

Rezumat teză doctorat

Aplicații ale inteligenței artificiale în endoscopia digestivă

Doctorand: Ioanovici Andrei-Constantin

Conducător doctorat: prof. univ. dr. Dobru Daniela

Introducere

Endoscopia digestivă inferioară este standardul de aur pentru screening și diagnostic în cancerul colorectal, al treilea cel mai frecvent tip de cancer la nivel mondial, însă se estimează că aproximativ 26% dintre adenoame pot fi omise în cadrul procedurii. Sisteme bazate pe inteligența artificială pot îmbunătăți o serie de indicatori de performanță, precum rata de detecție a adenoamelor, însă progresele depind de seturi de date suficiente, heterogene și bine adnotate. Datele medicale sunt adesea în formă nestructurată, iar dezvoltarea de metode de a extrage și structura aceste date sunt necesare unei profilări mai complexe a pacienților și de a dezvolta strategii de management particularizat și eficient.

Obiective

Teza explorează dacă datele sintetice și datele pseudosintetice (concept nou introdus în lucrare) pot crește performanța și generalizarea modelelor de inteligență artificială în două direcții complementare (imagini și text).

Primul studiu introduce conceptul de imagini pseudosintetice, ca extindere a metodelor tradiționale de augmentare adaptată specific colonoscopiei. Imaginile colonoscopice reale au fost supuse unor transformări controlate, pentru a reproduce variabilitatea întâlnită în practica endoscopică, cu menținerea trasabilității la sursa inițială. Acest tip de date a fost utilizat împreună cu imagini reale și imagini sintetice (obținute prin GAN și DDPM) în antrenarea modelelor IA de detecție a polipilor, iar performanța a fost evaluată prin validare externă pe un set de imagini reale neexpuse anterior modelelor.

Al doilea studiu a evaluat realismul clinic al imaginilor pseudosintetice și sintetice printr-un chestionar adresat medicilor gastroenterologi (specialiști/primari și rezidenți).

A treia lucrare a avut ca obiectiv dezvoltarea de modele IA pentru procesarea limbajului natural, folosind seturi de date text reale și sintetice (rapoarte endoscopice), compararea acestor modele și evaluarea potențialului de extragere a informațiilor clinice utile în vederea integrării într-un sistem multimodal inteligent de management al pacienților.

Rezultate

Studiul 1 (imagini, model U-Net). În cadrul validării interne, antrenarea pe imagini reale și pseudosintetice a depășit experimentele cu o singură sursă de date. În experimentul cu imagini reale și pseudosintetice s-au obținut, pe setul de test, F1 0,8832 (Dice 0,8799; IoU 0,7875), în timp ce combinațiile cu date sintetice au variat între F1 0,775 pentru reale și sintetice (GAN) și F1 0,891/0,914 pentru reale și sintetice (DDPM) la 25k/50k epoci. Folosind toate sursele, modelul a atins F1 0,912 (Dice 0,902; IoU 0,823). În comparația directă a celor două metode de generare sintetice, metoda GAN a înregistrat F1 0,919 (Dice 0,911) comparativ cu metoda de difuzie - F1 0,885 (Dice 0,867). La validarea externă pe CVC-Clinic-DB (612 perechi imagini), s-au obținut: pe date reale F1 0,637 (Dice 0,582; IoU 0,495), pseudosintetice F1 0,750 (Dice 0,743; IoU 0,646), sintetice (GAN) F1 0,494 (Dice 0,109; IoU 0,083) și DDPM 25k/50k/100k F1 0,715/0,768/0,729; pentru combinații, mixul reale și pseudosintetice a obținut F1 0,780 (Dice 0,764; IoU 0,677), reale și sintetice (GAN) F1 0,693, reale, pseudosintetice și sintetice (GAN) F1 0,777, reale, pseudosintetice și sintetice (DDPM 25k) F1 0,751, iar reale, pseudosintetice și sintetice (GAN+DDPM) F1 0,768.

Studiul 2 (realism clinic/perceptual). În chestionarul adresat gastroenterologilor (24 imagini: 8 reale, 8 pseudosintetice, 8 sintetice – GAN/DDPM), acuratețea globală a fost 61,2% (IC 95%: 57,7–64,6%), fără diferențe între rezidenți (62,3%) și specialiști/primari (59,8%; $p=0,54$); κ Fleiss=0,30 (IC 95%: 0,15–0,43). Pe fiecare categorie de imagini, sensibilitatea și precizia au fost: reale 70,7% și 62,2%; pseudosintetice 51,6% și 58,9%; sintetice 61,3% și 62,1%. Imaginile GAN au fost recunoscute ca sintetice în 100% din evaluări (128/128; IC 97,1–100%), în timp ce pentru DDPM recunoașterea ca sintetică a fost 22,7% ($p<0,001$).

Studiul 3 (text, NER în limba română). Pe setul real, ModelR (antrenat pe rapoarte reale) a obținut F1 0,8978, ModelM (mix real+sintetic, 1:1) F1 0,8949, iar ModelS (doar sintetic) F1 0,3326; pe setul sintetic, ModelS/ModelM au atins F1 0,9922, iar ModelR F1 0,4686. La evaluarea globală (set combinat real+sintetic), ModelM a înregistrat F1 0,9425 (Precizie 0,9491; Sensibilitate 0,9348), depășind ModelR (F1 0,6976) și ModelS (F1 0,6404).

Discuții și concluzii

Prezenta teză introduce în premieră conceptul de date pseudosintetice, definite ca imagini colonoscopice reale supuse unor tehnici de augmentare controlată care simulează variabilitatea examinării ca și cum ar proveni din colonoscopii multiple ale aceluiași pacient. Această abordare oferă o cale etică și fezabilă de îmbogățire a seturilor de date, păstrând trasabilitatea la sursa inițială și plauzibilitatea clinică. Datele pseudosintetice răspund unei nevoi specifice endoscopiei: imposibilitatea repetării examinării la același pacient pentru a obține variația necesară antrenării, fără a compromite etica sau siguranța pacientului.

În ansamblu, rezultatele converg către aceeași concluzie: strategia folosind surse mixte (reale, sintetice, pseudosintetice) este o soluție atât în sarcini vizuale (U-Net pentru segmentare), cât și în NLP clinic (NER). Prin reducerea distanței dintre inovația tehnică și impactul clinic, de la mai puține leziuni omise și diagnostic mai bun, până la screening eficient și management personalizat, această teză indică un traseu realist de implementare.