der CSRD und der Taxonomie / *The regulatory environment for sustainable logistics in the European Union: implications of the Green Deal, CSRD and taxonomy*
- Roman Tranžík, Zuzana Hajduová** 57
Pacientska spätná väzba ako nástroj zlepšovania kvality služieb v zdravotníctve / *Patient Feedback as a Tool for Improving the Quality of Healthcare Services*

PRÍSPEVKY DO DISKUSIE (CONTRIBUTIONS TO THE DISCUSSION)

- Samuel Mihalčín, Juraj Mišún** 73
Vplyv hybridných pracovných režimov na finančný manažment podniku - systematická literárna rešerš / *The impact of hybrid work arrangements on the financial management of the company systematic literature review*
- Murat Tetik, Pavol Andrejovský, Peter Markovič** 83
Financial strategy and decision-making in the integration of AI-supported systems in general practice

VEDECKÉ PRÍSPEVKY
SCIENTIFIC CONTRIBUTIONS

AI trust a AI anxiety v manažmente zdravotnej starostlivosti: systematický prehľad determinantov, mechanizmov a organizačných implikácií

AI trust and AI anxiety in healthcare management: a systematic review of determinants, mechanisms, and organizational implications

Peter Bahna

Abstrakt

Integrácia umelej inteligencie do zdravotníckych organizácií vyvoláva rastúci záujem o psychologické a organizačné faktory determinujúce úspešnosť jej implementácie. Dôvera v AI a AI anxiety sa vyprofilovali ako dva centrálné, čiastočne nezávislé konštrukty mediujúce individuálne aj organizačné reakcie na AI systémy. Cieľom tohto systematického prehľadu je identifikovať hlavné determinanty dôvery v AI a AI anxiety u zdravotníckych pracovníkov a pacientov, syntetizovať mechanizmy ich vplyvu na prijatie AI a vymedziť organizačné implikácie a výskumné medzery so zreteľom na stredoeurópsky kontext. Systematické vyhľadávanie podľa PRISMA prebehlo v databázach Web of Science, Scopus, PubMed/MEDLINE, IEEE Xplore a PsycINFO za obdobie primárne 2015–2026. Do analýzy bolo zahrnutých 20 empirických štúdií. Výsledky ukazujú, že dôvera v AI funguje ako primárna mediujúca premenná medzi kvalitou technológie a zámerom adopcie. AI anxiety je viacrozmerný konštrukt s kvalitatívne odlišnými profilmi u zdravotníkov a pacientov, pričom môže mať maladaptívne aj adaptívne prejavy. Zdravotnícke organizácie potrebujú integrované governance rámce súčasne budujúce dôveru prostredníctvom transparentnosti a vzdelávania a diferencovane riadiace AI anxiety participatívnou implementáciou.

JEL klasifikácia: I11, I18, O33

Kľúčové slová: AI anxiety, AI trust, Healthcare management, technology acceptance

1 Úvod

Svetové zdravotníctvo prechádza hlbokou štrukturálnou transformáciou poháňanou technológiami na báze umelej inteligencie. Od diagnostických algoritmov v zobrazovacích metódach a systémov podpory klinického rozhodovania až po prediktívnu analytiku, automatizované triáže a AI platformy pre manažment pacientov. Rozsah uplatnenia AI v medicíne sa v priebehu dvadsiatich rokov 21. storočia dramaticky rozšíril. Podľa Grand View Research (2025) dosahuje globálny trh s AI v zdravotníctve ročný rast (CAGR) na úrovni približne 38,5 %, čo odráža inštitucionálne tlaky na zvyšovanie efektivity, presnosti a nákladovej efektívnosti poskytovania zdravotnej starostlivosti. Samotná dostupnosť umelej inteligencie a jej pridružených technológií však nezaručuje efektívnu integráciu do procesov. Implementačná veda opakovane preukazuje, že úspech závisí od postojov a psychologických reakcií jednotlivcov interagujúcich s inováciou (Rogers, 2003). V kontexte zdravotníctva to znamená, že klinickí pracovníci, ktorí nedôverujú AI môžu jej odporúčania ignorovať, ďalej pacienti, ktorí nedôverujú AI môžu pociťovať úzkosť a nemusia súhlasiť so spracovaním ich údajov za pomoci umelej inteligencie. Tak isto manažéri, ktorí nedôverujú AI governance odkladajú implementáciu (Arvai et al., 2025).

V literatúre sa vyprofilovali dva kľúčové konštrukty. AI trust (dôvera) v AI označuje ochotu personálu spoliehať sa na AI systémy pri rozhodovaní za podmienok neistoty; Stevens a Stetson (2023) ju identifikujú ako primárny prediktor akceptácie AI v klinickom prostredí. AI anxiety (úzkosť) označuje obavy a napätie spojené s anticipáciou alebo používaním AI systémov, pričom v zdravotníctve sa spája najmä s obavami z profesijného nahradenia, právnej

zodpovednosti, technologickej neistoty a zmien pracovného prostredia (Li & Liu, 2025; Ongun et al., 2025). Napriek rastúcej empirickej pozornosti zostáva literatúra fragmentovaná, keďže konceptualizácia dôvery nie je jednotná a psychologické bariéry implementácie AI sa často analyzujú oddelene od modelov akceptácie (Arvai et al., 2025; Starke et al., 2025).

Zameranie tohto článku je: (a) identifikovať determinanty dôvery v AI a AI anxiety; (b) syntetizovať mechanizmy ich vplyvu na adopciu AI; (c) vymedziť organizačné implikácie a výskumné medzery s dôrazom na stredo európsky kontext.

2 Súčasný stav riešenej problematiky doma a v zahraničí

McKnight a Chervany (2001) rozlišujú dôverčivé presvedčenia, dôverčivé zámery a správanie súvisiace s dôverou. V kontexte AI systémov tieto dimenzie korešponujú s hodnotením kompetentnosti, presnosti a spoľahlivosti AI, so zámerom riadiť sa jej odporúčaniami a so skutočným delegovaním časti rozhodovacích kompetencií na AI. McAllister (1995) zároveň rozlišuje kognitívnu dôveru, založenú na evidencii o výkone a kompetencii a afektívnu dôveru, spojenú so subjektívnym pocitom istoty a relačného komfortu. V klinickom prostredí preto môžu zdravotnícki pracovníci uznávať technickú presnosť AI, napriek tomu môžu pociťovať diskomfort pri delegovaní rozhodnutí. Súčasná literatúra zároveň naznačuje pretrvávajúci nesúlad medzi technicky deklarovanou dôveryhodnosťou AI systémov a subjektívne prežívanou dôverou používateľov, čo poukazuje na význam transparentnosti, zodpovednosti a používateľskej skúsenosti pri implementácii AI v zdravotníctve.

2.1 Modely prijatia AI

Technology Acceptance Model (TAM; Davis, 1989) predpokladá, že vnímaná užitočnosť a vnímaná jednoduchosť používania patria medzi základné determinanty akceptácie technológie. Unified Theory of Acceptance and Use of Technology (UTAUT; Venkatesh et al., 2003) tento rámec rozširuje o výkonnostné očakávania, očakávania ohľadom náročnosti používania, sociálny vplyv a facilitujúce podmienky. Práve facilitačné, resp. podporné podmienky sú v zdravotníckom prostredí osobitne významné, pretože aj pri pozitívnom postoji lekára k AI nástroju môže nedostatok školenia, technickej infraštruktúry alebo funkčnej systémovej podpory oslabiť jeho reálne používanie a znížiť úspešnosť implementácie AI. V porovnaní s klasickými modelmi akceptácie technológií Stevens a Stetson (2023) navrhli model Theory of Trust and Acceptance of AI Technology (TrAAIT), ktorý do centra vysvetlenia prijatia umelej inteligencie v klinickom prostredí kladie dôveru v konkrétny AI systém. Stevens a Stetson (2023) empiricky ukázali, že dôvera klinikov v konkrétnu AI aplikáciu je hlavným prediktorom jej akceptácie, teda ochoty ju používať, a zároveň ovplyvňuje aj širšiu následnú orientáciu používateľa na dôveru voči AI technológiám vo všeobecnosti. Stevens a Stetson (2023) zároveň zistili, že táto dôvera je utváraná najmä vnímanou dôveryhodnosťou poskytovaných informácií, vnímanou hodnotou aplikácie a jej spoľahlivosťou. Na tieto zistenia nadviazali Schulz et al. (2023), ktorí vo výskume realizovanom na vzorke 164 odborníkov v gastroenterológii preukázali, že dôvera a presvedčenia o AI plne sprostredkujú vzťah medzi všeobecným postojom k AI a akceptáciou konkrétnych AI aplikácií. Výsledky Schulz et al. (2023) preto naznačujú, že dôvera v klinickom prostredí nepôsobí iba ako priamy determinant prijatia AI, ale aj ako kľúčový mechanizmus, prostredníctvom ktorého sa všeobecné postoje premietajú do reálnej ochoty používania AI.

2.2 AI anxiety: definície, dimenzie a psychologické dôsledky

Autori Li a Liu (2025) charakterizujú úzkosť z používania umelej inteligencie v zdravotníckom kontexte ako súbor obáv, ktoré sa objavujú pri očakávaní alebo používaní AI v interakcii medzi pacientom a lekárom. Ďalej vo svojej publikácii demonštrujú, že u pacientov sa tieto obavy prejavujú najmä ako averzia voči algoritmom, obavy zo straty ľudskej

starostlivosti, problémy v interakcii človek–stroj a pochybnosti o univerzálnej aplikovateľnosti AI na individuálne prípady. Zároveň autori zistili, že u lekárov sú dominantné najmä obavy z profesijného nahradenia, právnej zodpovednosti, emocionálnych dôsledkov zmien pracovného prostredia a technologická neistota. Li a Liu (2025) preto naznačujú, že AI anxiety má odlišný obsah u pacientov a u lekárov. Preto je potreba diferencovať medzi komunikačnými stratégiami medzi jednotlivými subjektami.

Ongun et al. (2025) v prierezovej štúdií realizovanej na vzorke 155 profesionálov z operačných sál v Turecku skúmali vzťah medzi AI anxiety a postojmi k bezpečnosti pacientov. Ongun et al. (2025) ukázali, že AI anxiety v tomto prostredí súvisela najmä s neistotou týkajúcou sa zmeny práce, učenia sa novým systémom a konfigurácie AI. Zároveň však treba dodať, že nezistili štatisticky významnú priamu koreláciu medzi celkovou AI anxiety a bezpečnostnými postojmi, čo znamená, že vyššia úzkosť sa neprejavovala jednotne negatívnym vzťahom k bezpečnosti pacientov. Ďalej uvádzajú, že profesionáli, ktorí verili, že AI môže zlepšiť bezpečnosť pacientov, dosahovali vyššie skóre v niektorých subškálach AI anxiety, čo možno interpretovať ako prejav zvýšenej ostražitosťi voči zmene, a nie iba ako odmietanie technológie.

Lambert et al. (2023) v integratívnom prehľade o akceptácii AI medzi zdravotníckymi pracovníkmi v nemocniciach identifikovali ako konzistentné prekážky najmä strach zo straty profesijnej autonómie a ťažkosti s integráciou AI do klinických pracovných postupov. Lambert et al. (2023) zároveň ukázali, že školenie v používaní AI a adekvátne infraštruktúra patria medzi faktory, ktoré akceptáciu AI podporujú. Preto sme toho názoru, že prijatie AI v nemocničnom prostredí je podmienené nielen vlastnosťami technológie, ale aj organizačnými podmienkami implementácie.

Asan et al. (2020) zdôrazňujú, že dôvera je kľúčovým psychologickým mechanizmom, ktorý formuje používanie a prijatie AI zo strany zdravotníckych pracovníkov. Asan et al. (2020) zároveň poukazujú na to, že vzťah medzi schopnosťami AI a správaním zdravotníckeho pracovníka nemožno vysvetliť iba technickými parametrami systému, ale aj tým, ako používateľ interpretuje neistotu, riziko a spoľahlivosť technológie. Z tohto pohľadu sa podporuje argument, že dôvera sprostredkúva vzťah medzi charakteristikami AI a ochotou zdravotníckeho personálu tieto systémy reálne využívať.

3 Výskumný dizajn

V štúdií sa aplikovali systematický prehľad literatúry podľa rámca PRISMA (Page et al., 2021). Vyhľadávanie literatúry bolo realizované primárne v databázach Web of Science a Scopus, ktoré tvorili jadro identifikácie relevantných recenzovaných publikácií, pričom doplnkovo boli prehľadané aj databázy PubMed/MEDLINE, IEEE Xplore a PsycINFO s cieľom zvýšiť úplnosť záchytu štúdií z oblasti zdravotníctva, psychológie a technologického výskumu. Vyhľadávanie bolo časovo vymedzené primárne na obdobie 2015–2026, pričom hlavný analytický dôraz bol kladený na práce publikované po roku 2020 vzhľadom na akceleráciu implementácie umelej inteligencie v zdravotníctve v postpandemickom období. Staršie práce boli zaradené selektívne, výlučne ako konceptuálne alebo metodologické východiská. Analýza literatúry a zdrojov bola zameraná na štyri hlavné tematické okruhy: dôveru v umelú inteligenciu, AI anxiety, akceptáciu a adopciu AI a modely technologickej akceptácie. Na doplnenie korpusu bola využitá aj podporná AI-asistovaná identifikácia literatúry cez Perplexity AI, pričom všetky takto získané záznamy boli následne manuálne verifikované v databázach Web of Science alebo Scopus. Úplnosť korpusu bola ďalej posilnená technikou spätného citačného sledovania, ktorú Webster a Watson (2002) odporúčajú ako vhodný postup na zachytenie kľúčových výskumných prúdov a relevantných konceptuálnych väzieb.

Do finálneho korpusu boli zaradené empirické štúdie kvantitatívneho, kvalitatívneho alebo mixed-methods charakteru realizované v prostredí zdravotnej starostlivosti, ktoré sa zamerali na dôveru v AI, AI anxiety, akceptáciu AI alebo psychologické reakcie na AI. Štúdie museli byť publikované v recenzovaných časopisoch a indexované vo Web of Science alebo Scopus. Naopak, vylúčené boli čisto technické práce bez respondentov, štúdie mimo zdravotníckeho kontextu, nerecenzované zdroje a duplicitné záznamy. Po odstránení duplicit nasledoval skríning názvov a abstraktov, následne plno textové posúdenie štúdií podľa stanovených kritérií zaradenia a vylúčenia. Pre zabezpečenie čo najvyššej kvality bola snaha pracovať len s Q1 a Q2 článkami. Následne sa extrahovali zo štúdií dáta a výskumný dizajn, charakteristiku vzorky, krajinu realizácie výskumu, typ AI aplikácie, sledované konštrukty, použitý teoretický model a kľúčové zistenia. Výsledný korpus sme sa snažili koncipovať tak, aby identifikoval dominantné prúdy vo výskume, zhody a rozpory medzi autormi, ako aj výskumné medzery, ktoré vytvárajú priestor pre ďalšie empirické skúmanie.

Tabuľka 1
PRISMA diagram selekcie

Fáza	Popis	Záznamy
Identifikácia	Vyhľadávanie v databázach (WoS, Scopus, PubMed, IEEE Xplore, PsycINFO)	812
Deduplikácia	Odstránenie duplicitných záznamov naprieč databázami	638
Skríning titulov/abstraktov	Vylúčené: mimo HC kontextu, čisto technické, bez ľudských účastníkov	185
Hodnotenie plných textov	Vylúčené: bez empirických dát, neindexované vo WoS/Scopus	52
Zahrnuté do prehľadu	Empirické štúdie zamerané na dôveru, AI anxiety, akceptáciu v zdravotníctve	20

Zdroj: vlastné spracovanie

4 Výsledky výskumu

4.1 Technologické faktory

Vo výsledkoch treba zdôrazniť, že Jermetus et al. (2022) a Astobiza et al. (2025) zhodne uvádzajú, že medzi základné technologické determinanty dôvery v AI v zdravotníctve patria presnosť, spoľahlivosť a bezpečnosť systému. Astobiza et al. (2025) zároveň ukazujú, že technologické faktory nemožno oddeliť od širšieho kontextu používania AI, keďže dôveru ovplyvňujú aj transparentnosť systému a miera ľudského dohľadu. Asan, Bayrak, and Choudhury (2020) zdôrazňujú, že transparentnosť a interpretovateľnosť AI patria medzi významné predpoklady klinickej dôvery, pretože ovplyvňujú, ako zdravotnícki pracovníci posudzujú spoľahlivosť a rizikovosť systému. Starke et al. (2025) dopĺňajú, že technologický dizajn a regulačné rámce sú síce dôležité, no dôveru používateľov výrazne formujú aj komunikácia a pozitívna skúsenosť s používaním AI. Z tohto dôvodu možno technologické faktory chápať nie ako postačujúce, ale ako nevyhnutné východisko pre budovanie dôvery v AI.

4.2 Kontextuálne a organizačné faktory

Astobiza et al. (2025) identifikujú ako samostatnú skupinu determinantov dôvery tzv. healthcare context factors, medzi ktoré patrí najmä to, ako dobre AI zapadá do zdravotníckeho prostredia a či sú zdravotnícki pracovníci primerane vyškolení na jej používanie. Lambert et al. (2023) vo svojom integratívnom prehľade ukazujú, že medzi najčastejšie bariéry prijatia AI v

nemocničnom prostredí patria obavy zo straty profesijnej autonómie a ťažkosti s integráciou AI do klinických pracovných postupov. Lambert et al. (2023) zároveň uvádzajú, že školenie používateľov a adekvátne infraštruktúra patria medzi faktory, ktoré akceptáciu AI podporujú. Stevens a Stetson (2023) vo modeli TrAAIT potvrdili, že dôvera v konkrétny AI systém je úzko spätá s vnímanou dôveryhodnosťou informácií, hodnotou aplikácie a jej spoľahlivosťou, pričom významnú úlohu zohrávajú aj organizačné záruky. Starke et al. (2025) navyše upozorňujú, že regulačné hranice a spôsob implementácie AI v konkrétnom prostredí patria medzi kľúčové kontextové faktory dôvery.

4.3 Individuálne faktory a dôvera ako mediátor

V odborných publikáciách sa uvádza, že medzi individuálne determinanty dôvery patria najmä skúsenosti používateľov a ich postoje voči AI (Astobiza et al. 2025). Starke et al. (2025) zároveň konštatujú, že pozitívne prežité skúsenosti s AI budú stáť v popredí formovania používateľskej dôvery v zdravotníctve. Stevens a Stetson (2023) empiricky ukázali, že system-specific trust in AI je primárnym prediktorom akceptácie konkrétnej AI aplikácie a širšej dôvernej orientácie používateľa voči AI technológiám. Schulz et al. (2023) na vzorke 164 odborníkov preukázali, že trust a belief plne mediujú vzťah medzi všeobecným postojom k AI a akceptáciou konkrétnych AI aplikácií. Toto zistenie naznačuje, že dôvera v AI v klinickom prostredí nepôsobí iba ako priamy determinant prijatia technológie, ale aj ako sprostredkujúci mechanizmus, cez ktorý sa všeobecné postoje premietajú do ochoty AI reálne používať.

4.4 AI anxiety a zdravotnícky personál

Ongun, Sahin Koze a Altinbas (2025) v prierezovej štúdií realizovanej na vzorke 155 profesionálov z operačných sál dvoch tureckých nemocníc skúmali vzťah medzi AI anxiety a postojmi k bezpečnosti pacientov. Výsledky, na ktoré prišli, ukázali, že medzi celkovou mierou AI anxiety a bezpečnostnými postojmi nebola zistená štatisticky významná priama korelácia. Toto zistenie naznačuje, že prítomnosť anxiety vo vzťahu k AI nemožno automaticky interpretovať ako faktor vedúci k horším bezpečnostným postojom alebo menej zodpovednému správaniu. Ich autorský kolektív zároveň tvrdí, že respondenti, ktorí verili, že AI môže zlepšiť bezpečnosť pacientov, dosahovali vyššie skóre v niektorých subškálach AI anxiety. Najmä v oblastiach učenia, zmeny práce a konfigurácie AI. AI anxiety sa preto v tomto kontexte javí skôr ako mnohvrstevný psychologický jav než ako jednoznačne negatívna bariéra (Nirgiz et al., 2026)

V roku 2025 autori vypracovali prehľad obáv zdravotníckych pracovníkov voči medicínskej AI (Arvai et al., 2025). Identifikovali tri hlavné tematické oblasti, ktoré zahŕňali aktuálne postoje zdravotníkov, psychologické dimenzie technostresu a širšie implikácie implementácie AI v zdravotníctve. Autori zároveň identifikovali 15 zdrojov negatívnych postojov, ktoré rozčlenili na vnútorné determinanty súvisiace s profesijnou identitou, úlohami a kapacitami zdravotníckych pracovníkov a na vonkajšie determinanty vzťahujúce sa na dopad implementácie AI na pacientov, patientsku starostlivosť a širšie etické a spoločenské dôsledky. Na základe týchto zistení autori odporúčajú venovať osobitnú pozornosť vzdelávaniu, vhodnej legislatíve a jasnému vymedzeniu rolí pri implementácii umelej inteligencie do medicínskeho prostredia.

Lambert et al. (2023) taktiež vo svojom prehľade o akceptácii AI medzi zdravotníckymi pracovníkmi v nemocniciach uvádza, že medzi hlavné prekážky prijatia AI patria obavy zo straty profesijnej autonómie a problémy s jej začlenením do klinických pracovných postupov. Na druhej strane treba povedať, že upozorňujú na fakt, že výsledky jednotlivých štúdií boli pomerne rôznorodé, pričom tieto rozdiely možno čiastočne vysvetliť odlišnosťami medzi profesijnými skupinami a odbornými oblasťami. Podobne ako Arvai et al., 2025 aj Lambert et

al. 2023 poukazuje na to, že školenie používateľov a dostupnosť primeranej infraštruktúry patria medzi faktory, ktoré akceptáciu AI podporujú.

4.5 AI anxiety u pacientov

Samostatnou premennou, ktorá má nezanedbateľnú váhu pri AI integrácii je úzkosť, ktorú majú pacienti. Štúdia publikovaná v Patient Education and Counseling analyzovala AI anxiety z perspektívy pacientov aj lekárov (Li & Liu, 2025). Sú toho názoru, že úzkosť pacientov sa spája najmä s averziou voči algoritmom, nedostatkom „ľudskej“, starostlivosti, problémami v interakcii človek–stroj a pochybnosťami o univerzálnej aplikovateľnosti AI na individuálne prípady. Keď sa porovnajú obe dotknuté skupiny, či pacientov alebo zdravotnícki personál vyplýva nám z toho fakt, že AI anxiety je problém, ktorý nemožno ignorovať, vyskytuje sa pri všetkých záujmových skupinách, no má odlišný obsah.

4.6 Kontrastné názory medzi odborníkmi

Pri systematickom prehľade literatúry sa narazilo na päť hlavných konceptuálnych rozdielov medzi autormi. Pre lepšiu prehľadnosť sú výsledky spracované v tabuľke 2.

Tabuľka 2

Kontrastné perspektívy vo výskume AI trust a AI anxiety v zdravotníctve

Oblasť	Kontrast	Štúdie	Implikácia
Úloha dôvery v adopcii	Dôvera vystupuje buď ako priamy prediktor akceptácie AI, alebo ako sprostredkujúci mechanizmus medzi postojom a akceptáciou.	Stevens & Stetson (2023); Schulz et al. (2023)	Budovanie dôvery má byť súčasťou implementácie už pred reálnym nasadením AI.
Zameranie na aktéra	Štúdie zamerané na zdravotníkov identifikujú iné obavy než štúdie zamerané na pacientov a lekárov v interakcii s AI.	Arvai et al. (2025) vs. Li & Liu (2025)	Implementačné a komunikačné stratégie majú byť diferencované podľa cieľovej skupiny.
Charakter AI anxiety	AI anxiety nie je vždy jednoznačne negatívna bariéra; v niektorých kontextoch môže súvisieť aj s vyššou opatrnosťou voči používaniu AI.	Ongun et al. (2025)	Potrebné je rozlišovať medzi úzkosťou vedúcou k odmietaniu AI a úzkosťou vedúcou k opatrnému používaniu.
Vysvetliteľnosť vs. výkon	Časť literatúry zdôrazňuje význam transparentnosti a vysvetliteľnosti, no empirické výsledky ukazujú, že vysvetlenia nezvyšujú dôveru automaticky.	Asan et al. (2020); Lambert et al. (2023)	Pri AI v zdravotníctve nestačí len vysvetlenie; rozhoduje aj jeho kvalita, zrozumiteľnosť a klinická relevantnosť.
Individuálna vs. organizačná úroveň	Časť štúdií sa sústreďuje na individuálne determinanty dôvery, iné zdôrazňujú potrebu organizačných a governance rámcov. Práca rieši governance, kultúru a leadership.	Jermetus et al. (2022); Reddy et al. (2020)	Implementácia AI si vyžaduje prepájanie individuálnej dôvery s organizačným riadením a governance.

Zdroj: vlastné spracovanie

V tabuľke 2 bola snaha zdôrazniť, že literatúra o dôvere v AI a AI anxiety v zdravotníctve nie je úplne jednotná, ale formuje sa okolo viacerých opakujúcich sa konceptuálnych napätí. Stevens a Stetson (2023) a Schulz et al. (2023) sa zhodujú na centrálnej úlohe dôvery pri prijímaní AI, odlišujú sa však v tom, či ju chápu primárne ako priamy prediktor akceptácie

alebo ako sprostredkujúci mechanizmus medzi postojmi a akceptáciou. Arvai, Katonai a Mesko (2025) a Li and Liu (2025) zároveň ukazujú, že determinanty obáv a prijatia AI sa líšia podľa toho, či je pozornosť sústredená na zdravotníckych pracovníkov alebo na pacientov a lekárov ako aktérov klinickej interakcie.

Ďalší dôležitý kontrast sa týka interpretácie AI anxiety. Ongun, Sahin Koze a Altinbas (2025) naznačujú, že AI anxiety nemožno chápať len ako jednoznačne negatívnu bariéru, pretože sa nepreukázal jej priamy negatívny vzťah k bezpečnostným postojom a v niektorých dimenziách sa spájala aj s vyššou opatrnosťou voči používaniu AI. Podobne aj diskusia o vysvetliteľnosti algoritmov naznačuje, že dôvera v AI nie je podmienená iba technickou výkonnosťou systému, ale aj tým, či používatelia rozumejú jeho odporúčaniam a dokážu ich zodpovedne integrovať do klinickej praxe.

Na záver bola snaha, aby tabuľka poukazovala aj na rozdiel medzi individuálnou a organizačnou úrovňou analýzy. Jermetus et al. (2022) sa sústreďujú najmä na determinanty dôvery používateľov, zatiaľ čo Reddy et al. (2020) zdôrazňujú potrebu širších governance rámcov, ktoré by prepájali technické, etické a organizačné aspekty implementácie AI v zdravotníctve. Tým možno povedať, že budúci výskum by mal viac prepájať psychologické, organizačné a regulačné dimenzie dôvery a AI anxiety namiesto ich oddeleného skúmania.

5 Diskusia

V diskusii sa poukazuje na to, že podmienkou kvalitnej a bezproblémovej integrácie umelej inteligencie do procesov v nemocniciach je vysoká úroveň AI trust a správne pochopená AI anxiety. Spolu tieto premenné tvoria jadro automatizácie a zmien v zdravotníctve.

5.1 Syntéza a navrhovaný model

Analyzované štúdie sa napriek metodologickej rôznorodosti zbiehajú v tom, že dôvera v AI vystupuje ako kľúčová premenná prepájajúca technologické vlastnosti systému s reálnym používaním AI. Dôvera sprostredkúva, ako zdravotnícki pracovníci transformujú informácie o presnosti, spoľahlivosti či klinickej validácii na ochotu akceptovať odporúčania AI a integrovať ich do rozhodovania. Súbežne s tým pôsobí AI anxiety, ktorá však nie je nevyhnutne zrkadlovým opakom dôvery. Dostupné práce naznačujú, že zdravotníci môžu súčasne deklarovať vysokú dôveru v technickú kompetentnosť AI a zároveň prežívať výrazné obavy týkajúce sa právnej zodpovednosti, zmeny pracovných rolí či dopadu na pacientov. Na tomto základe možno navrhnuť integratívny model, v ktorom triádu tvoria:

- dôvera v AI,
- AI anxiety a
- adopcia a kvalita používania AI.

Dôvera pôsobí prevažne facilitujúco, zatiaľ čo vzťah medzi AI anxiety a adopciou závisí od povahy tejto odpovede. Maladaptívna úzkosť vedie k vyhýbaniu sa AI, kým adaptívna, na obozretnosti založená úzkosť môže podporovať bezpečnejšie a reflexívnejšie používanie AI. Oba konštrukty sú determinované technologickými faktormi (presnosť, spoľahlivosť, vysvetliteľnosť, bezpečnosť a ochrana dát), organizačným kontextom (integrácia do pracovných postupov, tréning, klinická validácia, governance) a individuálnymi charakteristikami (predchádzajúca skúsenosť, technologická pripravenosť, profesijná identita). Navrhovaný model sa tým odlišuje od etablovaných rámcov TAM a UTAUT, ako aj od TrAAIT, v ktorých je AI anxiety skôr implicitnou alebo okrajovou premennou, nie centrálnou konceptualizovaným komponentom adopčného procesu.

5.2 Implikácie pre prax a manažment zdravotnej starostlivosti

Z poznatkov vyplýva niekoľko odporúčaní pre manažerov a pre iné záujmové skupiny v zdravotníctve. Po prvé, dôveru v AI nemožno chápať ako prirodzenú vlastnosť zdravotníckeho personálu, ale ako výsledok cieľavedomého budovania prostredníctvom technického dizajnu, validácie a predovšetkým vzdelávania. Čím viac je tendencia rozumieť technológiám, tým vyššia je sanha dôverovať im. Investície do transparentných a pre používateľov zrozumiteľných rozhraní, nezávislých auditov výkonu, klinickej validácie v reálnych prostrediach a štruktúrovaných tréningových programov pred aj počas nasadenia AI sa ukazujú ako kľúčové predpoklady dôvery.

Po druhé, AI anxiety by mala byť systematicky monitorovaná pomocou validovaných nástrojov, keďže existujú už škály zamerané na zdravotníckych profesionálov aj študentov, ktoré zachytávajú špecifické dimenzie tejto úzkosti. Zistenia naznačujú potrebu profilovo špecifickej komunikácie: obavy viazané na profesijnú identitu či stratu autonómie si vyžadujú iný typ intervencie než obavy z technickej nekompetentnosti alebo nedostatku informácií o fungovaní AI.

Po tretie, governance rámce pre AI by nemali byť redukované len na úroveň individuálneho úsudku zdravotníka/doktora, ale mali by fungovať súbežne na úrovni jednotlivca, tímu, oddelenia aj organizácie. Literatúra zdôrazňuje význam jasných politík, auditných mechanizmov, etických komisií a transparentného prerozdelenia zodpovedností medzi AI systémom, zdravotníckym pracovníkom a organizáciou.

Po štvrté, komunikácia s pacientmi by mala cielene adresovať ich obavy a informačné potreby v súvislosti s AI. Štúdie poukazujú na význam jasného vysvetlenia, ako je AI validovaná, monitorovaná a korigovaná, ako aj na dôležitosť zachovania reálnej možnosti odmietnuť AI-asistovanú starostlivosť.

5.3 Výskumné medzery

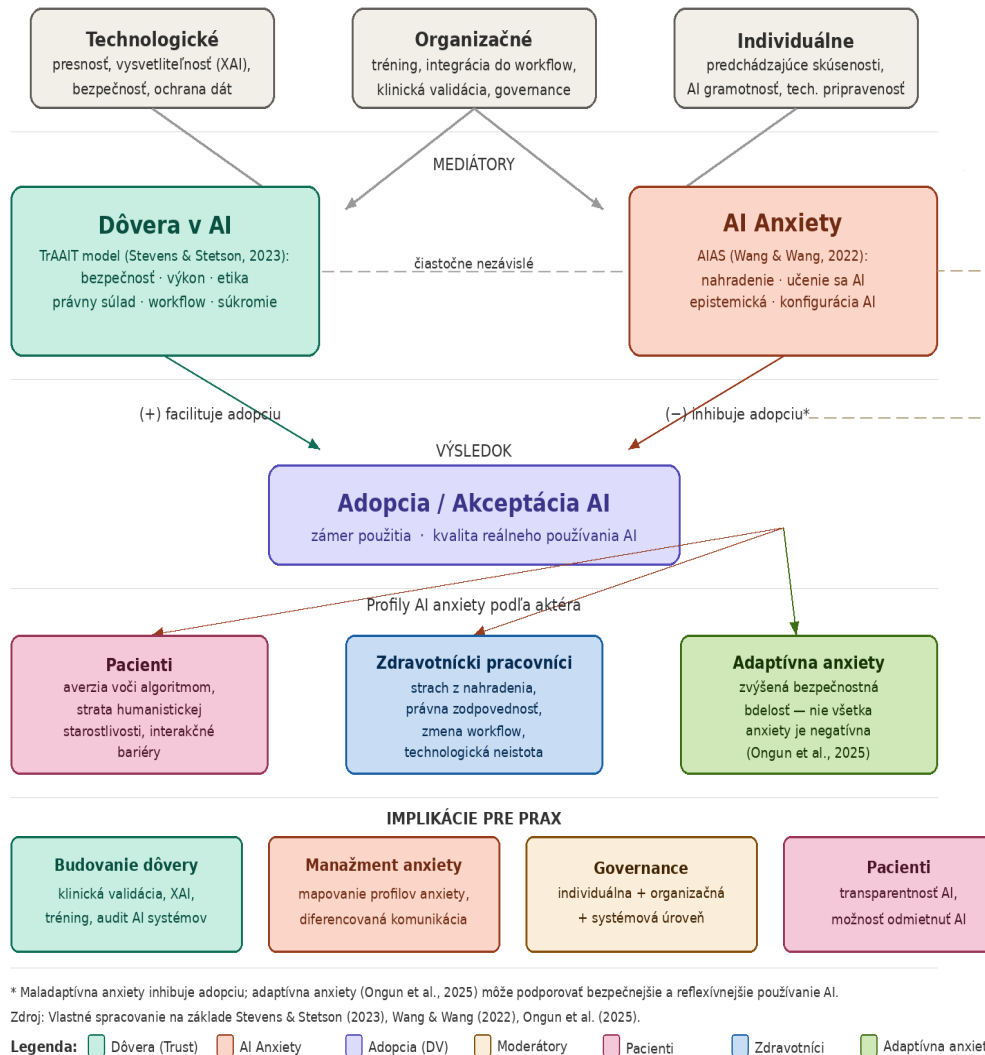
Väčšina empirických prác modeluje dôveru a AI anxiety oddelene a využíva nástroje zamerané buď na AI trust, alebo na technologickú úzkosť, zriedkavejšie ich spája v jednom ucelenom psychometrickom rámci. Chýba validovaný multikonštruktový nástroj, ktorý by súčasne zachytával dimenzie dôvery (napr. podľa TrAAIT), dimenzie AI anxiety a zámer adopcie a ktorý by bol použiteľný v multilingválnych zdravotníckych prostrediach. Vývoj a cross-kultúrna validácia takéhoto nástroja, následne využitého v modelovaní štruktúrnymi rovnicami na testovanie triády dôvera–AI anxiety–adopcia, predstavuje prioritnú teoretickú výskumnú potrebu.

V empirických výskumoch dominujú štúdie zamerané na odborníkov v konkrétnych odboroch, študentov zdravotníckych profesií a pacientov. Pričom manažéri, riaditelia nemocníc a administrátori zostávajú na okraji analytického záujmu. Pritom práve títo aktéri rozhodujú o obstarávaní AI riešení, nastavení interných politík, alokácii zdrojov a spôsobe komunikácie implementačných zmien. Systematický výskum manažérskych profilov dôvery a AI anxiety a ich vplyvu na governance rozhodnutia by významne zvýšil praktickú využiteľnosť poznatkov o dôvere v AI.

Prevažujúci prierezový charakter existujúcich výskumov neumožňuje zachytiť dynamiku vývoja dôvery a AI anxiety v čase, napríklad počas celého implementačného cyklu AI od prípravy, cez pilotné nasadenie až po rutinné používanie. Len málo štúdií sleduje, ako tréning, programy zvyšovania AI gramotnosti či zmeny pracovného prostredia ovplyvňujú dlhodobé trajektórie dôvery, úzkosti a pohody zdravotníkov. Longitudinálne výskumy zamerané na vzťah medzi AI literacy, hybridným pracovným prostredím a dlhodobými výsledkami v oblasti

dôvery, psychickej záťaže a kvality starostlivosti by preto doplnili dôležitú chýbajúcu dimenziu poznania.

Obrázok 1
Konceptuálny model AI trust, AI anxiety a adopcie v zdravotníctve



Zdroj: vlastné spracovanie

6 Záver

Systematický prehľad empirických štúdií ukazuje, že dôvera v AI a AI anxiety sú centrálné, čiastočne nezávislé a spolu rozhodujúce determinanty adopcie AI v zdravotníckych organizáciách. Dôvera funguje ako kľúčová premenná prepájajúca technologickú kvalitu AI so skutočným používaním, zatiaľ čo AI anxiety predstavuje viacrozmerný psychologický konštrukt s odlišnými profilmi u zdravotníkov a pacientov, ktorý môže mať maladaptívne aj adaptívne prejavy. Výsledky naznačujú potrebu rozšíriť etablované modely TAM, UTAUT a TrAAIT o explicitnú anxiety dimenziu a o silnejšie ukotvenie v organizačnom a governance kontexte zdravotníctva.

Pre manažment zdravotníckych organizácií z toho vyplýva, že dôveru v AI treba systematicky budovať prostredníctvom transparentného dizajnu, klinickej validácie, tréningu a jasných governance štruktúr, zatiaľ čo AI anxiety je potrebné monitorovať a adresovať diferencovanými komunikačnými a podpornými stratégiami pre pacientov a zdravotníkov.

Kľúčovými výskumnými prioritami zostávajú vývoj integrovaných meracích nástrojov pre dôveru a AI anxiety, zapojenie manažérov a lídrov do empirických štúdií, lepšie pokrytie stredo európskeho kontextu a longitudinálne analýzy zachytávajúce dynamiku týchto konštruktov v priebehu implementácie AI.

