

Livrabil 2.4. Set de agenți de inteligență artificială integrați în sistemul robotic

Implementarea agenților de inteligența artificială în sistemul de control al robotului RAISE

Considerând că implicarea agenților artificiali în sistemul de control al robotului trebuie să fie limitată și trebuie să fie efectuată ținând cont de siguranța pacienților, s-a luat în considerare implementarea unui sistem care să ajusteze sistemul de control în funcție de progresul pacientului.

Astfel algoritmi de inteligență artificială ar fi implicați atât în prima fază a tratamentului, prin analiza profilului pacientului și recomandarea unui program de tratament personalizat cât și în fazele următoare prin ajustarea continuă a tratamentului (și implicit a sistemului de control) bazată pe progresul pacientului.

În Figura 1 se poate observa reprezentarea schematică a integrării algoritmilor de AI în sistemul de control al robotului Raise.

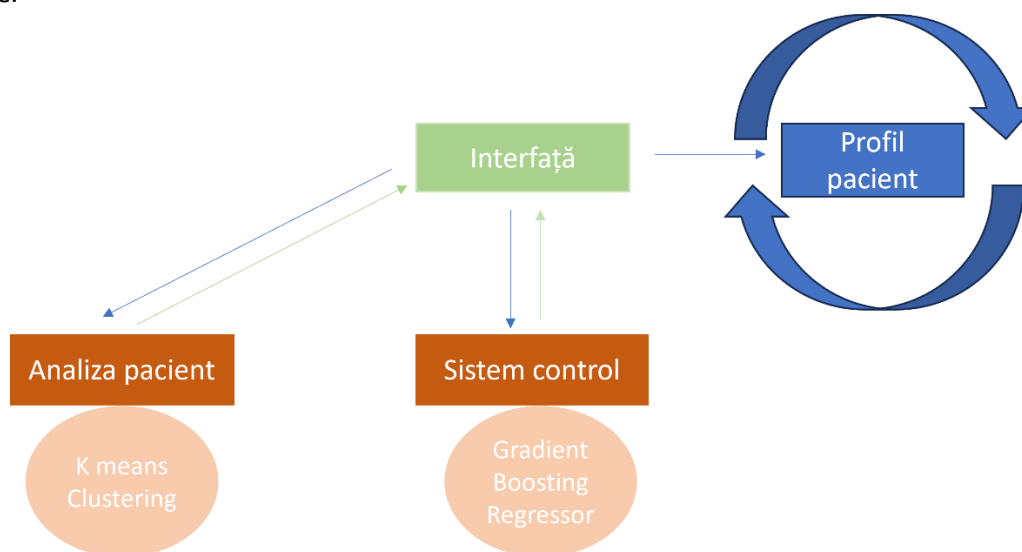


Figura 1. Integrarea algoritmilor AI în sistemul robotului

Interfața robotului Raise oferă posibilitatea introducerii datelor pacientului, facilitând astfel procesul de gestionare a informațiilor relevante pentru procesul de recuperare. După ce informațiile sunt introduse, algoritmul K-means clustering analizează profilul pacientului, comparându-l cu profilele altor pacienți recomandând cel mai potrivit tratament, acesta fiind prezentat doctorului în interfață.

În timpul tratamentului, Gradient Boosting Regressor intervine pentru a ajusta tratamentul în funcție de datele colectate de la motoarele robotului. Acest model de regresie îmbunătățește continuu procesul terapeutic, adaptându-se la evoluția pacientului și asigurând că recomandările de tratament sunt personalizate și eficiente. Astfel, utilizarea algoritmilor avansați de analiză și ajustare contribuie semnificativ la optimizarea procesului de reabilitare, oferind o abordare personalizată și eficientă în îngrijirea pacienților. Analiza progresului pacientului și eventualele ajustări ale tratamentului sunt de asemenea afișate doctorului prin intermediul interfeței.

Aceste sisteme vor fi analizate în continuare, ținând cont atât de particularitățile fiecărui model AI în parte, cât și de metoda de implementare a fiecăruia în interfața robotului.

1. Analiza pacient

1.1 Colectarea datelor

Studiul profilului unui pacient în cazul reabilitării membrului inferior implică evaluarea detaliată a stării sale de sănătate, istoricului medical, funcției musculare, a articulațiilor, a echilibrului și a capacității de mișcare. Mai jos vor fi prezentate caracteristicile considerate importante în procesul de evaluare:

1. Istoric medical:

- Aflarea informațiilor despre afecțiunile medicale anterioare și actuale ale pacientului (incluzând cauza afecțiunii actuale, ex: boli localizate la nivelul sistemului circulator, boli neurologice, artroze etc).

