



UNIVERSITATEA DE MEDICINĂ ȘI FARMACIE „CAROL DAVILA”, BUCUREȘTI
ȘCOALA DOCTORALĂ
DOMENIUL MEDICINĂ

***ANALIZA PREDICTIVĂ CA INSTRUMENT ÎN
OPTIMIZAREA ÎNGRIJIRII PACIENȚILOR
METODE ȘI APLICAȚII ALE ȘTIINȚEI DATELOR ÎN SĂNĂTATE***

REZUMATUL TEZEI DE DOCTORAT

Conducător de doctorat:

PROF. UNIV. DR. SEBASTIAN IONESCU

Student-Doctorand:

ANDREEA-MĂDĂLINA ȘERBAN

Cuprins

Terminologie.....	3
1. Introducere și Obiective.....	4
2. Metodologia Cercetării.....	6
3. Rezultate.....	9
4. Concluzii și Contribuții Personale.....	12
Bibliografie Selectivă.....	14
Lucrări Publicate.....	16

Terminologie

AI	Inteligență Artificială (Artificial Intelligence)
AVE	Varianța Extrasă Medie (Average Variance Extracted)
AUC	Aria de sub Curbă (Area Under the Curve)
CYBER	Insecuritate Cibernetică (Cyber Insecurity)
DSE	Autoeficacitate Digitală (Digital Self-Efficacy)
mHealth	Aplicații Mobile de Sănătate (Mobile Health)
ML	Machine Learning
PDP	Grafice de Dependență Parțială (Partial Dependence Plots)
OOB Error	Eroare din Afara Eșantionului (Out-of-bag Error)
PEOU	Ușurința de Folosire Percepută (Perceived Ease of Use)
PU	Utilitatea Percepută (Perceived Usefulness)
RF	Random Forest
RISK	Riscul Perceput (Perceived Risk)
RITAM	Modelul de Acceptare a Tehnologiei Integrat cu Factorul de Risc (Risk-Integrated Technology Acceptance Model)
SHAP	Explicații Aditive de tip Shapley (SHapley Additive Explanations)
TAM	Model de Acceptare a Tehnologiei (Technology Acceptance Model)

1. Introducere și Obiective

În ciuda progreselor continue în domeniul îngrijirii pediatrice, clinicienii se confruntă în continuare cu dificultăți majore în anticiparea evoluției pacienților și în identificarea celor cu cel mai mare risc de evoluție nefavorabilă. Creșterea disponibilității datelor clinice — provenite din dosarele electronice de sănătate, registrele de pacienți și datele generate de pacienți prin aplicații de tip mobile health (mHealth) — oferă oportunități fără precedent pentru îmbunătățirea stratificării riscului, optimizarea traseelor terapeutice și consolidarea îngrijirii centrate pe pacient [1–3]. Analiza predictivă, aflată la intersecția dintre medicina clinică și știința datelor, reprezintă fundamentul metodologic al acestei tranziții majore — de la o evaluare reactivă a riscului, bazată pe semne clinice tardive, la o îngrijire proactivă și personalizată a pacientului.

Pe baza acestor fundamente, integrarea analiticii predictive în sistemul medical marchează o schimbare de paradigmă: de la simpla colectare de date, la aplicarea lor clinică cu impact în plan practic. Valoarea acestor instrumente nu constă doar în capacitatea lor de a genera predicții, ci mai ales în potențialul de a sprijini deciziile clinice în timp real, de a eficientiza fluxurile de lucru și de a îmbunătăți continuitatea îngrijirii medicale. În pediatrie, unde intervențiile realizate la timp pot modifica semnificativ prognosticul, modelele predictive deschid calea de la baze de date medicale complexe la decizii medicale corect documentate [4,5]. Totuși, pentru ca aceste progrese să fie transpuse eficient în practica clinică, dezvoltarea instrumentelor predictive trebuie să se bazeze pe un cadru metodologic riguros, care să asigure fiabilitate, interpretabilitate și încredere atât din partea clinicianului, cât și a pacientului.