Použitá literatúra (References)

- Arvai, N., et al. (2025). Health care professionals' concerns about medical AI and psychological barriers and strategies for successful implementation: Scoping review. *Journal of Medical Internet Research*, 27, e66986. <https://doi.org/10.2196/66986>
- Asan, O., et al. (2020). Artificial intelligence and human trust in healthcare: Focus on clinicians. *Journal of Medical Internet Research*, 22(6), e15154. <https://doi.org/10.2196/15154>
- Astobiza, A. M., et al. (2025). Trust and AI in healthcare: A systematic review. *Monash Bioethics Review*. Advance online publication. <https://doi.org/10.1007/s40592-025-00272-z>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>
- Grand View Research. (2025). AI in healthcare market size, share & trends analysis report. Retrieved from <https://www.grandviewresearch.com/industry-analysis/artificial-intelligence-ai-healthcare-market>
- Jermutus, E., et al. (2022). Influences on user trust in healthcare artificial intelligence: A systematic review. *Wellcome Open Research*, 7, 65. <https://doi.org/10.12688/wellcomeopenres.17550.1>
- Lambert, S. I., et al. (2023). An integrative review on the acceptance of artificial intelligence among healthcare professionals in hospitals. *npj Digital Medicine*, 6(1), 111. <https://doi.org/10.1038/s41746-023-00852-5>
- Li, W., & Liu, X. (2025). Anxiety about artificial intelligence from patient and doctor perspectives. *Patient Education and Counseling*, 133, 108619. <https://doi.org/10.1016/j.pec.2024.108619>
- McAllister, D. J. (1995). Affect- and cognition-based trust as foundations for interpersonal cooperation in organizations. *Academy of Management Journal*, 38(1), 24–59. <https://doi.org/10.2307/256727>
- McKnight, D. H., & Chervany, N. L. (2001). What trust means in e-commerce customer relationships: An interdisciplinary conceptual typology. *International Journal of Electronic Commerce*, 6(2), 35–59. <https://doi.org/10.1080/10864415.2001.11044235>
- Nirgiz, C., et al. (2026). The relationship between nurses' anxiety and attitudes towards artificial intelligence and examination of influencing factors. *BMC Nursing*, 25, 122. <https://doi.org/10.1186/s12912-026-04293-9>
- Ongun, P., et al. (2025). Artificial intelligence anxiety and patient safety attitudes among operating room professionals: A descriptive cross-sectional study. *Healthcare*, 13(16), 2021. <https://doi.org/10.3390/healthcare13162021>
- Page, M. J., et al. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Reddy, S., et al. (2020). A governance model for the application of AI in health care. *Journal of the American Medical Informatics Association*, 27(3), 491–497. <https://doi.org/10.1093/jamia/ocz192>

Rogers, E. M. (2003). *Diffusion of innovations* (5th ed.). Free Press.

Schulz, P. J., et al. (2023). Modeling the influence of attitudes, trust, and beliefs on endoscopists' acceptance of artificial intelligence applications in medical practice. *Frontiers in Public Health*, 11, 1301563. <https://doi.org/10.3389/fpubh.2023.1301563>

Starke, G., et al. (2025). Finding consensus on trust in AI in health care: Recommendations from a panel of international experts. *Journal of Medical Internet Research*, 27, e56306. <https://doi.org/10.2196/56306>

Stevens, A. F., & Stetson, P. D. (2023). Theory of trust and acceptance of artificial intelligence technology (TrAAIT): An instrument to assess clinician trust and acceptance of artificial intelligence. *Journal of Biomedical Informatics*, 148, 104550. <https://doi.org/10.1016/j.jbi.2023.104550>

Venkatesh, V., et al. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>

Webster, J., & Watson, R. T. (2002). Analyzing the past to prepare for the future: Writing a literature review. *MIS Quarterly*, 26(2), xiii–xxiii.

Clean Energy Investment Growth, Grid Adequacy, and Regional Concentration: Evidence from Global Investment Trends (2015–2024)

Maksym Mykhei, Katarína Čulková, Henrieta Pavolová, Anna Tabišová, Ivana Tkáčová

Abstract

This study examines global energy investment dynamics over 2015–2024 and the regional allocation of clean-energy investment across major world regions in 2019 and 2024 using investment data reported in real 2023 USD (MER). Results show a marked shift toward clean energy: clean investment increased from USD 1,125 bn in 2015 to USD 2,003 bn in 2024, raising the clean share of total energy investment from 45.0% to 64.2%. Growth decomposition indicates that renewables and energy efficiency/end use account for the majority of the net clean-investment increase, whereas grids and storage contribute a smaller share. Grid adequacy indicators reveal a declining grid-to-renewables ratio, suggesting that enabling infrastructure is not scaling in proportion to renewable investment. Regional analysis finds strong heterogeneity and a modest rise in concentration of clean investment across major regions, with HHI ($\times 10,000$) increasing from 657 (2019) to 740 (2024). The findings highlight a dual challenge for the next phase of the transition: accelerating grid and flexibility investment relative to renewables and reducing spatial disparities driven by capital-cost and risk differentials.

JEL klasifikácia: O13

Kľúčové slová: Clean energy investment; energy transition; electricity grids and storage; investment concentration; Herfindahl–Hirschman Index (HHI); renewable energy; energy efficiency; cost of capital; regional inequality; IEA World Energy Investment

1 Introduction

The energy transition is increasingly defined not only by technology choices but by the scale, composition, and spatial allocation of investment. While global capital flows into clean energy have accelerated, the transition's effectiveness depends on whether investment is balanced across system components—particularly electricity networks and flexibility—and whether it diffuses beyond a small set of leading regions. If renewable generation expands faster than grids and storage, the system may face congestion, curtailment, and integration constraints that slow decarbonization gains. At the same time, if clean investment remains geographically concentrated, regions with higher financing risk and limited institutional capacity may fall behind, reinforcing unequal transition pathways.

Against this background, this study provides an investment-based assessment of (i) how the composition of clean-energy investment evolved over 2015–2024, (ii) whether grid-related investment kept pace with renewable investment, and (iii) how concentrated clean investment is across major world regions between 2019 and 2024. Using harmonised investment categories reported in real 2023 USD (MER), the analysis combines trend indicators, growth decomposition, grid-intensity metrics, and a concentration measure (HHI). By linking technology composition to spatial concentration, the study contributes evidence on two interrelated risks for the transition: infrastructure underprovision and regional divergence in investment capacity.

2 Current State of the Solved Problem at Home

Spatial unevenness in the energy transition is repeatedly identified in the literature as a structural—not random—phenomenon: capital, innovation, and the benefits of low-carbon

technologies tend to concentrate in regions with higher purchasing power, stronger institutions, more stable regulatory environments, and lower financing risk. The economic-geography perspective on clean-tech finance explains this concentration through agglomeration effects, the presence of investment ecosystems, and spatially differentiated policy incentives that channel capital toward locations with lower perceived risk and higher expected returns (Knight, 2010; Knight, 2012). A complementary normative strand on “clean energy equity” cautions that even well-intentioned green policies and financing schemes can be distributionally regressive if they structurally favour larger actors with superior access to capital and greater ability to optimise within financial programs (Mormann, 2019).

Regional disparities are documented across multiple, interconnected dimensions of the transition, with some of the most robust evidence emerging from subnational studies. In China, inequality is already evident at the knowledge-creation stage: Zhao et al. (2022) report substantial regional inequality in renewable-energy innovation, with knowledge stocks and R&D expenditures as key determinants. Inequality also manifests in structural energy outcomes. Li et al. (2024) find pronounced spatial differences in renewable-energy consumption, highlighting inter-group disparity as the dominant contributor to overall inequality. Related work shows widening regional disparities in energy intensity linked to heterogeneous regulatory regimes and technology levels (Shao et al., 2020), while inequality in low-carbon development is associated with variation in energy intensity and regional economic conditions (Liu et al., 2020). Collectively, these studies imply that expansion of low-carbon activity does not automatically produce convergence; instead, transition dynamics may coexist with persistent or widening regional gaps in the absence of compensatory mechanisms and coordination.

A major—yet often insufficiently operationalised—mechanism of inequality concerns the allocation of infrastructure investment capacity. Yang et al. (2020) show that power-grid investment can serve as a cohesion instrument when directed toward less developed areas, while also highlighting trade-offs between short-run growth effects and equality objectives. System-transition modelling further suggests that least-cost optimisation tends to generate spatially concentrated impacts, whereas explicit equality objectives produce different (and typically more costly) spatial configurations (Sasse & Trutnevyte, 2020). Subsequent evidence indicates that even a low-carbon electricity sector can sustain uneven distributions of benefits and vulnerabilities across space (Sasse & Trutnevyte, 2023). In the United States, Chen et al. (2024) map spatial heterogeneity in “inequity potential” during the clean-energy transition and argue for place-based policy design; similarly, Ding et al. (2023) identify spatial disparity in utility-scale solar deployment and show that policy design can exacerbate these disparities. Together, these findings align with the proposition that the interaction between local conditions and incentive structures shapes inequality in transition outcomes.

Distributional issues also appear strongly in household-level adoption of low-carbon technologies and demand-side measures. Mechanisms of cumulative advantage help explain why higher-income areas adopt low-carbon technologies faster and why gaps may become self-reinforcing through peer diffusion and social-network effects (Stewart, 2022). Evidence on residential solar adoption indicates persistent disparities over time and across settlement types, with local policies and market processes either dampening or amplifying gaps (Dokshin et al., 2024). A systematic review by Konzen et al. (2024) documents that rooftop solar incentives are often regressive and concentrate adoption among affluent households. Methodologically, Tidemann et al. (2019) warn that spatial aggregation can mask inequities, implying that the apparent magnitude of concentration depends on the level of spatial resolution.

A related strand examines distributional consequences of policy instruments, particularly tax credits and subsidies. Borenstein and Davis (2015) show that U.S. clean-energy tax credits

are disproportionately captured by higher-income households, underscoring the pivotal role of incentive design in equity outcomes. Work on the justice implications of clean-energy programs similarly reports uneven allocation of support across socio-economic and demographic groups (Sustainability, 2019). In a broader environmental-justice frame, Goforth and Nock (2022) demonstrate that decarbonization strategies can either reduce or reproduce air-pollution disparities depending on whether equity objectives are explicitly embedded in policy design. These results imply that least-cost strategies can generate concentrated impacts that may overlap with investment concentration.

For a global perspective, it is essential to connect the spatial concentration of clean-energy investment with financial constraints, since differences in the cost of capital and access to financial instruments can shape where and in what structure clean investment occurs. Studies spanning developing regions and cross-country panels suggest that financial development can support renewable-energy outcomes, but its effect is weakened by the context of income inequality (Asongu & Odhiambo, 2020). He and Jones (2025) further indicate that income inequality can reduce the effectiveness of renewable-energy investment, whereas ICT development can strengthen investment efficiency, suggesting heterogeneous mechanisms beyond capital availability. Li et al. (2025) show that the impact of renewables on energy intensity depends on income inequality, underscoring the need to account for heterogeneity when interpreting regional differences. At the same time, the empirical literature does not converge on whether renewables increase or reduce inequality: Apergis (2015) reports a positive association between renewable production and inequality in OECD contexts, whereas other work identifies inequality-mitigating effects in specific settings (Meng & Kozybay, 2024; Amin et al., 2022). This inconsistency suggests that investment concentration and its consequences cannot be evaluated without explicit regional differentiation and technology segmentation.

Policy uncertainty and public-finance design are additional mechanisms that shape the spatial allocation of investment. Emami Meybodi and Owjimehr (2024) show that climate policy uncertainty can alter the relationship between renewables and energy inequality, with effects varying across country income groups. In the European context, Florkowski and Rakowska (2022) show that cohesion funding can help overcome up-front cost barriers but may remain geographically concentrated. Bharadwaj et al. (2022) provide evidence that spatially targeted subsidies can reduce energy disparities in developing contexts, supporting interventions such as de-risking and targeted financial schemes. In the sphere of development-finance programs, geographic selectivity is also visible: Coma-Cunill et al. (2009) document a concentrated investment plan for concentrated solar power in MENA that mobilises co-financing but also reflects selective allocation across countries and projects. Taken together, these findings imply that public and development-finance instruments may either mitigate concentration (when designed to support underinvested regions) or reproduce it (when mirroring market preferences for low risk).

Methodologically, several contributions relevant to concentration analysis emerge from broader scholarship on spatial inequality. Barbieri et al. (2023) find associations between green-technology development and rising income inequality in U.S. metropolitan areas, consistent with the hypothesis that technological investment can have inequality-enhancing side effects. Feng et al. (2023) document regionally heterogeneous effects of renewable innovation on environmental efficiency across unevenly developing areas. Wei and Ye (2009) and Buckwalter (1995) represent a broader tradition of studying spatial investment flows and inequality, supporting the use of capital-concentration measures in empirical analysis beyond the energy sector. Register et al. (2012) add a perspective on concentration across renewable-industry subsectors, although its contemporary relevance for global clean-investment flows is more

limited. Wells (2012) broadens the system view by linking industrial and environmental policy and highlighting risks of interregional competition and inequality during the transition to electric mobility. Although older and outside the contemporary clean-energy core, Rose et al. (1982) caution that energy projects can alter income distributions, so increased investment should not be assumed to yield equitable outcomes automatically.

Synthesising these strands reveals two consistent analytical gaps. First, much of the empirical evidence on inequality is anchored in subnational distributional outcomes, while macro-level quantification of clean-investment concentration across major world regions—using consistent investment categories over time—remains less systematically developed. Second, although inequality-renewables research is extensive, there is weaker integration between the technology composition of investment (especially grids and flexibility) and the financial constraints (cost of capital, risk, and the ability to mobilise private capital) that shape investment feasibility, particularly in regions with lower investment capacity. Against this background, it is analytically justified to assess the concentration of clean-energy investment across regions using concentration indices (e.g., HHI) while simultaneously evaluating whether investment into grids and flexibility keeps pace with renewables, given that infrastructure constraints are repeatedly identified as potential bottlenecks for system-wide transition.

Research questions

- RQ1: How did the technology composition of clean-energy investment (renewables, electricity grids and storage, energy efficiency and end use, nuclear and other clean energy, and low-emission fuels) evolve over 2015–2024, and what is the relative trajectory of grid investment compared with renewable-generation investment?
- RQ2: To what extent are clean-energy investments spatially concentrated across major world regions in 2019 and 2024 (measured by regional shares and the Herfindahl–Hirschman Index), and how has this concentration changed?
- RQ3: How do the dynamics of clean-energy investment and its components differ across major regions (e.g., China, the United States, the European Union, India, Latin America, Southeast Asia, and Africa) in terms of growth, composition, and infrastructure intensity (grids and storage)?

3 Research design and methodology

3.1 Research design

This study applies a descriptive–comparative quantitative design to assess (i) the evolution of clean-energy investment composition over time, (ii) the degree of spatial concentration of clean-energy investment across major world regions, and (iii) the relative pace of investment into electricity grids and storage compared with investment into renewable generation. The empirical strategy is based on constructing a consistent set of investment indicators and concentration metrics from harmonised investment accounts, followed by trend analysis and cross-regional comparison.

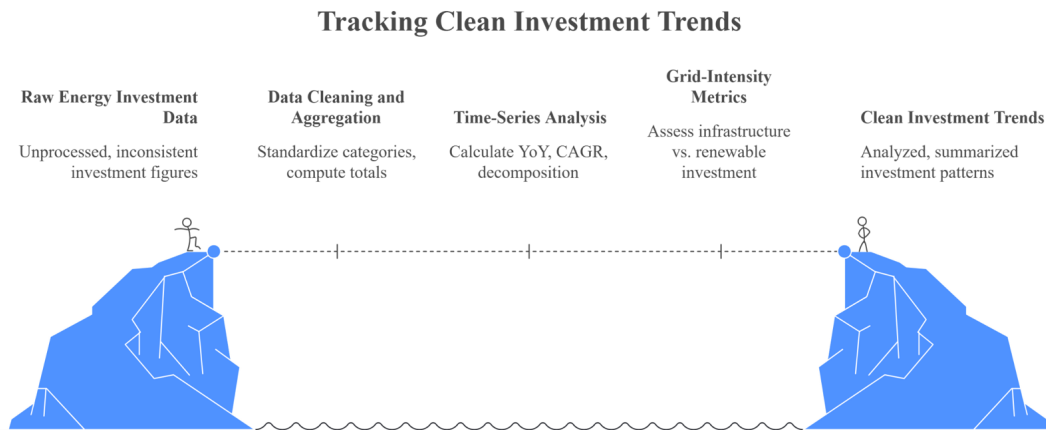
3.2 Data sources and sample

All investment figures are taken from the International Energy Agency (IEA) World Energy Investment 2024 dataset and are expressed in real 2023 USD at market exchange rates (MER), consistent with the IEA reporting convention. The IEA defines investment as ongoing annual capital spending on assets, aligned with capital expenditure concepts, and reports time series in real 2023 USD terms adjusted for inflation.

The analysis uses (a) a global time series (2015–2024) by investment category; (b) a regional cross-section for 2019 and 2024 for major economies/regions (China, United States,

European Union, India, Latin America, Southeast Asia, Africa); and (c) a supplementary time series on clean-energy manufacturing investment (photovoltaics and other manufacturing technologies, 2021–2024). Financing-source shares reported by the IEA (commercial/public/DFI; and investor-type shares corporate/households/governments-SOEs) are treated as contextual descriptors and used only to support interpretation in the discussion, not as inputs to the main indicator construction.

Figure 1
Procedural workflow



Source: our elaborations

3.3 Variable construction

Investment categories follow IEA definitions: Fossil fuels, Renewable energy, Electricity grids and storage, Nuclear and other clean energy, Energy efficiency and end use, and Low-emission fuels. Based on these categories, the analysis constructs the following indicators.

Clean-energy aggregate and total investment

Clean-energy investment is defined as:

$$Clean = Renewable + Grids + Nuclear + Efficiency + LowEmission \quad [1]$$

Total energy investment is defined as:

$$Total = Fossil + Clean \quad [2]$$

Composition and growth indicators (RQ1)

Technology composition is assessed using category shares within *Clean* and within *Total*. Growth is quantified using:

Year-on-year growth (YoY):

$$YoY_t = \frac{X_t}{X_{t-1}} - 1 \quad [3]$$

Compound annual growth rate (CAGR) over n years:

$$CAGR = \left(\frac{X_{end}}{X_{start}} \right)^{1/n} - 1 \quad [4]$$

Contribution (decomposition) of categories to clean-growth over a period:

$$Contribution_i = \frac{\Delta Category_i}{\Delta Clean} = \frac{Category_e - Category_s}{Clean_e - Clean_s} \quad [5]$$

This decomposition attributes the change in Clean to changes in each clean component and is reported as percentages.

Grid “bottleneck” indicators (RQ1 & RQ3)

To quantify the relative adequacy of grid investment vis-à-vis renewable deployment, three indicators are constructed.

- Grid share in clean:

$$GridShare = \frac{GridsStorage}{Clean} \quad [6]$$

- Grid-to-renewables ratio:

$$GridToRenew = \frac{GridsStorage}{Renewable} \quad [7]$$

- Relative growth differential: comparison of $CAGR_{Renewable}$ vs. $CAGR_{GridsStorage}$ (and/or YoY differentials) to test whether grid investment keeps pace with renewable investment.

Regional clean investment levels and concentration (RQ2)

For the regional dataset, the IEA table reports Total investment by region and year. Regional clean investment is therefore derived as.

$$Clean_r = Total_r - Fossil_r \quad [8]$$

Regional shares of clean investment are computed as:

$$Share_r = \frac{Clean_r}{\sum_r Clean_r} \quad [9]$$

Spatial concentration is measured using:

- Herfindahl–Hirschman Index (HHI): $HHI = \sum_r Share_r^2$ (also reported as HHI x 10000 for readability).
- CR3 (optional but interpretable): the combined share of the three largest regions in clean investment. Because the regional set does not include a full “Rest of world” aggregate, HHI is interpreted as concentration *within the set of included regions*, not as a complete global concentration estimate.

3.4 Analytical strategy and outputs

The empirical analysis proceeds in three blocks aligned with the research questions: (i) global trend and composition analysis (levels, shares, YoY, CAGR, and contribution decomposition); (ii) grid-intensity analysis using *GridShare* and *GridToRenew* across time and regions; and (iii) regional concentration analysis using clean shares, HHI (and CR3), including a comparison of 2019 vs. 2024 to identify whether concentration has increased or declined. Results are reported through summary tables and figures (time-series lines for clean vs. fossil and *GridToRenew*; stacked composition charts; and regional share/concentration visuals). All computations are replicable using spreadsheet software, with formulas explicitly defined above.

3.5 Limitations

First, investment estimates follow IEA accounting conventions and modelling assumptions; consequently, category boundaries and the treatment of multi-year project spending reflect the IEA methodology and may differ from alternative datasets. Second, the regional concentration metric is computed on the available set of major regions, which may bias concentration upward relative to a full global partition that includes a residual “rest of world.” Third, grid and storage are aggregated into a single category, limiting separate inference on network expansion versus storage scaling.

4 Research Result

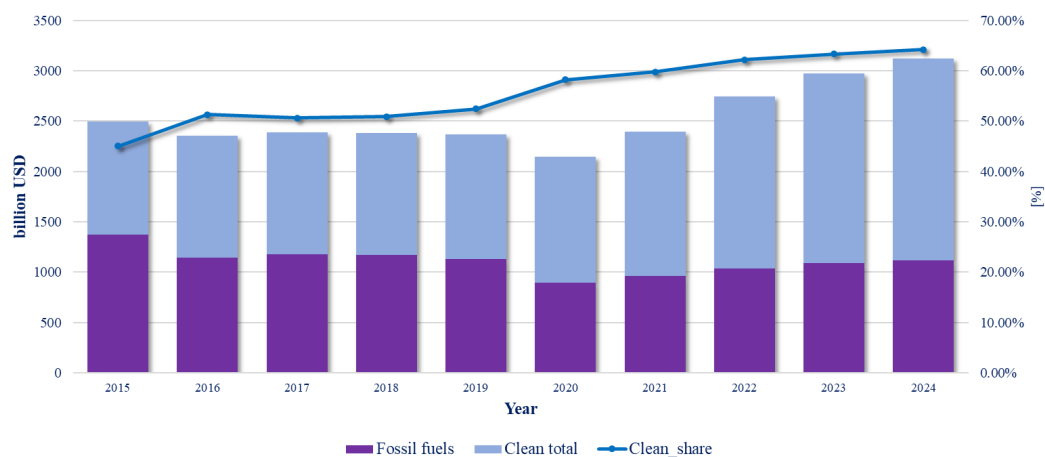
Across 2015–2024 (real 2023 USD, MER), global energy investment exhibits a clear reallocation from fossil fuels toward clean energy. Fossil-fuel investment declined from USD 1,374 bn in 2015 to USD 1,116 bn in 2024, while total clean-energy investment increased from USD 1,125 bn to USD 2,003 bn.

This shift is reflected in the clean share of total energy investment, which rose from 45.0% (2015) to 64.2% (2024), while the fossil share fell from 55.0% to 35.8%. In ratio terms, clean investment moved from being lower than fossil investment in 2015 (clean-to-fossil = 0.82) to nearly 1.80× fossil investment by 2024.

The trajectory of this structural change is not linear and accelerates after 2020. In 2016, clean investment grew by 7.38% year-on-year while fossil investment contracted by 16.67%, lifting the clean share above 50% for the first time in the series. The 2020 shock is visible as a sharp contraction in fossil investment (−20.41% YoY), accompanied by continued, albeit modest, growth in clean investment (+0.48% YoY), pushing the clean share to 58.2%.

Figure 2

Total energy investment and the rising clean-energy share, 2015–2024



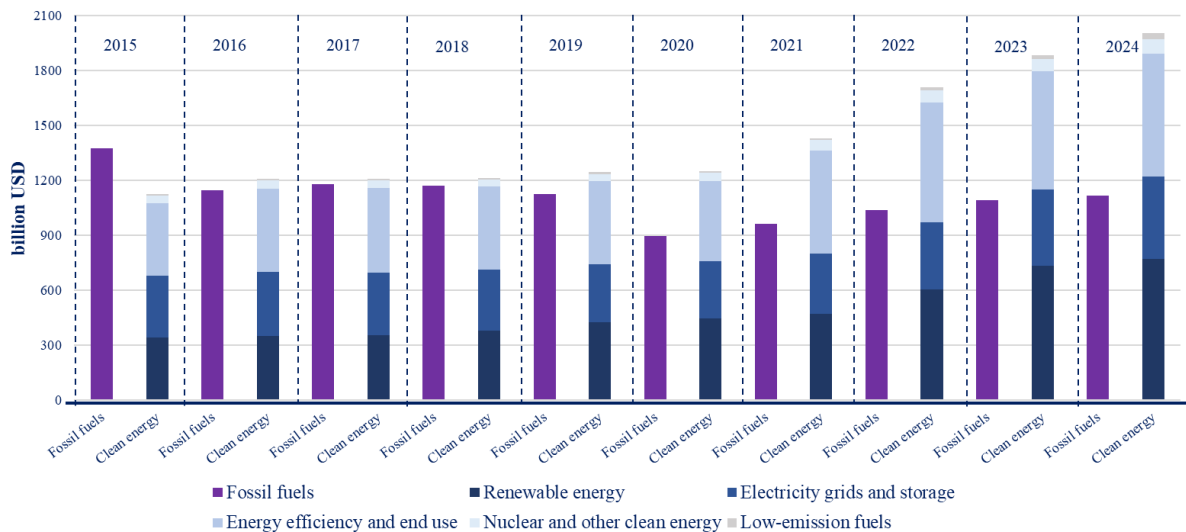
Source: our elaborations

From 2021 onward, clean investment growth consistently outpaced fossil growth: clean expanded by 14.48% (2021) and 19.29% (2022), before moderating to 10.37% (2023) and 6.32% (2024). Fossil investment recovered in 2021–2024, but at lower momentum (+7.36%, +7.58%, +5.21%, +2.39%, respectively), reinforcing the dominant role of clean-energy expansion in driving the post-2020 increase in total energy investment.

In terms of clean-energy composition, renewables and energy efficiency/end use dominate both investment levels and growth over the period. Renewable-energy investment increased from USD 343 bn (2015) to USD 771 bn (2024), while energy efficiency/end use rose from USD 393 bn to USD 669 bn.

Figure 3

Global energy investment by category, 2015–2024: fossil fuels versus clean-energy components



Source: our elaborations


Electricity grids and storage grew more moderately—from USD 338 bn to USD 452 bn—and nuclear/other clean energy increased from USD 43 bn to USD 80 bn, while low-emission fuels rose from USD 8 bn to USD 31 bn.

A decomposition of the total increase in clean investment between 2015 and 2024 ($\Delta_{\text{clean}} = \text{USD } 878 \text{ bn}$) indicates that renewables contribute the largest share (48.75%), followed by energy efficiency/end use (31.44%). Grids and storage account for 12.98%, nuclear/other clean energy for 4.21%, and low-emission fuels for 2.62%. This pattern implies that nearly four-fifths of the net clean-investment increase is driven by renewables and efficiency, rather than by grid infrastructure or fuel-switching technologies.

Grid-intensity indicators suggest a relative decoupling between renewable generation investment and enabling infrastructure investment. The grid share within clean investment declined from 30.0% in 2015 to 22.6% in 2024.

Figure 4

Grid investment adequacy and drivers of clean-energy investment growth, 2015–2024



Source: our elaborations

Consistently, the grid-to-renewables ratio decreased from approximately 0.99 (2015) to 0.59 (2024), following a predominantly downward trajectory after 2016 with only a minor uptick in 2024 relative to 2023. Substantively, this indicates that each dollar invested in renewables is associated with progressively fewer cents invested into grids and storage than earlier in the period, consistent with a growing risk that network expansion and system flexibility may lag behind renewable capacity additions.

Regional results for 2019–2024 indicate a strong expansion of clean-energy investment across all major regions in the sample, but with substantial heterogeneity in both the pace of growth and the internal technology mix. Aggregate clean investment across the included regions increased from USD 953 bn (2019) to USD 1,615 bn (2024), while total energy investment rose from USD 1,674 bn to USD 2,309 bn, confirming that the clean-energy expansion was not merely a compositional shift but also accompanied by higher overall investment volumes (Table 1).

Table 1

Regional change in energy investment by segment (2019–2024): absolute changes (USD bn, real 2023 MER) and relative changes (%)

	Δ Fossil	Δ RES	Δ Grids	Δ Nuclear	Δ Efficiency	Δ Low-em	Δ Total clean energy	Δ Total energy
billion USD								
China	-12	195	8	12	68	4	287	275
United States	-31	29	34	4	37	6	110	79
European Union	7	52	60	8	61	3	184	191
India	7	25	0	3	8	0	36	43
Latin America	22	19	8	3	-5	2	27	49
Southeast Asia	-8	-4	0	0	4	1	1	-7
Africa	-12	13	2	1	0	1	17	5
	Δ Fossil	Δ RES	Δ Grids	Δ Nuclear	Δ Efficiency	Δ Low-em	Δ Total clean energy	Δ Total energy
China	-6.09%	118.90%	9.88%	200.00%	56.67%	400.00%	77.15%	48.33%
United States	-13.60%	51.79%	45.95%	66.67%	71.15%	300.00%	57.89%	18.90%
European Union	24.14%	96.30%	98.36%	114.29%	59.22%	300.00%	81.42%	74.90%
India	23.33%	208.33%	0.00%	150.00%	66.67%	0.00%	100.00%	200.00%
Latin America	27.50%	86.36%	66.67%	0.00%	-23.81%	100.00%	47.37%	35.77%
Southeast Asia	-10.39%	-21.05%	0.00%	0.00%	66.67%	100.00%	2.70%	-6.14%
Africa	-15.00%	144.44%	25.00%	0.00%	0.00%	0.00%	100.00%	200.00%

Source: our elaborations

China remained the dominant contributor in absolute terms, with clean-energy investment increasing from USD 372 bn (2019) to USD 659 bn (2024), representing an absolute increase of USD 287 bn and a relative expansion of 77.2%. This growth was primarily driven by renewables (+USD 195 bn) and energy efficiency/end-use (+USD 68 bn), while fossil investment marginally declined (–USD 12 bn). The clean share in China rose from 65.4% to 78.1%, indicating a substantial reorientation of investment away from fossil fuels.

The European Union had the largest clean share among major regions and maintained a high level of clean intensity. Clean investment increased from USD 226 bn to USD 410 bn (+USD 184 bn; +81.4%), while the clean share rose from 88.6% to 91.9%, reflecting a system already dominated by clean investment categories. The EU's growth profile is notable for the balanced expansion of renewables (+USD 52 bn) and electricity grids and storage (+USD 60 bn), alongside a substantial increase in efficiency/end-use (+USD 61 bn), suggesting parallel investment into both supply-side and enabling infrastructure.

The United States expanded clean-energy investment from USD 190 bn to USD 300 bn (+USD 110 bn; +57.9%) while fossil investment declined from USD 228 bn to USD 197 bn (–USD 31 bn). The clean share increased from 45.5% to 60.4%, indicating a transition from a fossil-dominant to a clean-majority investment structure over the period. In contrast to China and the EU, U.S. growth shows a relatively strong increase in grids and storage (+USD 34 bn) and efficiency/end-use (+USD 37 bn) compared with renewables (+USD 29 bn), suggesting a more infrastructure- and demand-oriented composition of the clean expansion.

India recorded the strongest proportional increase in total energy investment within the sample, with total energy rising from USD 75 bn to USD 118 bn (+USD 43 bn; +57.3%) and clean investment doubling from USD 45 bn to USD 81 bn (+USD 36 bn; +80.0%). The clean share increased from 60.0% to 68.6%, driven primarily by renewables (+USD 25 bn) and efficiency/end-use (+USD 8 bn). At the same time, grids and storage remained flat (no net increase), which may indicate a potential infrastructure lag relative to generation expansion.


Latin America shows a more mixed pattern. Clean investment rose from USD 57 bn to USD 84 bn (+USD 27 bn; +47.4%) while total energy increased from USD 137 bn to USD 186 bn (+USD 49 bn; +35.8%). However, the region also experienced a substantial rise in fossil investment (+USD 22 bn), and the clean share increased only modestly from 41.6% to 45.2%. Importantly, energy efficiency/end-use declined (–USD 5 bn; –23.8%), while renewables and grids increased (+USD 19 bn and +USD 8 bn), suggesting a reallocation away from demand-side measures toward supply and infrastructure.

Southeast Asia exhibited near-stagnation in clean investment. Clean investment increased only marginally from USD 37 bn to USD 38 bn (+USD 1 bn; +2.7%), while total energy investment declined from USD 114 bn to USD 107 bn (–USD 7 bn; –6.1%). Renewables decreased (–USD 4 bn; –21.1%), grids were flat, and the limited clean-growth was driven by efficiency/end-use (+USD 4 bn) and low-emission fuels (+USD 1 bn). This profile is consistent with an uneven or delayed scaling of renewable investment in the region relative to other major regions.

Africa shows a low base but rapid proportional growth in clean investment, increasing from USD 26 bn to USD 43 bn (+USD 17 bn; +65.4%) and raising the clean share from 24.5% to 38.7%. This improvement is supported by increased renewables (+USD 13 bn), modest growth in grids (+USD 2 bn), and low-emission fuels (+USD 1 bn), alongside a decline in fossil investment (–USD 12 bn). Despite this progress, absolute investment levels remain far below those of major economies, underscoring persistent scale disparities.

Figure 5

Regional distribution and composition of clean-energy investment (2024): clean-investment levels (USD bn) and technology shares by region



Source: our elaborations

Regional concentration metrics suggest that the global expansion of clean investment has been accompanied by a modest increase in concentration among the included regions. China's share of clean investment rose from 39.0% (2019) to 40.8% (2024), while the EU share increased from 23.7% to 25.4% and the U.S. share declined from 19.9% to 18.6%. Correspondingly, the Herfindahl–Hirschman Index increased from $HHI = 0.0657$ ($HHI \times 10,000 = 657$) in 2019 to $HHI = 0.0740$ ($HHI \times 10,000 = 740$) in 2024, indicating a moderate rise in concentration within the observed regional set.

A focused comparison for the European Union confirms both the scale-up of investment volumes and a compositional shift toward system-enabling assets. Total EU energy investment increased from USD 259 bn in 2019 to USD 451 bn in 2024. Over the same period, the fossil component rose slightly in absolute terms (from USD 29 bn to USD 36 bn). However, its share declined from 11% to 8%, indicating that non-fossil segments predominantly drove EU investment expansion.

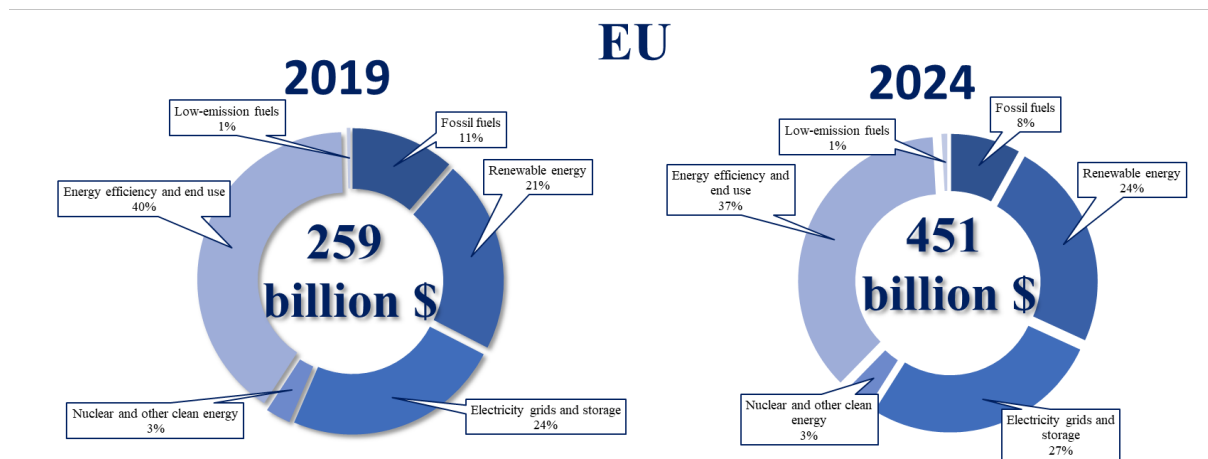
Within the EU portfolio, renewables nearly doubled from USD 54 bn (2019) to USD 106 bn (2024), increasing their share from 21% to 24%. Electricity grids and storage expanded from USD 61 bn to USD 121 bn, with the share rising from 24% to 27%, consistent with intensified investment into infrastructure and flexibility. Energy efficiency and end-use remained the single largest component in absolute terms, increasing from USD 103 bn to USD 164 bn. However, its share declined slightly from 40% to 37%, reflecting faster growth in renewables and grid-related spending. Nuclear and other clean energy increased from USD 7 bn to USD 15 bn (stable at ~3% share). In comparison, low-emission fuels rose from USD 1 bn to USD 4 bn (around

1% of the total), indicating that these segments remained comparatively small within the EU investment profile in both years.

Financing structure results for 2024 highlight a strong dominance of market-based capital in the analysed regional aggregate. Applying the reported financing shares to the 2024 total energy investment of USD 2,309 bn (sample aggregate) yields USD 1,708.66 bn financed by commercial sources (74%), USD 577.25 bn by public sources (25%), and only USD 23.09 bn by development finance institutions (1%). This composition indicates that the investment cycle is primarily sustained by commercial capital, with public funding playing an important but secondary role and DFIs contributing a comparatively marginal volume at the aggregate level—an important contextual result for interpreting cross-regional disparities in investment capacity and risk tolerance.

Figure 6

European Union energy investment structure (2019 vs. 2024): technology composition and total investment volume.



Source: our elaborations

5 Discussion

The results confirm that the 2015–2024 period is characterised by a pronounced reallocation of global energy investment from fossil fuels toward clean-energy segments, with the clean share rising to nearly two-thirds by 2024. This macro-level pattern is consistent with the broad literature that frames the energy transition as a capital-intensive restructuring process, but it also reinforces a core warning from equity- and economic-geography perspectives: aggregate growth alone does not guarantee balanced spatial distribution or system adequacy (Knight, 2010; Knight, 2012; Mormann, 2019). In this respect, our empirical evidence adds two substantive contributions to the existing debate. First, it quantifies how clean investment growth is disproportionately driven by renewables and energy efficiency rather than by grids and flexibility. Second, it shows that clean-energy expansion across major regions is accompanied by a measurable increase in concentration (HHI), implying that the transition’s investment backbone is becoming more geographically centred among a small set of regions.