- Identificarea oricăror intervenții chirurgicale anterioare la nivelul membrelor inferioare.
 - Luarea în considerare a altor probleme de sănătate care pot afecta reabilitarea, cum ar fi afecțiuni cardiace sau diabet.
- 2. Evaluarea funcției articulare:**
 - Analizarea flexibilității și a amplitudinii de mișcare la nivelul articulațiilor membrelor inferioare.
 - Identificarea eventualelor rigidități sau contracturi musculare care pot afecta mobilitatea.
 - 3. Forța musculară:**
 - Măsurarea forței musculare în diferite grupuri musculare ale membrelor inferioare.
 - Identificarea eventualelor dezechilibre în forța musculară între diferite grupuri musculare.
 - 4. Evaluarea echilibrului:**
 - Testarea echilibrului în diferite poziții, cum ar fi în picioare sau în mers.
 - Evaluarea coordonării și a controlului motor.
 - 5. Evaluarea capacității de mers:**
 - Analiza modului de mers al pacientului, inclusiv lungimea și simetria pașilor.
 - Identificarea oricăror deficiențe în mers, cum ar fi șchiopătatul sau dificultățile în menținerea echilibrului.
 - 6. Evaluarea durerii:**
 - Obținerea informațiilor despre nivelul de durere resimțit de pacient în timpul mișcărilor sau activităților specifice.
 - Identificarea factorilor care pot agrava sau ameliora durerea.
 - 7. Evaluarea capacității funcționale:**
 - Evaluarea capacității pacientului de a desfășura activități specifice, cum ar fi ridicarea de obiecte, urcarea și coborârea scârilor sau mersul pe distanțe lungi.
 - 8. Evaluarea psihosocială:**
 - Luarea în considerare a factorilor psihosociali care pot influența reabilitarea, cum ar fi suportul social, starea de spirit și motivația pacientului.

1.2 Dezvoltarea modelului de inteligență artificială

Pentru analiza profundă a profilului pacientului și generarea de recomandări personalizate pentru tratament, am ales să implementăm algoritmul K-Means Clusters. Alegerea acestui algoritm se bazează pe capacitățile sale distincte de grupare a datelor, permițând identificarea pattern-urilor și similarităților între pacienți într-un mod automat și non-supervizat.

Un aspect notabil al K-Means Clusters este capacitatea sa de a partitiona setul de date în clustere distincte, astfel încât pacienții cu caracteristici similare să fie grupați împreună. Acest lucru este deosebit de util în contextul medical, unde profilurile pacienților pot varia semnificativ. De exemplu, pacienții cu nevoi similare de tratament sau cu răspunsuri similare la anumite intervenții pot fi identificați în mod eficient și incluși în același cluster.

În Figura 2, se poate observa cum pacienții au fost grupați în clustere distincte pe baza caracteristicilor lor. Fiecare punct reprezintă un pacient, iar culorile diferite indică apartenența la un anumit cluster. În acea figură poate remarca este prezența unui punct care are doar contur, reprezentând un pacient nou sau recent adăugat în sistem. Acest punct nu are o culoare specifică, deoarece încă nu a fost asignat unui cluster.




Figura 2. Schema reprezentativa a algoritmului K- Means

Un avantaj important al K-Means este simplitatea sa și ușurința în implementare. Algoritmul este eficient din punct de vedere computațional, ceea ce îl face potrivit pentru seturi de date de dimensiuni variate. În plus, prin selectarea numărului optim de clustere, putem obține grupuri semnificative și interpretabile de pacienți.

Prin aplicarea K-Means Clusters în analiza profilului pacientului, vom putea să identificăm subgrupurile omogene de pacienți, facilitând astfel personalizarea tratamentelor în funcție de nevoile specifice ale fiecărui grup. Această abordare ne va permite să generăm recomandări mai precise și să optimizăm strategiile de intervenție medicală, contribuind la îmbunătățirea globală a asistenței medicale personalizate.