Fiecare etapă a procesului de analiză predictivă este esențială pentru atingerea relevanței clinice și a impactului real în practica medicală [5,6]. În acest context, prezenta teză își propune să dezvolte un cadru teoretic și practic solid, care să susțină implementarea instrumentelor de analiză predictivă în domeniul sănătății. Obiectivele cercetării sunt structurate în trei domenii interconectate: colectarea datelor, adoptarea tehnologiilor digitale și dezvoltarea și validarea modelelor de învățare automată (Machine Learning - ML).

În primul rând, în ceea ce privește colectarea datelor, teza stabilește principii pentru asigurarea calității ridicate și a preprocesării adecvate a datelor, elemente fundamentale pentru antrenarea și validarea modelelor de ML. O atenție deosebită este acordată dosarelor electronice de sănătate, registrelor depacienți și platformelor mHealth pentru colectarea structurată a datelor medicale provenind de la pacienți și pentru predicția rezultatelor la populațiile pediatrice [7].

În al doilea rând, în domeniul medicinei comportamentale și al adoptării tehnologiilor digitale, cercetarea analizează factorii care influențează utilizarea instrumentelor digitale de către beneficiarul final, și anume pacientul. Atitudinile utilizatorilor — inclusiv autoeficacitatea digitală și preocupările legate de confidențialitate — se dovedesc a fi determinanți esențiali ai acceptării unei anume soluții tehnologice pentru sănătate [8]. Modelul conceptual propus, Risk-Integrated Technology Adoption Model (RITAM), extins și adaptat contextului medical [9–13], oferă perspective strategice pentru creșterea gradului de adoptare și pentru utilizarea eficientă a datelor colectate în scopuri predictive.

În al treilea rând, în domeniul modelării și validării predictive bazate pe ML, teza demonstrează aplicabilitatea practică a analiticii predictive prin dezvoltarea și validarea unui clasificator Random Forest (RF) pentru predicția mortalității pe termen scurt la pacienții pediatrici supuși intervențiilor chirurgicale, utilizând un set de date extins, multicentric. Interpretabilitatea modelului este asigurată prin utilizarea tehnicilor Partial Dependence Plots (PDPs) și SHapley Additive exPlanations (SHAP), care permit clinicianului să înțeleagă contribuția fiecărui predictor individual la rezultatul final, asigurând transparența decizională și încrederea în predicțiile modelului [14–18].

În ansamblu, această cercetare integrează calitatea datelor, adoptarea tehnologiilor digitale centrate pe utilizator și metode avansate de învățare automată într-un cadru unitar dedicat analiticii predictive în sănătate. Prin combinarea construcției unui cadru teoretic riguros și designului unor instrumente cu aplicabilitate practică, teza oferă direcții concrete pentru îmbunătățirea rezultatelor clinice, susținerea deciziilor medicale bazate pe date și implementarea responsabilă a instrumentelor predictive în practica pediatrică modernă.

2. Metodologia Cercetării

Această teză utilizează o abordare multidisciplinară, integrând pediatria clinică, știința datelor și cercetarea comportamentală, pentru a dezvolta și valida instrumente statistice predictive destinate modelării parametrilor clinici de evoluție a pacienților. Cadrul metodologic general combină analiza retrospectivă a rezultatelor, modelarea comportamentală a adopției tehnologiilor și metode avansate de învățare automată, oferind astfel o punte între generarea de date și aplicarea lor în clinică.

În acest sens, studiile retrospective de audit descrise în Secțiunea 5.1 exemplifică modul în care evaluarea convențională a rezultatelor poate fi transformată prin analitica predictivă. Prin colectarea sistematică a datelor clinice și paraclinice, aceste studii demonstrează potențialul bazelor de date structurate de a ghida modelele predictive și de a sprijini deciziile bazate pe dovezi în îngrijirea pacientului. Standardizate riguros, acestea pot oferi perspective semnificative asupra riscului postoperator și a parametrilor de evoluție a pacienților, punând astfel bazele suportului decizional clinic bazat pe date, ca parte integrantă a medicinei personalizate.