A central finding with direct theoretical implications is the declining grid-to-renewables ratio over the decade. The ratio falls from approximately parity (≈ 0.99) in 2015 to roughly 0.59 in 2024, while the grid share within clean investment declines from about 30% to 23%. This aligns closely with the “infrastructure constraint” logic documented in power-system transition research, where enabling infrastructure can become a binding constraint when generation investment outpaces network and flexibility capacity. Although much of the literature addresses

this mechanism through modelling of system outcomes, our results complement that work by providing a clear investment-side signal: the capital allocation pattern itself indicates a potential bottleneck. This is conceptually consistent with Sasse and Trutnevte (2020), who show that least-cost pathways generate spatially concentrated and uneven impacts; if grid and flexibility investment lags, least-cost renewable deployment may accelerate where conditions are favourable, while system constraints and congestion risks concentrate elsewhere. Similarly, Yang et al. (2020) demonstrate that grid investment is not a neutral technical category but has macro-distributional consequences; our findings suggest that regions failing to scale grid investment proportionately may be structurally disadvantaged in their ability to absorb renewable additions without rising system costs or reliability risks.

The decomposition of clean investment growth provides an additional interpretive layer: renewables account for nearly half of the net clean increase, energy efficiency for roughly one-third, and grids for only about one-eighth. From a policy and equity standpoint, this composition is ambiguous. On the one hand, the prominence of energy efficiency is consistent with the literature emphasising demand-side interventions as critical for decarbonisation and mitigating household energy burdens in some contexts (Wang et al., 2023). On the other hand, the comparatively modest contribution of grids suggests that investment priorities may be skewed toward assets that are easier to finance or deploy under prevailing market conditions. This interpretation is compatible with the economic geography of clean-tech finance (Knight, 2010, 2012), in which capital tends to flow into segments with clearer revenue models and lower risk. Grid assets often face regulatory complexity, cost-recovery constraints, and long permitting horizons; therefore, an observed decline in grid intensity can be interpreted as a financial–institutional friction rather than purely a technological preference. The literature on policy design and uncertainty further strengthens this reading: under heightened uncertainty, investors may select segments with shorter payback horizons and clearer subsidy structures (Emami Meybodi & Owjimehr, 2024), which can structurally underprovide network investment relative to generation additions.

The regional results demonstrate pronounced heterogeneity and support the literature’s claim that the clean transition is spatially uneven. China, the EU, and the United States account for the overwhelming majority of clean investment in the sample, and the rise in HHI from 657 to 740 indicates increasing concentration within this set. This pattern resonates with the core economic-geography argument that investment ecosystems and institutional settings generate cumulative advantage, leading to persistent capital clustering (Knight, 2010; Knight, 2012). The direction of change is also consistent with evidence of spatial concentration in deployment and benefits, documented for both the United States and Europe (Chen et al., 2024; Sasse & Trutnevte, 2023). However, our results broaden this literature by showing that concentration is not limited to local deployment outcomes; it is visible already at the macro-investment allocation level, suggesting that unequal transition outcomes may be “baked in” through upstream capital flows.

The region-specific trajectories also map onto several mechanisms proposed in the literature. The EU exhibits extremely high clean shares in both 2019 and 2024 and expands renewables, grids, and efficiency in parallel, which is consistent with coordinated policy frameworks and mature regulatory settings capable of sustaining investment across complementary system components. This aligns with cohesion-policy evidence that public funding can reduce upfront barriers, though it may remain geographically concentrated within regions or member states (Florkowski & Rakowska, 2022). The U.S. pattern—rising clean share with strong growth in grids and efficiency—can be interpreted as a partial response to system integration needs and demand-side electrification, consistent with findings that policy design and local market conditions shape adoption and allocation patterns (Ding et al., 2023; Dokshin

et al., 2024). China's large-scale expansion in renewables and efficiency, alongside a smaller proportional increase in grids, mirrors the structural risk highlighted above: even in a leading investor region, grid build-out may not keep pace with renewable scale-up.

By contrast, Southeast Asia and Africa illustrate two different constraints that are frequently discussed but rarely quantified in the same investment framework. Southeast Asia shows near-stagnant clean investment amid declining renewables, consistent with the literature emphasising the role of institutional capacity, financing conditions, and policy credibility in enabling renewable deployment (Asongu & Odhiambo, 2020; Emami Meybodi & Owjimehr, 2024). Africa displays rapid proportional growth from a low base, yet absolute volumes remain far below major economies; this reflects the “scale disparity” problem that underpins many just-transition and cost-of-capital discussions. Even where growth rates are high, low baseline investment can lead to infrastructure and deployment gaps that persist or widen in absolute terms, reinforcing regional inequality dynamics described in the broader inequality literature (Shao et al., 2020; Liu et al., 2020).

The financing structure provides a critical bridge between these empirical patterns and the equity literature. The dominance of commercial financing (74%) at the aggregate level implies that market risk perceptions and return requirements largely shape the transition. This finding closely aligns with the “clean energy equity” critique: when capital allocation is dominated by private finance, regions with higher risk premia and weaker institutions are structurally penalised, potentially leading to unequal access to clean infrastructure and its benefits (Mormann, 2019). It also aligns with the empirical evidence that inequality and financial development interact to shape renewable outcomes: financial development supports renewable energy, but income inequality can weaken its effectiveness (Asongu & Odhiambo, 2020; He & Jones, 2025; Li et al., 2025). In practical terms, the observed rise in concentration and the underweighting of grid investment can both be interpreted as downstream manifestations of a capital-cost gradient: private finance tends to scale where risks are manageable, and revenue models are clearer. In contrast, grids and emerging markets face higher uncertainty and longer payback horizons.

Our regional mix results further suggest that investment composition may itself have distributional consequences, consistent with policy-incidence evidence. The literature on tax credits and program design shows that incentives can be regressive and captured by higher-income groups (Borenstein & Davis, 2015; Konzen et al., 2024), while justice-oriented studies show unequal allocation across demographic and socio-economic groups (Sustainability, 2019). Although our study does not measure household-level incidence, the macro pattern is compatible with the same underlying mechanism. When investment is guided primarily by commercial logic, both geographic allocation and technology selection may systematically favour actors and regions with greater capacity to finance upfront costs. This is particularly relevant for demand-side efficiency and distributed generation, which can be equity-enhancing only if household-level financing constraints are addressed. Otherwise, adoption and benefits may concentrate among affluent groups, reinforcing the “inequality trap” dynamics identified by Stewart (2022).

Importantly, the rise in concentration does not imply that lagging regions are uniformly excluded. India shows strong proportional growth in clean investment, and Africa's share of clean investment improves substantially. These patterns indicate that policy and development pathways can shift investment structures even from low baselines. This is consistent with evidence that spatially targeted subsidies and place-based interventions can reduce disparities (Bharadwaj et al., 2022), and with the broader modelling insight that equality objectives can meaningfully reshape transition outcomes, albeit at the cost of trade-offs (Sasse & Trutnevyte, 2020). Nonetheless, our evidence suggests that without explicit mechanisms to lower risk and

mobilise capital for enabling infrastructure, the investment system may continue to reinforce concentration and infrastructure gaps.

Overall, the findings imply that the transition’s “investment bottleneck” is not primarily a shortage of aggregate clean capital, but a mismatch between where and how capital is allocated—across regions and across enabling system components. This conclusion is coherent with the literature’s emphasis on spatial heterogeneity, cumulative advantage, and policy design. It also highlights a clear policy-relevant implication for future research and practice: addressing regional inequality in the transition likely requires not only more clean investment, but specifically (i) accelerated grid and flexibility spending relative to renewables, and (ii) financing instruments that reduce capital costs and risk premia in underinvested regions.

5.1 Limitations and implications for future research

The discussion should be interpreted with three constraints in mind. First, concentration metrics are computed within the set of major regions included in the dataset and may differ under a full global partition. Second, investment categories aggregate grids with storage and do not allow a granular separation of network expansion versus flexibility assets. Third, the study is descriptive and does not identify causal effects of policies, institutions, or inequality measures. Future research should therefore (i) extend concentration analysis to a complete global set including “rest of world,” (ii) disaggregate grids and storage where possible, and (iii) test causal mechanisms linking financing conditions and policy uncertainty to both investment concentration and grid adequacy using panel methods and risk/cost-of-capital proxies.

6 Conclusion

This study examined the evolution of global energy investment over 2015–2024 and the regional allocation of clean-energy investment across major world regions in 2019 and 2024, to identify (i) changes in the technology composition of clean investment, (ii) whether investment in grids and flexibility is keeping pace with renewable generation, and (iii) the extent of regional concentration of capital in the clean transition. The results document a clear structural reallocation toward clean energy. Global clean-energy investment increased from USD 1,125 bn in 2015 to USD 2,003 bn in 2024, while investment in fossil fuels declined from USD 1,374 bn to USD 1,116 bn. Accordingly, the clean share of total energy investment rose from 45.0% to 64.2%, indicating that clean energy became the dominant investment segment by the end of the period.

In terms of growth drivers, the clean-energy expansion was primarily led by renewables and energy efficiency/end use. Decomposition of the 2015–2024 increase in clean investment ($\Delta_{\text{clean}} = \text{USD } 878 \text{ bn}$) shows that nearly half of the net growth is attributable to renewables and about one-third to efficiency. In contrast, grids and storage contributed a substantially smaller share. This composition matters because the “grid-intensity” evidence suggests a growing risk of underprovisioning of enabling infrastructure. The grid-to-renewables ratio declined from near parity in 2015 to approximately 0.59 in 2024, alongside a decline in the grid share within total clean investment. Taken together, these results indicate that investment flows are expanding renewable generation faster than network expansion and system flexibility, implying an increasing likelihood of grid bottlenecks as the transition progresses.

Regional analysis confirms strong heterogeneity in both scale and dynamics. Across the included major regions, clean investment increased from USD 953 bn in 2019 to USD 1,615 bn in 2024, yet the distribution remained highly uneven. China, the European Union, and the United States accounted for the majority of absolute clean investment volumes. At the same time, regions such as Africa and Southeast Asia remained at much lower levels, even when proportional growth was substantial in some cases. Importantly, regional concentration

increased modestly, reflected in a rise of HHI ($\times 10,000$) from 657 in 2019 to 740 in 2024. This suggests that the global clean transition is increasingly concentrated in a limited set of regions, potentially reinforcing differences in the ability to scale capacity, modernise infrastructure, and implement system-wide decarbonization strategies.

Finally, the financing profile—characterised by a strong dominance of commercial sources—has direct implications for interpreting spatial disparities. When the transition is largely shaped by market-based capital, investment allocation is likely to reflect risk premia and return requirements, potentially disadvantaging regions with higher capital costs and weaker investment conditions. Overall, the findings imply that the next phase of the transition will depend not only on increasing clean investment volumes, but also on improving the system's investment balance—particularly in grids and flexibility—and on mobilising capital in regions facing structural financing constraints. Future research should extend concentration analysis to a complete global partition, including “rest of world,” disaggregate grids versus storage where possible, and empirically test how financing conditions and the cost of capital shape both the spatial distribution of clean investment and the emergence of infrastructure bottlenecks.

References

- Amin, S., Amin, Y. N., Khandaker, M. K., Khan, F., & Rahman, F. M. (2022). Unfolding FDI, renewable energy consumption, and income inequality nexus: Heterogeneous panel analysis. *Energies*. <https://doi.org/10.3390/en15145160>
- Apergis, N. (2015). Does renewables production affect income inequality? Evidence from an international panel of countries. *Applied Economics Letters*. <https://doi.org/10.1080/13504851.2014.982852>
- Asongu, S., & Odhiambo, N. (2020). Inequality, finance and renewable energy consumption in Sub-Saharan Africa. *Renewable Energy*. <https://doi.org/10.1016/j.renene.2020.11.062>
- Barbieri, N., Consoli, D., Marin, G., & Perruchas, F. (2023). Green technology and income inequality: An empirical analysis of US metro areas. *Regional Studies*. <https://doi.org/10.1080/00343404.2023.2171378>
- Baruah, B. (2017). Renewable inequity? Women's employment in clean energy in industrialised, emerging and developing economies. *Gender, Work & Organisation*. <https://doi.org/10.1111/1477-8947.12105>
- Bharadwaj, B., Pattanayak, S. K., & Ashworth, P. (2022). Space matters: Reducing energy disparity in Nepal through spatially equitable renewable energy subsidies. *Environmental Research Communications*. <https://doi.org/10.1088/2515-7620/ac9458>
- Borenstein, S., & Davis, L. W. (2015). The distributional effects of US clean energy tax credits. *Tax Policy and the Economy*. <https://doi.org/10.1086/685597>
- Buckwalter, D. W. (1995). Spatial inequality, foreign investment, and economic transition in Bulgaria. *The Professional Geographer*. <https://doi.org/10.1111/j.0033-0124.1995.00288.x>
- Callaway, D. S., Fowlie, M., & McCormick, G. (2018). Location, location, location: The variable value of renewable energy and demand-side efficiency resources. *Journal of the Association of Environmental and Resource Economists*. <https://doi.org/10.1086/694179>
- Chen, H., Jang, S.-G., Zhang, Y., & Liu, Y. (2024). Clean energy for all? Mapping inequity potential in the clean energy transition in the United States. *Energy Research & Social Science*. <https://doi.org/10.1016/j.erss.2023.103400>

- Coma-Cunill, R., Govindarajalu, C., Pariente-David, S., & Walters, J. (2009). Clean Technology Fund investment plan approved for concentrated solar power in the MENA region. *World Bank*. <https://openknowledge.worldbank.org/handle/10986/10947>
- Deloitte. (2024). Financing the green energy transition: Innovative financing for a just transition (Report page). <https://www.deloitte.com/global/en/issues/climate/financing-the-green-energy-transition.html>
- Ding, Y., Si, Y., Xu, K., Zhang, S., & Wang, Z. (2023). Spatial disparity of utility-scale solar energy and the role of solar policy in the U.S. *Energy Strategy Reviews*. <https://doi.org/10.1016/j.esr.2023.101179>
- Dokshin, F. A., Gherghina, M., & Thiede, B. C. (2024). Closing the green gap? Changing disparities in residential solar installation and the importance of regional heterogeneity. *Energy Research & Social Science*. <https://doi.org/10.1016/j.erss.2023.103338>
- Dziawgo, L. (2021). Energy sectors on the capital market: Financing the process “towards sustainability”. *European Research Studies Journal*, 24(2B), 938–955. <https://doi.org/10.35808/ersj/2316>
- Emami Meybodi, M., & Owjimehr, S. (2024). The nexus of climate policy uncertainty, renewable energy and energy inequality under income disparities. *Energy Strategy Reviews*. <https://doi.org/10.1016/j.esr.2024.101381>
- Feng, C., Yang, X., Afshan, S., & Irfan, M. (2023). Can renewable energy technology innovation improve the green utilisation efficiency of mineral resources? Novel insights from regional development inequality. *Resources Policy*. <https://doi.org/10.1016/j.resourpol.2023.103449>
- Florkowski, W., & Rakowska, J. (2022). Review of regional renewable energy investment projects: The example of EU Cohesion Fund disbursement. *Sustainability*. <https://doi.org/10.3390/su142417007>
- Goforth, T., & Nock, D. (2022). Air pollution disparities and equality assessments of US national decarbonization strategies. *Nature Communications*. <https://doi.org/10.1038/s41467-022-35098-4>
- Goforth, T., & Nock, D. (2021). Inequality in energy transitions: Subnational air pollution disparities resulting from national decarbonization strategies (Preprint). Research Square. <https://doi.org/10.21203/rs.3.rs-945021/v1>
- Guo, S., & Kontou, E. (2020). Disparities and equity issues in electric vehicles rebate allocation (SSRN Working Paper). <https://doi.org/10.2139/ssrn.3687504>
- He, Y., & Jones, D. (2025). Social inequality, ICT development, and renewable energy investment: Implications for ecological sustainability in Central Africa. *Sustainable Development*. <https://doi.org/10.1002/sd.70389>
- International Energy Agency. (2024). World Energy Investment 2024. <https://www.iea.org/reports/world-energy-investment-2024>
- International Energy Agency. (2024). Reducing the cost of capital: Strategies to unlock clean energy investment in emerging and developing economies. <https://www.iea.org/reports/reducing-the-cost-of-capital>
- Knight, E. (2012). The economic geography of financing clean energy technologies. *Competition & Change*, 16(2), 77–90. <https://doi.org/10.1179/1024529412Z.0000000009>

- Knight, E. (2010). The economic geography of clean tech venture capital (SSRN Working Paper). <https://doi.org/10.2139/ssrn.1588806>
- Konzen, G., Best, R., & de Castro, N. D. (2024). The energy injustice of household solar energy: A systematic review of distributional disparities in residential rooftop solar adoption. *Energy Research & Social Science*. <https://doi.org/10.1016/j.erss.2024.103473>
- Laurentis, C., & Pearson, P. (2020). Understanding the spatial unevenness of regional renewable energy deployment: Insights for policy design (Preprint). <https://doi.org/10.21203/rs.3.rs-27946/v1>
- Latham & Watkins. (2024, June). Financing the energy mix in an era of energy transition. <https://www.latham.energy/2024/06/financing-the-energy-mix-in-an-era-of-energy-transition/>
- Li, M., Liu, X., & Yang, M. (2024). Analyzing the regional inequality of renewable energy consumption and its driving factors: Evidence from China. *Renewable Energy*. <https://doi.org/10.1016/j.renene.2024.120043>
- Li, R., Yang, Z., & Wang, Q. (2025). Does renewable energy reduce energy intensity? A matter of income inequality. *Humanities and Social Sciences Communications*. <https://doi.org/10.1057/s41599-025-04439-1>
- Liu, Y., Wang, M., & Feng, C. (2020). Inequalities of China's regional low-carbon development. *Journal of Environmental Management*. <https://doi.org/10.1016/j.jenvman.2020.111042>
- Meng, S., & Kozybay, Z. (2024). A spatial–temporal analysis of income inequality and wind energy development in the U.S. *World Development Sustainability*. <https://doi.org/10.1016/j.wds.2024.100129>
- Mormann, F. (2019). Clean energy equity. *Utah Law Review*, 2019(2). <https://dc.law.utah.edu/ulr/vol2019/iss2/2/>
- Nowak, M., James, V., & Golubchikov, O. (2022). The role of spatial policy tools in renewable energy investment. *Energies*. <https://doi.org/10.3390/en15072393>
- Register, D. L., Lambert, D., English, B., Jensen, K., Menard, R. J., et al. (2012). Geographic distribution of renewable energy sector industries: An analysis using recent developments in industry concentration measurement (AAEA Selected Paper / conference paper). *AgEcon Search record*: <https://ageconsearch.umn.edu/record/124038/>
- Rose, A., Nakayama, B., & Stevens, B. K. (1982). Modern energy region development and income distribution: An input-output analysis. *Energy Economics*. [https://doi.org/10.1016/0095-0696\(82\)90019-5](https://doi.org/10.1016/0095-0696(82)90019-5)
- Sasse, J.-P., & Trutnevyte, E. (2020). Regional impacts of electricity system transition in Central Europe until 2035. *Nature Communications*. <https://doi.org/10.1038/s41467-020-18812-y>
- Sasse, J.-P., & Trutnevyte, E. (2023). A low-carbon electricity sector in Europe risks sustaining regional inequalities in benefits and vulnerabilities. *Nature Communications*. <https://doi.org/10.1038/s41467-023-37946-3>
- Shao, S., Wang, C., Guo, Y., Yang, L., Chen, S., et al. (2020). Enlarging regional disparities in energy intensity within China. *Earth's Future*. <https://doi.org/10.1029/2020EF001572>
- Stewart, F. (2022). Friends with benefits: How income and peer diffusion combine to create an inequality “trap” in the uptake of low-carbon technologies. *Energy Policy*. <https://doi.org/10.1016/j.enpol.2022.112832>

- Tidemann, C., Engerer, N. A., Markham, F., Doran, B. J., & Pezzey, J. C. V. (2019). Spatial disaggregation clarifies the inequity in distributional outcomes of household solar PV installation. *Journal of Renewable and Sustainable Energy*. <https://doi.org/10.1063/1.5097424>
- Tidwell, J., Tidwell, A., & Nelson, S. (2018). Surveying the solar power gap: Assessing the spatial distribution of emerging photovoltaic solar adoption in the State of Georgia, U.S.A. (Preprint). <https://doi.org/10.20944/preprints201810.0184.v1>
- Wang, Q., Fan, J., Kwan, M.-P., Zhou, K., Shen, G., et al. (2023). Examining energy inequality under the rapid residential energy transition in China through household surveys. *Nature Energy*. <https://doi.org/10.1038/s41560-023-01193-z>
- Wei, Y., & Ye, X. (2009). Beyond convergence: Space, scale, and regional inequality in China. *Tijdschrift voor Economische en Sociale Geografie*, 100(1), 59–80. <https://doi.org/10.1111/j.1467-9663.2009.00507.x>
- Wells, P. (2012). Converging transport policy, industrial policy and environmental policy: The implications for localities and social equity. *Local Economy*. <https://doi.org/10.1177/0269094212455018>
- Yang, F., Zhang, S., & Sun, C. (2020). Energy infrastructure investment and regional inequality: Evidence from China's power grid. *Science of the Total Environment*. <https://doi.org/10.1016/j.scitotenv.2020.142384>
- Zhao, G., Zhou, P., & Wen, W. (2022). What causes regional inequality of technology innovation in renewable energy? Evidence from China. *Applied Energy*. <https://doi.org/10.1016/j.apenergy.2021.118464>
- Zhuang, X., & Pan, L. (2022). Study on the impact of clean power investment on regional high-quality economic development in China. *Energies*. <https://doi.org/10.3390/en15228364>

Das regulatorische Umfeld für nachhaltige Logistik in der Europäischen Union: Auswirkungen des Green Deal, der CSRD und der Taxonomie

The regulatory environment for sustainable logistics in the European Union: implications of the Green Deal, CSRD and taxonomy

Laura Oltmanns

Abstrakt

Die Europäische Union hat mit dem EU Green Deal und daraus folgenden Regulierungen wie Fit for 55, CSRD und EU-Taxonomie den regulatorischen Rahmen für nachhaltiges Wirtschaften deutlich verschärft. Dieser Artikel analysiert die wirtschaftlichen Auswirkungen dieser Regulierungen auf die Logistikbranche. Durch die Ausweitung der Regulierung auf zusätzliche Verkehrsträger, verschärfte Emissionsziele sowie verbindliche Vorgaben zu Infrastruktur, Fahrzeugstandards und Emissionshandel, intensiviert das Fit for 55-Paket die klimapolitischen Anforderungen an den Logistiksektor erheblich. Für die Logistikunternehmen resultieren daraus erhebliche Investitionserfordernisse, insbesondere in die Flottenmodernisierung sowie in strategische und infrastrukturelle Anpassungen, die durch deutliche Unterschiede zwischen den EU-Mitgliedsstaaten zusätzlich erschwert werden. Neben den verkehrsträgerspezifischen Regulierungen erhöhen die CSRD und EU-Taxonomie die Anforderungen an Organisationsaufwand und IT-Systeme. Gleichzeitig eröffnen datengetriebene Nachhaltigkeitsstrategien Chancen zur Stärkung der Wettbewerbsfähigkeit und zum Zugang zu langfristigen Finanzierungsquellen. Insgesamt ist davon auszugehen, dass die EU-Nachhaltigkeitsregulierung langfristig als verbindlicher Ordnungsrahmen bestehen bleibt, an den sich die Logistikunternehmen strategisch anpassen müssen.

JEL klasifikácia: M14, Q54, Q58

Kľúčové slová: Fit for 55, Corporate Sustainability Reporting Directive (CSRD), EU Taxonomy, Logistics

1 Einführung

Die Generalversammlung der Vereinten Nationen (VN) hat im Jahr 2015 die Agenda 2030 verabschiedet. Damit wurde ein globaler Orientierungsrahmen für nachhaltige Entwicklung geschaffen. Die ESG-Kriterien: E- Environmental, S- Sozial und G- Governance, bilden die grundlegenden Dimensionen der Nachhaltigkeit und sind bereits seit den 1970er Jahren in Fachgesprächen etabliert gewesen. Diese Dimensionen wurden von VN in 17 Nachhaltigkeitsziele (SDGs) formuliert und bilden einen politischen Rahmen für die nationale Umsetzung der jeweiligen Staaten. Bei der Agenda 2030 und den SDGs handelt es sich nicht um völkerrechtlich verbindliches Übereinkommen. Die Konkrete Ausgestaltung und die Implementierung in das nationale Recht liegt in der Verantwortung der einzelnen Staaten.

Auf europäischer Ebene wurde dieser globale Orientierungsrahmen mit dem EU Green Deal in eine politische Transformationsstrategie überführt. Der EU Green Deal verfolgt das Ziel, die EU bis 2050 bei wirtschaftlichem Wachstum klimaneutral zu gestalten. Zur operativen Umsetzung dieses Ziels wurden in den vergangenen Jahren mehrere regulatorische Instrumente eingeführt. Zu den zentralen Elementen zählen das Fit for 55-Paket, die Corporate Sustainability Reporting Directive (CSRD) sowie die EU-Taxonomie-Verordnung.

Der vorliegende Artikel untersucht die Auswirkungen dieser politischen Instrumente auf die Logistikbranche. Grundlage der Analyse bildet eine systematische Auswertung aktueller

wissenschaftlicher Artikel zu diesem Thema. Der Abschnitt 2 dieses Artikels gibt zunächst einen Überblick über die EU-Regulierungen und analysiert deren spezifische Auswirkungen auf die Logistikunternehmen. Im Abschnitt 3 werden das zugrunde liegende Research Design dargestellt. Abschnitt 4 fasst die zentralen Ergebnisse der Analyse zusammen und die Abschnitte 5 und 6 diskutieren die Ergebnisse und leiten Handlungsempfehlungen für Logistikunternehmen ab.

2 Stand der gelösten Problematik in den heimischen und ausländischen Quellen

Im nachfolgenden Kapitel werden die Auswirkungen der EU-Regulierung auf die Logistikbranche in der EU aufgezeigt. Der EU-Green Deal, der daraus resultierende Fit for 55-Paket, CSRD-Berichterstattung sowie die EU-Taxonomie bilden ein komplexes und herausforderndes Regelwerk. Dieses hat tiefgreifende Folgen auf die bestehende Geschäftsmodelle, Kostenstrukturen und die Wettbewerbsfähigkeit von Logistikunternehmen.

2.1 EU Green Deal und Fit for 55- Paket

Die EU-Kommission hat im Jahr 2019 die Mitteilung zum europäischen grünen Deal veröffentlicht. Es legt den politischen Rahmen für eine ökologische, wirtschaftliche und soziale Transformation in der EU fest. Der EU Green Deal ist kein unmittelbar verbindliches Gesetz, sondern eine strategische Leitlinie aus der konkrete Rechtsakte, Programme und Maßnahmenpakete ausgearbeitet wurden. Die EU-Transformationsstrategie berücksichtigt auch das Wohl der europäischen Bevölkerung, die von einer sauberen Umwelt und Wirtschaftswachstum profitieren werden. Die Zielsetzung, keine Netto-Treibhausgasemissionen bis 2050, bei gleichzeitigem Wirtschaftswachstum, ist jedoch mit erheblichen Investitionen verbunden. Diese können allein mit Haushaltsmitteln der Länder nicht gedeckt werden. Deswegen dient das Maßnahmenpaket auch als regulatorischer Rahmen für mehr Transparenz und Vergleichbarkeit zur Vertrauensbildung am Privatkapitalgebermarkt.

Eines aus dem EU Green Deal resultierenden Maßnahmenpakete ist der „Fit for 55“. Dieser sieht vor, dass die europäische Union bis zum Jahr 2030 die Treibhausgasemissionen um mindestens 55% gegenüber dem Niveau von dem Jahr 1990 senkt. Insgesamt umfasst „Fit for 55“ 19 Legislativakte, von denen 11 unmittelbar den Verkehrssektor betreffen. Diese 11 sind in sektorübergreifende Wirkungen geteilt (horizontale Reformen): Straßen-, See-, Schienen- und Luftverkehr. Eines der zentralen Elemente des „Fit for 55“-Paketes ist die Reform des EU-Emissionshandelssystems. Die Emissionsminderungsziele wurden angehoben in dem die Gesamtmenge der Zertifikate reduziert und der maritime Sektor erstmalig in den Emissionshandel aufgenommen wurde. Zudem kam ein Emissionshandelssystem für Brennstoffe im Straßen- und Bahnverkehr sowie für Gebäudesektor neu hinzu.

Um eine mögliche Benachteiligung einkommensschwacher Haushalte und kleiner Unternehmen abzufedern, wurde als Unterstützung ein sozialer Klimafond eingerichtet. Um die Dekarbonisierung praktisch zu unterstützen, legt das Paket verbindliche Mindestvorgaben für Lade- und Betankungsinfrastruktur in allen Verkehrsträgern fest. Weitere horizontale Elemente sind die Überarbeitung der Lastenteilungsverordnung (nationale Emissionsziele für nicht dem Emissionshandel unterliegende Sektoren) sowie die Neufassung der Richtlinie für Erneuerbare-Energien. Der Einsatz der erneuerbaren Energien soll insbesondere im Verkehrssektor deutlich ausgebaut und beschleunigt werden.

Insgesamt ist das „Fit for 55“-Paket sehr umfassend und reguliert den Verkehrssektor tiefgreifend. Die Kombination aus marktbasierenden Instrumenten, verbindlichen Standards, sozialen Ausgleichsmechanismen und Infrastrukturvorgaben soll der Verkehrssektor einen wirksamen Beitrag zur Erreichung von EU-Klimazielen leisten (European Parliament, 2024).

Im maritimen Sektor wurden die gravierendsten Änderungen vorgenommen. Die Schifffahrt ist nun ab dem Jahr 2025 zur Abgabe von Emissionszertifikaten für ihre CO₂-Emissionen verpflichtet. Parallel dazu setzt die Fuel EU-Maritime-Verordnung verbindliche Grenzwerte für die Treibhausgasintensität der Schiffe und fördert den Einsatz erneuerbarer Kraftstoffe. Hinzukommen ergänzende Vorgaben, wie die Nutzung von Landstrom in Häfen, die auf die Senkung der Emissionen auch im Hafenerbetrieb, regulieren sollen (European Parliament & Council of the European Union, 2023). Es ist wenig überraschend, dass die EU-Kommission mit dem „Fit for 55“-Paket auch den maritimen Sektor zur Senkung der Treibhausgasemissionen mitaufgenommen hat. Weltweit werden ca. 90% aller Waren per Schiff transportiert, wodurch der CO₂-Ausstoß des globalen Schiffsverkehrs zwischen 2-3% der weltweit ausgestoßenen CO₂-Emissionen entspricht (Möller et al., 2021). Ohne zusätzliche Regulierung wäre ein Emissionsanstieg zu erwarten. Das Emissions Trading System (ETS) der EU erzeugt direkten Kostendruck auf die Reedereien, weil der Einsatz fossiler Kraftstoffe teurer wird. Die Preiserhöhungen werden von Reedereien entsprechend an Kunden weitergegeben. Grundsätzlich ist die Kundenbereitschaft da, einen höheren Preis für weniger CO₂ Ausstoß beim Transport zu zahlen, jedoch sind es lediglich geschätzte 2%. Erforderliche Preiserhöhung wäre jedoch höher, wodurch die Notwendigkeit einer anderweitigen Finanzierung wie z.B. staatliche Förderung für die Reedereien entstehen würde. Zudem besteht die grundsätzliche Sorge, dass durch die deutlichen Preissteigerungen für die Reedereien eine Wettbewerbsverzerrung bzw. Standortnachteil entstehen könnte. Wenn eine einheitliche internationale Maritime-Regulierung ausbleibt, könnte der EU-Standort für die Schiffsbetreiber auf Dauer weniger attraktiv werden. Durch die Ausweichreaktionen (Flucht zu weniger regulierten Standorten), wird die CO₂ Belastung eher steigen als gesenkt werden. Nicht zu vernachlässigen ist auch die hohe Umweltbelastung bei der Herstellung der Schiffe selbst, sowie die lange Amortisationsdauer aufgrund der hohen Anschaffungskosten. Zusätzliche Investitionen in neue Schiffe oder für den Umbau der bestehenden, verstärkt den Kostendruck auf die Reedereien kurz- und langfristig. Christodoulou et al. erwähnen sogar, dass ab dem Jahr 2040 durch die FuelEU Maritime kein Kraftstoffmix mehr für die Erreichung der Regularien ausreichen wird. Deshalb kann behauptet werden, dass diese Regulierung den Einsatz von erneuerbaren Energien bzw. Synthetischen Kraftstoffen erzwingt (Christodoulou and Cullinane, 2022). Die Herausforderung für den maritimen Sektor besteht also nicht nur in einer technischen Umsetzung, sondern darin, den gesamten Sektor strategisch auf die aufwendige Transformation auszurichten (Koilo, 2024; Menner & Reichert, 2022).

Das „Fit for 55“-Paket sieht drei Kerninstrumente für den Luftverkehr vor: die Reform des EU- Emissionshandelssystems (EU ETS), die Einführung einer Kerosinsteuer für innereuropäische Flüge sowie eine verbindliche Beimischungsquote für Sustainable Aviation Fuels (SAF). Und obwohl die meisten Studien zu dem Thema „Fit for 55“ in Aviation, sich auf Passagierflugverkehr beziehen, sind die drei genannten EU-Regulatorien gleichermaßen für Fracht- und Passagierflüge gültig. Die Auswirkungen auf der Nachfrageseite sind aufgrund der unterschiedlichen Marktdynamiken bei Passagier- und Cargo Flügen nicht direkt übertragbar und werden an dieser Stelle deshalb nicht miteinbezogen. Grundsätzlich lässt sich behaupten, dass „Fit for 55“-Paket sich kostensteigernd auf die Airlines auswirken wird. Nach der Reform des EU ETS, werden die kostenlosen Zertifikate ab dem Jahr 2026 abgeschafft und die CO₂-Preise angehoben. Die Kerosinsteuer Plus die Ausgaben für die Erfüllung der SAF-Quote, kommen als zusätzliche Punkte ebenfalls in die Kostenrechnung der Airlines hinzu (Oesingmann, 2022). Besonders relevant ist für den Luftfrachtverkehr die in „Fit for 55“ enthaltene Regelung zur „Fuel Tankering“. Für jeden Union- Airport (EU-Flughafen mit SAF-Pflicht) muss ein Airline-Betreiber über ein Jahr betrachtet vor Ort 90% der Menge an Treibstoff tanken, die er für alle seine Abflüge ab diesem Flughafen in diesem Jahr benötigt. Somit werden die Cargo-Airlines durch die 90% Tankregelung gezwungen, einen Großteil ihres

Treibstoffes an großen EU- Hubs zu kaufen. Dadurch entfällt größtenteils die bisher mögliche Kostenoptimierung durch Betankung an günstigeren kleineren Zubringer- Flughäfen. Durch die übrig gebliebenen 10% kann jedoch bei wenigen systematisch ausgewählten Routen, trotzdem Tankering betrieben werden. Das bedeutet, dass die EU-Anti-Tankering-Regelung das Tankering begrenzt, aber nicht vollständig verhindert. Zudem untergräbt dies nicht nur die Umweltwirkung dieser Regelung, sondern kann auch die Drehkreuze der EU wirtschaftlich unattraktiv gestalten. Die Cargo-Airlines könnten aufgrund der höheren Betankungskosten ihre Hubs nach nahegelegene nicht- EU Flughäfen wie Istanbul oder Dubai verlagern (Transport & Environment, 2022). Gleichzeitig ist der SAF aufgrund der höheren Kosten nicht konkurrenzfähig zu dem konventionellen Kerosin. Deshalb sichert eine garantierte Abnahme durch den „Fit for 55“-Paket, einerseits eine Investitionssicherheit für die Produzenten und löst das so genannte „First- Mover-Problem“ für die Airlines (Detsios et al., 2023).

Im Straßenverkehr zielt das „Fit for 55“ vor allem auf die Innovationsförderung und die Verringerung der Abhängigkeit von fossilen Energieträgern ab. Da die Pkw und leichte Nutzfahrzeuge den Großteil der verkehrsbedingten Emissionen verursachen, steht dessen CO²-Reduktion im Vordergrund. Hierfür wurden deutlich verschärfte Grenzwerte festgelegt, um den vollständigen Ausstieg aus fossilen Antriebstechnologien zu beschleunigen. Nach der Verschärfung der CO²-Flottenregulierung für schwere Nutzfahrzeuge (VO (EU) 2024/1610) sind die Fahrzeughersteller verpflichtet, den durchschnittlichen jährlichen CO²-Ausstoß aller neu zugelassenen schweren Nutzfahrzeuge, den vorgeschriebenen Zielwert nicht zu überschreiten. Dieser Flottenmittelwert muss:

- um 15% in den Jahren 2025 bis 2029,
- um 45% in den Jahren 2030 bis 2034,
- um 65% in den Jahren 2035 bis 2039,
- und um 90% ab 2040,

gegenüber dem Referenzniveau in den Jahren 2019/2020 sinken. Bei der Hochrechnung sind die gesamte Flotte und nicht einzelne Fahrzeuge maßgeblich. Die Studie von Breed et al. bezieht sich auf die anfängliche VO (EU) 2019/1242, die im Jahr 2024 mit der VO (EU) 2024/1610 abgelöst wurde. Laut der Studie werden die CO²-Reduktionsziele: -30% bis zum Jahr 2030, ohne Zero-Emission-Vehicles (ZEV) nicht erreichbar sein. Während die 2025 (-15%) Ziele noch über Effizienzmaßnahmen der Diesel-Lkw erfüllbar waren, machen die 2030-Ziele den Einsatz von batterieelektrischer und wasserstoffbasierter Lkw unabdingbar (Breed et al., 2021). Mit der Erhöhung der CO²-Reduktionsziele auf mind. 45% bis 2030 wird demnach die Herausforderung sowohl für die Hersteller als auch für die Logistiker größer. Nach der Bewertung von McKinsey & Company sind die bisher unzureichende flächendeckende Ladeinfrastruktur sowie die mangelnde Rentabilität der E-Lkw, die größten Verkaufshindernisse. Somit treffen auf die Lkw-Hersteller unzureichende Verkaufszahlen bei gleichzeitig hohem Investitionsdruck in die F&E. Für die Logistikunternehmen bedeutet das, dass die Fahrzeugverfügbarkeit, Anschaffungspreise und die Lieferzeiten zunehmend durch die regulatorischen Vorgaben für die Hersteller bestimmt werden. Fleet-Investitionsentscheidungen werden also nicht mehr ausschließlich auf klassische betriebswirtschaftliche Kalkulation beruhen (Breed et al., 2021; Suneson et al., 2025).