Antrenarea Modelului

După colectarea datelor, prima etapă crucială este curățarea acestora pentru a asigura calitatea și fiabilitatea informațiilor utilizate în antrenarea algoritmului K-Means. Această etapă implică gestionarea valorilor lipsă, eliminarea duplicatelor și tratarea oricăror inconsistente sau aberații în setul de date. Valorile lipsă pot fi înlocuite cu medii sau mediane, iar datele pot fi normalizate sau scalate pentru a asigura coerența în scala valorilor. Detectarea și eliminarea outlier-ilor sunt, de asemenea, proceduri importante pentru a preveni influența negativă a datelor nereprezentative asupra rezultatelor finale ale algoritmului.

De asemenea, este esențial să se evalueze și să se gestioneze corect variabilele categorice, dacă există, prin aplicarea unor tehnici precum codificarea one-hot sau transformarea acestora în variabile numerice. O atenție specială trebuie acordată și rezolvării eventualelor probleme de coliniaritate sau corelații puternice între caracteristici.

Implementarea algoritmului

Implementarea algoritmului se face conform pașilor de mai jos, reprezentarea grafica a acestui proces aflându-se în Figura 3.




Figura 3. Implementarea algoritmului în analiza pacientului

1. Scopul Specific:

Scopul este de a identifica subgrupuri omogene de pacienți cu caracteristici și răspunsuri similare la tratament. K-Means Clustering va ajuta la gruparea pacienților în clustere astfel încât să poți personaliza tratamentul în funcție de nevoile și profilul fiecărui cluster.

2. Inițializarea Centroizilor:

Se aleg inițial K centroizi, unde K reprezintă numărul de clustere dorite. Acești centroizi reprezintă profiluri medii de pacienți.

3. Atribuirea la Clustere:

Fiecare pacient este asignat celui mai apropiat centru de cluster, măsurând distanța între caracteristicile pacientului și centroizii clustrelor.

4. Recalcularea Centroizilor:

Se recalculează noii centroizi pentru fiecare cluster, reprezentând o imagine actualizată a profilului mediu al pacienților din acel cluster.

5. Reatribuirea la Clustere:

Pacienții sunt reatribuiți la clustere în funcție de noii centroizi, reflectând actualizarea profilului lor în funcție de caracteristicile medii ale clusterului respectiv.

1.3 Atribuirea unui Nou Pacient la un Cluster

Când un nou pacient este introdus în sistem, procesul de atribuire a acestuia la un cluster implică calculul distanței față de centroizii existenți și alegerea celui mai apropiat.

a) Calculul Distanțelor

Se calculează distanța (de obicei, distanța euclidiană) între caracteristicile noului pacient și toți centroizii existenți.

b) Alegerea Celui Mai Apropiat Centru

Se identifică centrul de cluster cel mai apropiat în funcție de distanța calculată.

c) Atribuirea la Cluster

Se atribuie noul pacient la clusterul asociat centrului identificat.

d) Actualizarea Clusterului (Opțional):

Dacă este necesar, se recalculează centrul clusterului asociat pentru a reflecta adăugarea noului pacient.

1.4 Echipamente hardware si software

Pentru implementarea K-Means Clustering în Python, am folosit biblioteca scikit-learn, în special modulul cuML pentru a beneficia de accelerarea pe GPU. Acesta a fost antrenat pe un PC echipat cu o placă grafică NVIDIA RTX A2000, care suportă tehnologii precum CUDA pentru calcule paralele.

Am încărcat datele relevante pentru analiza profilului pacientului, apoi am inițializat și antrenat modelul K-Means folosind scikit-learn cu ajutorul implementării GPU de la cuML. Procesul de antrenare a fost accelerat semnificativ de placa grafică NVIDIA RTX A2000, permițând o eficiență sporită în manipularea și analiza datelor.

După antrenare, am utilizat modelul pentru a atribui noi pacienți la clustere existente și pentru a obține centrozii reprezentativi pentru fiecare grup.

2. Sistem control

2.1 Colectarea datelor

Datele sunt colectate atât de la motoarele dispozitivului de reabilitare, care furnizează informații referitoare la unghiuri, poziții și forțe exercitate, cât și de la senzorii care monitorizează mișcările, presiunea, temperatura și alte aspecte ale comportamentului pacientului. Aceste date variate și cuprinzătoare sunt apoi integrate în procesul de antrenare al algoritmului, furnizând un set complex de informații pentru dezvoltarea unui model de predicție.

A. De la Senzori:

1. Senzori de Mișcare:

- Unghiuri de Flexie și Extensie: Măsurători ale unghiurilor de flexie și extensie ale articulațiilor membrelor inferioare în timpul exercițiilor.
- Accelerare și Decelerare: Date despre accelerația și decelerația mișcărilor membrelor inferioare în timpul tratamentului.