În Secțiunea 5.2, teza avansează printr-un studiu de tip evaluare asupra registrelor pacienților chirurgicali, utilizând cadrul PRISMA pentru identificarea și clasificarea provocărilor metodologice legate de dezvoltarea unor seturi de date de înaltă calitate bazate pe registre. Această abordare a ghidat, de asemenea, selecția registrelor exemplare care ilustrează strategiile optime pentru asigurarea fiabilității, completitudinii și interoperabilității datelor — trăsături esențiale pentru integrarea lor în fluxurile analitice predictive [19]. Rezultatele subliniază faptul că valoarea clinică a modelelor de analiză predictivă depinde fundamental de calitatea și consistența datelor utilizate pentru antrenarea acestora.

Următoarea parte a cercetării se concentrează pe datele de sănătate generate de pacient. În această secțiune prezentăm KIDoc, o platformă mHealth originală creată pentru monitorizarea longitudinală a copiilor cu boli cronice. Ca o sursă de date medical

complementară dosarului electronic al pacientului și registrelor de boală, platformele de colectare de date provenind de la pacienți oferă o perspectivă neîntreruptă, în timp real, în monitorizarea zilnică a pacienților, vizând aderența la tratament și evoluția simptomelor. Această integrare a datelor clinice auto-raportate îmbunătățește rezoluția temporală și permite o înțelegere mai nuanțată a traiectoriilor pacienților, esențială pentru modelarea predictivă în pediatrie, unde degradarea clinică importantă poate surveni foarte precoce unor semne și simptome inițiale.

Capitolul 6 extinde aria metodologică către modelarea comportamentală, abordând provocarea persistentă a adoptării tehnologiilor digitale în sănătate. Prin utilizarea unui RITAM extins, teza identifică principalii determinanți ai intenției pacienților și aparținătorilor acestora de a utiliza soluții mHealth, precum și ponderea relativă a fiecărui factor în procesul decizional. Datele colectate prin sondaje au fost analizate prin Partial Least Squares Structural Equation Modeling (PLS-SEM), metodă aleasă pentru flexibilitatea sa în cazul eșantioanelor mici și eterogene și pentru orientarea sa predictivă. PLS-SEM funcționează printr-un algoritm în două etape: modelul de măsurare, care estimează constructele latente precum gradul de alfabetizare digitală, nivelul perceput de ușurință a folosirii unei anumite tehnologii și preocupările legate de confidențialitate; și modelul structural, care evaluează relațiile cauzale dintre aceste constructe prin analiză de cale (path analysis). Această abordare analitică pune accent pe predicție, fiind adecvată pentru studiul intențiilor comportamentale legate de adoptarea tehnologiilor digitale. Toate analizele din această secțiune au fost efectuate folosind software-ul WarpPLS 8.0.

Capitolul 7 reprezintă o contribuție originală în domeniul științei datelor aplicate chirurgiei pediatrice. Acesta se concentrează pe dezvoltarea și validarea unui algoritm RF pentru predicția mortalității pe termen scurt la pacienții pediatrice cu malformații congenitale gastrointestinale. Utilizarea unui set de date de mari dimensiuni a asigurat atât eterogenitate, cât și robustețe statistică. Preprocesarea datelor a fost un pas critic: valorile lipsă au fost completate folosind metode bazate pe RF (missForest și rfImpute), păstrând dependențele dintre variabile; variabilele categorice și continue au fost codificate și normalizate corespunzător; iar indicatori compuși noi, precum indici de comorbiditate și scoruri de risc perioperator, au fost construiți pentru a spori interpretabilitatea clinică. Având în vedere dezechilibrul numeric între

supraviețuitori și non-supraviețuitori, a fost aplicată o strategie hibridă de resampling și clasificare ponderată pentru a asigura robustețea modelului. Antrenarea și validarea modelului s-au realizat printr-o împărțire stratificată train-test, menținând prevalența rezultatelor. Indicatorii hiperparametrici — inclusiv numărul de arbori, adâncimea maximă și dimensiunea nodului — au fost ajustați prin grid search și estimarea erorii out-of-bag (OOB). Performanța modelului a fost evaluată folosind un set cuprinzător de metrici: acuratețe, sensibilitate, specificitate, F1-score, curbele precizie-rechemare și aria de sub curba ROC (AUC), asigurând atât rigoarea statistică, cât și interpretabilitatea clinică a rezultatelor.