Des Weiteren ist beachtenswert, dass die Dekarbonisierung des Straßentransports kein schrittweiser Technologiewechsel ist, sondern von Kosten- und Planungsentscheidungen über mehrere Jahre abhängt. Denn, ob alternative Antriebe wirtschaftlich sind, hängt stark davon ab, wo und wie die Lkw eingesetzt werden, den Energiepreisen und ob letztlich die Infrastruktur vorhanden ist. Für die Logistikunternehmen bleibt in diesem Fall nur eine systematische, datenbasierte Flotten- und Einsatzplanung, weil der geringere CO²-Ausstoß nicht automatisch

geringere Kosten bedeutet, vor allem nicht bei Hybrid- oder teil-elektrischen Lösungen (Krause et al., 2023). Die Flottenerneuerung ist eine langfristige Investition, der die Logistiker mit Bedacht und strategisch angehen müssen. Es ist davon auszugehen, dass in der Zukunft mit weiteren regulatorischen Verschärfungen zu rechnen ist. Deswegen stellt eine Investition in günstigere Übergangslösungen oder Nachrüstungen der Flotte keine langfristig ausgerichtete Erfolgsstrategie mehr dar (Gdowska et al., 2025).

Kommende zukünftige Investitionen sind nicht die einzige Herausforderung im daily business der Logistikunternehmen. Selbst wenn die Fleet-Problematik unternehmensintern erfolgreich gelöst werden kann, gibt es einige Implikationen in der Infrastruktur der EU. Aktuell fehlt es noch an breit ausgebauten Hochleistungsladeinfrastruktur und Megawatt-Charging-Systemen. Lange Wartezeiten und hohe Strompreisvolatilität gestalten heute die elektrischen Alternativen teurerer und zeitintensiver als dieselbasierte Transporte. So entsteht für die Logistikunternehmen kurzfristig ein schwerlösbarer Zielkonflikt zwischen regulatorischem Anpassungsdruck und wirtschaftlicher Effizienz (Panciu et al., 2024). Aus diesem Grund sind zwar die Maßnahmen des „Fit for 55“-Paketes den Logistikern gut bekannt, stoßen jedoch auf wenig Zuspruch. Teilweise werden die politischen Anforderungen sogar als wirtschaftlich unrealistisch betrachtet, was die Frage aufwirft, ob die nachhaltige Verkehrspolitik hier der Abwägung ökologischer und ökonomischer Belange ausreichend Rechnung getragen hat (Beil et al., 2025; Bekisz & Kruszyński, 2022).

Innerhalb des EU Green Deals und des Fit for 55-Paketes gilt der Schienengüterverkehr als besonders klimafreundlich, da er im Vergleich zu Straßen- und Luftverkehr deutlich weniger Emissionen verursacht. Dennoch wird in mehreren Studien erwähnt, dass die Elektrifizierung des Straßenverkehrs der zentrale Hebel zur Emissionsreduktion ist, auch wenn alle Zukunftsszenarien von einem Modal Shift zur Schiene ausgehen. Das Fit for 55 -Paket reguliert den Schienenverkehr nur indirekt. Es werden keine sektoralen Emissionsziele oder Quoten vorgegeben, stattdessen erfolgt eine Förderung über TEN-T-Regulierung (Schienenbauplan für Europa), Combined Transport Directive (Förderung des Gütertransports über Schiene oder Schiff) und der Internalisierung externer Kosten (Kostenverlagerung für Umweltschäden auf den Verkehrssektor). Trotzdem ist es derzeit nicht sichergestellt, dass der Schienenverkehr die Wettbewerbsfähigkeit, gegenüber der elektrifizierten Straßenverkehr in der Zukunft, besitzt.

Trotz der EU- Schienen-Förderprogrammen bestehen EU- weit Infrastrukturengpässe auf den TEN-T- Korridoren, unterschiedlicher innerländischer Stand der Umsetzung sowie lange Projekt- Realisierungszeiträume. Bei diesen bestehenden Kapazitätsengpässen ist die Verlagerung des Güterverkehrs von den Straßen oder Luft auf den Schienenverkehr, nur sehr begrenzt möglich. Zudem können die sinkenden Elektro- Lkw Betriebskosten und ETS-Kosten ebenso wettbewerbsmindernd für den Schienengüterverkehr entwickeln (Seibert et al., 2024, ; Ertürk & Toral, 2022; Činčurak Erceg et al., 2022).

Erwähnenswert ist der Umstand, dass auch im Schienenverkehr erhebliche ökologische Unterschiede bestehen. Gänzlich elektrifizierte Strecken erfüllen die Umweltkriterien, während dieselbetriebene Züge weiterhin relevante Emissionsquellen darstellen. Schienengüterverkehr ist somit nicht pauschal ökologisch im Vorteil gegenüber anderen Verkehrsträgern. Zudem fließen die unsicheren Energiepreise sowie die hohen Investitionskosten der Betreiber zu der Nachhaltigkeitsbewertung des Schienenverkehrs. Somit wird deutlich, dass eine gezieltere politische Förderung der Netzmodernisierung des Schienenverkehrs in Europa unabdingbar ist, derzeit aber noch ausbleibt (Čižiūnienė et al., 2024).

Zusammenfassend zeigen die ausgewerteten Studien, dass der EU Green Deal sowie der Fit for 55- Paket den Schienengüterverkehr eher politisch stärken, als eine strukturell gesicherte Transformation des Sektors bewirken. Die politische Wirkung entfaltet sich über die

Kostenverschiebungen zulasten anderer Verkehrsträger, während infrastrukturelle und operative Defizite des Schienenverkehrs innerhalb der EU noch nicht gelöst sind. Für Logistikunternehmen bedeutet dies, dass der Schienenverkehr aufgrund der EU- Klimapolitik zwar an strategischer Bedeutung gewinnt, gleichzeitig jedoch mit erheblichen Investitionsrisiken verbunden ist.

2.2 Corporate Sustainability Reporting Directive

Ein weiterer zentraler Baustein des EU Green Deals ist die EU-Richtlinie (EU) 2022/2464, auch bekannt als Corporate Sustainability Reporting Directive (CSRD). Sie wurde von der Europäischen Kommission überarbeitet und ersetzt die aus dem Jahr 2017 beschlossene, Non-Financial Reporting Directive (NFRD). Diese Richtlinie regelt die Nachhaltigkeitsberichterstattung von Unternehmen. Demnach sind Unternehmen ab einer bestimmten Größe dazu verpflichtet einen Nachhaltigkeitsbericht nach ESRS (European Sustainability Reporting Standards) zu verfassen. Dadurch sollen Transparenz, Vergleichbarkeit und Verlässlichkeit von ESG (Environmental, Social, und Governance) für Investoren, Kunden, Finanzinstitute und weitere Stakeholder sichergestellt werden. Die CSRD verpflichtet betroffene Unternehmen zur Offenlegung ihrer nachhaltigkeitsbezogenen Auswirkungen, Risiken und Chancen entlang der gesamten Wertschöpfungskette. Hierbei gilt das Prinzip der doppelten Wesentlichkeit:

- Darstellung wie das unternehmerische Handeln die Umwelt und die Gesellschaft beeinflusst.
- Darstellung wie die Nachhaltigkeitsaspekte die wirtschaftliche Lage und die Zukunftsfähigkeit des Unternehmens beeinflussen.
- Da die Logistikbranche zu den besonders emissionsintensiven Wirtschaftsbereichen gehört, ist die CSRD besonders relevant. Nach der CSRD- Anforderung sind von dem Unternehmen die Treibhausemissionen in drei Scopes einzuteilen:
 - Scope 1: direkt von dem Unternehmen verursachte Emissionen wie z.B. Emissionen des eigenen Fuhrparks oder Heizöl Verbrennung in eigenen Hallen
 - Scope 2: indirekte Emissionen aus der vom Unternehmen eingekauften Energie wie z.B. der Stromverbrauch in Bürogebäuden oder Lagerhallen
 - Scope 3: Emissionen, die durch die Geschäftstätigkeit verursacht werden, jedoch bei Dritten (Partnern, Lieferanten, Kunden) anfallen. In der Logistik können es z.B. eingekaufte Transportleistungen bei Subunternehmen sein oder die Emissionen der Herstellung der Lkw sowie die Emissionen, die bei der Entsorgung von Verpackungsmaterialien entstehen (European Parliament and Council, 2022).

Transport- und Logistikleistungen sind bei vielen Unternehmen im CSRD- Bericht unter Scope 3 Emissionen zu erfassen. Dadurch übernehmen Logistikunternehmen die Rolle des Datenlieferanten für andere Unternehmen, selbst wenn sie durch eigene Unternehmensgröße nicht CSRD- berichtspflichtig sind. Das Vorliegen solcher Daten könnte sich zwar bei der Kundengewinnung für die Logistikunternehmen auszahlen, andererseits könnten Lieferanten ohne ausreichende Datenbereitstellung auch vom Markt ausgeschlossen werden. Zudem erfordert die CSRD- Datenbereitstellung Budgetausgaben und personellen Aufwand, die besonders für kleine und mittelständische Unternehmen sehr belastend sein können (Niemann et al., 2025; Luin et al., 2025). Aufgrund von unterschiedlichen Berechnungsmodellen und Tools können identische Transportleistungen Abweichungen von bis zu 50% aufweisen. Hauptursache hierfür sind Systemgrenzen, Emissionsfaktoren und Annahmen. Besonders aufwendig ist die Berechnung der Emissionen für Logistikunternehmen mit intermodalen, internationalen und stark fragmentierten Netzwerken (Dagnæs, 2022; Marek & Staniuk, 2025).

Hinzu kommt, dass die administrative Bealstung zusätzlich durch die Parallelberichterstattung verstärkt wird. Neben CSRD-Pflichten müssen Logistikunternehmen häufig kundenspezifische ESG-Fragebögen ausfüllen oder Berichtssysteme bedienen, ohne, dass diese einheitlich sind (Dagnæs, 2022).

Langfristig betrachtet kann die CSRD-Berichterstattung die Wettbewerbslogik der Logistikbranche verändern. Nachhaltigkeitsperformance wird schrittweise zu einem gleichwertigen Kriterium neben Preis und Zeit. Durch die CSRD-Berichterstattung bestehen Chancen für eine Beschleunigung der Digitalisierung, Standardisierung und Prozessoptimierung nicht nur in der Logistikbranche. Praxisbeispiele zeigen, dass durch datenbasierte Routenoptimierung, bessere Auslastung oder multimodale Koordination spürbare Emissions- und Effizienzgewinne realisiert werden können. Die uneinheitliche nationale Umsetzung der CSRD-Richtlinie innerhalb der EU erzeugt jedoch auch regulatorische Unsicherheiten für die betroffenen Unternehmen. Unterschiedliche Zeitpläne und Auslegungsspielräume erschweren die Planungssicherheit und können dazu führen, dass Investitionsentscheidungen in Digitalisierung, Flottenmodernisierung oder IT-Systeme aufgeschoben werden. Damit können die zuvor erwähnten Effizienzgewinne verzögert eintreten und die Wettbewerbsfähigkeit einzelner Standorte beeinträchtigt werden (Niemann et al., 2025; Marek & Staniuk, 2025).

2.3 EU Taxonomy

Zusätzlich sind in der EU tätige Unternehmen, die unter die CSRD fallen, auch EU – Taxonomie anwendungspflichtig. Die EU-Taxonomie-Verordnung (EU 2020/852) legt fest, wann wirtschaftliche Tätigkeiten als ökologisch nachhaltig gelten. Die Unternehmen müssen offenlegen, welcher Anteil ihrer Umsätze, Investitionen (CapEx) und Betriebsausgaben (OpEx) Taxonomie fähig ist. Die Verordnung verschriftlicht ein einheitliches Klassifikationssystem, welches für Investoren, Unternehmen und Aufsichtsbehörden eine vergleichbare Bewertung nachhaltiger Aktivitäten ermöglicht. Demnach ist eine unternehmerische Tätigkeit nur dann nachhaltig, wenn sie mindestens einem von sechs Umweltzielen beiträgt und keinem der anderen der Umweltziele erheblich schadet. Die von der EU-Taxonomie-Verordnung vorgeschriebene sechs Umweltziele sind:

1. Climate Change Mitigation.
2. Climate Change Adaptation.
3. Nachhaltige Nutzung und Schutz von Wasser- und Meeresressourcen.
4. Übergang zu einer Kreislaufwirtschaft.
5. Vermeidung und Verminderung der Umweltverschmutzung.
6. Schutz und Wiederherstellung der Biodiversität und der Ökosysteme.

Hinzukommen Mindestanforderungen an soziale und Governance- Standards, die von den Unternehmen eingehalten werden müssen (European Parliament & Council of the European Union, 2020).

Für Logistikunternehmen ist die EU-Taxonomie-Verordnung zunehmend kapitalmarktrelevant. Die erhobenen und die klassifizierten Unternehmenskennzahlen werden insbesondere von professionellen Investoren aktiv in Investitionsentscheidungen einbezogen. Für Taxonomie konforme Investitionen entstehen so finanzielle Anreize, gleichzeitig, aber auch ökonomische Nachteile für die Unternehmen, die eine niedrige Taxonomie-Quote aufweisen (Chrzan & Pott, 2024). Dieser Effekt ist jedoch vor allem bei größeren Unternehmen bei direktem Kapitalmarktzugang ausgeprägt, wobei kleinere Unternehmen eher selten profitieren. Hierdurch entsteht ein Risiko für Investitionslücken, insbesondere für kleine- und mittelständische Unternehmen (Brabec & Macháč, 2025).

Wie bei der CSRD- Berichterstattung, so auch für die EU-Taxonomie- Berichterstattung ist das Vorliegen relevanter ganzheitlicher Unternehmensdaten eine Voraussetzung für die Erstellung der Berichte. Somit stellt die EU- Taxonomie- Berichterstattung eine zusätzliche personelle, organisatorische und monetäre Belastung für die Unternehmen dar. Da die praktische Umsetzung der Taxonomie mit methodischen Herausforderungen verbunden ist, werden geschultes Personal sowie unterstützende Buchhaltungs- und Controlling Systeme benötigt (Brabec & Macháč, 2025). Die EU- Taxonomie- Verordnung kann für die Logistikunternehmen als ein externer Referenzrahmen dienen, um Transformationsinvestitionen besser priorisieren zu können. Außerdem kann die bessere Vergleichbarkeit ökologisch vorteilhafter Logistikleistungen Greenwashing- Risiken reduzieren. Logistikunternehmen, die Dekarbonisierung als Teil eigener Unternehmensstrategie verstanden haben, können sich wettbewerbliche Vorteile schaffen (Kamiński, 2023).

3 Forschungsdesign

Die vorliegende Publikation basiert auf einem Scoping- Review- Ansatz nach Arksey und O'Malley (2005). Ziel der angewandten Methodik ist es, aktuelle wissenschaftliche Erkenntnisse systematisch zu bündeln, Argumentationslinien abzuleiten und regulatorische Wirkungszusammenhänge einzuordnen. Im Rahmen der Datenerhebung wurden die für die Logistikbranche relevanten EU-Rechtsvorschriften identifiziert sowie der aktuelle Stand der wissenschaftlichen Literatur zu den Auswirkungen dieser Regularien dargestellt.

Die Literaturrecherche erfolgte in anerkannten wissenschaftlichen Datenbanken und Suchplattformen wie Web of Science, Scopus, Academia.edu oder Google Scholar. Für die Recherche der EU- Rechtsvorschriften sowie ihrer Inhalte wurden ausschließlich die Originaltexte der Europäischen Union auf der offiziellen Veröffentlichungsplattform EUR- Lex herangezogen. Damit konnte eine breite Abdeckung relevanter Fachliteratur sichergestellt werden. Die Suchstrategie erfolgte anhand vordefinierter Suchbegriffe in englischer Sprache, unter anderem: EU Green Deal, Fit for 55, CSRD, EU Taxonomy sowie LOGISTICS oder TRANSPORT SECTOR. Es wurden bewusst Gesetzestexte oder Artikel ausgeschlossen, die lediglich nationale Regelungen einzelner Mitgliedstaaten betreffen. Dies erfolgte zum einen aufgrund der begrenzten Kapazitäten dieser Arbeit, zum anderen zur Sicherstellung der Vergleichbarkeit der Auswirkungen auf die gesamte Logistikbranche. Analysiert wurden daher ausschließlich EU- Regulierungen auf Unionsebene, die für die Logistikbranche unmittelbar relevant sind. Nationale Umsetzungen von EU- Richtlinien wurden in dieser Arbeit nicht gesondert berücksichtigt. Aufgrund der Neufassungen der EU- Regelungen und zur Sicherstellung der Aktualität wurden ausschließlich Artikel berücksichtigt, die ab dem Jahr 2022 veröffentlicht wurden. Insgesamt wurden 37 Fachartikel und Gesetzestexte analysiert und die verwendeten Aussagen zitiert.

Die Einschlusskriterien waren:

- peer- reviewte wissenschaftliche Publikationen,
- Erscheinungsjahr 2022-2025,
- Thematischer Fokus: die Logistikbranche in allen Sektoren wie Maritimer Sektor, Luftgüterverkehr, Straßengüterverkehr und Schienengüterverkehr.

Die Ausschlusskriterien waren:

- nationale Gesetzgebungen und nationale Umsetzungen von EU- Richtlinien, wie z.B. nationale Maut Regulatorik oder nationale Vorgaben zur Strompreisgestaltung,
- nicht peer- reviewte wissenschaftliche Publikationen,
- Studien außerhalb des definierten Zeitraums,

- Studien, die sich zum Zeitpunkt der Recherche (2025) auf nicht mehr aktuelle EU-Verordnungen beziehen,
- Publikationen ohne Volltext- Zugang.

Die Auswertung erfolgte mittels qualitativer Inhaltsanalyse. Dazu wurden die Beiträge nach thematischen Schwerpunkten sortiert und anschließend auf ihre Auswirkungen auf die Logistikbranche analysiert, zusammengefasst und auf abweichende Einschätzungen hin ausgewertet. Die Ergebnisse der Recherche wurden im 4. Teil dieser Publikation in einer Tabelle zusammengefasst, nach Logistiksektoren sortiert und die Auswirkungen der jeweiligen Regularien auf die Logistikbranche dargestellt.

Trotz der systematischen Vorgehensweise ist der gewählte Ansatz mit Einschränkungen verbunden. Da die Analyse von der Verfügbarkeit und der Qualität der vorhandenen Literatur abhängt, kann weder eine vollständige Abdeckung relevanter Studien noch eine vollständige Vermeidung von Selektionsverzerrungen gewährleistet werden. Außerdem werden die EU-Regularien fortlaufend aktualisiert, so dass einzelne Teile der Verordnungen und darauf bezogene Studien, schnell an Aktualität verlieren können. Dennoch bietet die gewählte Methodik eine tragfähige Grundlage, um eine kritisch-analytische Einordnung des aktuellen wissenschaftlichen Diskurses sowie die Ableitung von Handlungsempfehlungen für Logistikunternehmen zu ermöglichen.

4 Ergebnisse der Forschung

Die Auswertung der analysierten wissenschaftlichen Artikel zeigt, dass der EU Green Deal zu einer deutlichen Verschärfung der klimapolitischen Rahmenbedingungen im Logistiksektor führt. In der Tabelle 1 werden die relevanten EU-Verordnungen mit daraus resultierenden Auswirkungen für die Logistikunternehmen aufgelistet

Bei der Analyse der EU-Regulierungen lässt sich eine Kernbotschaft ableiten: die Logistikbranche ist auf dem Weg zur Transformation, sowohl sektorspezifisch durch Dekarbonisierung der Transportdurchführung (ETS, FuelEU Maritime-, Aviation und CO₂-Flottengrenzwerte), als auch sektorübergreifend mit Transparenz- und Berichtspflichten über CSRD und EU- Taxonomie. Hierdurch sind in allen Logistiksektoren höhere Kosten für die Logistikunternehmen zu erwarten. Dabei fällt auf, dass der Straßengüterverkehr, den höchsten kumulierten Anpassungsdruck aufweist. Mit ETS 2 und den verschärften CO₂-Flottengrenzwert greifen zwei Regulierungsmechanismen gleichzeitig und steigern nicht nur die laufenden Betriebskosten, sondern erzwingen die Umstellung der Flotte auf alternative Fahrzeugtechnologien. Ein weiterer wichtiger Punkt ist, dass die Umstellung auf nachhaltige Kraftstoffe oder das Laden vom Stom zur Betankung, unabhängig von dem Logistiksegment, eine Abhängigkeit von der Infrastruktur schafft. Dies erhöht die Investitionsrisiken von Logistikunternehmen zusätzlich. Weder kann den Logistikunternehmen das flächendeckende Vorhandensein der benötigten Infrastruktur innerhalb und außerhalb der EU garantiert werden, noch können sie sich bisher auf eine EU-weit gesetzlich zugesicherte Preisstabilität bei den Strompreisen berufen. Letztlich ist erwähnenswert, dass der Schienengüterverkehr zwar mit Wachstumszielen und daraus resultierenden politischen Förderungen bevorteilt wird, dies jedoch nicht pauschal. Denn dieselbetriebene Loks sind ebenso von ETS 2 betroffen, wie auch der Straßengüterverkehr.

Derzeit sind keine Hinweise darauf vorhanden, dass die EU- Nachhaltigkeitsregulierung künftig weniger stringent ausgestaltet wird. Die bestehenden gesetzlichen Vorgaben sind als dauerhafte Rahmenbedingungen zu betrachten, an die sich Unternehmen anpassen müssen. Nachhaltigkeit ist damit zu einer verbindlichen Kernanforderung für Logistikunternehmen geworden.

Tabelle 1

EU-Verordnungen im Zusammenhang mit Logistikunternehmen

Regulierungsbereich/ Sektor	Relevante EU-Vorschriften	Zentrale regulatorische Änderung	Quantitative Vorgaben	Auswirkungen auf die Logistikunternehmen
Maritimer Sektor	EU ETS (European Parliament and Council of the European Union, 2003)	Einbeziehung der Schifffahrt in das EU-Emissionshandelssystem	Zertifikatsabgabe in Höhe von 40 % der gemeldeten Emissionen im Jahr 2025, 70 % im Jahr 2026 und 100 % ab 2027 Emissionsabdeckung von 100 % bei Fahrten zwischen EU-Häfen und 50 % bei Fahrten zwischen EU- und Nicht-EU-Häfen	Steigende Betriebskosten durch CO ₂ -Bepreisung und Kraftstoffumstellung Transformations- und Investitionsdruck auf Flotten- und Betriebsprozesse
	FuelEU Maritime (European Parliament and Council of the European Union, 2023)	Anforderungen zur Nutzung erneuerbarer Kraftstoffe sowie Landstromvorgaben	Senkung der Treibhausgasintensität der an Bord verwendeten Energie um 2 % ab 2025 und stufenweise bis 80 % bis 2050	
Luftgüterverkehr	EU ETS	Abschaffung kostenloser Emissionszertifikate	Erwerb aller benötigten Zertifikate für Flüge innerhalb der EU	Höhere Betriebskosten durch ETS
	ReFuelEU Aviation (European Parliament and Council of the European Union, 2023)	Steigerung der Beimischungsquoten von nachhaltigen Kraftstoffen Einführung Anti-Tankering Regelung	Stufenweise Steigerung der SAF-Quote von 2% in 2025 bis 70% ab 2050 Mind. 90% des Kraftstoffes, der für einen von einem EU-Flughafen ausgehenden Flug benötigt wird, muss vor Ort (EU) getankt werden.	Höhere Kraftstoffpreise und eingeschränkte Betankungsoptimierung
Straßengüterverkehr	EU ETS 2 (European Parliament and Council of the European Union, 2023)	Einführung eines neuen Emissionshandelssystems für Straßenverkehr ab 2027	Verpflichtung der Inverkehrbringer von fossilen Brennstoffen zum Kauf von CO ₂ -Emissions- Zertifikaten	Höhere Betriebskosten durch ETS
	VO(EU) 2024/1610 (European Parliament and Council of the European Union, 2024)	Verschärfung der CO ₂ -Flottenregulierung für schwere Nutzfahrzeuge	CO ₂ -Reduktion gegenüber dem Referenzniveau 2019/2020 um 15 % in den Jahren 2025–2029, 45 % in den Jahren 2030–2034, 65 % in den Jahren 2035–2039 und 90 % ab 2040	Transformations- und Investitionsdruck auf Flotten- und Betriebsprozesse Abhängigkeit von Verfügbarkeit der Ladeinfrastruktur

Fortsetzung der Tabelle 1

Regulierungsbereich/ Sektor	Relevante EU-Vorschriften	Zentrale regulatorische Änderung	Quantitative Vorgaben	Auswirkungen auf die Logistikunternehmen
Schienengüterverkehr	EU ETS 2	Einführung eines neuen Emissionshandelssystems für Dieselbetriebenen Bahnverkehr ab 2027	Verpflichtung der Inverkehrbringer von fossilen Brennstoffen zum Kauf von CO ₂ -Emissions- Zertifikaten	Höhere Betriebskosten durch ETS
	VO(EU) 2024/1679 (European Parliament and Council of the European Union, 2024)	Festlegung von Wachstumszielen für Schienengüterverkehr	Steigerung des Aufkommens im Schienengüterverkehr um 50% bis 2030 und 100% bis 2050	Politische Aufwertung des Schienengüterverkehrs, aber keine strukturell abgesicherte Transformation
Alle Logistik Sektoren	CSRD (European Parliament and Council of the European Union, 2022)	Verpflichtung zur Nachhaltigkeitsberichterstattung nach ESRS entlang der Wertschöpfungskette	Erfassung von Scope 1-3 und Anwendung des Prinzips der doppelten Wesentlichkeit	Hoher personeller, organisatorischer und finanzieller Aufwand
Alle Logistik Sektoren	EU Taxonomie (European Parliament and Council of the European Union, 2020)	Verpflichtung zur Offenlegung, welcher Anteil wirtschaftlicher Aktivitäten als ökologisch nachhaltig einzustufen ist	Offenlegung von Umsatz, CapEx und OpEx; Bewertung anhand von 6 Umweltzielen sowie die Einhaltung sozialer Mindeststandards	Hoher personeller, organisatorischer und finanzieller Aufwand Kapitalmarktrisiken bei niedriger Quote

Quelle: eigene Darstellung

5 Diskussion

Die im Zuge des europäischen Green Deal eingeführten Förderinstrumente, wie der Social Climate Fund, verfolgen primär das Ziel, soziale Härten im Zusammenhang mit den neuen Emissionsregulierungen abzufedern (Eden et al., 2023). Aus unternehmerischer Sicht ist jedoch festzuhalten, dass diese Fördermechanismen nicht geeignet sind, die erheblich gestiegenen regulatorischen Belastungen aus dem Fit for 55- Paket, CSRD und EU-Taxonomie-Verordnung für Logistikunternehmen substanziell zu kompensieren. Ein Grund hierfür liegt in der begrenzten Förderadressierung, da sich die Förderung ausschließlich an private Haushalte und Kleinstunternehmen richten, während kleine- und mittelständische oder auch große Logistikunternehmen trotz hoher Anpassungs- und Investitionskosten weitgehend unberücksichtigt bleiben. Des Weiteren unterliegt die konkrete Mittelverwendung aus dem Social Climate Fund der nationalen Entscheidungshoheit der Mitgliedstaaten. Somit besteht das Risiko, dass selbst potenziell förderfähige Kleinstunternehmen keine Unterstützung erhalten, was insbesondere die kapitalintensive Logistikbranche weiter dämpfen könnte.

Eine Flottenmodernisierung im Güterverkehr mit dem Umstieg auf alternative Antriebstechnologien und dem Ausbau digitaler Berichtssysteme ist mit erheblichen Kosten verbunden. Da diese Kosten nur sehr begrenzt förderfähig sind, erscheint eine Weitergabe an die Kunden ökonomisch unvermeidbar. Aufgrund der Querschnittsfunktion der Logistik wirken sich steigende Transportkosten entlang nahezu aller Wertschöpfungsketten aus. In der Folge ist davon auszugehen, dass die europäische Klima Regulatorik nicht ausschließlich Logistikunternehmen belastet, sondern preissteigernd auf eine Vielzahl von Gütern auswirkt. In welchem Maß diese Effekte die Nachfrage beeinflussen werden, bleibt offen und bedarf weiterer empirischer Untersuchung.

Kritisch zu bewerten ist zudem das in der Literatur erwähnte Risiko einer Verlagerung wirtschaftlicher Aktivitäten in Länder mit geringeren regulatorischen Anforderungen. Sollte es international nicht zu einer zeitnahen Ausgleichung der Nachhaltigkeitsstandards kommen, besteht die Gefahr einer First-Mover-Nachteilsposition der EU. Die Problematik steht sogar im Spannungsverhältnis zu dem erklärten politischen Ziel, Wettbewerbsverzerrungen, wie sie etwas im Luftverkehr durch die 90%- Betankungsregel vermieden werden sollten, zu verhindern.

Es erscheint ebenso inkonsistent, dass der Schienengüterverkehr zwar als besonders nachhaltiger Verkehrsträger anerkannt wird, bislang jedoch keine ausreichend wirksamen und gezielten Förderimpulse erhält. Ohne einer Verknüpfung regulatorischer Anforderungen mit intensiveren Anreizen droht die verkehrspolitisch angestrebte Transformation nicht erreicht zu werden.

Schließlich ist diskutabel, ob die EU- Taxonomie gegenüber der bereits durch die CSRD gewährleisteten, umfassenden und prüfbareren Nachhaltigkeitsberichterstattung einen zusätzlichen Erkenntnisgewinn bietet. Da ökologische Wirkungen und Zielpfade bereits im Rahmen der CSRD transparent dargestellt werden müssen, erscheint fraglich, inwieweit der mit der Taxonomie verbundene zusätzliche Umsetzungsaufwand und ggf. Nachteile bei der Finanzmittelbeschaffung in einem angemessenen Verhältnis zu der unterstellten Reduktion von Greenwashing- Versuchen steht. Meist entfaltet Greenwashing seine Wirkung dort, wo Nachhaltigkeit als Marketinginstrument genutzt werden kann. Klassische Beispiele sind Produktkommunikation, Nachhaltigkeitsversprechen oder Imagekampagnen. Greenwashing für den Finanzsektor ist risikoreicher, da dieser aufgrund regulatorischer Prüfmechanismen und standardisierter Berichterstattungsanforderungen höhere Analysetiefe aufweist und falschangaben schneller identifiziert und sanktioniert werden.

6 Schlusswort

Vor dem Hintergrund der zunehmenden regulatorischen Anforderungen aus dem Fit for 55 -Paket, der CSRD und der EU-Taxonomie sollten Logistikunternehmen regulatorische Vorgaben frühzeitig und systematisch in ihre Unternehmensstrategie integrieren. Dabei gewinnt der gezielte Ausbau von Daten- und Reportingstrukturen an Bedeutung, da eine belastbare Erfassung von Emissions- und Leistungskennzahlen nicht nur Voraussetzung für CSRD- und Taxonomie- Konformität ist, sondern auch Effizienzsteigerungen im operativen Betrieb ermöglicht. Bei der Flottenmodernisierung empfiehlt sich eine schrittweise und priorisierte Transformationsstrategie. Investitionen sollten technologieoffen und innerhalb realistischer Amortisationszeiträumen sein.

Da regulatorisch bedingte Mehrkosten nur eingeschränkt kompensiert werden, ist eine transparente Weitergabe von Kosten an Kunden erforderlich. Sofern nachweislich nachhaltige Maßnahmen umgesetzt wurden, ist eine gezielte Intensivierung der Marketing- und Kommunikationsaktivitäten ratsam, um Wettbewerbsvorteile gegenüber Kunden und Partnern zu erzielen.

Ergänzend sollten Logistikunternehmen eine aktive Mitwirkung in Branchenverbänden und politischen Konsultationsprozessen anstreben, um praxisnahe Regulierungen zu fördern und langfristige Wettbewerbsnachteile zu begrenzen.

References

- adelphi. (2023). *Policy brief: Making the ETS 2 and Social Climate Fund work*. Europäische Klimaschutzinitiative (EUKI). https://adelphi.de/system/files/document/euki-jcp_policy-brief_5.12.2023_final.pdf
- Arksey, H., & O'Malley, L. (2005). Scoping studies: Towards a methodological framework. *International Journal of Social Research Methodology*, 8(1), 19–32. <https://doi.org/10.1080/1364557032000119616>
- Beil, D., Putz-Egger, L.-M., Sys, C., & Roorda, M. J. (2025). Assessing the acceptance of modal shift policy among shippers and logistics providers. *Transport Policy*, 166, 148–165. <https://doi.org/10.1016/j.tranpol.2025.03.010>
- Bekisz, A., & Kruszyński, M. (2022). European Green Deal in the transport industry. *Economics and Organization of Logistics*, 7(4), 5–17. <https://doi.org/10.22630/EIOL.2022.7.4.25>
- Brabec, J., & Macháč, J. (2025). Impacts of the EU Taxonomy implementation: A systematic literature review. *Climate Policy*. <https://doi.org/10.1080/14693062.2025.2526683>
- Breed, A. K., Speth, D., & Plötz, P. (2021). CO₂ fleet regulation and the future market diffusion of zero-emission trucks in Europe. *Energy Policy*, 159, Article 112640. <https://doi.org/10.1016/j.enpol.2021.112640>
- Christodoulou, A., & Cullinane, K. (2022). Potential alternative fuel pathways for compliance with the 'FuelEU Maritime Initiative'. *Transportation Research Part D: Transport and Environment*, 112, Article 103492. <https://doi.org/10.1016/j.trd.2022.103492>
- Chrzan, S., & Pott, C. (2024). Limiting environmental reporting flexibility: Investor judgment based on the EU taxonomy. *Review of Quantitative Finance and Accounting*, 63, 1511–1548. <https://doi.org/10.1007/s11156-024-01297-x>

- Činčurak Erceg, B., Vasili, A., & Perković, A. (2022). Fit for 55 – Does it fit all? Air and rail transport after COVID-19 pandemic. *EU and Comparative Law Issues and Challenges Series (ECLIC)*, (6), 66–8. <https://doi.org/10.25234/eclic/22411>
- Čižiūnienė, K., Matijošius, J., Sokolovskij, E., & Balevičiūtė, J. (2024). Assessment of implementing green logistics principles in railway transport: The case of Lithuania. *Sustainability*, 16, Article 2716. <https://doi.org/10.3390/su16072716>
- Dagnæs, L. (2022). Beregningsmodeller og emissionsdata i den grønne omstilling af transportsektoren. *Trafikdage på Aalborg Universitet [Proceedings from the Annual Transport Conference at Aalborg University]*. <https://doi.org/10.54337/ojs.td.v29i1.7434>
- Detsios, N., Theodoraki, S., Maragoudaki, L., Atsonios, K., Grammelis, P., & Orfanoudakis, N. G. (2023). Recent advances on alternative aviation fuels/pathways: A critical review. *Energies*, 16, Article 1904. <https://doi.org/10.3390/en16041904>
- Ertürk, A. C., & Toral, B. (2022). Full steam ahead or down? An evaluation of European railways after the “Year of Rail”. *Marmara Journal of European Studies*, 30(2), 113–132. <https://doi.org/10.29228/mjes.433>
- European Commission. (2021). *Fit for 55: Delivering the EU’s 2030 climate target on the way to climate neutrality*. <https://www.europeansources.info/record/fit-for-55-delivering-the-eus-2030-climate-target-on-the-way-to-climate-neutrality/>
- European Parliament and Council of the European Union. (2003). *Directive 2003/87/EC of the European Parliament and of the Council of 13 October 2003 establishing a scheme for greenhouse gas emission allowance trading within the Community and amending Council Directive 96/61/EC*. Official Journal of the European Union, L 275, 32–46. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32003L0087>
- European Parliament and Council of the European Union. (2003). *Directive 2003/87/EC of the European Parliament and of the Council of 13 October 2003 establishing a scheme for greenhouse gas emission allowance trading within the Community and amending Council Directive 96/61/EC* (Consolidated version of 1 March 2024). EUR-Lex. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:02003L0087-20240301>
- European Parliament and Council of the European Union. (2020). Regulation (EU) 2020/852 of the European Parliament and of the Council of 18 June 2020 on the establishment of a framework to facilitate sustainable investment, and amending Regulation (EU) 2019/2088. Official Journal of the European Union, L 198, 13–43. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32020R0852>
- European Parliament and Council of the European Union. (2022). *Directive (EU) 2022/2464 of the European Parliament and of the Council of 14 December 2022 amending Regulation (EU) No 537/2014, Directive 2004/109/EC, Directive 2006/43/EC and Directive 2013/34/EU, as regards corporate sustainability reporting*. Official Journal of the European Union, L 322, 15–80. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32022L2464>
- European Parliament and Council of the European Union. (2023). *Directive (EU) 2023/959 of the European Parliament and of the Council of 10 May 2023 amending Directive 2003/87/EC establishing a system for greenhouse gas emission allowance trading within the Union and Decision (EU) 2015/1814 concerning the establishment and operation of a market stability reserve for the Union greenhouse gas emission trading system*. Official Journal of the European Union, L 130, 134–202. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32023L0959>

European Parliament and Council of the European Union. (2023). *Regulation (EU) 2023/2405 of the European Parliament and of the Council of 18 October 2023 on ensuring a level playing field for sustainable air transport (ReFuelEU Aviation)*. Official Journal of the European Union, L, 2023/2405. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32023R2405>

European Parliament and Council of the European Union. (2023). *Regulation (EU) 2023/1805 of 13 September 2023 on the use of renewable and low-carbon fuels in maritime transport*. EUR-Lex. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32023R1805>