2. Senzori de Presiune:

- Distribuția Presiunii: Măsurarea modului în care presiunea este distribuită pe picior în timpul exercițiilor, util pentru evaluarea distribuției greutateii.

3. Senzori de Forță:

- Forța Exercițată: Măsurarea forței aplicate asupra membrelor inferioare în timpul mișcărilor specifice de reabilitare.

4. Senzori de Temperatură:

- Temperatura Pielii: Măsurători ale temperaturii pielii în zonele relevante pentru tratament.

B. De la Motoare:

1. Unghiuri și Poziții ale Motoarelor:

- Unghiul Articulațiilor: Măsurarea unghiului și poziției motoarelor pentru a evalua traiectoria și amplitudinea mișcărilor.

2. Viteza de Rotație:

- Viteză de Rotație: Date despre cât de rapid se mișcă motoarele în timpul diferitelor faze ale tratamentului.

3. Forța Exercițată de Motoare:

- Forța Progresivă: Măsurarea nivelului de rezistență oferit de motoare în funcție de progresul pacientului.

4. Feedback al Motoarelor:

- Feedback asupra Performanței: Informații despre performanța motoarelor, cum ar fi orice semnale de eroare sau ajustări în timp real.

2.2 Dezvoltarea modelului

Utilizarea algoritmului Gradient Boosting Regressor în procesul de predicție bazat pe datele colectate de la motoare și senzori reprezintă o abordare eficientă pentru evaluarea și îmbunătățirea tratamentului de reabilitare a membrului inferior. Prin integrarea datelor detaliate de la motoare, care furnizează informații despre unghiuri, viteze

și forțe exercitate, precum și datele provenite de la senzori, care acoperă aspecte precum mișcările, presiunea și temperatura, Gradient Boosting Regressor devine un instrument versatil pentru predicții precise.

Acest algoritm este capabil să identifice modele complexe și relații non-liniare între variabilele măsurate și progresul în reabilitare. Prin abordarea adaptativă și iterativă a antrenamentului, algoritmul optimizează predicțiile, ajustându-se la variațiile subtile în date și la schimbările în dinamica progresului pacientului.

Gradient Boosting Regressor excelază în gestionarea datelor zgomotoase și a anomaliilor, furnizând predicții robuste și rezistente la variabilitatea înregistrărilor. De asemenea, permite identificarea și evaluarea importanței diferitelor caracteristici, oferind o înțelegere clară a factorilor cheie care influențează rezultatele tratamentului.

Prin optimizarea parametrilor, gestionarea overfitting-ului și furnizarea de feedback interpretabil, Gradient Boosting Regressor devine un partener esențial în procesul de personalizare a tratamentului. Acesta nu doar prezice progresul, ci și oferă o perspectivă semnificativă asupra influenței variabilelor specifice, contribuind astfel la optimizarea și eficacitatea tratamentului de reabilitare a membrului inferior.

2.3 Implementarea modelului

Gradient Boosting Regressor este un algoritm de învățare supervizată, în special un algoritm de ansamblu, care combină multiple modele mai slabe pentru a crea un model puternic de predicție. Aici sunt pașii cheie în funcționarea acestui algoritm:

1. Construirea unui Arbore de Decizie Simplu (Weak Learner):

Algoritmul începe prin construirea unui prim arbore de decizie simplu, care servește drept model inițial sau "weak learner". Acest arbore de decizie este ajustat pentru a minimiza eroarea pe setul de antrenare.

2. Calcularea Restului (Residual):

Se calculează restul dintre valorile reale și predicțiile făcute de primul arbore de decizie. Acest rest reprezintă diferența dintre predicția inițială și rezultatul dorit.

3. Construirea unui Al Doilea Arbore pentru Rest:

Al doilea arbore de decizie este construit pentru a prezice restul calculat în pasul anterior. În acest fel, modelul încearcă să compenseze erorile făcute de primul arbore.

4. Calcularea Noului Rest și Construirea unui Al Treilea Arbore:

Procesul continuă prin calcularea unui nou rest și construirea unui al treilea arbore pentru a-l prezice. Acest proces se repetă până când un număr predefinit de arbori sunt construiți sau până când o anumită precizie este atinsă.

5. Sumarea Predicțiilor Arborilor:

Predicțiile fiecărui arbore sunt apoi adunate pentru a obține predicția finală a modelului.