Recunoscând importanța interpretabilității pentru acceptarea clinică, au fost aplicate tehnici model-agnostice de explicabilitate. PDP-urile desenate au ilustrat efectul marginal al predictorilor cheie — precum vârsta gestațională, statusul preoperator și timpul scurs de internare până la intervenție — asupra probabilității de supraviețuire, în timp ce SHAP a cuantificat importanța caracteristicilor la nivel global și individual. Aceste tehnici vizuale aduc aproape predicția algoritmică și raționamentul clinic, permițând clinicianilor să înțeleagă, să evalueze și, astfel, să dobândească încredere în rezultatele modelului.

În ansamblu, teza utilizează un cadru metodologic integrat, care acoperă de la colectarea datelor de înaltă calitate și modelarea adoptării tehnologice, până la învățarea automată avansată și metodele de explicabilitate. Prin alinierea inovației tehnice cu aplicabilitatea clinică, aceasta oferă un model scalabil pentru dezvoltarea de instrumente predictive transparente, fiabile și relevante clinic. Această abordare cuprinzătoare garantează că modelele predictive nu sunt doar robuste din punct de vedere statistic, ci și utilizabile, de încredere și cu impact real în practica medicală curentă.

3. Rezultate

Pornind de la cadrul metodologic multidisciplinar, rezultatele prezentate în această teză demonstrează modul în care analiza predictivă poate fi aplicată eficient la diferite niveluri ale îngrijirii pediatrice. Studiile sunt organizate pentru a reflecta logica secvențială a cercetării: de la evaluarea surselor și calității datelor, la înțelegerea adoptării de către utilizatori a instrumentelor digitale și, în final, la implementarea și validarea modelelor de învățare automată pentru predicția rezultatelor clinice.

Prima componentă a contribuțiilor originale analizează diferitele surse de date clinice care stau la baza algoritmilor de analiză predictivă. Studiile de audit și registrele chirurgicale demonstrează că datele clinice bine structurate pot informa în mod fiabil modelele predictive. Auditurile retrospective identifică factorii de risc relevanți la nivel de pacient și de procedură, în timp ce registrele chirurgicale – îmbunătățite prin protocoale standardizate și gestionare centralizată a datelor – asigură seturi de date multisursă, de înaltă calitate, adecvate pentru aplicații predictive. Platforma originală KIDoc ilustrează, de asemenea, modul în care aceste informații predictive pot fi extinse la copiii cu boli cronice, oferind monitorizare longitudinală în timp real și facilitând predicții care sprijină îngrijirea personalizată și anticipativă. În ansamblu, aceste rezultate subliniază rolul esențial al datelor clinice de calitate în analiza predictivă și potențialul lor de a transforma luarea deciziilor în practica medicală, de a îmbunătăți stratificarea riscului și de a promova un model de îngrijire preventivă, centrat pe pacient.

Pornind de la aceste premise, capitolul 6 abordează dimensiunile comportamentale și tehnologice care determină dacă instrumentele de colectare de date pentru analiză predictivă pot fi adoptate cu succes în practică. Studiul validează un model extins RITAM, oferind perspective empirice asupra modului în care utilizatorii percep și interacționează cu tehnologiile de sănătate mobilă. Modelul de măsurare a demonstrat fiabilitate și validitate excelente, cu valori ale fiabilității compozite între 0,901 și 0,991, alfa Cronbach peste 0,83 și varianță medie extrasă (AVE) peste 0,69 pentru toate constructele, confirmând consistența internă și validitatea

convergentă. Validitatea discriminantă a fost susținută prin analize de corelație, raporturi heterotrait-monotrait sub 0,9 și rădăcini pătrate ale AVE mai mari decât corelațiile inter-construct, iar o valoare standardizată a rădăcinii pătrate a rezidualului mediu pătrat de 0,063 a indicat o potrivire excelentă a modelului [20].