European Parliament and Council of the European Union. (2024). *Regulation (EU) 2024/1610 of the European Parliament and of the Council of 14 May 2024 amending Regulation (EU) 2019/1242 as regards strengthening the CO₂ emission performance standards for new heavy-duty vehicles and integrating reporting obligations, amending Regulation (EU) 2018/858 and repealing Regulation (EU) 2018/956*. Official Journal of the European Union, L, 2024/1610. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32024R1610>

European Parliament and Council of the European Union. (2024). *Regulation (EU) 2024/1679 of the European Parliament and of the Council of 13 June 2024 on Union guidelines for the development of the trans-European transport network, amending Regulations (EU) 2021/1153 and (EU) No 913/2010 and repealing Regulation (EU) No 1315/2013*. Official Journal of the European Union, L, 2024/1679. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32024R1679>

European Parliament. (2024). *The impact of EU climate and energy policies on the competitiveness of the transport and logistics sector*. Policy Department for Economic, Scientific and Quality of Life Policies, Directorate-General for Internal Policies of the Union. [https://www.europarl.europa.eu/RegData/etudes/STUD/2024/752457/IPOL_STU\(2024\)752457_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2024/752457/IPOL_STU(2024)752457_EN.pdf)

Kamiński, R. (2023). European Union Directive 2464/2022 on information on sustainable business and the European Commission's "taxonomy" regulations – assumptions and objectives. *Studia Prawa Publicznego*, (44), 71–87. <https://doi.org/10.14746/spp.2023.4.44.4>

Koilo, V. (2024). Decarbonization in the maritime industry: Factors to create an efficient transition strategy. *Environmental Economics*, 15(2), 42–63. [https://doi.org/10.21511/ee.15\(2\).2024.04](https://doi.org/10.21511/ee.15(2).2024.04)

Korczyk, A., Gdowska, K., & Książek, R. (2026). A decision-support model for holistic energy-sustainable fleet transition. *Sustainability*, 18(1), Article 62. <https://doi.org/10.3390/su18010062>

Krause, J., Arcidiacono, V., Maineri, L., Broekaert, S., & Fontaras, G. (2023). Calculating heavy-duty vehicle CO₂ emission reduction costs for Green Deal scenarios: Extension of the DIONE model. *Transportation Research Procedia*, 72, 2597–2603. <https://doi.org/10.1016/j.trpro.2023.11.788>

Luin, B., Bajec, P., Lorenčič, V., Zanne, M., Tuljak-Šuban, D., & Twrdy, E. (2025). ADMIRAL's multimodal digital marketplace in the logistics industry: Addressing Corporate Sustainable Development Reporting Directive (CSRD). *Transportation Research Procedia*, 83, 43–54. <https://doi.org/10.1016/j.trpro.2025.02.008>

Marek, R., & Staniuk, W. (2025). ESG reporting in the logistics chain. *European Research Studies Journal*, 28(3), 368–389. <https://doi.org/10.35808/ersj/4048>

- Menner, M., & Reichert, G. (2022). *Fit for 55: Climate and maritime transport* (cepAnalysis No. 17/2022, long version). Centrum für Europäische Politik (cep). https://www.cep.eu/fileadmin/user_upload/cep.eu/Analysen/COM_2022_551_Fit_for_55_Klima_und_Seeverkehr/cepAnalyse_Fit_for_55_Klima_und_Seeverkehr_Langfassung.pdf
- Möller, S., Gentes, T., Gohlke, M., Jathe, J., Jung, F., Kenanidou, K., & Orlando, L. (Hrsg.). (2021). *Schlüssel zur Welt – Die bremischen Häfen in der Globalen Politischen Ökonomie* (IPW Working Paper, Vol. 1). Institute for Political Science, University of Bremen. https://www.researchgate.net/profile/Sebastian-Moeller-4/publication/348690968_Schlussel_zur_Welt_-_Die_bremischen_Hafen_in_der_Globalen_Politischen_Oekonomie/links/600b2cff92851c13fe2d7833/Schlussel-zur-Welt-Die-bremischen-Haefen-in-der-Globalen-Politischen-Oekonomie.pdf
- Niemann, L., Morssinkhof, S., van der Linden, M. J., & de Vries, K. (2025). Data requests in value chains: The effects of corporate sustainability reporting on SMEs in the Netherlands. *Sustainability*, 17, Article 8029. <https://doi.org/10.3390/su17178029>
- Oesingmann, K. (2022). *The economic impacts of EU climate policies on intra-European aviation* (Working Paper). German Aerospace Center (DLR), Institute of Air Transport and Airport Research. https://www.researchgate.net/profile/Katrin-Oesingmann/publication/380605331_The_Economic_Impacts_of_EU_Climate_Policies_on_Intra-European_Aviation/links/6645dbca22a7f16b4f2ea07f/The-Economic-Impacts-of-EU-Climate-Policies-on-Intra-European-Aviation.pdf
- Panciu, A., Zerbes, M. V., & Lobonț, L. (2024). Is the European infrastructure ready for long haul electric transportation? An analysis of a freight transport from Romania to Germany using an electric semi-trailer truck. *Annals of the University of Petroșani, Electrical Engineering*, 26, 247–262. <https://www.upet.ro/annals/electrical/doc/2024/22%20Panciu.pdf>
- Seibert, D., Kasten, P., Graichen, J., & Wissner, N. (2024). *EU 2040 climate target: Contributions of the transport sector*. Öko-Institut e.V. <https://www.oeko.de/en/projects/detail/new-objective-and-necessary-increase-in-ambition-for-eu-climate-protection-by-2040/>
- Sunesson, A., Kässer, M., & Schneiderbauer, T. (2025, 20. November). *Europe's ZE truck transition: Key for decarbonization—and competitiveness*. McKinsey & Company. <https://www.mckinsey.com/industries/automotive-and-assembly/our-insights/europes-ze-truck-transition-key-for-decarbonization-and-competitiveness>
- Transport & Environment. (2022, 10. Februar). *Tankering in aviation*. <https://www.transportenvironment.org/articles/tankering-in-aviation>

Pacientska spätná väzba ako nástroj zlepšovania kvality služieb v zdravotníctve

Patient Feedback as a Tool for Improving the Quality of Healthcare Services

Roman Tranžik, Zuzana Hajduová

Abstract

The article examines the potential of patient feedback and patient-reported experience measures (PREMs) as tools for improving healthcare service quality and supporting the motivation of healthcare staff. Based on a systematic literature review, the study analyses the relationships between patient experience, identification of service deficiencies, managerial and organisational responses, and human resource management practices. The findings suggest that patient feedback represents a valuable source of information for identifying weaknesses in communication, coordination, and organisation of care. However, its effectiveness depends on the ability of healthcare organisations to transform collected data into actionable improvement strategies. The study highlights that leadership, organisational culture, and employee engagement play a critical role in this process. Furthermore, patient feedback is shown to have not only a corrective but also a motivational function, as it can support recognition, learning, and professional development of healthcare staff. The paper contributes by integrating patient experience, quality improvement, and personnel management into a unified analytical framework.

JEL classification: I31, I38, O46

Keywords: patient feedback, healthcare quality, quality improvement, patient satisfaction, health services, service quality

1 Úvod

Zdravotníctvo v súčasnosti čelí rastúcim požiadavkám na kvalitu, efektívnosť a pacientsku orientáciu. Popri klinických, bezpečnostných a ekonomických ukazovateľoch sa preto čoraz viac zdôrazňuje aj význam pacientskej perspektívy, ktorá umožňuje hodnotiť zdravotnú starostlivosť z pohľadu jej prijímateľov (Nutti et al., 2017; Mihaljevic et al., 2022). V tejto súvislosti nadobúdajú na význame pacientom reportované ukazovatele skúsenosti (PREMs), ktoré zachytávajú, ako pacienti vnímajú komunikáciu, organizáciu a koordináciu starostlivosti, ako aj mieru rešpektovania ich potrieb (Bull et al., 2018). Východiskom je predpoklad, že pacientom reportované údaje môžu slúžiť nielen na identifikáciu slabých miest služby, ale aj ako podklad pre manažérsku a organizačnú reakciu v oblasti komunikácie a riadenia ľudských zdrojov (Fanelli et al., 2020; Xiao et al., 2022). Článok si preto kladie výskumnú otázku: Ako možno pacientsku spätnú väzbu využiť na podporu motivácie zdravotníckeho personálu a na zlepšenie kvality služieb pre pacientov? Napriek rastúcemu významu pacientskej skúsenosti v hodnotení kvality zdravotnej starostlivosti zostáva jej praktické využitie v manažérskom rozhodovaní a riadení ľudských zdrojov stále nedostatočne preskúmané. Existujúce štúdie sa často zameriavajú najmä na meranie pacientskej spokojnosti a skúsenosti, avšak menej pozornosti venujú tomu, ako možno tieto údaje efektívne transformovať do konkrétnych organizačných a personálnych opatrení. Práve prepojenie medzi pacientskou spätnou väzbou, motiváciou zdravotníckeho personálu a reálnym zlepšovaním kvality služieb tak predstavuje významnú výskumnú výzvu.

2 Súčasný stav riešenej problematiky doma a v zahraničí

Hodnotenie zdravotnej starostlivosti sa už neopiera len o klinické výsledky, bezpečnostné ukazovatele a ekonomické parametre, ale čoraz viac zohľadňuje aj pohľad samotného pacienta. V tejto súvislosti sa do popredia dostáva koncept patientsky orientovanej starostlivosti, ktorý zdôrazňuje potrebu vnímať pacienta nielen ako príjemcu zdravotnej služby, ale aj ako dôležitý zdroj informácií o kvalite poskytovanej starostlivosti (Nutti et al., 2017; Mihaljevic et al., 2022). Z tohto dôvodu významnú úlohu zohrávajú pacientom reportované ukazovatele skúsenosti, teda inak označované ako PREMs, ktoré umožňujú systematicky zachytávať, ako pacienti vnímajú komunikáciu, organizáciu starostlivosti, koordináciu služieb či mieru rešpektovania ich potrieb (Bull et al., 2018). V praktickej rovine sa PREMs v dotazníkoch najčastejšie premietajú do otázok zameraných na to, či pacient dostal jasné a zrozumiteľné informácie, či s ním zdravotnícky personál komunikoval s rešpektom, empatiou a úctou, či bol zapojený do rozhodovania o starostlivosti, či bola starostlivosť dobre organizovaná a koordinovaná, či bola zabezpečená kontinuita starostlivosti vrátane prípravy na prepustenie, či boli zohľadnené jeho individuálne potreby a či mal primeraný prístup k službám, špecialistom alebo nadväznej starostlivosti. Takto zostavený prehľad vychádza najmä z tematického vymedzenia PREMs podľa Bull et al. (2018), z interaktívneho modelu „patient-centeredness“ podľa Scholl et al. (2014) a z prehľadového spracovania podľa Mihaljevic et al. (2022). Mihaljevic et al. (2022) tento rámec rozširujú a ukazujú, že PREMs môžu slúžiť aj ako nástroj hodnotenia patientskej orientácie ako celku, nie iba jednotlivých kontaktných momentov starostlivosti. Ďalší pohľad ponúkajú Kang et al. (2024), ktorí v systematickej rešerši PREMs identifikovali medzi najčastejšie meranými doménami okrem komunikácie a informovania aj bezpečnosť a prostredie, profesionálnu kompetenciu a zapojenie pacienta spolu s emocionálnou podporou. Osobitnú perspektívu predstavujú aj práce zamerané na kontinuitu starostlivosti, kde sa „patient-reported measures“ používajú na zachytenie relačnej, informačnej a manažérskej kontinuity, teda toho, do akej miery pacient vníma starostlivosť ako prepojenú, nadväzujúcu a zrozumiteľnú naprieč viacerými poskytovateľmi (Burge et al., 2012). V literatúre sa zároveň ukazuje potreba rozlišovať medzi pojmami patientska spokojnosť a patientska skúsenosť. Patientska spokojnosť predstavuje širšie subjektívne hodnotenie zdravotníckej služby, ktoré je ovplyvnené aj očakávaniami, osobnými charakteristikami a individuálnym hodnotovým rámcom pacienta (Ng a Luk, 2019). Naopak, patientska skúsenosť sa vzťahuje ku konkrétnym aspektom priebehu starostlivosti, teda k tomu, čo sa počas kontaktu so zdravotníckym systémom skutočne udialo a ako to pacient vnímal (Bull et al., 2018). Patientska spätná väzba má význam najmä preto, že umožňuje odhaľovať konkrétne slabé a silné stránky zdravotníckych služieb. Výskumy ukazujú, že pacienti vo svojich hodnoteniach najčastejšie poukazujú na kvalitu komunikácie zdravotníckeho personálu, spôsob vysvetľovania zdravotného stavu a liečby, mieru zapojenia do rozhodovania, čas venovaný pacientovi, koordináciu starostlivosti či celkový prístup personálu (Fernandes et al., 2019; Etingen et al., 2016). Manzoor et al. (2019) zároveň potvrdzujú, že správanie lekára významne ovplyvňuje to, ako pacienti posudzujú zdravotnícku službu ako celok. Kvalita starostlivosti je teda podmienená nielen odbornou a technickou úrovňou výkonu, ale aj medziľudským rozmerom služby.

Literatúra sa zhoduje v tom, že samotný zber patientskej spätnej väzby automaticky nevedie k zlepšeniu kvality. Rozhodujúce je, či zdravotnícka organizácia dokáže získané dáta správne interpretovať a premietnuť ich do konkrétnych manažérskych opatrení. De Rosis et al. (2020) ukazujú, že pacientom reportované údaje sú najhodnotnejšie vtedy, keď sa zbierajú systematicky, priebežne, sú dostupné v reálnom čase a používajú sa na úrovni celého systému aj jednotlivých oddelení. Ferrè (2023) zdôrazňuje, že využitie pacientom reportovaných informácií pri zlepšovaní kvality si vyžaduje podporu manažmentu, jasne nastavené ciele,

zapojenie viacerých aktérov a vhodné organizačné mechanizmy. Peruzzo et al. (2025) navyše ukazujú, že pacientsku skúsenosť možno využiť aj na určovanie priorít, teda na identifikáciu tých oblastí služby, ktoré majú najväčší vplyv na celkové hodnotenie pacienta.

Štúdie upozorňujú aj na bariéry, ktoré bránia efektívnemu využívaniu patientskych dát v Shunmugasundaram et al. (2022) identifikujú medzi najčastejšími prekážkami nedostatok času, obmedzené personálne a finančné kapacity, neistotu pri interpretácii výsledkov a obavy zamestnancov z negatívneho hodnotenia. Barry et al. (2016) zároveň ukazujú, že patientské prieskumy síce bývajú v zdravotníckych organizáciách realizované pravidelne, no bez dostatočne konkrétnych výstupov a bez jasného postupu ich využitia vedú skôr k menším operatívnym úpravám než k hlbšej organizačnej zmene. Groene et al. (2015) vo svojej európskej analýze dokonca poukazujú na to, že ani formálne rozvinuté management stratégie nemusia automaticky viesť k lepším výsledkom v oblasti „patient experience“. Kennedy et al. (2011) zdôrazňujú, že zlepšovanie kvality služby si vyžaduje nielen zber dát, ale aj zodpovednosť, vzdelávanie, tréning, priebežné monitorovanie a uznanie zamestnancov.

Abid a Al Masoudi (2023) ukazujú, že zlepšenie patientskej skúsenosti možno podporiť aj prostredníctvom intervencií zameraných na kultúru organizácie, napríklad pomocou tréningov empatie, zapojenia pacientov a rodín či vytvárania interných ambasádorov orientovaných na „patient experience“. Rasheed et al. (2022) zároveň potvrdzujú, že leadership a zapojenie zamestnancov do zlepšovacích aktivít môžu pozitívne ovplyvniť skúsenosť pacientov, pričom dôležitou podmienkou ostáva dlhodobé ukotvenie týchto prístupov v organizácii. Význam riadenia ľudských zdrojov v tejto oblasti potvrdzujú aj ďalšie práce. Xiao et al. (2022) poukazujú na to, že pohoda zdravotníckeho personálu, najmä sestier, je úzko spätá s organizačnou podporou, pracovným prostredím a kvalitou personálnych praktík. Buchelt et al. (2020) dopĺňajú, že nemocnice často čelia problémom pri budovaní takej organizačnej kapacity HRM, ktorá by dokázala adekvátne reagovať na meniace sa požiadavky zdravotníckeho prostredia. Barchielli et al. (2022) zároveň ukazujú, že pacientom reportované ukazovatele, údaje o organizačnej klíme a ošetrovateľské indikátory možno prepájať v rámci komplexnejších systémov hodnotenia výkonnosti zdravotníckej organizácie.

3 Výskumný dizajn

Postup vychádza z odporúčaného rámca pre systematické prehľady v manažérskom výskume, ktorý zahŕňa formulovanie výskumnej otázky, stanovenie výberových kritérií, vyhľadanie a selekciu relevantných publikácií, syntézu literatúry a prezentáciu výsledkov. Na základe zamerania článku bola formulovaná výskumná otázka: Ako možno pacientsku spätnú väzbu a pacientom reportované ukazovatele využiť na podporu motivácie zdravotníckeho personálu a na zlepšenie kvality služieb pre pacientov? Po definovaní výskumnej otázky boli určené kritériá výberu relevantnej literatúry.

Tabuľka 1

Kritériá výberu literatúry

Kritérium	Špecifikácia
Časové obdobie	2015–2025
Databázy	Web of Science, Scopus, Google Scholar, Scispace
Kľúčové slová	„patientska spätná väzba“ „patientska skúsenosť“ „PREMs“ „patientska spokojnosť“ „manažment zdravotníctva“ „zlepšovanie kvality“ „líderstvo a riadenie ľudských zdrojov“
Jazyk	slovenčina
Typ dokumentu	recenzované vedecké články, systematické rešerše, empirické štúdie
Dostupnosť	plný text

Zdroj: vlastné spracovanie

Na základe uvedených kritérií prebehlo vyhľadanie a následná selekcia literatúry. Zo súboru boli vyradené duplicity, nerelevantné práce, dizertácie a zdroje bez jasnej väzby na skúmanú problematiku. Výsledný súbor tvorilo 25 vedeckých prác, ktoré boli následne podrobené tematickej analýze. Keďže išlo o metodologicky rôznorodé štúdie, nebola použitá meta-analýza. Namiesto nej bola zvolená syntéza literatúry založená na porovnávaní hlavných tém, zhôd a rozdielov medzi autormi. Na základe tejto analýzy boli identifikované frekvencie tematického kódovania článkov podľa ich primárneho a vedľajšieho obsahového zamerania, pričom jeden zdroj mohol byť zaradený do viacerých oblastí. Zobrazené výsledky ktoré dominujú v literatúre znázorňuje obrázok 1.

Obrázok 1

Frekvencia hlavných tém v analyzovaných článkoch (n = 25)




Zdroj: vlastné spracovanie

Najčastejšie bola zastúpená oblasť patientskej skúsenosti a PREMs, nasledovaná manažérskou a organizačnou reakciou a oblasťou identifikácie slabých miest. Menej často boli zastúpené témy metodické otázky, HRM, well-being. Na účely ďalšej analýzy však boli tieto tematické oblasti zlúčené a usporiadané do štyroch hlavných analytických okruhov, ktoré zobrazuje obrázok 2. Ide o štyri základné časti, ktoré najlepšie zodpovedajú logike skúmanej problematiky.

Obrázok 2

Štyri kľúčové oblasti výskumu



Zdroj: vlastné spracovanie

4 Výsledky výskumu

Štyri základné oblasti, ktoré zobrazuje obrázok č.2 boli ďalej analyzované pričom zahŕňali systematické prehľady, kvalitatívne a kvantitatívne empirické štúdie aj implementačné prípadové štúdie, čo umožnilo porovnať skúmanú problematiku z viacerých uhlov pohľadu (Shunmugasundaram et al., 2022; Vaughn et al., 2019; De Rosis et al., 2020). Ich obsahové zameranie a autori sú uvedení v tabuľke 2.

Tabuľka 2

Tematické oblasti s obsahovým zameraním autorov

Tematická oblasť	Obsahové zameranie	Autori
Pacientska skúsenosť a PREMs	vymedzenie pojmov patient satisfaction, patient experience a PREMs; význam patientsky reportovaných ukazovateľov pri hodnotení kvality starostlivosti; metodické otázky merania a interpretačné riziká	Bull et al. (2018); Ng a Luk (2019); Mihaljevic et al. (2022); Shunmugasundaram et al. (2022); Dunsch et al. (2018)
Identifikácia slabých miest služby a kvalita služby	využitie patientskych dát pri odhaľovaní problémov v komunikácii, koordinácii, zapájaní pacienta, organizácii procesu a celkovej kvalite služby	De Rosis et al. (2020); Barry et al. (2016); Fernandes et al. (2019); Etingen et al. (2016); Manzoor et al. (2019); Peruzzo et al. (2025)
Manažérska a organizačná reakcia	využitie patient feedback pri quality improvement, nastavovaní akčných plánov, organizačnej zmene, benchmarkingu, leadershipu, komunikácii, kultúre a participácii	Ferrè (2023); Nielsen et al. (2013); Quigley et al. (2022); Kennedy et al. (2011); Groene et al. (2015); Abid a Al Masoudi (2023); Fanelli et al. (2020); Haldane et al. (2019); Rasheed et al. (2022); Vaughn et al. (2019)
Motivácia zdravotníckeho personálu a zlepšenie kvality služby	vzťah medzi patientskou spätnou väzbou, motiváciou zdravotníckeho personálu, pracovnou pohodou, organizačnou klímou, riadením ľudských zdrojov a kvalitou služby	Xiao et al. (2022); Buchelt et al. (2020); Barchielli et al. (2022); Kennedy et al. (2011); Rasheed et al. (2022); Fanelli et al. (2020)

Zdroj: vlastné spracovanie

Tabuľka 3

Oblasti sledované v rámci PREMs

Pojem	Obsahové zameranie	Význam pre článok	Autori
Pacientska spokojnosť	subjektívne celkové hodnotenie zdravotníckej služby	širší hodnotiaci koncept, ovplyvnený aj očakávaniami pacienta	Ng a Luk (2019)
Pacientska skúsenosť	konkrétne vnímanie priebehu starostlivosti a interakcie so systémom	akcieschopnejší zdroj poznania o kvalite služby	Bull et al. (2018); Etingen et al. (2016)
PREMs	pacientom reportované ukazovatele skúsenosti	nástroj systematického zachytávania skúsenosti pacienta	Bull et al. (2018); Mihaljevic et al. (2022); Shunmugasundaram et al. (2022)
Patient-centeredness	širší rámec orientácie zdravotnej starostlivosti na pacienta	prepája kvalitu služby, skúsenosť pacienta a organizáciu starostlivosti	Nuti et al. (2017); Mihaljevic et al. (2022)

Zdroj: vlastné spracovanie

Autori nepracujú s pojmami pacientska spokojnosť, pacientska skúsenosť a patient-centeredness ako s totožnými kategóriami. Ng a Luk (2019) chápu pacientsku spokojnosť ako širší hodnotiaci koncept ovplyvnený postojom poskytovateľa, technickou kompetenciou, dostupnosťou a účinnosťou služby. Bull et al. (2018) naopak zdôrazňujú, že PREMs zachytávajú konkrétnu skúsenosť pacienta so zdravotnou starostlivosťou, teda to, čo sa počas poskytovania služby reálne udialo. Mihaljevic et al. (2022) zasa ukazujú, že patient-centeredness predstavuje širší viacrozmerný rámec, v ktorom PREMs slúžia ako jeden z hlavných nástrojov merania. Súčasne však autori upozorňujú, že aj tieto ukazovatele treba interpretovať opatrne. Dunsch et al. (2018) ukázali, že výsledky prieskumov spokojnosti môžu byť významne ovplyvnené formuláciou otázok, čo predstavuje riziko skresleného hodnotenia kvality.

Štúdie sa zároveň zhodujú, že pacientska skúsenosť má úzky vzťah ku kvalite zdravotnej starostlivosti. Etingen et al. (2016) ukázali, že dimenzie súvisiace s empatiou, komunikáciou a participáciou pacienta poskytujú doplnkové informácie o kvalite starostlivosti. Fernandes et al. (2019) vo svojej štúdií ambulantnej starostlivosti v Maďarsku zistili, že pacienti relatívne pozitívne hodnotili zrozumiteľnosť vysvetlení a čas venovaný konzultácii, avšak slabšie hodnotili zapájanie do rozhodovania o liečbe. To naznačuje, že pacientska skúsenosť neodráža len všeobecný dojem zo služby, ale pomáha identifikovať konkrétne oblasti, ktoré si vyžadujú zlepšenie (Fernandes et al., 2019; Etingen et al., 2016).

4.1 Pacientska spätná väzba ako nástroj identifikácie slabých miest služby

Druhou oblasťou výsledkov je využitie patientskej spätnej väzby pri odhaľovaní problémových oblastí zdravotníckych služieb. V tejto rovine panuje medzi autormi výrazná zhoda. De Rosis et al. (2020) ukazujú, že systematický a priebežný zber PREMs umožňuje identifikovať slabé miesta starostlivosti až na úrovni jednotlivých oddelení a tímov. Barry et al. (2016) zistili, že poskytovatelia out-of-hours služieb považovali pacientsku spätnú väzbu za užitočnú najmä vtedy, keď mala konkrétnu a kvalitatívnu podobu, ktorá lepšie vysvetľovala príčiny problémov. Ferrè (2023) potvrdzuje, že patient-reported information môže odhaliť kritické miesta v celej trajektórii starostlivosti a slúžiť ako základ pre kvalitatívne zmeny na úrovni klinických sietí. Peruzzo et al. (2025) navyše ukazujú, že patientske dáta možno využiť aj na určovanie priorít, teda na identifikáciu tých oblastí skúsenosti, ktoré majú najväčší vplyv na celkové hodnotenie služby.

Tabuľka 4

Slabé miesta zdravotníckej služby

Oblasť služby	Čo patientská spätná väzba odhaľuje	Implikačný význam pre organizáciu	Autori
Komunikácia so zdravotníckym personálom	zrozumiteľnosť informácií, prístup, empatia	potreba zlepšiť komunikačné zručnosti personálu	Fernandes et al. (2019); Etingen et al. (2016); Manzoor et al. (2019)
Organizácia procesu starostlivosti	čakanie, koordinácia, orientácia v procese	potreba úprav pracovných procesov a organizácie služby	Barry et al. (2016); Peruzzo et al. (2025)
Zapájanie pacienta do rozhodovania	nízka participácia pacienta, slabý shared decision-making	potreba väčšieho dôrazu na patientsku orientáciu	Etingen et al. (2016); Fernandes et al. (2019)
Kvalita služby na úrovni oddelenia	silné a slabé stránky konkrétnych pracovísk	využitie dát na lokálne zlepšovanie kvality	De Rosis et al. (2020); Peruzzo et al. (2025)
Celková trajektória starostlivosti	problémové body naprieč starostlivosťou	podklad pre systémové zmeny a koordináciu	Ferrè (2023); Nuti et al. (2017)

Zdroj: vlastné spracovanie

Z výsledkov zároveň vyplýva, že autori neprístupujú k tejto diagnostickej funkcii rovnako. Časť prác sa sústreďuje na širšiu systémovú úroveň. Nuti et al. (2017) tvrdia, že patient experience by mala byť súčasťou celkového systému hodnotenia výkonnosti zdravotníctva a mala by sa prepájať s ďalšími ukazovateľmi kvality. Podobne De Rosis et al. (2020) a Barchielli et al. (2022) ukazujú, že patientsky hlas možno integrovať do viacrozmerých rámcov hodnotenia organizácie. Iné práce pristupujú k spätnej väzbe skôr na úrovni konkrétnych dimenzií služby, ako sú komunikácia, koordinácia, rešpekt alebo správanie lekára (Etingen et al., 2016; Fernandes et al., 2019; Manzoor et al., 2019).

4.2 Manažérska a organizačná reakcia na pacientom reportované údaje

Tretou oblasťou výsledkov je otázka, akým spôsobom zdravotnícke organizácie reagujú na údaje získané od pacientov. V analyzovanej literatúre sa opakovane ukazuje, že meranie spätnej väzby samo osebe nestačí. Shunmugasundaram et al. (2022) vo svojej systematickej rešerši uvádzajú, že využitie PREMs v klinickej praxi závisí od podmienok na úrovni organizácie, personálu aj pacienta. Ako facilitátory identifikujú najmä podporu leadershipu, dostatok zdrojov, tréning pracovníkov a vhodne zvolený nástroj merania. Kennedy et al. (2011) opisujú podobnú logiku v podobe modelu, ktorý spája viac zdrojov dát, zodpovednosť za kvalitu, tréning, priebežné monitorovanie a uznanie zamestnancov. Quigley et al. (2022) zároveň zdôrazňujú, že patientska skúsenosť prináša najväčší úžitok vtedy, keď je zapojená do štandardizovaného quality improvement procesu a kombinovaná s ďalšími zdrojmi dát. Avšak literatúra nie je v hodnotení účinnosti týchto procesov úplne jednotná. Groene et al. (2015) vo viacštátnej európskej štúdiu nezistili výrazný vzťah medzi formálne rozvinutými quality management stratégiami a výsledkami patient experience. Tento záver je v kontraste s prácami De Rosis et al. (2020), Ferrè (2023), Kennedy et al. (2011) či Abid a Al Masoudi (2023), ktoré opisujú pozitívne efekty využitia patientskych dát pri zlepšovaní služieb. Rozdiel spočíva najmä v úrovni analýzy. Kým Groene et al. (2015) skúmajú širšie nemocničné stratégie na systémovej úrovni, implementačné štúdie zachytávajú konkrétne mechanizmy, procesy a praktiky, prostredníctvom ktorých sa patientske dáta premietajú do zmeny.

Medzi autormi prevláda zhoda, že účinná manažérska reakcia na patientsku spätnú väzbu musí byť viacúrovňová a zahŕňať komunikáciu výsledkov, facilitáciu, tréning, leadership a priebežný follow-up (Ferrè, 2023; Abid & Al Masoudi, 2023; Rasheed et al., 2022).

4.3 Motivácia zdravotníckeho personálu a riadenie ľudských zdrojov

Štvrtá oblasť výsledkov ukazuje, že patientska spätná väzba je v literatúre prepojená s motiváciou zdravotníckeho personálu skôr nepriamo než priamo. Autori zhodne naznačujú, že patient feedback pôsobí na personál prostredníctvom leadershipu, kultúry organizácie, komunikácie. Fanelli et al. (2020) identifikovali medzi najdôležitejšími manažérskymi kompetenciami v zdravotníctve hodnotenie kvality, rozvoj profesijných kompetencií, procesný manažment, neformálnu komunikáciu. Xiao et al. (2022) ukazujú, že pohoda sestier závisí od individuálnych, pracovných, organizačných aj inštitucionálnych faktorov, pričom kľúčovú rolu zohráva organizačná podpora. Buchelt et al. (2020) zároveň upozorňujú, že nemocnice často nemajú dostatočne rozvinutú organizačnú kapacitu HRM na zvládanie zmien a nových požiadaviek.

Tabuľka 5

Pacientska spätná väzba a personálna rovina kvality služby

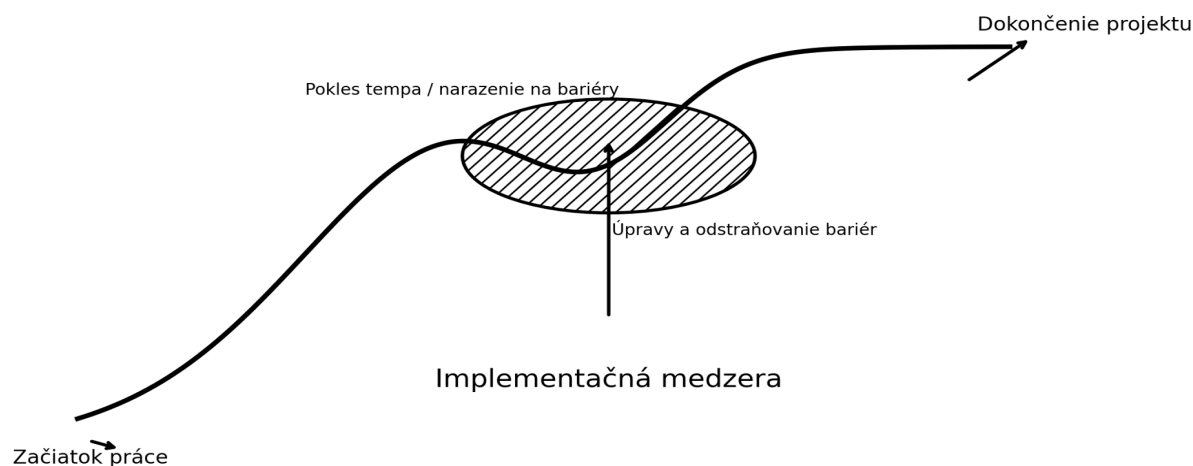
Oblasť	Vzťah k zdravotníckemu personálu	Implikačný význam	Autori
Komunikácia a správanie personálu	pacienti hodnotia prístup, rešpekt a vysvetľovanie	spätná väzba usmerňuje správanie a profesionálny štandard	Manzoor et al. (2019); Etingen et al. (2016); Fernandes et al. (2019)
Uznanie pozitívneho správania	naratívna spätná väzba odhaľuje aj pozitívne skúsenosti	možnosť oceňovania a posilňovania žiaducich prejavov	De Rosis et al. (2020); Kennedy et al. (2011)
Leadership a employee voice	zapojenie pracovníkov do zlepšovania služieb	posilňuje angažovanosť a ownership zmien	Rasheed et al. (2022); Fanelli et al. (2020)
Organizačná kultúra	kultúra empatie, participácie a učenia	podporuje motiváciu a orientáciu na kvalitu služby	Abid a Al Masoudi (2023); Vaughn et al. (2019); Haldane et al. (2019)
HRM a pracovná pohoda	spätná väzba sa prepája s klímou, podporou a well-beingom	kvalita služby a riadenie ľudí sú navzájom prepojené	Xiao et al. (2022); Buchelt et al. (2020); Barchielli et al. (2022)

Zdroj: vlastné spracovanie

Niektoré práce nevnímajú patientsku spätnú väzbu iba deficitne, teda ako upozornenie na nedostatky, ale aj motivačne. De Rosis et al. (2020) zdôrazňujú význam naratívnej spätnej väzby, ktorá dokáže zviditeľniť aj pozitívne správanie a situácie, ktoré pacienti hodnotili mimoriadne priaznivo. Takéto údaje môžu byť využité pri manažmente ľudí, organizačnom učení aj oceňovaní zamestnancov. Rasheed et al. (2022) rovnako ukazujú, že spätná väzba, uznanie a zapojenie zamestnancov patrili medzi dôležité faktory podpory zlepšovacích aktivít. Barchielli et al. (2022) navyše prepájajú patient-reported measures, údaje o organizačnej klíme a HR ukazovatele do jedného rámca hodnotenia výkonnosti. Z toho vyplýva, že patientska spätná väzba môže byť pre personál nielen zdrojom korekcie, ale aj zdrojom uznania, profesionálneho významu a tímového učenia. Súčasne však literatúra upozorňuje aj na limity tejto motivačnej funkcie. Shunmugasundaram et al. (2022) zároveň zdôrazňujú, že bez tréningu, kapacít a podpory vedenia môže byť agenda personálom vnímaná ako dodatočná záťaž.

Obrázok 3

Implementačná medzera medzi zberom patientskej spätnej väzby a zlepšovaním kvality služby



Zdroj: vlastné spracovanie

Obrázok 3 znázorňuje proces implementácie zmien v zdravotníckych organizáciách, pričom identifikuje tzv. implementačnú medzeru (implementation gap) medzi zberom patientskej spätnej väzby a jej reálnym využitím v praxi. Táto fáza je charakteristická poklesom tempa a narážaním na organizačné bariéry, ktoré si vyžadujú aktívne riadenie, úpravy procesov a odstránenie prekážok.

Analýzy vybraných štúdií umožnili odpovedať na výskumnú otázku článku. Z analyzovanej literatúry vyplýva, že patientska spätná väzba a pacientom reportované ukazovatele skúsenosti majú významný potenciál pri zlepšovaní kvality zdravotníckych služieb, najmä preto, že pomáhajú identifikovať slabé miesta v komunikácii, organizácii procesu, koordinácii a prístupe zdravotníckeho personálu (De Rosis et al., 2020; Barry et al., 2016; Ferrè, 2023). Zároveň sa však potvrdzuje, že samotný zber údajov nepostačuje. Rozhodujúce je, či zdravotnícka organizácia dokáže tieto údaje správne interpretovať a premeniť ich na konkrétnu manažérsku a organizačnú reakciu (Shunmugasundaram et al., 2022; Kennedy et al., 2011; Quigley et al., 2022). V tomto smere sa zároveň ukazuje, že medzi meraním patientskej skúsenosti a reálnym zlepšením kvality stojí leadership, organizačná kultúra a spôsob riadenia ľudí, ktoré určujú, či sa spätná väzba stane reálnym nástrojom zmeny, alebo zostane len na úrovni merania (Abid & Al Masoudi, 2023; Rasheed et al., 2022; Groene et al., 2015). Z analýzy ďalej naznačujú, že vzťah medzi patientskou spätnou väzbou a motiváciou zdravotníckeho personálu je prevažne nepriamy. Patientske dáta nepôsobia na motiváciu samy osebe, ale prostredníctvom komunikácie, participácie, organizačnej kultúry a personálnych praktík (Fanelli et al., 2020; Xiao et al., 2022; Buchelt et al., 2020). Zároveň sa ukazuje, že patientska spätná väzba nemusí mať iba korekčný charakter, ale môže slúžiť aj ako podklad na uznanie pozitívneho správania, podporu učenia a posilňovanie orientácie na kvalitu služby (De Rosis et al., 2020; Kennedy et al., 2011; Barchielli et al., 2022).

Zistenia tejto štúdie poskytujú ucelený pohľad na úlohu patientskej spätnej väzby a pacientom reportovaných ukazovateľov skúsenosti (PREMs) pri zlepšovaní kvality zdravotníckych služieb a podpore motivácie zdravotníckeho personálu. Hoci literatúra konzistentne potvrdzuje ich diagnostickú hodnotu, ich efektívnosť ako nástroja zlepšovania kvality zostáva podmienená organizačným kontextom.