6. Optimizarea Prin Regularizare:

Pentru a evita overfitting-ul, Gradient Boosting Regressor utilizează tehnici de regularizare, cum ar fi limitarea adâncimii arborilor și aplicarea unui coeficient de învățare (learning rate) pentru a reduce contribuția fiecărui arbore.

7. Predicții pe Setul de Testare:

După antrenarea modelului pe setul de antrenare, acesta este folosit pentru a face predicții pe setul de testare sau pe datele noi.

Am divizat setul de date într-un set de antrenare și un set de testare folosind funcția `train_test_split` din `sklearn.model_selection`. Am ales modelul Gradient Boosting Regressor pentru a prezice progresul în funcție de datele de intrare. Acest algoritm a fost inițializat cu parametri precum numărul de arbori (`n_estimators`), rata de învățare (`learning_rate`), și adâncimea maximă a arborilor (`max_depth`).

Procesul de antrenare a constat în utilizarea setului de antrenare pentru a ajusta modelul la datele existente. La fiecare iterație, am evaluat performanța modelului pe setul de testare, măsurând Mean Squared Error (MSE) între predicțiile modelului și valorile reale. Acest proces a fost repetat de un număr predefinit de ori.

Prin colectarea predicțiilor la fiecare iterație, am obținut o evoluție a modelului în timp, reflectând modul în care acesta a îmbunătățit precizia predicțiilor. Vizualizarea acestui proces prin graficul cu evoluția predicțiilor ne permite să observăm modul în care modelul se adaptează și îmbunătățește prognozele pe parcursul antrenării, Figura 4.

Prin utilizarea Gradient Boosting Regressor în acest context, modelul poate identifica relații complexe și non-lineare între variabilele măsurate, adaptându-se la schimbările subtile în date și oferind predicții precise asupra progresului în procesul de reabilitare a membrilor inferioare.