Analizele structurale au confirmat că autoeficacitatea digitală (DSE) prezice puternic percepția asupra ușurinței în utilizare (PEOU), iar preocupările privind securitatea cibernetică (CYBER) prezic semnificativ riscul perceput (RISK), vârsta reprezentând un factor suplimentar semnificativ. Modelul a susținut, de asemenea, că PEOU influențează pozitiv utilitatea percepută (PU) și intenția de utilizare (INT), în timp ce RISK afectează negativ INT. Indicii de potrivire (Tenenhaus 0,703–0,817) și valorile R^2 (PEOU 68,7%, RISK 53,2%, INT 72,9%) indică o putere explicativă substanțială. Analizele diagnostice cu Warp2 și Warp3 au confirmat direcțiile cauzale ipotetizate, fără dovezi care să susțină inversarea între PU și RISK [20]. În ansamblu, aceste rezultate validează modelul conceptual RITAM în contextul sănătății, evidențiind că ușurința în utilizare, beneficiul perceput și percepția riscului sunt determinanți comportamentali cheie pentru adoptarea tehnologiilor.

Capitolul 7 traduce aceste perspective teoretice și comportamentale în aplicații practice de data science, demonstrând valoarea practică a abordărilor de învățare automată pentru predicția parametrilor de evoluție a pacienților. Analiza RF a inclus 3.559 de pacienți pediatrici cu 3.680 de afecțiuni gastrointestinale congenitale, intervenția chirurgicală reprezentând tratamentul principal în 89,6% dintre cazuri. Setul de date a prezentat, tipic pentru o bază de date clinice, un dezechilibru între clase, corectat printr-o strategie hibridă de resampling, pentru a asigura antrenament echilibrat și performanță robustă a modelului. Modelul final a atins 89,3% acuratețe, 89,98% sensibilitate pentru non-supraviețuitori, 84,1% specificitate pentru supraviețuitori, scor F1 de 0,746 și AUC de 0,941, depășind semnificativ performanța de referință fără informație. Performanța modelului a rămas constantă între subtipurile de malformații congenitale și nivelurile de venit [21].

Analiza ponderii fiecăruia dintre parametrii incluși în model a evidențiat predictorii clinici intuitivi pentru mortalitatea la 30 de zile post-intervenție, inclusiv prezența complicațiilor, durata terapiei antibiotice postoperatorii, necesitatea ventilației sau nutriției parenterale, scorul ASA, greutatea pacientului la internare și respectarea protocoalelor de

siguranță chirurgicală, precum și factori sociodemografici precum continentul și nivelul de venit. PDP-urile au evidențiat asocieri neliniare – de exemplu între vârsta gestațională și probabilitatea de supraviețuire – în timp ce analizele SHAP au facilitat înțelegerea predicțiilor la nivel global și individual [21]. Aceste rezultate confirmă capacitatea modelului RF de a genera calculi de risc precise și transparente, sprijinind evaluarea individualizată a riscului și luarea deciziilor clinice bazate pe date în chirurgia pediatrică.

Împreună, rezultatele celor trei componente analizate în teză – calitatea datelor, adoptarea tehnologiei și învățarea automată – conturează un cadru coerent și clinic orientat pentru analiza predictivă în sănătate. Ele demonstrează cum integrarea surselor diverse de date, a factorilor umani și a modelelor de AI explicabilă poate transforma perspectivele predictive în strategii acționabile pentru îmbunătățirea evoluției pacienților pediatrici.

4. Concluzii și Contribuții Personale

Această teză ilustrează valoarea analizei predictive ca instrument esențial pentru îmbunătățirea îngrijirii medicale, prin transformarea datelor complexe, provenind din surse multiple, în informații clinice utile și aplicabile. Prin combinarea unor cadre teoretice solide, inovație metodologică și studii empirice, lucrarea abordează principalele obstacole în aplicarea inteligenței artificiale în practică: colectarea inegală a datelor, înțelegerea limitată a adoptării tehnologiilor și dificultățile de validare a modelelor predictive în context real.