Kľúčovým zistením je rozdiel medzi meraním patientskej skúsenosti a jej reálnym využitím v praxi. Napriek rozšírenému využívaniu PREMs viacerí autori poukazujú na to, že samotný zber dát nevedie automaticky k zlepšeniu kvality. To naznačuje existenciu „medzery medzi

dátami a ich využitím“ (translation gap), ktorá je ovplyvnená najmä faktormi ako angažovanosť leadershipu, dostupnosť zdrojov a existencia štruktúrovaných procesov zlepšovania kvality.

Analýza zároveň poukazuje na rozdiely v hodnotení efektívnosti patientskej spätnej väzby na rôznych úrovniach riadenia. Kým veľkoplošné štúdie identifikujú slabšie prepojenie medzi formálnymi stratégiami riadenia kvality a výsledkami v oblasti patientskej skúsenosti, implementačne orientované štúdie preukazujú pozitívne efekty v prípadoch, keď je spätná väzba integrovaná do kontinuálnych a participatívnych procesov zlepšovania. Tento rozdiel možno vysvetliť odlišnými metodologickými prístupmi a rôznou úrovňou vyspelosti systémov riadenia kvality.

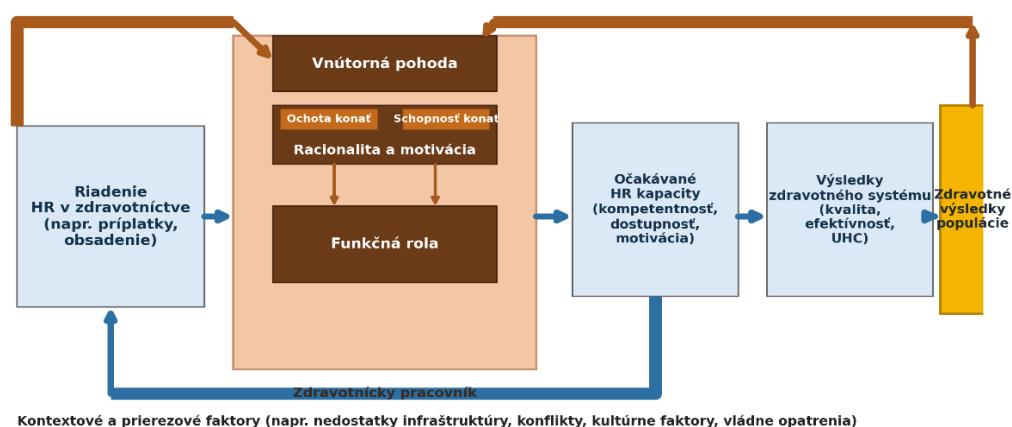
Na základe syntézy zistení možno vzťahy medzi patientskou spätnou väzbou, motiváciou zdravotníckeho personálu a výsledkami zdravotného systému schematicky znázorniť prostredníctvom konceptuálneho modelu (Obrázok 4). Model poukazuje na to, že patientska spätná väzba nepôsobí izolovane, ale je súčasťou širšieho systému riadenia ľudských zdrojov a organizačných procesov.

V centre modelu sa nachádza zdravotnícky pracovník, ktorého vnútorná pohoda, ochota konať a schopnosť konať determinujú jeho funkčnú rolu v poskytovaní zdravotnej starostlivosti. Tieto faktory sú ovplyvňované riadením ľudských zdrojov, ako aj širšími kontextovými podmienkami. Výsledkom sú očakávané kapacity zdravotníckeho personálu, ktoré sa následne premietajú do kvality a efektívnosti zdravotného systému a konečných zdravotných výsledkov populácie.

Model zároveň implikuje, že efektívne využitie patientskej spätnej väzby si vyžaduje prepojenie medzi úrovňou merania, riadenia ľudí a systémových výstupov, čím rozširuje tradičné chápanie patient feedback ako izolovaného nástroja hodnotenia kvality.

Obrázok 4

Konceptuálny model vplyvu patientskej spätnej väzby na motiváciu zdravotníckeho personálu a výsledky zdravotného systému



Zdroj: vlastné spracovanie

Významným prínosom je aj identifikácia nepriameho vzťahu medzi patientskou spätnou väzbou a motiváciou zdravotníckeho personálu. Pacientom reportované údaje nepôsobia na motiváciu priamo, ale prostredníctvom sprostredkujúcich faktorov, ako sú organizačná kultúra, leadership, komunikácia a zapojenie zamestnancov. V tomto kontexte patientska spätná väzba funguje ako nástroj formovania profesionálneho správania a podpory organizačného učenia.

Literatúra zároveň zdôrazňuje aj jej motivačný potenciál. Naratívna spätná väzba umožňuje identifikovať pozitívne praktiky a podporovať uznanie zamestnancov, čím prispieva k ich angažovanosti a profesijnému rozvoju. Tento prístup je v súlade s modernými konceptmi riadenia ľudských zdrojov, ktoré zdôrazňujú význam spätnej väzby a participácie zamestnancov.

Na druhej strane, efektívne využívanie patientskej spätnej väzby je limitované viacerými bariérami, najmä nedostatkom času, analytických kapacít, tréningu a obavami z negatívneho hodnotenia. Bez adekvátnej organizačnej podpory môže byť spätná väzba vnímaná skôr ako administratívna záťaž než ako nástroj zlepšovania.

Z teoretického hľadiska štúdia prepája oblasti merania patientskej skúsenosti, zlepšovania kvality a riadenia ľudských zdrojov do jedného analytického rámca. Z praktického hľadiska výsledky naznačujú potrebu prechodu od pasívneho zberu dát k systematickému využívaniu spätnej väzby, vrátane jej prepojenia so systémami riadenia výkonnosti a aktívneho zapojenia zamestnancov do jej interpretácie a implementácie zmien.

5 Diskusia a záver

Predkladaný článok sa zamerá na analýzu toho, ako možno patientsku spätnú väzbu a pacientom reportované ukazovatele skúsenosti využiť pri motivácii zdravotníckeho personálu a zlepšovaní kvality služieb pre pacientov. Na základe literárnej rešerše možno konštatovať, že patient feedback a PREMs predstavujú relevantný zdroj informácií pre manažment zdravotníckych organizácií. Ich význam nespočíva iba v meraní patientskej skúsenosti, ale aj v tom, že vytvárajú podklad pre zlepšovanie organizačných procesov, práce personálu a celkovej kvality poskytovanej starostlivosti. Výsledky zároveň naznačujú, že úspešné využitie patientskej spätnej väzby si vyžaduje nielen technické a metodické zvládnutie zberu dát, ale aj primerané organizačné a manažérske podmienky. Pre prax z toho vyplýva potreba vnímať patient feedback ako súčasť širšieho systému riadenia kvality a riadenia ľudských zdrojov. Prínos článku spočíva v systematickom prepojení patientskej skúsenosti, identifikácie slabých miest služby, manažérskej reakcie a motivácie zdravotníckeho personálu v jednom analytickom rámci.

Limity článku vyplývajú zo samotného charakteru systematickej literárnej rešerše a z rozsahu analyzovaného súboru zdrojov. Ďalší výskum by sa preto mohol zamerať na širší počet empirických štúdií a na detailnejšie skúmanie toho, ako patientska spätná väzba ovplyvňuje správanie zdravotníckeho personálu, organizačnú kultúru a kvalitu služieb v konkrétnych typoch zdravotníckych zariadení.

Poznámka o riešenom projekte

Tento príspevok je čiastkovým výstupom riešenia projektu VEGA MŠ SR 1/0109/24.

Použitá literatúra (References)

Alagoz, E., Chih, M.-Y., Hitchcock, M., Brown, R., & Quanbeck, A. (2018). The use of external change agents to promote quality improvement and organizational change in healthcare organizations: A systematic review. *BMC Health Services Research*, 18(1), Article 42. <https://doi.org/10.1186/s12913-018-2856-9>

Almohaisen, N. A., Alsayari, N. M., Abid, M. H., Al Subhi, N. F., Al Masoudi, A., AlGhazali, O. S., & Woodman, A. (2023). Improving patient experience by implementing an organisational culture model. *BMJ Open Quality*, 12(2), e002076. <https://doi.org/10.1136/bmjopen-2022-002076>

- Barchielli, C., Rafferty, A. M., & Vainieri, M. (2022). Integrating key nursing measures into a comprehensive healthcare performance management system: A Tuscan experience. *International Journal of Environmental Research and Public Health*, 19(3), Article 1373. <https://doi.org/10.3390/ijerph19031373>
- Barry, H. E., Campbell, J. L., Asprey, A., & Richards, S. H. (2016). The use of patient experience survey data by out-of-hours primary care services: A qualitative interview study. *BMJ Quality & Safety*, 25(11), 851–859. <https://doi.org/10.1136/bmjqs-2015-003963>
- Bull, C., Byrnes, J., & Mulhern, B. (2018). We respect their autonomy and dignity, but how do we value patient-reported experiences? *MDM Policy & Practice*, 3(2), 2381468318807458. <https://doi.org/10.1177/2381468318807458>
- Buchelt, B., Frączkiewicz-Wronka, A., & Dobrowolska, M. (2020). The organizational aspect of human resource management as a determinant of the potential of Polish hospitals to manage medical professionals in Healthcare 4.0. *Sustainability*, 12(12), Article 5118. <https://doi.org/10.3390/su12125118>
- Burge, F., Haggerty, J. L., Pineault, R., Beaulieu, M.-D., Lévesque, J.-F., Beaulieu, C., & Santor, D. A. (2011). Relational continuity from the patient perspective: Comparison of primary healthcare evaluation instruments. *Healthcare Policy*, 7(Special Issue), 124–138.
- De Rosis, S., Cerasuolo, D., & Nuti, S. (2020). Using patient-reported measures to drive change in healthcare: The experience of the digital, continuous and systematic PREMs observatory in Italy. *BMC Health Services Research*, 20(1), Article 315. <https://doi.org/10.1186/s12913-020-05099-4>
- Dunsch, F., Evans, D. K., Macis, M., & Wang, Q. (2018). Bias in patient satisfaction surveys: A threat to measuring healthcare quality. *BMJ Global Health*, 3(2), e000694. <https://doi.org/10.1136/bmjgh-2017-000694>
- Etingen, B., Miskevics, S., & LaVela, S. L. (2016). Assessing the associations of patient-reported perceptions of patient-centered care as supplemental measures of health care quality in VA. *Journal of General Internal Medicine*, 31(Suppl. 1), 10–20. <https://doi.org/10.1007/s11606-015-3557-2>
- Fanelli, S., Lanza, G., Enna, C., & Zangrandi, A. (2020). Managerial competences in public organisations: The healthcare professionals' perspective. *BMC Health Services Research*, 20(1), Article 303. <https://doi.org/10.1186/s12913-020-05179-5>
- Fernandes, Ó. B., Baji, P., Kringos, D., Klazinga, N., Gulácsi, L., Lucevic, A., Boncz, I., & Péntek, M. (2019). Patient experiences with outpatient care in Hungary: Results of an online population survey. *The European Journal of Health Economics*, 20(Suppl. 1), 79–90. <https://doi.org/10.1007/s10198-019-01064-z>
- Ferrè, F. (2024). Exploring how to trigger the use of patient-reported information for quality improvement in multi-stakeholder governance. *The TQM Journal*, 36(9), 22–39. <https://doi.org/10.1108/TQM-07-2023-0236>
- Groene, O., Arah, O. A., Klazinga, N. S., Wagner, C., Bartels, P. D., Kristensen, S., Saillour, F., Thompson, A., Thompson, C. A., Pfaff, H., DerSarkissian, M., & Sunol, R. (2015). Patient experience shows little relationship with hospital quality management strategies. *PLOS ONE*, 10(7), e0131805. <https://doi.org/10.1371/journal.pone.0131805>
- Haldane, V., Chuah, F. L. H., Srivastava, A., Singh, S. R., Koh, G. C. H., Seng, C. K., & Legido-Quigley, H. (2019). Community participation in health services development, implementation,

- and evaluation: A systematic review of empowerment, health, community, and process outcomes. *PLOS ONE*, 14(5), e0216112. <https://doi.org/10.1371/journal.pone.0216112>
- Kang, Y., Guan, T., Chen, X., & Zhang, Y. (2024). Patient-reported experience measures in adult inpatient settings: A systematic review. *Journal of Nursing Management*, 2024, Article 5166392. <https://doi.org/10.1155/jonm/5166392>
- Kennedy, D. M., Caselli, R. J., & Berry, L. L. (2011). A roadmap for improving healthcare service quality. *Journal of Healthcare Management*, 56(6), 385–400. <https://doi.org/10.1097/00115514-201111000-00007>
- Manzoor, F., Wei, L., Hussain, A., Asif, M., & Shah, S. I. A. (2019). Patient satisfaction with health care services: An application of physician's behavior as a moderator. *International Journal of Environmental Research and Public Health*, 16(18), Article 3318. <https://doi.org/10.3390/ijerph16183318>
- Mihaljevic, A. L., Michalski, C. W., Kaisers, U., & Strunk, G. (2022). *Patientenorientierung* [Patient-centeredness]. *Die Chirurgie*, 93(9), 861–869. <https://doi.org/10.1007/s00104-022-01629-4>
- Ng, J. H. Y., & Luk, B. H. K. (2019). Patient satisfaction: Concept analysis in the healthcare context. *Patient Education and Counseling*, 102(4), 790–796. <https://doi.org/10.1016/j.pec.2018.11.013>
- Nielsen, J. F., & Riiskjær, E. (2013). From patient surveys to organizational change: Rational change processes and institutional forces. *Journal of Change Management*, 13(2), 179–205. <https://doi.org/10.1080/14697017.2012.745584>
- Nuti, S., De Rosis, S., Bonciani, M., & Murante, A. M. (2017). Rethinking healthcare performance evaluation systems towards the people-centredness approach: Their pathways, their experience, their evaluation. *Healthcare Papers*, 17(2), 56–64. <https://doi.org/10.12927/hcpap.2017.25408>
- Peruzzo, E., Seghieri, C., Vainieri, M., & De Rosis, S. (2025). Improving the healthcare user experience: An optimization model grounded in patient-centredness. *BMC Health Services Research*, 25, Article 132. <https://doi.org/10.1186/s12913-024-11960-7>
- Quigley, D., Qureshi, N., Rybowski, L., Shaller, D., Edgman-Levitan, S., Cleary, P. D., Ginsberg, C., & Hays, R. D. (2022). Summary of the 2020 AHRQ research meeting on advancing methods of implementing and evaluating patient experience improvement using consumer assessment of healthcare providers and systems (CAHPS®) surveys. *Expert Review of Pharmacoeconomics & Outcomes Research*, 22(6), 883–890. <https://doi.org/10.1080/14737167.2022.2064848>
- Rasheed, M. A., Hussain, A., Hashwani, A., Kedzierski, J. T., & Hasan, B. S. (2022). Implementation evaluation of a leadership development intervention for improved family experience in a private paediatric care hospital, Pakistan. *BMC Health Services Research*, 22(1), Article 944. <https://doi.org/10.1186/s12913-022-08342-2>
- Scholl, I., Zill, J. M., Härter, M., & Dirmair, J. (2014). An integrative model of patient-centeredness: A systematic review and concept analysis. *PLOS ONE*, 9(9), e107828. <https://doi.org/10.1371/journal.pone.0107828>
- Shunmuga Sundaram, C., Campbell, R., Ju, A., King, M. T., & Rutherford, C. (2022). Patient and healthcare provider perceptions on using patient-reported experience measures (PREMs) in routine clinical care: A systematic review of qualitative studies. *Journal of Patient-Reported Outcomes*, 6(1), Article 122. <https://doi.org/10.1186/s41687-022-00524-0>

Vaughn, V. M., Saint, S., Krein, S. L., Forman, J. H., Meddings, J., Ameling, J., Winter, S., Townsend, W., & Chopra, V. (2019). Characteristics of healthcare organisations struggling to improve quality: Results from a systematic review of qualitative studies. *BMJ Quality & Safety*, 28(1), 74–84. <https://doi.org/10.1136/bmjqs-2017-007573>.

Xiao, Q., Cooke, F. L., & Chen, L. (2022). Nurses' well-being and implications for human resource management: A systematic literature review. *International Journal of Management Reviews*, 24(4), 599–624. <https://doi.org/10.1111/ijmr.12295>

PRÍSPEVKY DO DISKUSIE

CONTRIBUTIONS TO THE DISCUSSION

Vplyv hybridných pracovných režimov na finančný manažment podniku - systematická literárna rešerš

The impact of hybrid work arrangements on the financial management of the company systematic literature review

Samuel Mihalčín, Juraj Mišún

Abstract

Hybridné pracovné modely ktoré kombinujú prácu z domu s prácou z kancelárie sa v posledných rokoch stali dominantným trendom v organizácii práce. V tejto štúdii sa vykonáva systematická literárna rešerš z vedeckých databáz so zameraním na vplyv hybridných pracovných režimov na finančný manažment a finančnú stratégiu podniku. Cieľom článku je identifikovať a zhodnotiť kľúčové zmeny, ktoré nastali vo finančnom manažmente podnikov po zavedení práce z domu a hybridných pracovných režimov. Článok sa bude opierať o relevantné vedecké publikácie, ktoré sa zaoberajú problematikou finančného manažmentu v podnikoch so zavedenými hybridnými pracovnými režimami. Výsledky tejto štúdie prispievajú k lepšiemu pochopeniu vplyvu hybridných pracovných režimov na finančný manažment, následne na finančnú stratégiu podnikov a poskytnú cenné informácie pre prax, čo môže pomôcť manažérom efektívnejšie riadiť finančné prostriedky zavedením práce z domu.

JEL classification: M12, D29, D22

Keywords: hybridné pracovné režimy, finančný manažment podniku, home office, vzdialená práca, finančná stratégia podniku

1 Úvod

V posledných rokoch prišlo k zásadnej transformácii spôsobu, akým podniky organizujú pracovné prostredie, pričom hybridné pracovné režimy – kombinácia práce na diaľku a práce v kancelárii – sa stali novým štandardom najmä pri administratívnych prácach. Tento posun bol urýchlený pandemiou COVID-19, ale jeho dôsledky presahujú rámec krízového riadenia a zasahujú do strategických oblastí podnikového fungovania, vrátane finančného manažmentu a tvorby finančných stratégií.

Hybridné pracovné režimy ovplyvňujú finančný manažment podnikov viacerými spôsobmi. Na jednej strane prinášajú potenciál na zníženie prevádzkových nákladov, ako sú náklady na kancelárske priestory, energie či cestovné výdavky (Toluwalase et al. 2024; Abdulrahim, Yousif, 2023; Franken et al. 2021). Na druhej strane však vytvárajú nové výzvy v oblasti plánovania kapitálových výdavkov, riadenia likvidity a alokácie zdrojov, najmä v súvislosti s investíciami do digitálnej infraštruktúry a kybernetickej bezpečnosti (Gross-Golacka et al. 2022; Ren, 2022).

Z pohľadu finančnej stratégie sa hybridný režim práce spája s potrebou väčšej flexibility a adaptability. Podniky musia prehodnotiť svoje dlhodobé finančné ciele a prispôsobiť ich dynamickému prostrediu, ktoré je charakteristické vyššou mierou neistoty a technologickej závislosti (Toscano et al. 2025). Peetzov (2019) výskum ukazuje, že úspešné podniky v hybridnom prostredí čoraz viac využívajú agilné prístupy k finančnému plánovaniu a integrujú flexibilné systémy riadenia, ktoré umožňujú rýchle reakcie na zmeny v externom aj internom prostredí.

Cieľom tejto systematickej literárnej rešerše je analyzovať a syntetizovať poznatky z vedeckých štúdií, ktoré sa zaoberajú vplyvom hybridných pracovných režimov na finančný

manažment a finančnú stratégiu podnikov. Rešerš sa zameriava na identifikáciu hlavných tém, trendov a výskumných medzier, ktoré môžu slúžiť ako základ pre budúci výskum a praktické odporúčania pre manažerov.

2 Súčasný stav riešenej problematiky doma a v zahraničí

Hybridné pracovné režimy predstavujú moderný spôsob organizácie práce, ktorý flexibilne kombinuje prácu na diaľku (napríklad z domova, coworkingových centier alebo iných vzdialených lokalít) s prácou na tradičnom pracovisku (kancelária, firemné priestory). Znamená to, že zamestnanci môžu počas týždňa striedať pracovné prostredie, pričom zvyčajne časť pracovných dní vykonávajú svoje povinnosti mimo kancelárie a časť dní v kancelárii (Sampat et al. 2022). V súčasnosti sa hybridné pracovné režimy etablujú ako štandard najmä v odvetviach, kde je väčšina pracovných činností realizovateľná digitálne (napr. IT, financie, marketing, poradenstvo), aj keď ich význam narastá vo viacerých sektoroch v dôsledku dlhodobých zmien, ktoré priniesla pandémia COVID-19 (Gilson et al. 2022; Fan, Moen, 2023).

Finančný manažment predstavuje komplexnú disciplínu orientovanú na plánovanie, získavanie, alokáciu, kontrolu a analýzu finančných zdrojov podniku s cieľom zabezpečiť jeho likviditu, rentabilitu, udržateľný rast a finančnú stabilitu v meniacom sa podnikateľskom prostredí. Kľúčové úlohy finančného manažmentu zahŕňajú zostavovanie finančných plánov, riadenie cash flow, rozhodovanie o investíciách a získavaní kapitálu, rozpočtovanie, kontrolu nákladov, riadenie rizík a zabezpečenie transparentného a včasného finančného výkazníctva. Moderný finančný manažment sa čoraz viac opiera o digitalizáciu a veľké dáta, čo umožňuje zvyšovať presnosť plánovania a robustnosť systémov včasného varovania pred finančnými rizikami (Yang et al. 2022).

Finančná stratégia nadväzuje na finančný manažment a je definovaná ako dlhodobý koncepčný plán, ktorý určuje optimálny spôsob zabezpečenia zdrojov na realizáciu strategických cieľov podniku, štruktúru kapitálu, investičné priority, dividendovú politiku a spôsob tvorby a ochrany finančnej hodnoty v kontexte neustálych zmien vnútorného a vonkajšieho podnikateľského prostredia (Borodin et al. 2021) Formulácia finančnej stratégie zahŕňa analýzu existujúcich finančných možností a rizík, strategickú segmentáciu finančných potrieb podniku, voľbu optimálneho modelu financovania (pomer vlastného a cudzieho kapitálu), ako aj definovanie finančných cieľov zodpovedajúcich celkovej podnikovej stratégii (Ullah et al. 2024).

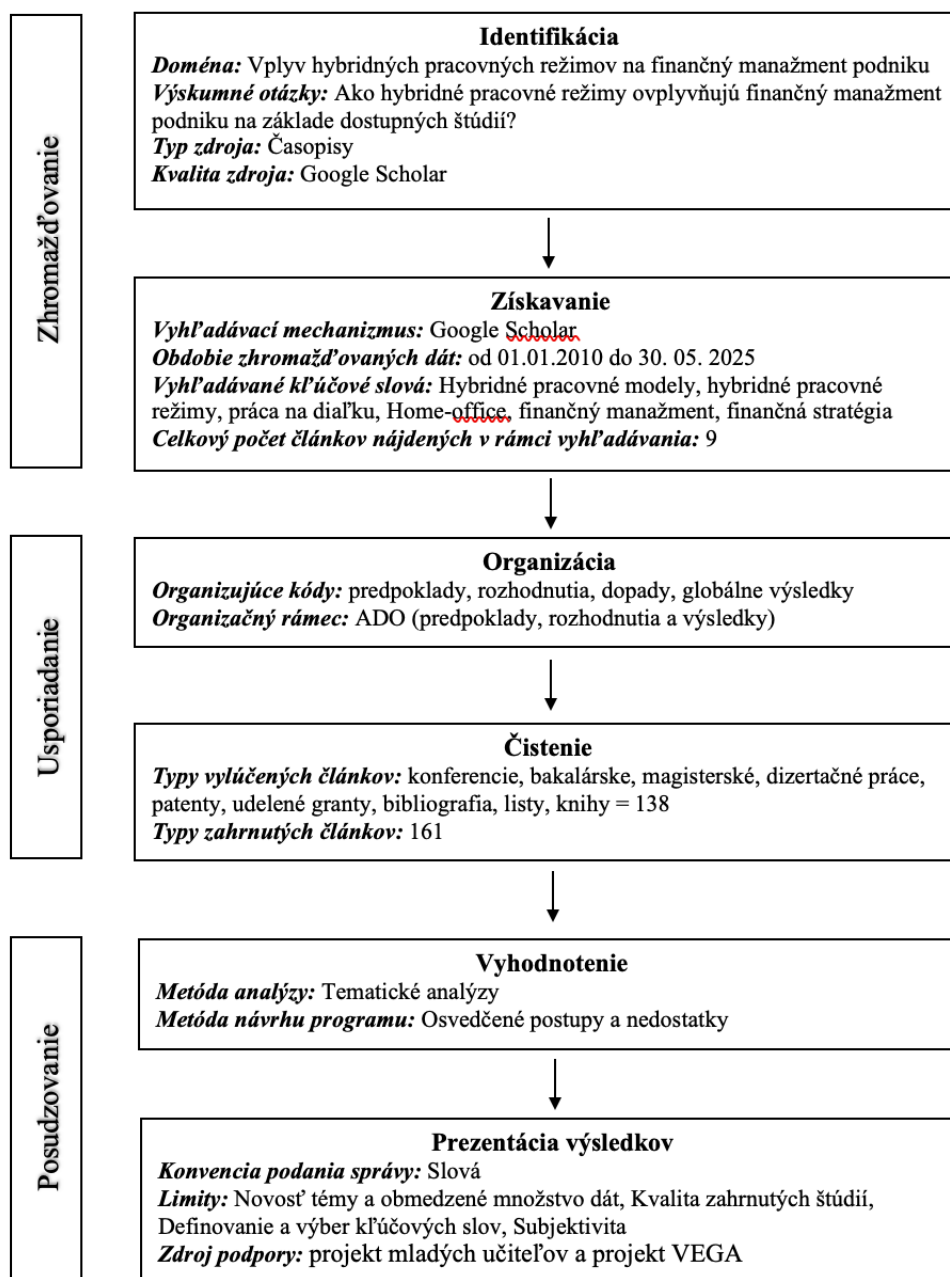
3 Výskumný dizajn

Cieľom článku je analyzovať a syntetizovať poznatky z vedeckých štúdií, ktoré sa zaoberajú vplyvom hybridných pracovných režimov na finančný manažment a finančnú stratégiu podnikov. V tejto štúdií sme vykonali trojfázovú literárnu rešerš zloženú zo šiestich podstupňov, podľa zavedeného rámca SPAR-4-SLR od Paul et al. (2021), ktorý predstavujeme na obrázku 1.

Zvolený postup nám pomohol získať z analyzovaných článkov relevantné informácie, ktoré odhalili existujúce podobnosti a rozdiely medzi nimi. Systematická literárna rešerš sa ukázala ako efektívny prístup ku komplexnému zmapovaniu a štruktúrovaniu súčasných naliehavých oblastí výskumu.

Obrázok 1

Vedecké postupy a zdôvodnenia pre systematické protokoly prehľadu literatúry (SPAR-4-SLR)



Zdroj: vlastné spracovanie na základe Paul et al. (2021)

4 Výsledku výskumu

Tento výskum sa zameril na vplyv hybridných pracovných režimov na finančný manažment podniku. Výsledky ukázali že podniky, ktoré majú zavedené hybridné pracovné režimy, alebo umožňujú zamestnancom pracovať mimo kancelárie, dokážu ušetriť na rôznych typoch nákladov, napríklad na energiu, kancelárske priestory a pod. Na druhej strane tieto typy podnikov čelia zvýšenému množstvu kybernetických hrozieb a je preto potrebné investovať do kybernetickej bezpečnosti. V tabuľke 1 vysvetlíjeme hlavné zistenia získané z analyzovaných článkov, metódy ich výskumov a limitácie daných článkov.

Tabuľka 1

Prehľad výsledkov literatúry

Autor	Výsledky a zistenia	Limity	Využité metódy
Pitchaya, Auckarakhun, 2024	Výskum ukazuje, že dodržiavanie predpisov a pracovných zákonov má priamy vplyv na to, koľko peňazí sa vyčlení na právne konzultácie a úpravy potrebné pre prácu na diaľku. Daňové dôsledky sú tiež dôležité pri finančnom rozhodovaní a organizácie často vyhľadávajú odborné poradenstvo, aby pochopili finančný dopad. Znalosti o vládnych iniciatívach a stimuloch môžu pomôcť organizáciám prijímať informované rozhodnutia o finančných stratégiách, najmä pokiaľ ide o investície do technológií a programy podpory zamestnancov.	Výskum zdôrazňuje regulačné výzvy a procesy finančného rozhodovania, ale neskúma potenciálne technologické obmedzenia alebo prekážky, ktorým môžu organizácie čeliť pri implementácii vzdialených a hybridných pracovných modelov, ktoré by mohli ovplyvniť celkovú účinnosť týchto stratégií.	Štúdia využíva kvalitatívne výskumné metódy. V práci boli uskutočnené hĺbkové rozhovory s 20 jednotlivcami na manažérskych pozíciách, s cieľom zhromaždiť poznatky o ich skúsenostiach a rozhodovacích procesoch týkajúcich sa vzdialených a hybridných pracovných modelov. Výskum analyzuje finančné dôsledky vyhodnotením finančných ukazovateľov, skúmaním vzťahov medzi pracovnými modelmi a dynamikou zamestnancov a skúmaním regulačných rámcov, ktoré ovplyvňujú finančné rozhodovanie v vyvíjajúcom sa pracovnom prostredí.
Toluwalase et al. 2024	Prehľad vysvetľuje, ako môže práca na diaľku viesť k významným úsporám nákladov pre organizácie. Zistilo sa, že vzdialená práca môže so sebou prinášať znížené režijné náklady súvisiace s kancelárskymi priestormi a verejnými službami, ako aj potenciálne zvýšenie produktivity v dôsledku menšieho rozptýlenia zamestnancov.	Článok je koncepčný revízny dokument, nehodnotí konkrétne spoločnosti alebo určitý počet podnikov, namiesto toho skúma ekonomické dôsledky práce na diaľku vyhodnotením finančných a HR metrik všeobecne použiteľných pre vzdialené pracovné prostredia. Poskytuje prehľad dojednaní práce na diaľku a diskutuje o ich vplyve na tradičné finančné metriky, ako sú úspory nákladov a produktivita.	Základnou metódou je hodnotenie tradičných finančných metrik (ako sú úspory nákladov a produktivita) a metriky HR (vrátane zapojenia zamestnancov, udržania a efektívnosti komunikácie) v kontexte práce na diaľku. Diskutuje o ich vplyve a výzvach spojených s ich meraním vo vzdialených nastaveniach.
Abdulrahim, Yousif, 2023	Článok poukazuje na to, že hybridné pracovné režimy so sebou prinášajú úspory pri udržiavaní fyzických kancelárskych priestorov a financií zamestnancov pracujúcich z domu, ktorí nemusia vynakladať finančné prostriedky pri cestách na miesto výkonu práce, je však nevyhnutné, aby podniky zabezpečili reinvestovanie úspor do potrebných zdrojov využívaných pri hybridnej práci napr. IT systémov.	Prieskum bol vykonaný len v súkromných inštitúciách finančného sektoru. Existujú však aj verejné finančné inštitúcie, ako napríklad Fond ľudských zdrojov a Fond rozvoja nehnuteľností, ktoré neboli zahrnuté do prieskumu.	Dáta sú zhromaždené prostredníctvom prieskumu, ktorý pokrýva vzorku skladajúcu sa z 1 270 respondentov z bánk, finančných a poisťovních spoločností v Saudskej Arábii. Sekundárne údaje pochádzajú z predchádzajúcich vedeckých štúdií, oficiálnych správ vydaných Saudskou centrálnou bankou (SAMA) a ďalších príslušných medzinárodných inštitúcií.

<p>Franken et al. 2021</p>	<p>Štúdia uvádza, že organizáciám sa pri prechode na hybridné pracovné modely darí znižovať prevádzkové náklady, najmä náklady na nehnuteľnosti, energie a zároveň aj iné režijné náklady. Prechod na hybridný model práce si však vyžaduje prehodnotenie stratégií finančného prognózovania a pridelovania rozpočtových prostriedkov. Organizácie preto musia vyvinúť nové modely na predpovedanie priamych finančných nákladov a vplyvu hybridnej práce na fluktuáciu a produktivitu zamestnancov.</p>	<p>Hlavným obmedzením je malá veľkosť vzorky. Ďalším súvisiacim obmedzením je obmedzený kontext výskumu, ktorý sa sústreďuje na sektor zdrojov v Austrálii. Hoci tento kontext poskytol bohatý a jedinečný pohľad na zdroje a výzvy, ktoré sú k dispozícii a ktoré poskytuje sektor zdrojov, obmedzuje reprezentatívnosť a všeobecnú platnosť výskumu.</p>	<p>V článku boli použité kvalitatívne výskumné metódy, konkrétne prípadová štúdia, ktorá pozostávala z dvoch fáz zberu dát. Prvou fázou bola denníková štúdia, ktorá spočívala v tom, že 11 respondentov (traja manažéri a ôsmi členovia tímu) zaznamenávalo denné pozitívne a negatívne udalosti súvisiace s prácou na diaľku. Druhou fázou bola štúdia kritických udalostí, ktorá začala po uvoľnení opatrení súvisiacich s COVID-19. Táto fáza využívala techniku kritických incidentov prostredníctvom online dotazníka, do ktorého sa zapojilo 15 členov tímu, a taktiež hĺbkové rozhovory so 7 členmi tímu. Dátová analýza bola vykonaná kvalitatívnou metódou a zahŕňala tematickú analýzu textových odpovedí, ktorú nezávisle uskutočnili traja členovia výskumného tímu, kým sa nedosiahla zhoda na identifikovaných témach.</p>
<p>Akbari et al. 2025</p>	<p>Podnikové financie investované do finančných príspevkov pre zamestnancov na zriadenie domácej kancelárie zvyšujú produktivitu a posilňujú lojalitu zamestnancov. Tieto faktory môžu následne výrazne prispieť k finančnej prosperite organizácie.</p>	<p>Hlavným limitom článku bolo obmedzenie len na Vietnam. To znamená, že podobné výsledky by sa nemuseli nevyhnutne prejavíť v iných rozvíjajúcich sa krajinách, čo naznačuje potrebu ďalších štúdií na potvrdenie zistení v širšom geografickom kontexte.</p>	<p>Štúdia bola založená na online prieskume, ktorým sa zbierali primárne dáta od vietnamských pracovníkov. Prieskum bol vyplnený 217 vietnamskými pracovníkmi. Analýza zozbieraných dát zahŕňala použitie rôznych analytických techník, ako sú priemer, Pearsonov Chi-kvadrát test a t-test nezávislých vzoriek. Spoľahlivosť dotazníka bola overená Cronbachovým alfa koeficientom, ktorý prekročil hodnotu 0,7, čo naznačuje štatistickú validitu tam, kde boli použité škálované položky. Teoretický rámec štúdie vychádza z teórie zachovania zdrojov a je doplnený teóriou pozitívneho organizačného správania. Teória COR pomáha pochopiť straty a zisky zdrojov súvisiace s flexibilnými pracovnými podmienkami, zatiaľ čo POB sa využíva na identifikáciu a rozvoj špecifických typov zdrojov, ktoré môžu zvýšiť rodovú rovnosť.</p>
<p>Bilderback, Kilpatrick, 2024</p>	<p>Organizácie, ktoré zamestnávajú zamestnancov pracujúcich formou hybridných pracovných režimov a zároveň aj zamestnancov pracujúcich iba z kancelárie musia vo finančných stratégiách uprednostniť spravodlivé rozdelenie zdrojov s cieľom zachovať súdržnú organizačnú kultúru.</p>	<p>Hlavným limitom tohto článku je, že nepredstavuje nové empirické zistenia ani primárne dáta. Zistenia a odporúčania sú založené výlučne na syntéze existujúcej literatúry, teoretických úvahách a analýze už publikovaných prípadových štúdií.</p>	<p>Článok využíva konceptuálny prístup, s cieľom analyzovať dôsledky práce na diaľku pre organizačnú kultúru a preskúmať praktické aplikácie teoretických rámcov. Medzi konkrétne teoretické rámce, ktoré sú v článku preskúmané, patria Kotterov 8-krokový model zmien, rámec konkurenčných hodnôt, teória sociálnej výmeny, teória rolí, teória sebaurčenia a teória spravodlivosti.</p>

<p>Gross-Golacka et al. 2022</p>	<p>Kybernetická bezpečnosť sa stáva dôležitým aspektom stratégií finančného riadenia, pretože práca na diaľku vystavuje organizácie vyššiemu riziku narušenia údajov a vyššiemu počtu kybernetických hrozieb. Z tohto dôvodu je dôležité vyčleniť finančné zdroje na posilnenie opatrení kybernetickej bezpečnosti a prostriedky na školenia zamestnancov v oblasti ochrany údajov.</p>	<p>Výskum bol vykonaný výlučne v Poľsku a zameral sa len na IT priemysel, čo obmedzuje generalizovateľnosť zistení na iné krajiny, kultúrne kontexty alebo odvetvia. Dáta boli zozbierané len od zamestnancov jednej medzinárodnej IT korporácie, čo môže ovplyvniť reprezentatívnosť vzorky pre celý IT priemysel alebo pre rôzne typy organizácií.</p>	<p>Výskum bol realizovaný ako kvantitatívna štúdia. Dáta boli zozbierané od 1 889 zamestnancov pracujúcich na diaľku zo siedmich poľských pobočiek jednej medzinárodnej IT korporácie, ktorá patrí medzi najväčších zamestnávateľov v poľskom IT priemysle. Metóda zberu dát bola realizovaná formou dotazníkového prieskumu, ktorý bol vykonaný online.</p>
<p>Arslan et al. 2012</p>	<p>Hybridné režimy menia načasovanie a štruktúru cash flow, či už prostredníctvom posunov v rozdelení mzdových a prevádzkových nákladov, alebo zmenami v benefitných a odmeňovacích systémoch. Podniky, ktoré efektívne využívajú flexibilitu získanú z hybridných režimov, môžu vykazovať vyššiu odolnosť voči neočakávaným šokom (napr. počas krízy), čo je dané vyššou schopnosťou rýchlo optimalizovať výdavky aj investície. Vyššia finančná flexibilita sa pritom javí ako kľúčová výhoda aj pri plánovaní a reakciách na turbulentné situácie.</p>	<p>Geografické zameranie štúdie je výlučne na firmy z východnej Ázie, čo obmedzuje všeobecnú platnosť záverov pre firmy v iných regiónoch sveta s odlišnými makroekonomickými politikami a právnym prostredím. Časová špecifickosť, keďže dôraz je kladený na obdobia finančných kríz, čo môže silne ovplyvniť zistenia a nemusia tak plne odrážať správanie firiem v období bežného ekonomického cyklu. Okrem toho, vzorka zahŕňa iba verejne kótované firmy, čo obmedzuje aplikovateľnosť zistení na súkromné spoločnosti.</p>	<p>Výskum využíva kvantitatívnu metodológiu založenú na panelových dátach, pričom analyzoval 1 068 verejne kótovaných firiem z 13 východoázijských krajín. Na skúmanie vplyvu finančnej flexibility na firemné investície a výkonnosť sa používa dynamický panelový dátový model s estimátorom System GMM.</p>
<p>Ren, 2022</p>	<p>S hybridným režimom narastajú požiadavky na zabezpečenie striktnej compliance a kybernetickej bezpečnosti, čo znamená vyššie náklady súvisiace s ochranou dát, auditmi a právnymi službami. Finančné riadenie preto musí reflektovať tieto nové zdroje rizika aj vo svojich modeloch a rezervách.</p>	<p>Hlavným limitom je jeho koncepčná a teoretická povaha - článok neobsahuje primárny empirický výskum ani zber dát. Navrhované optimalizácie a analyzované mechanizmy nie sú priamo empiricky overené prostredníctvom testovania s reálnymi dátami od špecificky definovanej vzorky firiem. Implementačné prípady slúžia skôr ako ilustračné príklady, nie ako podrobné empirické kazuistiky, ktoré by umožnili robustné generalizovanie záverov. Z tohto dôvodu chýba overenie teoretických poznatkov na konkrétnej, rozsiahlej empirickej vzorke.</p>	<p>Výskum v tomto článku je založený na koncepcnej a teoretickej analýze. V článku sú využité existujúce teórie, ako sú teória informačnej asymetrie, teória principal-agent a teória riadenia rizík, na analýzu mechanizmu vplyvu veľkých dát na finančné rozhodovanie. Článok ďalej analyzuje štyri dimenzie tohto vplyvu a diskutuje o optimalizácii systémov finančného riadenia a rozhodovania. Súčasťou metodiky je aj analýza špecifických implementačných prípadov podnikov, ktoré využívajú veľké dáta vo finančnom rozhodovaní. Tieto prípady slúžia na ilustráciu reálnych problémov a efektívnosti riešení prostredníctvom platforiem veľkých dát.</p>

Zdroj: vlastné spracovanie na základe autorov

4.1 Návrhy pre budúci výskum

Na základe výkonu systematickej literárnej rešerše sa podarilo nájsť len deväť publikácií, ktoré sa zaoberali nami analyzovanou oblasťou výskumu. Analyzované publikácie zdôrazňujú úspory nákladov, výzvy v oblasti dodržiavania predpisov, potrebu reinvestícií, vplyv na cash flow a kybernetickú bezpečnosť. Na základe zistení z daných publikácií preto navrhujeme nasledovné odporúčania pre budúci výskum:

1. *Kvantifikácia dlhodobých finančných úspor a investícií*: hoci sa niektoré štúdie zaoberali analýzou úspor nákladov (napr. na nehnuteľnosti, energie a pod.) je potrebné kvantifikovať dlhodobé finančné prínosy a ich udržateľnosť. Napríklad aký je stredno a dlhodobý vplyv hybridných režimov na čistý zisk a návratnosť investícií (ROI) pre rôzne typy podnikov a rôzne odvetvia.
2. *Vplyv na cash flow a finančnú flexibilitu*: Zistenia naznačujú, že hybridné režimy menia načasovanie a štruktúru cash flow a zvyšujú finančnú odolnosť. Chýba však podrobná analýza dynamiky cash flow v podnikoch so zavedenými hybridnými pracovnými režimami v porovnaní s tradičnými režimami.
3. *Preskúvanie finančnej odolnosti a riadenia rizík*: V analyzovaných výskumoch chýba hlbšie preskúvanie toho, či podniky so zavedenými hybridnými pracovnými režimami majú vyššiu finančnú odolnosť voči ekonomickým šokom a krízam a či v konečnom dôsledku môžu takéto podniky byť viac konkurencie schopné.
4. *Vplyv na produktivitu, fluktuáciu a lojalitu zamestnancov z finančného hľadiska*: V analyzovaných štúdiách sa spomína potenciálne zvýšenie produktivity a posilnenie lojality zamestnancov vďaka príspevkom zamestnancom na vytvorenie domácej kancelárie. Bolo by preto vhodné výskum zamerať na kvantifikáciu finančného dopadu na produktivitu zamestnancov. Vhodnou otázkou by preto bolo: „ako sa zvýšenie produktivity prejavuje vo finančných výsledkoch podniku?“
5. *Kvantifikácia finančného prínosu zvýšenej lojality a zníženej fluktuácie zamestnancov*: Žiaden z výskumov sa nezaoberal vzťahom medzi lojalitou a finančnou výkonnosťou podniku. Bolo by preto vhodné nasmerovať výskum aj do tejto oblasti a zmerať tento vzťah v podnikoch so zavedenými hybridnými režimami a porovnať ho s porovnateľnými podnikmi, ktoré hybridné pracovné režimy ešte nevyužívajú. Následne by bolo vhodné zamyslieť sa nad otázkou, či by bolo možné modelovať ROI investícií do zamestnaneckých benefitov, prípadne príspevkov na vytvorenie domácej kancelárie v hybridnom pracovnom prostredí.