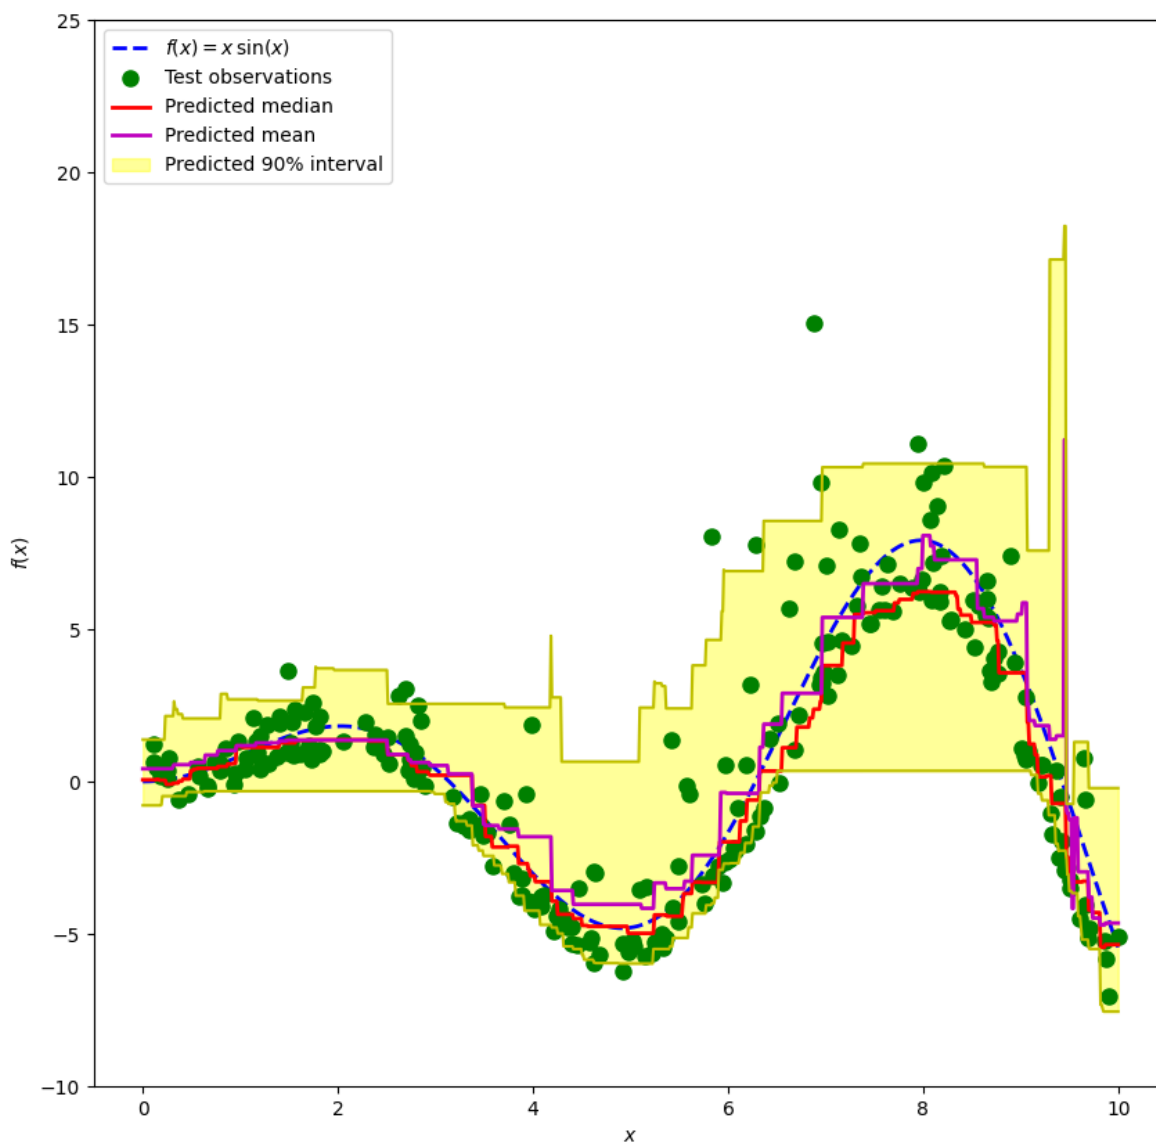


Figura 4. Reprezentarea grafică a procesului de antrenare

În Figura 4, linia punctată albastră reprezintă funcția așteptată ($f(x)=x \cdot \sin(x)$) iar punctele verzi reprezintă datele de test. Modelul de regresie produce două linii principale: cea roșie reprezentând predicția medianei și cea mov reprezentând predicția mediei. Intervalul de 90% pentru predicții este evidențiat printr-o bandă galbenă înconjurând ambele linii de predicție. Această reprezentare vizuală permite evaluarea performanței modelului în capturarea distribuției datelor și furnizează informații despre incertitudinea predicțiilor realizate de model.

Pe baza acestor predicții obținute prin modelul de regresie, se pot face sugestii pertinente pentru îmbunătățirea tratamentului în contextul reabilitării membrilor inferioare. Predicțiile pentru mediană și medie ar putea indica

direcția generală a progresului pacientului, în timp ce intervalul de 90% pentru predicții oferă o măsură a incertitudinii asociate cu aceste estimări. Aceste informații personalizate ar putea fi utilizate pentru a monitoriza schimbările în timp, identificând perioadele de progres semnificativ sau, dimpotrivă, recunoașterea momentelor în care poate fi necesară ajustarea tratamentului.

De asemenea, analiza constantă a datelor în timp ar putea permite identificarea unor modele sau tendințe specifice pentru pacientul respectiv. De exemplu, dacă se observă o variație semnificativă în rezultatele tratamentului în anumite perioade, acest lucru ar putea indica necesitatea adaptării strategiilor de intervenție sau implementarea unor tehnici specifice pentru a maximiza progresul.

Dacă modelul de regresie furnizează indicații clare asupra momentelor sau situațiilor în care progresul pacientului este maxim sau minim, medicii pot adapta planurile de tratament pentru a profita de aceste perioade propice sau pentru a depăși eventualele obstacole. Acest lucru ar putea include modificarea intensității exercițiilor, ajustarea tipurilor de intervenții sau introducerea unor tehnici noi și personalizate pentru a aborda nevoile specifice ale pacientului.

De exemplu, dacă modelul indică că pacientul înregistrează progrese semnificative în anumite contexte sau în anumite intervale de timp, terapeutul ar putea decide să concentreze eforturile pe acele aspecte sau să adapteze exercițiile pentru a stimula continuarea îmbunătățirilor. Pe de altă parte, în cazul în care modelul indică o posibilă stagnare sau o rată scăzută de progres în anumite condiții, terapeutul poate interveni prin schimbarea strategiilor sau adăugarea de elemente noi pentru a revigora evoluția pacientului.

Prof. dr. ing. Calin VAIDA