Un rezultat important al cercetării este că seturile de date structurate și de calitate — inclusive dosarele electronice ale pacienților, registrele chirurgicale și platformele mHealth — pot susține modele predictive fiabile, dacă sunt însoțite de măsuri riguroase de control al calității. Auditurile retrospective și registrele atent selectate oferă informații relevante despre factorii de risc ai pacienților, protocoalele de tratament și rezultatele clinice, creând o bază solidă pentru dezvoltarea unor modele predictive precise și relevante din punct de vedere clinic.

În ceea ce privește adoptarea tehnologiei, teza extinde cadrul RITAM și arată că intenția comportamentală de a folosi soluții digitale de sănătate este influențată în special de utilitatea percepută și de ușurința în utilizare, în timp ce riscul perceput, mediat de vulnerabilități cibernetice și de autoeficacitatea digitală, rămâne un obstacol important. Această abordare oferă un cadru validat pentru optimizarea modului în care datele generate de pacienți pot fi colectate și integrate în analiza predictivă.

Pe partea de modelare predictivă, dezvoltarea unui algoritm RF pentru estimarea mortalității pe termen scurt la pacienții pediatrici chirurgicali a demonstrat acuratețe ridicată și relevanță clinică. Predictorii cei mai importanți au fost complicațiile postoperatorii, necesarul de nutriție și ventilație, scorul ASA și respectarea protocoalelor de siguranță. Folosirea tehnicilor de inteligență artificială explicabilă, precum PDP și SHAP, a permis ca modelele să fie transparente și ușor de interpretat de către clinicieni, asigurând astfel că deciziile bazate pe ele sunt fiabile și justificabile.

Contribuțiile personale ale tezei acoperă mai multe dimensiuni: conceptual, metodologic, tehnic și aplicativ. Conceptual, lucrarea leagă cunoștințele teoretice de aplicarea în practică, identificând barierele de adoptare și integrând analiza retrospectivă a rezultatelor cu modelarea predictivă. În plan metodologic, PLS-SEM este folosit pentru a analiza determinanții adoptării tehnologiei. Tehnic, prezenta cercetare implementează și validează un flux de lucru robust de învățare automată adaptat la date din sănătate, incluzând strategii de preprocesare pentru date lipsă și dezechilibre între clase. În plan practic, lucrarea oferă recomandări concrete pentru clinicieni și decidenți privind integrarea analizei predictive în activitatea clinică, demonstrând atât fezabilitatea, cât și impactul acestei abordări.

Privită în ansamblu, teza subliniază rolul esențial al analizei predictive în medicina modernă, arătând drumul de la baze de date complexe la informații utile pentru decizii clinice proactive, personalizate și bazate pe dovezi. Această lucrare contribuie nu doar la avansarea cunoașterii științifice, ci și la îmbunătățirea efectivă a îngrijirii pacienților, făcând legătura între cercetarea AI și practica clinică.