4.2 Limity výskumu

Medzi obmedzenia výskumu sme zaradili nasledujúce obmedzenia:

- *Novosť témy a obmedzené množstvo dát*: niektoré formy vzdialenej práce existovali aj v minulosti, masové prijatie možnosti vykonávania práce z domu však prišlo až po vypuknutí pandémie Covid-19. Viacero komplexných a dlhodobých štúdií preto môže byť stále v počiatočnom štádiu a je preto aktuálne náročné na základe dostupných štúdií vytvárať optimálne závery k tejto problematike.
- *Kvalita zahrnutých štúdií*: keďže sa jedná o novú tému, v kvalitných žurnáloch sa aktuálne nenachádza mnoho štúdií, ktoré by sa zaoberali touto problematikou, preto sme museli zaradiť aj články z menej známych žurnálov.
- *Definovanie a výber kľúčových slov*: pri vyhľadávaní článkov sme použili viaceré kľúčové slová, ktoré však boli subjektívne vybrané a preto sa mohlo stať, že niektoré relevantné štúdie mohli obsahovať iné kľúčové slová.

- *Subjektivita*: kritériá zaradenia a vylúčenia, ktoré sme zvolili pri analýze článkov mohli byť subjektívne a mohli viesť k vylúčeniu relevantných článkov.

5 Diskusia a záver

Predložený článok vo forme SPAR-4-SLR literárnej rešerše komplexne analyzoval vplyv hybridných pracovných režimov na finančný manažment a následne na finančnú stratégiu podnikov. Zistenia jednoznačne potvrdzujú, že prechod na hybridný model prináša podnikom významné príležitosti na úsporu nákladov, najmä v oblastiach režijných nákladov spojených s kancelárskymi priestormi, energiami a inými prevádzkovými nákladmi.

Je však nevyhnutné, aby podniky tieto úspory reinvestovali do kľúčových oblastí, ktoré podporujú vzdialenú prácu, ako sú napríklad IT systémy a kybernetická bezpečnosť. Zvýšené požiadavky na ochranu dát a školenia zamestnancov v tejto oblasti si vyžadujú alokáciu finančných zdrojov, aby sa predišlo potenciálnym finančným stratám z dôvodu narušenia údajov. Zároveň je dôležité poskytovať finančné príspevky zamestnancom na zriadenie domácej kancelárie, čo preukázateľne zvyšuje produktivitu a lojalitu zamestnancov, a tým prispieva k celkovej finančnej prosperite organizácie.

Výskum tiež zdôrazňuje, že hybridné modely si vyžadujú prehodnotenie stratégií finančného prognózovania a pridelovania rozpočtových prostriedkov. Podniky musia vyvinúť nové modely na predpovedanie priamych finančných nákladov a vplyvu hybridnej práce na fluktuáciu a produktivitu zamestnancov. Dodržiavanie regulačných rámcov a pracovných zákonov má priamy vplyv na finančné rozhodovanie, a preto je nevyhnutné vyhľadávať odborné poradenstvo v oblasti právnych a daňových dôsledkov. Vládne iniciatívy a stimuly môžu tiež výrazne ovplyvniť finančné stratégie, najmä pri investíciách do technológií a programov podpory zamestnancov.

Napokon, štúdia ukázala, že hybridné režimy ovplyvňujú načasovanie a štruktúru cash flow a môžu viesť k vyššej finančnej flexibilitě a odolnosti podnikov voči neočakávaným šokom. Avšak pre zachovanie súdržnej organizačnej kultúry je nevyhnutné uprednostniť spravodlivé rozdelenie zdrojov medzi zamestnancov pracujúcich hybridne a tých, ktorí pracujú výlučne z kancelárie.

Na základe uvedeného sme preto naformulovali nasledovné smery budúcich výskumov: kvantifikácia dlhodobých finančných úspor a investícií, vplyv pracovných režimov na cash-flow a finančnú flexibilitu, preskúmanie finančnej odolnosti a riadenia rizík, vplyv na hybridných pracovných režimov na produktivitu, fluktuáciu a lojalitu zamestnancov z finančného hľadiska, kvantifikácia finančného prínosu zvýšenej lojality a zníženej fluktuácie zamestnancov pracujúcich v hybridných pracovných režimoch.

Acknowledgement

Táto práca bola podporená projektom mladých učiteľov, vedcov a doktorandov v dennej forme štúdia č. A-25-104/3020-05 „Kľúčové faktory strategickej udržateľnosti podnikov a miesto hybridných pracovných modelov a rovnováhy medzi pracovným a súkromným životom medzi týmito faktormi“ a výskumným projektom VEGA č. 1/0188/24 „Hybridné pracovné režimy ako výsledok korporátneho učenia sa z krízy a dôsledky ich implementácie pre riadenie ľudských zdrojov“.

Použitá literatúra (References)

- Abdulrahim, H., & Yousif, G. (2023). Remote Work Implications on Productivity of Workers in the Saudi Financial Sector. *International Journal of Professional Business Review*, 8(4), e01064. <https://doi.org/10.26668/businessreview/2023.v8i4.1064>.
- Akbari, M., Alonso, A. D., Vu, O. T. K., Hopkins, J., Bardeel, A., & Kok, S. K. (2025). From Pandemic to Progress: Rethinking Work Patterns in Vietnam to Improve Flexibility and Support Gender Equality. *Asia Pacific Journal of Human Resources*, 63(2), e70003. <https://doi.org/10.1111/1744-7941.70003>.
- Arslan-Ayaydin, Ö., Florackis, C., & Ozkan, A. (2011). Financial Flexibility, Corporate Investment and Performance: Evidence from East Asian Firms. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1234682>.
- Bilderback, S., & Kilpatrick, M. D. (2024). Global perspectives on redefining workplace presence: The impact of remote work on organizational culture. *Journal of Ethics in Entrepreneurship and Technology*, 4(1), 62–72. <https://doi.org/10.1108/JEET-08-2024-0023>.
- Borodin, A., Panaedova, G., Frumina, S., Kairbekuly, A., & Shchegolevatykh, N. (2021). Modeling the business environment of an energy holding in the formation of a financial strategy. *Energies*, 14(23), 8107. <https://doi.org/10.3390/en14238107>
- Fan, W., & Moen, P. (2025). The Future(s) of Work? Disparities Around Changing Job Conditions When Remote/Hybrid or Returning to Working at Work. *Work and Occupations*, 52(1), 91–129. <https://doi.org/10.1177/07308884231203668>.
- Franken, E., Bentley, T., Shafaei, A., Farr-Wharton, B., Onnis, L., & Omari, M. (2021). Forced flexibility and remote working: Opportunities and challenges in the new normal. *Journal of Management & Organization*, 27(6), 1131–1149. <https://doi.org/10.1017/jmo.2021.40>.
- Gilson, N., Coenen, P., Hallman, D. M., Holtermann, A., Mathiassen, S., & Straker, L. (2022). Postpandemic hybrid work: opportunities and challenges for physical activity and public health. *British Journal of Sports Medicine*, 56, 1203-1204.
- Gross-Gołacka, E., Szkudlarek, E., Brzegowy, A., Kupczyk, T., & Ligaj, M. (2022). Well-being among IT Employees Working Remotely: Post Covid-19 Reality from the Perspective of IT Industry. *European Research Studies Journal*, XXV(2), 223–235. <https://doi.org/10.35808/ersj/2917>.
- Leonardi, P. M. (2011). When Flexible Routines Meet Flexible Technologies: Affordance, Constraint, and the Imbrication of Human and Material Agencies. *MIS Quarterly*, 35(1), 147–167. <https://doi.org/10.2307/23043493>.
- Paul, J., Lim, W. M., O’Cass, A., Hao, A. W., & Bresciani, S. (2021). Scientific procedures and rationales for systematic literature reviews (SPAR-4-SLR). *International Journal of Consumer Studies*, 45(4). <https://doi.org/10.1111/ijcs.12695>.
- Peetz, D. (2019). Flexibility, the ‘gig economy’ and the employment relationship. In *The Realities and Futures of Work* (pp. 141–178). ANU Press. <http://www.jstor.org/stable/j.ctvq4c16w.11>.
- Pitchaya-Auckarakhun, M. (2024). The future of work: Financial implications of remote and hybrid work models. *Nowoczesne Systemy Zarządzania*, 19(1), 13–38. <https://doi.org/10.37055/nsz/192812>.

Ren, S. (2022). Optimization of Enterprise Financial Management and Decision-Making Systems Based on Big Data. *Journal of Mathematics*, 2022(1), 1708506. <https://doi.org/10.1155/2022/1708506>.

Sampat, B., Raj, S., Behl, A., & Schöbel, S. (2022). An empirical analysis of facilitators and barriers to the hybrid work model: A cross-cultural and multi-theoretical approach. *Personnel Review*, 51(8), 1990–2020. <https://doi.org/10.1108/PR-02-2022-0176>.

Toluwalase Vanessa Iyelolu & Patience Okpeke Paul. (2024). Remote work economics: A conceptual review of financial and HR metrics. *Journal of Science and Technology*, 11(2), 047–054. <https://doi.org/10.53022/oarjst.2024.11.2.0092>.

Toscano, F., González-Romá, V. & Zappalà, S. The Influence of Working from Home vs. Working at the Office on Job Performance in a Hybrid Work Arrangement: A Diary Study. *Journal of Business Psychology* 40, 497–512 (2025). <https://doi.org/10.1007/s10869-024-09970-7>.

Ullah, R., Ahmad, H., Rizwan, S., & Khattak, M. S. (2024). Financial resource and green business strategy: The mediating role of competitive business strategy. *Journal of Sustainable Finance & Investment*, 14(2), 410–429. <https://doi.org/10.1080/20430795.2022.2031850>.

Yang, W., Zhou, Y., Xu, W., & Tang, K. (2022). Evaluate the sustainable reuse strategy of the corporate financial management based on the big data model. *Journal of Enterprise Information Management*, 35(4/5), 1185–1201. <https://doi.org/10.1108/JEIM-04-2021-0169>.

Financial strategy and decision-making in the integration of AI-supported systems in general practice

Murat Tetik, Pavol Andrejovský, Peter Markovič

Abstract

The financial valuation of investments in artificial intelligence (AI) is possible in principle, but requires specific adjustments due to the special characteristics of intangible assets such as software, algorithms and data-based systems. Based on capital budget theory, the dissertation presents proven financial methods such as cost approaches, repayment time and NPV method and analyzes their suitability for AI investments. A simple financial model is presented that takes into account typical framework conditions of a general practice and is based on literature on digitization costs, licenses and empirical data on efficiency gains. Model assumptions include procurement costs, annual maintenance fees, expected time savings, qualitative benefits (e.g., quality improvements, error mitigation), and implementation and training costs. The analysis shows that classical present value methods are generally suitable, but should be supplemented by sensitivity analyses and scenario techniques to map uncertainties in technology development, regulations and licensing models. In addition to the financially quantifiable effects, qualitative advantages such as improved documentation quality and patient safety are also important. The results show that investments in AI systems can pay for themselves after about three years, if time savings, additional revenue and operating costs are considered. The dissertation recommends a holistic view and a structured integration of the financial strategy in order to efficiently exploit the opportunities of digitization and minimize risks. In addition to cost savings, AI investments also offer strategic benefits through inclusive-oriented solutions, market potential, and improved resource utilization, creating long-term value for practices.

JEL classification: D24, I11, I18, L86, O33, J24, J23, C63

Keywords: Artificial Intelligence in Healthcare, AI-Powered Diagnostics, Cost-Benefit Analysis in Healthcare, Externalities of AI, Market Structures in the Medical Sector, Digitization in Healthcare

1 Introduction

General practitioners are increasingly investing in AI-powered systems to improve diagnostics, workflows, and administrative efficiency. This trend is evident both in the broader digitalization of the healthcare sector and in specific applications: AI is used, for example, to analyze image data or laboratory values, to support diagnoses and to automate routine activities such as documentation or scheduling (Rodacki, n.d.).

However, the effect of such systems is not automatically universally positive: Studies show that efficiency gains are not always significant and depend heavily on local conditions (Wenderott et al., 2024). Continue reporting. GPs in qualitative studies on ambivalent experiences: On the one hand, AI relieves the administrative burden, but on the other hand, it can disrupt the workflow, for example through too many system inputs, lack of transparency or increased cognitive load (Mache et al., 2025).

Especially when investing in AI, the question of financial valuation arises: Many of these systems are based on intangible assets such as software, data or algorithms, the value of which is difficult to quantify. In financial and company valuation, it is therefore a challenge to map

these intangible investments in an economically sensible way (Value Creation through Software in Germany: Current Status, Perspectives, Recommendations for Action, n.d.).

The aim of this article is to provide a comprehensible overview of how investments in AI systems – especially those in intangible assets such as software or data – can be valued financially. In addition, a simple valuation model is presented that takes into account both medical and economic factors. This model builds on methods from health economics and financial planning and is intended to help general medical practices make better decisions about AI investments, identify risks and realistically assess the potential benefits of such systems.

2 Current State of the Solved Problem at Home

2.1 General status

In medical practice, a well-founded financial strategy is becoming increasingly important: In view of rising operating costs, increasing organizational complexity and technical innovations – especially through the use of AI systems – targeted control is essential. The focus is on three economic goals: cost control, sales optimization and long-term, sustainable investment planning.

Effectively implemented control is essential for this. Systematic target/actual comparisons make it possible to identify financial deviations at an early stage, and key performance indicators (KPIs) – such as the expense ratio or return on sales – can be used to continuously monitor the economic performance of the practice (Kammerer, 2022).

For investment decisions, especially when acquiring new medical technologies or IT/AI solutions, practices often resort to classic methods of the capital budget. One example is dynamic investment accounting, which calculates the present value (NPV). In a practical example from the Ratiopharm Group, the purchase of a digital X-ray machine resulted in a positive NPV with an assumed minimum return of 10%, which economically justified the purchase (Rederer, n.d.). These methods make it possible to predict the economic benefits of future cash flows and quantify investment risks.

A particular problem with such investments are intangible assets such as software, algorithms, databases or other intellectual property rights. These values are difficult to evaluate because they are physically intangible, their future benefits can be uncertain, and the useful life is difficult to estimate. A key standard for the accounting of these assets is the IAS 38, which sets out the conditions under which intangible assets can be deducted. According to IAS 38, an asset should be recognised if it is likely to generate economic benefits and the costs can be reliably measured (IAS 38 ▷ Intangible Assets | WTS Germany, n.d.).

In practice, development costs are often capitalized in software or AI developments, provided that the requirements are met – as these costs are usually easily documented (e.g. for programming, testing) (reserved & Schmitt, n.d.)

In the context of artificial intelligence in healthcare, additional assessment dimensions are added: AI systems can automate workflows, improve diagnostic accuracy, support patient communication, or make regulatory processes such as billing more efficient. The economic value of such systems results not only from cost savings, but also from improved quality, risk mitigation (e.g. fewer errors) and additional strategic advantages.

Since AI investments are often associated with a high degree of uncertainty (technology, regulation, market acceptance), the use of modern valuation methods makes sense. Analysis of real options is particularly useful: this method models investments as options, such as "postpone investment", "expand further" or "withdraw when in doubt". This flexible model allows

decision-makers to react to unexpected developments, maximizing the value of the investment under uncertainty (Coyle & Shrimp, 2024).

Another strategic advantage of AI investments lies in market strategy and inclusion: if AI solutions are designed to be suitable for different patient groups, regions and care contexts, this can create not only social but also economic added value. Inclusive AI can open up new markets, create trust and secure long-term competitive advantages (Unnikrishnan et al., 2025).

A final aspect of investment planning concerns the Efficiency AI systems can support decision-making processes (e.g. through simulations, adaptive models), which can reduce management and personnel costs in the long term. At the same time, the distribution of available resources is improving, as AI helps to identify and optimize needs and bottlenecks at an early stage (Alves et al., 2024).

Financial and investment planning in medical practices is becoming increasingly complex due to rising costs, organizational challenges, and technological innovations such as AI systems. Control tools and classic capital budgeting procedures allow for efficient management and valuation of investments, while real option analysis takes into account uncertainties. AI investments not only offer efficiency gains and cost reductions, but also strategic benefits through inclusive solutions, market potential, and improved performance Resource. Overall, they create economic, organizational and long-term added value for practices.

2.2 Investment decision-making in medicine

From the point of view of business economics, the financial management of medical practices focuses primarily on three basic goals: cost control, revenue optimization and strategic investment planning. Effective controlling is a prerequisite for achieving these goals. Through systematic comparisons of planned and actual values, as well as the use of Key Performance Indicators (KPIs), such as cost-to-revenue ratio or operating margin, economic deviations can be identified early on and corrective measures can be taken. The importance of financial controlling is even stronger in an environment of increasing technological complexity.

In investment decisions, especially in the procurement of medical technologies or digital and AI solutions, practices have traditionally used classic investment decision-making methods. The most commonly used methods include dynamic methods, in particular the calculation of the Net Present Value (NPV) and the payback period of the investment. These approaches make it possible to take into account the time value of money and compare expected future cash flows with initial investment costs. In the application practice of healthcare, these methods have proven themselves especially in the evaluation of capital-intensive technologies with relatively stable and predictable cash flows.

In the field of AI in healthcare, additional dimensions are added to these general valuation problems. AI systems in primary health care are mainly used to automate documentation, support diagnostic decisions, optimize appointment planning and streamline administrative processes, including invoicing and communication with insurance companies. The economic value of these systems is thus not only created through direct cost savings, but also through improved process quality, reduced errors, increased patient safety and indirect strategic effects.

Given the high level of uncertainty associated with AI investments, it is increasingly recommended in the current literature to complement classic financial assessment methods with advanced risk management approaches. These include, in particular, sensitivity analysis, scenario modelling and real-world options analysis. The real-world options approach allows AI investments to be modeled as flexible decisions that can be expanded, postponed, or discontinued over time depending on technological developments, legislative changes, or

market acceptance. In this way, the value of managerial flexibility, which is often underestimated by classic investment methods, can be better captured.

The strategic and societal dimension of AI investments also deserves special attention in the current discourse. Inclusive and ethically designed AI systems can contribute to increasing patient trust, better access to healthcare and long-term competitiveness of practice. Although these aspects are not always directly monetizable, they represent an important factor in investment decision-making from the point of view of the long-term value of the organization.

Thus, the current state of knowledge suggests that financial and investment planning in medical practices is becoming a more complex and multidimensional process due to the spread of AI systems. While traditional investment assessment tools provide a solid analytical foundation, they alone cannot fully capture the specifics of intangible and dynamically evolving AI technologies. This creates a need for integrated assessment frameworks that combine quantitative financial indicators with qualitative, strategic and risk aspects of investments.

Zeng et al. on the contrary, they implicitly show that the economic effects of AI are non-linear, uncertain, and highly context-dependent, which reduces the suitability of simple "one-size-fits-all" investment calculations. This reinforces the need for assessment approaches that can work with scenario variability, different adoption rates, and implementation risks. From the point of view of the current state of knowledge, AI in primary health care appears less as a technical individuality and more as a long-term transformation factor, the value of which arises primarily in interaction with the organizational and process environment of a healthcare facility. These findings are crucial for financial and investment decision-making in medical practices. (Zeng et al., 2026)

2.3 Efficiency, AI and Medicine

From the point of view of the current state of knowledge, it should be emphasized that empirical studies on the effectiveness of AI in healthcare bring mixed results. While some studies demonstrate significant time savings and productivity gains, others point to ambivalent experiences of healthcare professionals, including increased cognitive load, disruption of workflows, or limited transparency of decision-making processes in black-box models. At the same time, the effectiveness of AI systems varies significantly depending on the size of the practice, the level of existing digitization and the degree of integration of technology into everyday work processes.

- Review and systematic studies show that in some clinical and administrative applications, AI systems lead to significant time savings, increased productivity, and reduced administrative burdens, especially in documentation, planning, and data processing. At the same time, however, there are a growing number of qualitative and observational studies that point to the ambivalent experiences of healthcare staff. In addition to the benefits, doctors and healthcare professionals often describe increased cognitive load, disruption of workflows, and additional mental strain resulting from suboptimal integration of AI tools into existing processes. (Mache, S. et al., 2025) (El Arab – Al Moosa, 2025)
- A particular problem in clinical decision-making systems is the limited transparency of algorithmic models, especially when using deep learning-based black-box solutions. The lack of explainability of decisions can undermine doctors' trust in the system, complicate clinical accountability, and increase the psychological burden associated with the use of AI in everyday practice. (Chan, 2023)
- At the same time, the effectiveness and economic benefits of AI systems vary significantly depending on the context of implementation. Several studies point out that

the size of the medical facility, the level of existing digitization and the degree of process integration of technology fundamentally affect the real effects achieved. The highest benefits are seen in environments with clearly defined workflows and sufficient digital backgrounds, while in smaller or less digitised practices, the effects may be weaker or inconsistent. (Yousefi et al., 2025)

Empirical evidence on the impacts of artificial intelligence (AI) in primary care suggests that the effectiveness and economic benefits of these technologies are not universal or automatically guaranteed. On the contrary, they are strongly conditioned by the context of implementation, the organizational characteristics of the healthcare facility and the degree of integration of AI tools into existing work processes. This conclusion is also systematically confirmed by the conceptual article PRIMARY-AI published in the journal *Nature Medicine* in 2026, which highlights the need to evaluate AI in primary care not as a homogeneous technology, but as a context-bound intervention. (Zeng et al., 2026)

Zeng et al., point out that identical or very similar AI systems can lead to fundamentally different results in different environments – from noticeable time savings and streamlining of clinical and administrative processes to an increase in the cognitive burden on healthcare staff and disruption of workflows. The decisive factors turn out to be the size of the practice, the level of its existing digitization, the clarity of defined workflows and the organizational readiness to adapt new technologies. In less digitized or organizationally fragmented outpatient clinics, the introduction of AI can lead to parallel processes, duplicate checks, and an increased need for manual supervision, potentially reducing the expected benefits. At the same time, the assumption is that the implementation of AI itself automatically leads to improvements in efficiency, quality of care or economic performance. On the contrary, it is emphasized that without adequate process integration, clear ownership of responsibility and alignment with clinical goals, AI can act as an additional source of complexity. This aspect is particularly relevant for primary care, which is characterized by a high degree of patient variability, continuity of the doctor-patient relationship and temporal fragmentation of work. From the point of view of decision-making processes, the risks associated with the low transparency of some algorithmic solutions, especially the so-called black-box models, are also pointed out. Limited explainability of decisions can reduce trust in the system among doctors, increase the psychological burden associated with clinical responsibility, and complicate the acceptance of AI in everyday practice. It follows that the evaluation of AI cannot be limited to technical accuracy or isolated time savings, but must also include the organizational, ethical and operational implications of its use.

3 Research design

The present article follows a conceptual research design based on a systematic analysis of existing scientific literature on investment accounting, intangible assets and health economic valuation of AI systems. Such a literature-based approach is particularly suitable when theoretical models are to be developed or existing concepts are to be transferred to new fields of application (Webster & Watson, 2002). On this basis, the identified models are synthesized and evaluated with regard to their applicability to AI-related investments in general practice.

The selection of valuation methods is based on their relevance for investments in intangible assets and their broad application in the economic literature. Classic methods of capital budgeting, such as repayment period and present value (NPV), are considered standard tools for valuing long-term investment projects (Stephen et al., n. d.).

Since AI solutions are mostly software-based and do not represent physical goods, models that deal specifically with the valuation of intangible assets were also considered. These include

cost-based valuation approaches, market-based comparison methods and, to a certain extent, return-based methods for the valuation of patents and software (OECD, 2018)

The selected models were evaluated on the basis of their practicability, data requirements and suitability for mapping AI-specific uncertainties. Models with high complexity or high data requirements were excluded, as these are often not practical at the level of a single practice.

4 Research results

4.1 Assumptions for an AI investment in a general practice

In order to illustrate the evaluation methods, a simplified model is developed that takes into account typical framework conditions of a general medical practice. The assumptions are based on literature on digitization costs in healthcare, typical license prices of AI software, and empirical data on time and efficiency gains through automation (Ahuja, 2019) (Davenport & Kalakota, 2019).

The following model assumptions are made, including:

- Procurement costs of AI software (license or patent use).
- Annual maintenance and update fees.
- Expected time savings in the area of documentation, appointment management or decision support.
- Other qualitative advantages such as quality improvement or error reduction.
- Discount rate, based on standardized calculation rates for SMEs in the healthcare sector
- Implementation and training costs.

These assumptions allow the calculation of the present value and the repayment period on the basis of realistic but simplified parameters.

The following basic assumptions are made for the development of the model:

1. Type of AI application: An AI-powered system for automated documentation and decision support.
2. Acquisition costs: One-time license fee (e.g. EUR 12,000) and implementation and training costs (e.g. EUR 3,000).
3. Ongoing costs: Annual maintenance and update fees (e.g. 2,000 EUR).
4. Service components: Time savings per patient documentation, more efficient billing, improved diagnostic quality, reduced administrative burden.
5. Temporal perspective: Observation over five years.
6. Discount rate: 5%, based on typical calculated interest rates in the outpatient healthcare sector.

These assumptions come from the literature on digitization costs in healthcare, empirical case studies on AI applications, and standardized business parameters. Quantitative data such as time savings are converted into monetized values to enable their integration into the cash flow calculation.

4.2 Cash flow estimation for AI software or patents

The cash flow estimate includes both the costs and benefits of the AI investment over a defined period of time (e.g., five years). Based on the model assumptions, the expected annual net cash flows are calculated, consisting of:

- direct costs (license fees, maintenance, implementation),
- indirect costs (training, process adjustments),

- quantifiable benefits such as time savings, reduction of administrative tasks and possible minimization of errors,
- potential revenue increases (e.g., through more efficient patient management).

The cash flow calculation is based on established valuation approaches for software investments and intangible assets (Damodaran, 2012). For AI-specific uncertainties – such as the changeability of algorithms, regulatory requirements or data dependency – risk discounts or scenario analyses are integrated (Damodaran, 2012).

The cash flow calculation is carried out in several steps:

1. Initial Investment: Sum of license costs, implementation, and training.
2. Calculation of annual net cash flows:
 - monetized time savings (e.g. through faster documentation),
 - potential revenue increases (e.g., more treatable patients),
 - savings due to fewer administrative tasks,
 - minus the operating costs.
3. Calculation of the repayment period: Time at which the accumulated returns will offset the initial investment.
4. Calculating the present value (NPV): Discounting all future cash flows to evaluate the economy taking into account the monetary value over time.

Since AI systems have special uncertainties – such as future technical developments, possible regulatory requirements or changed licensing models – the cash flow estimate is additionally supplemented by sensitivity analyses. Alternative scenarios are considered, e.g. optimistic, realistic and pessimistic benefit estimates. This allows the robustness of the investment decision to be assessed. Overall, the calculation model shows that AI investments can make economic sense, but the assessment must be differentiated and qualitative factors must be taken into account in addition to quantifiable effects (Deisten, 2025) (Risikobasierte Bewertung von KI in der Medizin, 2025) (Ma et al., 2025).

Table 1
Exemplary calculation model

Year	Monetized Time Savings (EUR)	Additional revenue (EUR)	Operating costs (EUR)	Net Cashflow (EUR)
0	–	–	–	-15 000 (initial costs)
1	6 000	2 000	-2 000	6 000
2	6 000	2 000	-2 000	6 000
3	6 000	2 500	-2 000	6 500
4	6 500	3 000	-2 000	7 500
5	6 500	3 000	-2 000	7 500

Source: Ahuja, 2019

Explanation of the pillars

1. Year:
 - Shows the observation period of the investment (here 5 years). Year 0 corresponds to the time of purchase.
2. Monetized Time Savings (EUR):
 - Value of labor savings achieved by the AI system (e.g., automated documentation, scheduling, decision support).
 - The time saved is converted into monetary values, for example by multiplying the working hours of the practice employees by the hourly wage.

- Increasing values in later years reflect efficiency gains and experience effects.
- 3. Additional revenue (EUR):
 - Potential additional revenue from more efficient patient management, more patient numbers, or more billable services.
 - In the table, the values increase from year 3 onwards as soon as the system is established and additional optimizations are implemented.
- 4. Operating costs (EUR):
 - Recurring costs for maintenance, updates, support, or license renewals.
 - Used here all the time to simplify the calculation.
- 5. Net Cashflow (EUR):
 - Net Cash Flow=Monetized Time Savings+Additional Revenues–Ongoing Costs
 - Year 0: Negative sum (–EUR 15,000) = one-off investment costs (initial costs for procurement, implementation, training).
 - Subsequent years: Positive cash flows show the annual financial benefit minus ongoing costs.

The initial investment of EUR 15,000 will be offset by the cumulative net cash flows from the third year onwards, which corresponds to a repayment period of approximately three years. The subsequent positive cash flows and a positive present value (NPV) speak for the economic viability of the investment.

To increase the robustness of the investment decision, sensitivity analyses can be carried out in which alternative scenarios – such as optimistic, realistic or pessimistic assumptions – are taken into account. In this way, uncertainties caused by time savings, licensing or maintenance costs, and regulatory frameworks can be adequately taken into account.

In addition to the quantifiable monetary effects, qualitative benefit aspects must also be included in the assessment. These include, for example, higher documentation and diagnostic quality, improved patient safety and a reduction in administrative errors. These qualitative effects also contribute significantly to the overall valuation of the investment and underline the importance of a holistic view of AI systems in general medical practice.

Another example can model the use of an AI-based quality assurance system in an automotive factory (e.g. camera-based defect detection in car body construction). It assumes a one-off investment of EUR 500,000 in hardware and software, annual operating costs and efficiency gains through less waste, less rework and higher throughput; the logic of the cash flow calculation follows the same steps as in your medical example (initial investment, annual net cash flows, repayment period, NPV). Methodologically, the example is based on the same net present value-based methods as shown in the paper with reference to Damodaran (2012) and the general investment accounting.

Table 2
Example of the automotive industry AI quality assurance

Year	Monetized Time Savings (EUR)	Additional revenue (EUR)	Operating costs (EUR)	Net Cashflow (EUR)
0	–	–	–	-500 000
1	220 000	80 000	-70 000	230 000
2	240 000	90 000	-72 000	258 000
3	260 000	95 000	-74 000	281 000
4	270 000	100 000	-76 000	294 000
5	280 000	100 000	-78 000	302 000

Source: Buchenau, 2025

In this scenario, cost savings from lower scrap and rework (e.g., fewer defective bodies) and additional contribution margins from higher throughput are monetized over five years, while license, maintenance, and data infrastructure costs are deducted as operating costs. The cumulative net cash flows offset the initial investment of EUR 500,000 already between years 2 and 3, resulting in a repayment period of just under three years; applying an industry-standard discount rate of around 8-10% in the automotive sector, this pattern would typically result in a positive NPV.

The example is a separate calculation example for AI-supported quality control in automotive production based on the value contributions of AI in the automotive industry presented in McKinsey (2018) as well as current investment and efficiency programs by Volkswagen (Volkswagen Group, press release on AI investments) and Bosch (Autohersteller: Bis zu 9 Prozentpunkte höhere Rendite durch künstliche Intelligenz möglich | McKinsey, n. d.) (Buchenau, 2025).

4.3 General result

The integration of artificial intelligence (AI) into general medical practices is leading to profound changes in workflows, diagnostics and financial planning – this requires a structured and multi-layered evaluation of such investments.

To evaluate investments in AI systems, classic financial methods are used, such as the repayment period and, in particular, the net present value (NPV) method. However, AI applications have particular uncertainties, for example in terms of software updates, constant regulatory adjustments, changing licensing costs and benefit aspects that cannot be directly quantified, such as quality improvements or time savings.

Modern practices therefore complement the classic methods with sensitivity analyses and scenario techniques: Different development paths – such as optimistic, realistic or pessimistic scenarios – are calculated in order to comprehensively map opportunities and risks. In addition, qualitative factors are taken into account, such as improvements in documentation quality, patient safety and the reduction of administrative tasks. These play just as important a role in AI investments as measurable financial effects.

AI systems bring significant efficiency benefits, for example through pattern recognition in large amounts of data, support for diagnoses, automation of routine tasks or the development of individual treatment plans. The systems enable objective and comprehensive analysis of large amounts of data in real time; This allows doctors to react faster and reduce the administrative effort (Patient Assessment: How AI Analyzes Health Data, n.d.)

However, not all effects are purely positive: studies report ambivalent experiences. Although doctors see benefits in relieving the burden and improving the quality of care, they are feeling an increase in digital demands, cognitive load and a lack of transparency. Essential for success is the clear integration of AI into existing processes and continuous evaluation by external bodies to ensure reliability – especially in the case of "black box" models (2024_07_04_HAEV_Positionspapier_KI.pdf, n.d.)

The calculations show that investments in AI systems can already lead to a positive present value in the medium term: After only about three years, the initial investment of typical AI solutions pays off in terms of time saved, efficiency gains and additional revenue. Ongoing monitoring based on key metrics such as cash flows and labor time savings remains important. Financial planning should also include the costs of implementation, maintenance and training, as well as strategic aspects such as market potential and resource efficiency.

Investments in AI technology in medical practice are economically promising, but require a differentiated view. If quantitative and qualitative benefit aspects, possible scenarios and strategic advantages are taken into account, practices can exploit the potential of digitization in a targeted and long-term manner – and minimize risks (Patient Assessment: How AI Analyzes Health Data, n.d.).

For both tables in Chapter 3 Methodology, the calculation can be represented on an hourly basis by dividing the monetised amounts by an assumed hourly rate. In the following, EUR 60 per hour is calculated as an example (e.g. average full-cost hour of medical/medical staff or qualified specialist in industry).

4.4 Assumption of hourly rate

*„Hourly rate practice / automotive industry: 60 EUR per productive hour
(Controlling in der Arztpraxis, n. d.) (Autohersteller: Bis zu 9 Prozentpunkte
höhere Rendite durch künstliche Intelligenz möglich | McKinsey, n. d.)“*

The example calculation for the integration of AI systems in a general practitioner's practice is based on the conversion of monetized time savings into actual working hours. An average hourly rate of 60 EUR is assumed, which is typically considered a full-cost hour for medical or medical staff in Germany. The monetized time savings resulting from efficiency gains through automated documentation, appointment management and decision support are EUR 6,000 in each of the first three years. This corresponds to a saving of about 100 hours of working time per year (6,000 EUR / 60 EUR per hour). In the last two years, this saving has risen to 6,500 EUR, which corresponds to about 108 hours.

These time savings make a significant contribution to compensating for the high initial investment in AI software, implementation and training of around EUR 15,000 after about three years with cumulative hour savings. The use of AI thus not only improves the quality of patient care but also makes more efficient use of the working time of medical staff, which leads to a noticeable relief. The basis of this calculation is based on analyses and data from health economics and has been confirmed by studies such as those by Ahuja (2019) and reports by the German Medical Association as well as practice controlling experts. The application of AI in practice organizations is increasingly seen as an opportunity to reduce administrative effort and focus more on patient care.

In the automotive industry, the investment in AI-powered quality assurance systems is justified by the significant reduction in scrap, rework costs, and increased production throughputs. The example calculation uses an hourly rate of 60 EUR for qualified specialists in manufacturing. The monetized savings from AI applications start at around EUR 220,000 in the first year, which equates to a time saving of around 3,667 hours. Over the course of the five years, this value increases to about 280,000 EUR in the fifth year, which corresponds to about 4,667 hours saved.

These significant time savings result from efficiency gains through the automation of quality inspection using AI, which minimizes errors and production losses. The model shows that the high initial investment of EUR 500,000 can be amortized within three years due to the cumulative productivity-enhancing effects. Market studies by McKinsey and other consulting firms back up these figures, showing that integrating AI into the automotive industry's production processes leads to significant productivity and return gains. The savings and efficiency gains described underline the broad acceptance and strategic benefits of AI solutions in one of the most important industrial sectors.

Chapter 3 "Methodology" and Chapter 4 "Results" of the dissertation "Financial Strategy and Decision Making in the Integration of AI-Supported Systems in General Practice" form a

logically building unit that transitions from theoretical foundation to practical validation. While Chapter 3 establishes a literature-based research design and adapts classic capital budgeting methods such as repayment time and NPV method for intangible AI investments (software, algorithms), Chapter 4 applies these approaches empirically and expands them with cross-industry comparisons.

The methodology describes in detail assumptions for a general practice – e.g. 15,000 EUR initial investment (license 12,000 EUR + implementation/training 3,000 EUR), annual maintenance costs of 2,000 EUR, 5% discount rate and monetized time savings through automated documentation – as well as the multi-stage cash flow process (initial investment, net cash flows, sensitivity analyses for uncertainties such as regulations or technology development). This is based on sources such as Damodaran (2012), Ahuja (2019) and IAS 38 (Ahuja, 2019) (IAS 38 ▷ Immaterielle Vermögenswerte | WTS Deutschland, n.d).

Chapter 4 validates this methodology with concrete results: Table 1 shows a payback after about three years with increasing net cash flows (from EUR 6,000 to EUR 7,500 annually), supplemented by qualitative benefits such as improved patient safety. In addition, it contrasts with an automotive example (EUR 500,000 investment in AI quality assurance, <3-year payback period), which demonstrates higher economies of scale and refers to McKinsey (2018), according to which AI can increase automotive returns by up to 9 percentage points. Both chapters emphasize sensitivity analyses and ambivalent effects (e.g., cognitive load according to Mache et al. 2025), while Chapter 4 emphasizes the transferability of the methodology intersectorally and calls for a holistic assessment (quantitative + qualitative) (Automakers: Up to 9 percentage points higher returns possible through artificial intelligence | McKinsey, n.d.) .

In summary, the transition from methodology to results proves the robustness of NPV-based approaches to AI investments: from real-world assumptions to validated profitability forecasts that link general practice to industry and enable long-term value through efficiency gains and risk management.

Another key finding concerns the strategic importance of AI investments. The digitization of recurring activities creates space for patient-centered work, individual discussions and more complex medical decisions. At the same time, the practice's competitive position is improving more efficient processes, higher documentation quality and faster response times increase both the profitability and the attractiveness of the practice for patients, employees and cooperation partners.

In conclusion, AI investments not only enable short-term efficiency gains, but also initiate structural changes in the organization of medical practices. The results of the assessment clearly show that practices that systematically integrate AI and at the same time adapt their financial and work processes will become more resilient and competitive in the long term. This is particularly visible in areas such as documentation, appointment management, diagnostic support and billing, where AI continuously contributes to reliable, measurable relief.

In addition, the findings indicate that the true economic benefits of AI go beyond purely monetary effects. The investment creates a basis for continuous quality improvements, data-based decisions and a more sustainable resource use concept. AI is thus gradually developing into a strategic core component of modern practice management. The results underline that the financial added value is greatest when economic, qualitative and organizational aspects are considered together – and when practices are willing to adapt their workflows to the new digital possibilities. All in all, it is clear that AI is less a technical individual project and more a long-term transformation factor, the benefits of which continue to increase with each year of use.

Calculation examples like those in the results (NPV, payback period, cash flow analysis for AI investments) can also be found in the following industries with significant AI deployment:

Finance and Accounting Sector: AI automates accounting processes, e.g. invoice processing or financial forecasting, leading to measurable cost savings and efficiency gains. Calculation examples include time savings, error reduction, and faster financial closings.

AI automates accounting processes, e.g. invoice processing or financial forecasting, leading to measurable cost savings and efficiency gains. Calculation examples include time savings, error reduction, and faster financial closings (PricewaterhouseCoopers, n. d.).

Insurance Sector: AI supports risk assessment, fraud detection, and claims processing. Calculations show savings through automation and more accurate pricing (PricewaterhouseCoopers, n. d.).

These examples demonstrate that AI investments can also be economically quantified in service industries with high data volumes and complex processes.

5 Discussion

The current status of financial and investment planning in medical practices shows that the use of artificial intelligence (AI) is becoming increasingly important. Rising operating costs, more complex organizational requirements and new technological possibilities make it necessary to make investment decisions in a methodically sound manner. Practices use established capital budget instruments such as the present value (NPV) or the repayment period to assess the profitability of new technologies. These methods make it possible to realistically assess future cash flows and quantify risks. At the same time, intangible assets – such as software, algorithms or databases – pose a challenge because their benefits are difficult to predict and their valuation must meet special requirements according to standards such as IAS 38.

While AI systems offer a wide range of economic and organizational benefits, they are characterized by technological and regulatory uncertainties. Therefore, the use of modern assessment methods such as sensitivity analyses or scenario techniques is becoming increasingly important in order to be able to map different development paths. Real option approaches are also gaining in importance, as they take into account the possibility of adjusting or postponing investments depending on technological or regulatory developments. In addition to the financial aspects, qualitative benefit factors – such as efficiency increases, error reduction or improved patient safety – play a decisive role in the overall assessment (Coyle & Shrimp, 2024).

The results show that, under realistic assumptions, investments in AI systems often pay off in the medium term. Example calculations illustrate that general medical practices can amortize the initial costs after about three years, especially through time savings in documentation and administration, more efficient billing processes and potential additional revenue. In addition, it can be seen that qualitative effects such as improved documentation and diagnostic quality as well as a reduction in the workload of staff create considerable added value that cannot be fully monetised, but nevertheless contribute significantly to the attractiveness of such investments (Ahuja, 2019).

At the same time, studies report ambivalent experiences in everyday practice: Although AI can reduce the administrative burden and support diagnoses, the cognitive load often increases due to new digital processes. It is therefore crucial to have a clear integration into existing processes and a continuous external review of the systems, especially in the case of non-transparent "black box" models (Mache et al., 2025).

Overall, the results confirm that AI investments in general practice offer considerable economic potential, provided they are evaluated holistically. A combination of classic financial analysis, modern risk models and qualitative benefit assessments enables a realistic and sustainable basis for decision-making. It becomes clear that the use of AI not only creates efficiency gains and cost savings, but also opens up strategic advantages such as market potential, quality improvements and improved use of resources – and thus generates long-term added value for medical practices.

6 Conclusions

The financial valuation of artificial intelligence (AI) in medical practices is fundamentally feasible, yet it requires targeted methodological adjustments to accurately capture the specific characteristics of AI-driven systems. Traditional investment appraisal techniques—such as net present value (NPV), internal rate of return (IRR), and payback period—remain essential tools, but they must be complemented with approaches suitable for intangible, rapidly evolving digital assets. Medical practices should therefore integrate financial models that not only calculate discounted cash flows but also systematically monetize qualitative benefits, including improvements in documentation quality, diagnostic accuracy, workflow efficiency, and time savings for medical staff. These qualitative components often generate significant long-term value and should be explicitly incorporated into multi-criteria financial evaluations.

Furthermore, investments in AI software, data-driven applications, or patent-based technologies require adapted valuation methods specifically designed for intangible assets. Such methods account for characteristics like uncertain technological lifecycles, dependence on continuous updates, algorithmic performance variability, and regulatory obligations. Approaches used in intellectual property valuation—such as cost-based, income-based, and market-based models—provide a more accurate representation of these assets than classical material asset valuation. This is especially relevant in the healthcare sector, where AI solutions often operate as decision-support systems with high leverage on overall care quality, patient safety, and operational efficiency.

In addition to financial and technological considerations, regulatory, ethical, and quality-assurance requirements play a central role in the assessment of AI investments. Compliance with medical device regulations, data protection laws, algorithmic transparency standards, and clinical validation procedures must be considered early in the investment decision, as they significantly influence both cost structures and long-term applicability.

Future research should therefore focus on refining integrated valuation frameworks capable of representing both monetary and non-monetary outcomes of AI adoption. In particular, models that better quantify diagnostic improvements, reductions in medical errors, patient-safety enhancements, and long-term organizational transformation effects would provide a more realistic assessment of the true value generated by AI in healthcare. Developing hybrid evaluation methods—combining financial metrics, risk analyses, and qualitative outcome measures—would enable a more comprehensive and evidence-based foundation for investment decisions. This would support healthcare providers in aligning technological innovation with economic sustainability, clinical quality, and ethical responsibility.

Acknowledgement

This research was supported by a grant from the Slovak Ministry of Education Science, Research and Sport, VEGA 1/0109/24: Research on the Economic Performance of Family Businesses with a Focus on the Implementation of Tools for Measuring Technical Efficiency (100 %).

References

- 2024_07_04_HAEV_Positionspapier_KI.pdf. (o. J.). Abgerufen 18. November 2025, von https://www.haev.de/fileadmin/user_upload/News_Dateien/2024/2024_07_04_HAEV_Positionspapier_KI.pdf.
- Ahuja, A. S. (2019). The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ*, 7, e7702. <https://doi.org/10.7717/peerj.7702>.
- Alves, M., Seringa, J., Silvestre, T., & Magalhães, T. (2024). Use of Artificial Intelligence tools in supporting decision-making in hospital management. *BMC Health Services Research*, 24(1), 1282. <https://doi.org/10.1186/s12913-024-11602-y>.
- Autohersteller: Bis zu 9 Prozentpunkte höhere Rendite durch künstliche Intelligenz möglich | McKinsey. (o. J.). Abgerufen 2. Dezember 2025, von <https://www.mckinsey.de/news/presse/autohersteller-bis-zu-9-prozentpunkte-hoehere-rendite-durch-kuenstliche-intelligenz-moeglich>.
- Buchenau, M.-W. (2025, Juni 27). Autoindustrie: Bosch steckt 2,5 Milliarden in KI-basierten Strukturwandel. <https://www.handelsblatt.com/unternehmen/industrie/autoindustrie-bosch-steckt-25-milliarden-in-ki-basierten-strukturwandel/100137214.html>.
- Controlling in der Arztpraxis. (o. J.). Abgerufen 16. November 2025, von <https://www.virchowbund.de/praxis-knowhow/abrechnung-finanzen/controlling>.
- Coyle, D., & Gamberi, L. (2024). A real options approach to data valuation. *Business Economics*, 59(4), 227–234. <https://doi.org/10.1057/s11369-024-00374-2>.
- Damodaran, A. (2012). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset*: (3. Aufl., Bd. 3). John Wiley & Sons.
- Davenport, T., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future Healthcare Journal*, 6(2), 94–98. <https://doi.org/10.7861/futurehosp.6-2-94>.
- Deistler, N. (2025). Risiken, Regulierung und Evaluierung von KI-Systemen. *Wirtschaftsinformatik & Management*. <https://doi.org/10.1365/s35764-025-00560-7>.
- El Arab, R. A., Al Moosa, O. A. (2025). Systematic review of cost effectiveness and budget impact of artificial intelligence in healthcare. In *npj Digital Medicine*. <https://doi.org/10.1038/s41746-025-01722-y>.
- Chan, B. (2023). Black-box assisted medical decisions: AI power vs. ethical physician care. In *Med Health Care Philos*. <https://doi.org/10.1007/s11019-023-10153-z>.
- IAS 38 ▷ Immaterielle Vermögenswerte | WTS Deutschland. (o. J.). Abgerufen 16. November 2025, von <https://wts.com/de-de/news-knowledge/ifrs/ifrs-standards/ias-38-Immaterielle-vermoegenswerte>.
- Kammerer, K. (2022, Februar 1). Praxiscontrolling – einfach und leistungsorientiert—BDC|Online. BDC. <https://www.bdc.de/praxiscontrolling-einfach-und-leistungsorientiert/>.
- Ma, J., Weicken, E., Pahde, F., Weitz, K., Lapuschkin, S., Samek, W., & Wiegand, T. (2025). Künstliche Intelligenz auf dem Prüfstand: Anforderungen, Qualitätskriterien und Prüfwerkzeuge für medizinische Anwendungen. *Bundesgesundheitsblatt - Gesundheitsforschung - Gesundheitsschutz*, 68(8), 915–923. <https://doi.org/10.1007/s00103-025-04101-w>.

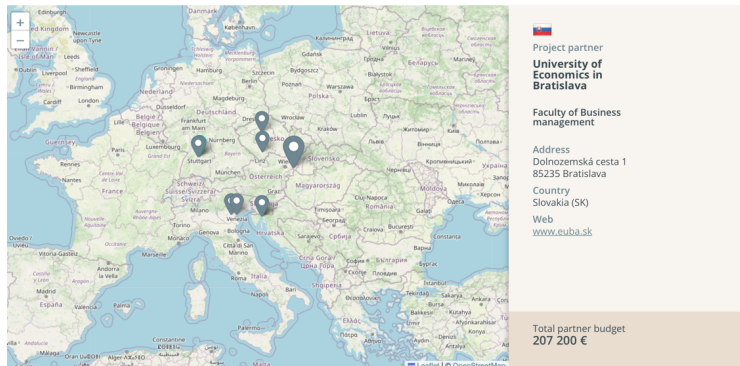
- Mache, S., Bernburg, M., Würtenberger, A., & Groneberg, D. A. (2025). Artificial Intelligence in Primary Care: Support or Additional Burden on Physicians' Healthcare Work?-A Qualitative Study. *Clinics and Practice*, 15(8), 138. <https://doi.org/10.3390/clinpract15080138>.
- OECD. (2018). *OECD Compendium of Productivity Indicators 2018*. OECD Publishing. <https://doi.org/10.1787/pdtvy-2018-en>.
- Patientenbewertung: Wie KI Gesundheitsdaten analysiert. (o. J.). Abgerufen 18. November 2025, von <https://evoluce.de/patientenbewertung/>
- PricewaterhouseCoopers. (o. J.). Künstliche Intelligenz im Finanzsektor. PwC. Abgerufen 2. Dezember 2025, von <https://www.pwc.de/de/finanzdienstleistungen/kuenstliche-intelligenz-im-finanzsektor.html>.
- Rederer, P. Dr. E. (o. J.). Investitionsrechnung in der Arztpraxis – Teil 2—Ratiopharm GmbH. Abgerufen 16. November 2025, von <https://fachkreis.ratiopharm.de/wissen/praxismanagement/hnu-beitragsserie/investitionsmanagement-teil-2.html>.
- reserved, C. H.-L. G. & C. K.- all rights, & Schmitt, Dr. M. (o. J.). F+E-Controlling: Aktivierung von Entwicklungskosten / 1.3 Abgrenzung der Forschungs- und ... Haufe.de News und Fachwissen. Abgerufen 16. November 2025, von <https://www.haufe.de/id/beitrag/fe-controlling-aktivierung-von-entwicklungskosten-13-abgrenzung-der-forschungs-und-entwicklungskosten-HI2197012.html>.
- Risikobasierte Bewertung von KI in der Medizin. (2025, März 21). <https://www.gesundheitsindustrie-bw.de/fachbeitrag/pm/risikobasierte-bewertung-von-ki-der-medizin>.
- Rodacki, P. (o. J.). Wie KI in der Medizin Ärzte bei Diagnose und Therapie entlastet. Wie KI in der Medizin Ärzte bei Diagnose und Therapie entlastet. Abgerufen 16. November 2025, von <https://www.proalpha.com/de/wissensportal/ki/ki-in-der-medizin>.
- Stephen, A. R., Westerfield, R. W., Jeffrey, J., Bradford, D. J., & Shue, K. (o. J.). *Corporate Finance: 2025 Release ISE*. Abgerufen 17. November 2025, von <https://www.mheducation.co.uk/corporate-finance-2025-release-ise-9781266961007-emea-group>.
- Unnikrishnan, B., Adames, A. G., Adibi, A., Peesapati, S., Kocielnik, R., Fischer, S., Kasimbazi, H. C., Gameiro, R., Peluso, A., Fernandes, C. O., Lange, M., Gondara, L., & Celi, L. A. (2025). Beyond Ethics: How Inclusive Innovation Drives Economic Returns in Medical AI (No. arXiv:2510.10338). arXiv. <https://doi.org/10.48550/arXiv.2510.10338>.
- Webster, J., & Watson, R. T. (2002). Analyzing the Past to Prepare for the Future: Writing a Literature Review. *MIS Quarterly*, 26(2), xiii–xxiii.
- Wenderott, K., Krups, J., Zaruchas, F., & Weigl, M. (2024). Effects of artificial intelligence implementation on efficiency in medical imaging—A systematic literature review and meta-analysis. *Npj Digital Medicine*, 7(1), 265. <https://doi.org/10.1038/s41746-024-01248-9>.
- Wertschöpfung durch Software in Deutschland: Aktueller Zustand, Perspektiven, Handlungsempfehlungen. (o. J.). Abgerufen 16. November 2025, von <https://www.digital.iao.fraunhofer.de/de/leistungen/DigitaleService-Systeme/IEDS.html>
- Yousefi, F., Dehnavieh, R., Laberge, M., Gagnon, M.-P., Ghaemi, M. M., Nadali, M., Azizi, N. (2025). Opportunities, challenges, and requirements for Artificial Intelligence (AI) implementation in Primary Health Care (PHC): a systematic review. In *BMC Prim Care*. <https://doi.org/10.1186/s12875-025-02785-2>.

Zeng, D. et al. (2026). PRIMARY-AI: outcomes-based standards to safeguard primary care in the AI era. In Nature Medicine. <https://doi.org/10.1038/s41591-025-04178-5>.



GREENPACT

Project partnership



Project overview

Futurepreneurs and SMEs for a sustainable Central Europe | Certification Scheme

Futurepreneurs are professionals that are driven by purpose and impact. They take on societal challenges and climate change with an entrepreneurial mindset and want to improve our lives. The GREENPACT project sets up partnerships between companies and futurepreneurs. The aim is to develop a certification scheme for a new generation of impact-driven top executives. To this end, the project develops joint action plans, pilot actions and a self-assessment tool.



Duration

Start date **04.2023**
 End date **03.2026**

Project progress

20%

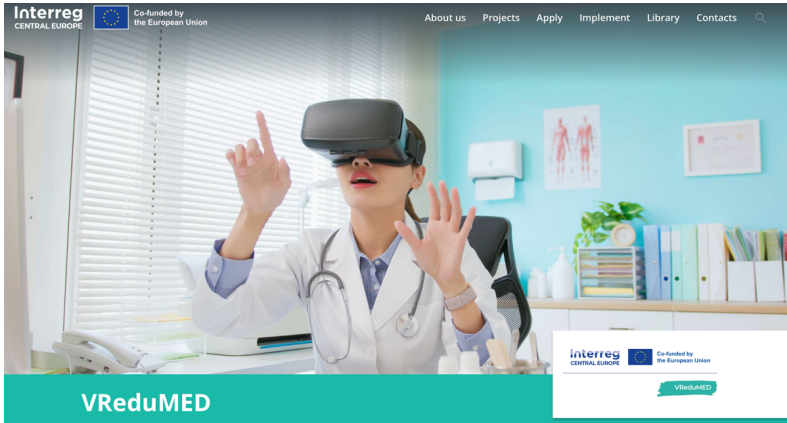
Project partners

Lead partner
Stuttgart Media University


Startup Center
 Address
 Nobelstr. 10
 740569 Stuttgart
 Country
 Germany (DE)
 Web
<https://www.hdm-stuttgart.de/en>

Project partner

- Stuttgart Region Economic Development Corporation**
- ENAIIP Veneto Social Enterprise**
- Region of Veneto - Department of Labour**
- STEP RI Science and Technology Park of the University of Rijeka Ltd**
- City of Rijeka**
- Czech Chamber of Commerce**
- Institute of Technology and Business in České Budějovice**
- University of Economics in Bratislava**



Project partners

 Lead partner
South Bohemian Science and Technology Park, corp.

 Address
 Lipová 1789/9
 37005 České Budějovice
 Country
 Czechia (CZ)
 Web
www.jvto.cz

- Project partner
-  **University of South Bohemia in České Budějovice** ▾
 -  **Business Upper Austria** ▾
 -  **Education Group** ▾
 -  **University of Economics in Bratislava** ▾
 -  **National Institute of Children's Diseases** ▾
 -  **Strategic Partnership for Sensor Technologies** ▾
 -  **Ostbayerische Technische Hochschule Regensburg** ▾
 -  **Innoskart Business Development Nonprofit Ltd.** ▾
 -  **Széchenyi István University** ▾

Project overview

Virtual Reality Education and Training Solutions for Medicine Sector

Medical interventions are increasingly digitalised but training of health care staff is still lagging behind. The VReduMED project helps to untap the potential of virtual and augmented reality for their education. The partnership develops a roadmap for virtual reality training products and services and will publish a handbook on the integration of virtual reality into health care education. They also set up three regional virtual reality labs to test different virtual reality use cases.

2,20

m €
Project Budget

5
Countries

6
Regions

10
Partners

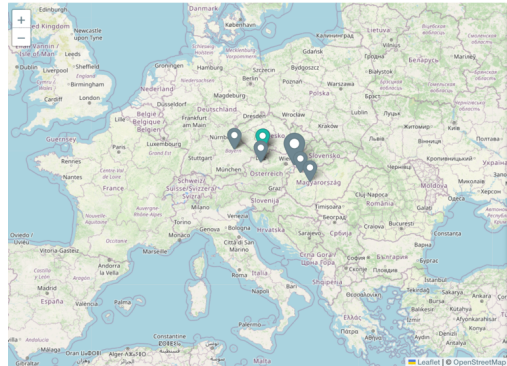
3
Pilots


80%
of the Budget is funded by ERDF

Duration

Start date **04.2023** | Project progress **20%**
 End date **03.2026**

Project partnership



 Project partner
University of Economics in Bratislava
 Faculty of Business Management
 Address
 Dolnozemska cesta 1/A
 852 35 Bratislava
 Country
 Slovakia (SK)
 Web
www.euba.sk

Total partner budget
220 900 €



Project overview

Start date:

01 January 2024

Status: ongoing

End date:

30 June 2026

€1,540,470 budget

80.00 % funded by
Interreg Funds

7 countries

10 partners




SOCIALLY RESPONSIBLE SLOW FOOD TOURISM IN THE DANUBE REGION

The main objective of the SReST project is to promote "slow food" tourism in the Danube region and enhance the employability of vulnerable groups by providing solutions that enable the valorisation of agrobiodiversity and gastronomic heritage and a fair distribution of generated benefits, including the well-being of the host communities.

By focusing on agro-biodiversity, food heritage and local identity, the goal is to broaden the socially responsible sustainable tourism offer and promote "slow food" tourism based on the exploration of gastronomic traditions and the local communities that preserve them. The project will help enhance local agricultural high-value chains while appreciating natural and cultural diversity of partner regions.

SReST will develop joint solutions to enhance socio-economic development and promote alternative models and competitive new tourism products of "slow food" itineraries grounded in agrobiodiversity and food heritage, tested in different territorial contexts of pilot regions. These solutions will not be limited to the local level, but will have a wider impact in the Danube area. Therefore, the success of the project will be based on close cooperation between partners from different countries and regions. You can learn more about the project partners [here](#).



Duration

Start date **06.2024**

End date **11.2026**

Project partners



Lead partner

Business Upper Austria

Mechatronics Cluster + Circular Economy
Team @ Plastics Cluster

Address
Hafenstraße 47-51
4020 Linz

Country
Austria (AT)

Web
<https://www.biz-up.at>

Project partner

- ConPlusUltra Ltd** ▼
- University of Economics in Bratislava** ▼
- Chamber of Commerce and Industry of Pécs- Baranya** ▼
- South Poland Cleantech Cluster Ltd.** ▼
- STEP RI science and technology park of the University of Rijeka Ltd.** ▼
- Development and Training Centre for the Metal Industry - Metal Centre Čakovec** ▼
- MESAP Innovation Cluster** ▼
- Science and Technology Park - Envipark** ▼
- Bayern Innovativ** ▼
- Cluster of Environmental Technologies Bavaria** ▼

Project partnership

Project partner
University of Economics in Bratislava

Faculty of Business management

Address
Dolnozemska cesta 1
85235 Bratislava

Country
Slovakia (SK)

Web
www.euba.sk


Total partner budget
174 020 €

Project overview

Circular design and development of Sustainable products in 4 key sectors in Central Europe

The ongoing transition to a circular economy is not only a tedious obligation for the manufacturing industry. It also offers an opportunity to develop innovative sustainable products. The CURIOST project helps small- and medium-sized companies in sectors like mechanics, packaging, plastics, and construction to harvest the potential benefits. They help selected companies to co-develop tailor-made, innovative, sustainable and circular product prototypes. The learnings are then aggregated into a universal strategy and action plans to accelerate the green transition in the manufacturing industry.





Duration

Start date **06.2024**
End date **05.2027**

Project partners



Lead partner
Primorje-Gorski Kotar County

Administrative Department for Regional Development, Infrastructure and Project Management

Address
Adamićeva 10
51000 Rijeka

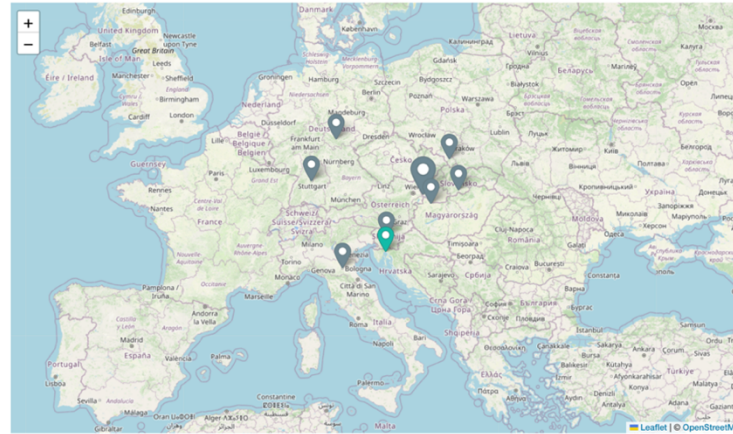
Country
Croatia (HR)

Web
www.pgz.hr

Project partner

-  **Alma Mater Studiorum - University of Bologna** ▼
-  **Technical University Ilmenau** ▼
-  **bwcon** ▼
-  **Chamber of Commerce and Industry of Slovenia** ▼
-  **Pannon Business Network Association** ▼
-  **University of Economics in Bratislava** ▼
-  **Regional Development Agency in Bielsko-Biala** ▼
-  **City Lucenec** ▼

Project partnership



 Project partner
University of Economics in Bratislava
Faculty of Business Management
Address
Dolnozemska cesta 1/B
85235 Bratislava
Country
Slovakia (SK)
Web
fpm.euba.sk

Total partner budget
286 428,83 €

Project overview

Enhancement of capacities of SMEs, public authorities and academia for digitalisation, digital era-fit management and achievement of digital well-being.

The digital transformation offers new opportunities for companies but also increases complexity. Especially employees over 55 can suffer from digital stress or burnout at the workplace. The Digi-B-Well project helps companies to transform and make employees fit for the digital age. The partners upskill competences of managers, public authorities, and academia to better prevent digital stress and burnout. They develop and test new tools to self-assess digital maturity and digital transformation models in companies. In addition, a digitalisation strategy and action plans ensure the uptake of their innovative solutions into broader policy and business practices.





Personalized Approach to Territorial Life and Career Support

Your path begins where you are. Let us help you walk it with purpose.

[Explore the Project](#)



Our Solution

PATHS introduces the **Life Path Support Service (LPSS)** model – a new approach to career guidance that is local, inclusive, and tailored to the individual.

Instead of one-size-fits-all programs, LPSS offers:

- Free, accessible services in small municipalities
- Career workshops, camps, and internships rooted in **self-awareness**
- Trained local **mentors** who provide personal guidance and support
- A long-term strategy for sustainable regional development

This model is being piloted in communities across Hungary, Slovakia, Czech Republic, Romania, Croatia, and Bosnia & Herzegovina – with expert support from Austria and Slovenia.

Project overview

Start date:

01 April 2025

Status: ongoing

End date:

31 March 2028



€2,516,726 budget

80.00 % funded by Interreg Funds

9 countries

13 partners

What did this project achieve?

This project will:

- **Strengthen regions' ability** to deliver smart specialisation in a sustainable way.
- **Develop and test new methods** to move from the Entrepreneurial Discovery Process to the Ongoing Discovery Process.
- **Improve cooperation** between authorities, businesses and researchers.
- **Enable inclusive decisions** and make better use of regional resources.
- **Boost innovation capacity** and strengthen regional competitiveness.
- **Create stronger ecosystems** and new opportunities that benefit both the economy and society.

A few numbers



1,793,584 €
budget



01 May 2025-
31 Jul 2029



12 partners

Project summary

Across Europe, regions face similar challenges. How can we build **innovation systems that endure** – systems that meet today's needs while paving the way for a **sustainable future, economically, socially, and environmentally**?

This project helps **regional authorities and agencies** strengthen **long-term cooperation** around smart specialisation.

Through **practical frameworks and tools**, it supports regions in creating **strong, inclusive networks** with **lasting commitment** from key actors.

The project builds on engagement through the **Entrepreneurial Discovery Process** and other **participatory methods**. This ensures that collaboration is rooted in **real regional needs and ambitions**.

Who we are

Persist brings together nine partners from across Europe – regions, universities, and development agencies working together for smarter, more sustainable regional growth.

- **Region Jönköping County** (Sweden)
- **Podkarpackie Region** (Poland)
- **Regional Development Agency of Khmelnytskyi oblast** (Ukraine)
- **University of Economics in Bratislava** (Slovakia)
- **Ústí Region** (Czech Republic)
- **Regional Management Northern Hessen** (Germany)
- **University of Groningen** (Netherlands)
- **Business Innovation Center of Cartagena** (Spain)
- **Udhëtimit i Lirë** (Albania)

Together, we share knowledge, test new ideas, and build long-term cooperation to strengthen smart specialisation across Europe.



A few numbers



1,617,350 €
budget



01 May 2025-
31 Jul 2029



9 partners

Project summary

Youth involvement is essential in all policy areas that affect their lives, as highlighted in the **EU Youth Strategy 2019–2027**. The project aims to develop **mechanisms and instruments** tailored to young people's needs, supporting the strengthening of their **voice in decision-making**, promoting effective use of resources, and fostering **cross-sector collaboration**.

The project's **innovative character** stems both from its **topic** and the **partnership structure**. The topic is highly relevant, as the gap between **urban strategies** and **youth interests** remains visible in the targeted regions. The partnership unites territories with contrasting demographic realities: some face **low birth rates** and an **ageing population**, while others stand out for having a **large youth population**, which is uncommon in many European areas.

The **overall objective** is to improve policies that enable **active youth participation** in community life and decision-making processes. The project seeks to create an environment where young people feel **valued, empowered, and motivated** to contribute to **societal progress and development**.

This objective will be achieved by:

- **Removing barriers and administrative blockages** that prevent young people from feeling appreciated;
- Encouraging them to **remain in or return to their birthplaces** and engage actively in their communities;
- **Engaging key stakeholders** (public institutions, NGOs, education, and private sector);
- **Transferring knowledge and good practices** from advanced regions to those with fewer youth-oriented solutions;
- Developing **tools and mechanisms** based on the gathered experiences;
- Promoting **social inclusion**, with a focus on **young emigrants** and the **youth diaspora**.

The project will be implemented within the framework of **territorial cooperation** among partner regions, through the **exchange of good practices and experiences** on youth participation.

Pokyny pre autorov

Príspevky prijíma redakcia vedeckého časopisu Ekonomika a manažment a uverejňuje ich v slovenskom, českom alebo anglickom jazyku, výnimočne po dohode s redakciou aj v inom jazyku. Základnou požiadavkou je originalita príspevku.

Redakčná rada odporúča autorom, aby rozsah vedeckých príspevkov nepresiahol 15 normalizovaných strán, príspevky do diskusie, prehľady a konzultácie 10 strán, recenzie a informácie 3 strany.

Zaslaním príspevku do redakcie nevzniká autorovi právny nárok na jeho uverejnenie.

Podmienkou publikovania príspevku sú:

- kladné stanovisko redakčnej rady a nezávislého recenzenta, ktorého určí redakčná rada
- úhrada poplatku vo výške 50,- € na účet vydavateľa (Nadácia Manažér)
- podpísanie Licenčnej zmluvy na dielo.

Autor zodpovedá za právnu a vecnú korektnosť príspevku a súhlasí s formálnymi úpravami redakcie.

Všetky príspevky doručené redakcii časopisu sú anonymne recenzované. Autorské práva vykonáva vydavateľ v súlade s platným autorským zákonom. Použitie celých publikovaných textov alebo ich časti, rozmnožovanie a šírenie akýmkoľvek spôsobom (mechanickým či elektronickým) bez výslovného súhlasu vydavateľa je zakázané.

Za textovú, jazykovú a grafickú úpravu jednotlivých príspevkov zodpovedajú autori.

Príspevky nie sú honorované.

Príspevok až po úprave bude recenzovaný.

Príspevky je potrebné zaslať mailom na adresu výkonného redaktora
katarina.grancicova@euba.sk , miroslav.toth@euba.sk

<https://fpm.euba.sk/veda-a-vyskum/vedecky-casopis/ekonomika-a-manazment>

Šablóna príspevkov a pokyny k formálnej úprave príspevku sú zverejnené na tejto stránke:

Pokyny štruktúra príspevku a formálna úprava príspevku pre časopis FPM Ekonomika a manažment (EaM)

Príspevok časopis EaM FPM v SJ 2021 editovateľný vzor

Contribution editable template for the EaM FPM journal in English language

Redakcia

Instructions for authors

Contributions are accepted by the editors of the scientific journal *Ekonomika a manažment* and published in Slovak, Czech or English, exceptionally in another language by agreement with the editors. The basic requirement is the originality of the paper.

The Editorial Board recommends to the authors that the length of scientific contributions should not exceed 15 standard pages, contributions to the discussion, reviews and consultations 10 pages, reviews and information 3 pages.

Submission of a Contribution to the Editorial Board does not give the author a legal right to its publication.

The following are the conditions for publication:

- a positive opinion of the editorial board and an independent reviewer appointed by the editorial board
- payment of a fee of 50 € to the account of the publisher (Foundation Nadácia Manažér)
- signing of the Licence Agreement for the Contribution.

The author is responsible for the legal and factual correctness of the Contribution and agrees to formal editing by the editorial board.

All Contributions received by the journal editors are anonymously peer-reviewed. Copyright is exercised by the publisher in accordance with applicable copyright law. The use of all or part of the published texts, reproduction and dissemination by any means (mechanical or electronic) without the express permission of the publisher is prohibited.

The authors are responsible for the textual, linguistic and graphic editing of the individual contributions.

We do not pay royalties to authors of contributions.

Only after editing will the paper be peer-reviewed.

Contributions should be sent by email to the Executive Editor at katarina.grancicova@euba.sk , miroslav.toth@euba.sk

<https://fpm.euba.sk/en/science-and-research/scientific-journal/economics-and-management>

A template for submissions and instructions on how to format the paper are posted on this page.

Pokyny štruktúra príspevku a formálna úprava príspevku pre časopis FPM *Ekonomika a manažment* (EaM)

Príspevok časopis EaM FPM v SJ 2021 editovateľný vzor

Contribution editable template for the EaM FPM journal in English language

Editorial Board

EKONOMIKA A MANAŽMENT
Vedecký časopis Fakulty podnikového manažmentu
Ekonomickej univerzity v Bratislave

ECONOMICS AND MANAGEMENT
Scientific Journal of the Faculty of Business Management
Bratislava University of Economics and Business

Ročník XXIII.
Číslo 1
Rok 2026

ISSN 2454-1028