Bibliografie Selectivă

- [1] Structured vs Unstructured Data in Healthcare. TrueNorth ITG 2022. <https://www.truenorthitg.com/healthcare-unstructured-data/> (accessed January 30, 2025).
- [2] Grosman-Rimon L, Li DHY, Collins BE, Wegier P. Can we improve healthcare with centralized management systems, supported by information technology, predictive analytics, and real-time data?: A review. *Medicine (Baltimore)* 2023;102:e35769. <https://doi.org/10.1097/MD.00000000000035769>.
- [3] Van Calster B, Wynants L, Timmerman D, Steyerberg EW, Collins GS. Predictive analytics in health care: how can we know it works? *J Am Med Inform Assoc* 2019;26:1651–4. <https://doi.org/10.1093/jamia/ocz130>.
- [4] Jayatilake SMDAC, Ganegoda GU. Involvement of Machine Learning Tools in Healthcare Decision Making. *J Healthc Eng* 2021;2021:6679512. <https://doi.org/10.1155/2021/6679512>.
- [5] Beam AL, Kohane IS. Big Data and Machine Learning in Health Care. *JAMA* 2018;319:1317–8. <https://doi.org/10.1001/jama.2017.18391>.
- [6] Shickel B, Tighe PJ, Bihorac A, Rashidi P. Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis. *IEEE J Biomed Health Inform* 2018;22:1589–604. <https://doi.org/10.1109/JBHI.2017.2767063>.
- [7] Lee TC, Shah NU, Haack A, Baxter SL. Clinical Implementation of Predictive Models Embedded within Electronic Health Record Systems: A Systematic Review. *Informatics (MDPI)* 2020;7:25. <https://doi.org/10.3390/informatics7030025>.
- [8] Ulfert-Blank A-S, Schmidt I. Assessing digital self-efficacy: Review and scale development. *Computers and Education* 2022;191. <https://doi.org/10.1016/j.compedu.2022.104626>.
- [9] Davis FD. A technology acceptance model for empirically testing new end-user information systems : theory and results, Thesis 1985.
- [10] Davis FD. Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly* 1989;13:319. <https://doi.org/10.2307/249008>.
- [11] Park C-K, Kim H-J, Kim Y-S. A study of factors enhancing smart grid consumer engagement. *Energy Policy* 2014;72:211–8. <https://doi.org/10.1016/j.enpol.2014.03.017>.
- [12] Shapira S, Cauchard JR. Integrating drones in response to public health emergencies: A combined framework to explore technology acceptance. *Front Public Health* 2022;10:1019626. <https://doi.org/10.3389/fpubh.2022.1019626>.
- [13] Alaiad A, Zhou L. The determinants of home healthcare robots adoption: an empirical investigation. *Int J Med Inform* 2014;83:825–40. <https://doi.org/10.1016/j.ijmedinf.2014.07.003>.
- [14] Imrie F, Davis R, van der Schaar M. Multiple stakeholders drive diverse interpretability requirements for machine learning in healthcare. *Nat Mach Intell* 2023;5:824–9. <https://doi.org/10.1038/s42256-023-00698-2>.
- [15] Lundberg SM, Erion GG, Lee S-I. Consistent Individualized Feature Attribution for Tree Ensembles 2019. <https://doi.org/10.48550/arXiv.1802.03888>.
- [16] Lundberg SM, Lee S-I. A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, vol. 30, Curran Associates, Inc.; 2017.

- [17] Ribeiro MT, Singh S, Guestrin C. “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA: ACM; 2016, p. 1135–44. <https://doi.org/10.1145/2939672.2939778>.
- [18] Zhang Y, Song K, Sun Y, Tan S, Udell M. “Why Should You Trust My Explanation?” Understanding Uncertainty in LIME Explanations 2019. <https://doi.org/10.48550/arXiv.1904.12991>.
- [19] Serban AM, Ionescu NS. Surgical patient registries: scoping study of challenges and solutions. *J Public Health Policy* 2023;44:523–34. <https://doi.org/10.1057/s41271-023-00442-5>.
- [20] Serban AM, Druică E. Mobile Technology Adoption in Healthcare—A Behavioral Understanding of Chronic Patients’ Perspective. *Clinics and Practice* 2025;15:181. <https://doi.org/10.3390/clinpract15100181>.
- [21] Serban AM. Short-term mortality prediction in children with gastrointestinal congenital anomalies using a random forest classifier. *Pediatr Res* 2025. <https://doi.org/10.1038/s41390-025-04378-2>.

Lucrări Publicate

Prim Autor

- **Serban AM**, Ionescu NS. [Surgical patient registries: scoping study of challenges and solutions](#). *J Public Health Policy*. 2023 Dec;44(4):523-534. doi: 10.1057/s41271-023-00442-5. Epub 2023 Sep 19. PMID: 37726394 (**Impact Factor 2.7**)
- **Serban AM**, Druica E. [Mobile Technology Adoption in Healthcare – A Behavioral Understanding of Chronic Patients’ Perspective](#). *Clinics and Practice*. 2025; 15(10):181. <https://doi.org/10.3390/clinpract15100181> (**Impact Factor 2.2**)
- **Serban AM**. [Short-term Mortality Prediction in Children with Gastrointestinal Congenital Anomalies using a Random Forest Classifier](#). *Pediatr Res*. 2025 Sep 15. doi: 10.1038/s41390-025-04378-2. PMID: 40954231 (**Impact Factor 3.7**)

Lucrări Publicate

Colaborări Internaționale

- **National Institute for Health and Care Research Global Health Research Unit on Global Surgery.** [Reducing the environmental impact of surgery on a global scale: systematic review and co-prioritization with healthcare workers in 132 countries.](#) Br J Surg. 2023 Jun 12;110(7):804-817. doi: 10.1093/bjs/znad092. Erratum in: Br J Surg. 2023 Nov 9;110(12):1907. doi: 10.1093/bjs/znad317. PMID: 37079880; PMCID: PMC10364528 (**Impact Factor 8.6**).
- NIHR Global Health Unit on Global Surgery; **COVIDSurg Collaborative.** [Elective surgery system strengthening: development, measurement, and validation of the surgical preparedness index across 1632 hospitals in 119 countries.](#) Lancet. 2022 Nov 5;400(10363):1607-1617. doi: 10.1016/S0140-6736(22)01846-3. Epub 2022 Oct 31. PMID: 36328042; PMCID: PMC9621702 (**Impact Factor 202.7**).
- **COVIDSurg Collaborative;** GlobalSurg Collaborative. [SARS-CoV-2 infection and venous thromboembolism after surgery: an international prospective cohort study.](#) Anaesthesia. 2022 Jan;77(1):28-39. doi: 10.1111/anae.15563. Epub 2021 Aug 24. PMID: 34428858; PMCID: PMC8652887 (**Impact Factor 12.9**).
- **Global PaedSurg Research Collaboration.** [Mortality from gastrointestinal congenital anomalies at 264 hospitals in 74 low-income, middle-income, and high-income countries: a multicentre, international, prospective cohort study.](#) Lancet. 2021 Jul 24;398(10297):325-339. doi: 10.1016/S0140-6736(21)00767-4. Epub 2021 Jul 13. PMID: 34270932; PMCID: PMC8314066 (**Impact Factor 202.7**).
- **COVIDSurg Collaborative,** GlobalSurg Collaborative. [SARS-CoV-2 vaccination modelling for safe surgery to save lives: data from an international prospective cohort study.](#) Br J Surg. 2021 Sep 27;108(9):1056-1063. doi: 10.1093/bjs/znab101. PMID: 33761533; PMCID: PMC7995808 (**Impact Factor 11.12**).
- **COVIDSurg Collaborative;** GlobalSurg Collaborative. [Timing of surgery following SARS-CoV-2 infection: an international prospective cohort study.](#) Anaesthesia. 2021 Jun;76(6):748-758. doi: 10.1111/anae.15458. Epub 2021 Mar 9. PMID: 33690889; PMCID: PMC8206995 (**Impact Factor 12.89**).

Prezentări Conferințe

- **Serban AM, Ionescu NS. National Disease Registries in Romania- status and perspectives.** Academia Oamenilor de Știință din România, Conferința Națională 2022.
- Ionescu NS, **Serban AM**, Tirlea S. **Personalized medicine in urinary tract dilatation.** Academia Oamenilor de Știință din România, Conferința Națională 2022.

Premii pentru Cercetare în domeniul Tezei de Doctorat

- **Young Transatlantic Innovation Fellowship 2022** – Departamentul de Stat al Statelor Unite – Cercetare realizată în colaborare cu University of Pennsylvania – Analize statistice avansate privind terapia orală cu insulină pe un model canin – predicția succesului terapiei diabetului.
- **Premiul „Innovators for Children” 2021 – Impact Hub** – pentru proiectul KIDoc, o platformă dedicată colectării și analizei de date pentru copiii cu boli cronice – axată pe identificarea pacienților cu risc crescut și predicția mortalității.
- **Premiul „Young Investigator Award”** – Congresul Internațional al Universității de Medicină și Farmacie „Carol Davila”, 2019 – **Șerban AM**, Spătaru R, Isac G, Ionescu NS. [Prognostic factors of short-term mortality for patients with congenital diaphragmatic hernia.](#)