

Hibasűrítés nagy felbontású nyelőcső manometriában géptanulás segítségével

Error filtering in high resolution esophageal manometry using machine learning

Zoltán CZAKO¹, Gheorghe SEBESTYEN², Anca HANGAN³

Számítástechnikai Tanszék, Kolozsvári Műszaki Egyetem, Kolozsvár, Románia
¹zoltan.czako@cs.utcluj.ro, ²gheorghe.sebestyen@cs.utcluj.ro, ³anca.hangan@cs.utcluj.ro

Abstract

In this paper we present a Machine Learning based solution for detecting probe positioning failures in High Resolution Esophageal Manometry images, which can be used before applying the Chicago Classification [1] algorithm, this way maximizing the precision of the esophageal motility diagnosis.

Keywords: probe positioning, high resolution esophageal manometry, machine learning

Kivonat

Ebben a cikkben egy gépi tanuláson alapuló megoldást mutatunk be a szonda pozicionálási hibáinak észlelésére nagy felbontású nyelőcső manometria képeken, amely felhasználható a Chicago osztályozási algoritmus [1] alkalmazása előtt, így maximalizálva a nyelőcső motilitás diagnózisának pontosságát.

Kulcsszavak: szonda pozicionálás, nagy felbontású nyelőcső manometria, gépi tanulás

1. BEVEZETŐ

A nyelőcső egy izmos cső, amely a torok alsó részétől (hypopharynx) a gyomorig nyúlik. Fő funkciója szilárd anyagok és folyadékok szállítása a gyomorba. A nyelőcső csíkos és simaizmainak összetett szinkronizálása lehetővé teszi az élelmiszer szállítását. Problémák akkor jelentkeznek, ha a betegeknek nyelési nehézségeik vannak, vagy gyomor-reflux esetén. Ezek a rendellenességek olyan technikákkal vizsgálhatók, mint a felső gasztrointesztinális (GI) nyelési vizsgálat, az esophagogastroduodenoscopy (EGD), a pH monitorozás és a nyelőcső manometria.

A nagy felbontású nyelőcső manometria (High-Resolution Esophageal Manometry - HRM) a leggyakrabban használt módszer a nyelőcső motilitási zavarainak (Esophageal Motility Disorders - EMD) vizsgálatára, mint például az Achalasia [2], Jackhammer Esophagus [3], stb. A HRM katétert transznazálisan kell behelyezni, és úgy kell elhelyezni, hogy lefedje a nyelőcső teljes hosszát a vizsgálat során. A katéteren 36 körkörös elhelyezett érzékelőt találhatók. Ezen érzékelők hőterkép-szerű képeket állítanak elő, amelyek a nyelés során a nyelőcső izommozgását jelzik.

Mivel a végső diagnózist szakember végzi manuálisan, a katéter elhelyezése befolyásolhatja a szakorvos döntését, például az IRP (Integrated Relaxation Pressure) paramétere érzékeny lehet a katéter mozgására, ezért a katéter pozicionálási hibájának észlelése kritikus a nyelőcső motilitási zavarainak pontos diagnózisa érdekében. Ebben a cikkben egy gépi tanuláson alapuló megoldást mutatunk be a szonda pozicionálási hibáinak észlelésére HRM-képeken, amely felhasználható a Chicago osztályozási algoritmus alkalmazása előtt, így maximalizálva a nyelőcső-motilitás diagnózisának pontosságát.

A cikk többi része a következőképpen van felépítve: a 2. részben néhány érdekes megoldást mutatunk be a HRM képek elemzésére, valamint összehasonlítjuk azokat más hasonló munkákkal, a 3. részben bemutatjuk a szonda pozicionálási hibáinak észlelésére használt algoritmust, a 4. részben a kísérleti eredményeket mutatjuk be, az 5. szakaszban pedig az összefoglalót találhatjuk.

2. KAPCSOLODÓ MUNKÁK

Az automatikus képfeldolgozás gépi tanulás segítségével alkalmazható számos betegség felismeréséhez. Számos cikk található az emlőrák osztályozásáról ([4], [5] stb.), az agydaganatok elemzéséről ([6], [7] stb.), a diabéteszes retinopátia osztályozásáról ([8], [9], stb.), vastagbél polipok kimutatására és osztályozására ([10], [11], stb.) stb., de csak néhány cikk foglalkozik a nyelőcső motilitásának diagnosztizálásával vagy a Chicago osztályozási algoritmus automatizálásával.

A [12] cikkben a szerzők fizikai-mechanikai modellt javasoltak a nyelőcső mozgásának és a perisztaltikus nyomáshullám terjedésének bemutatására, figyelembe véve a nyelőcső hosszában a morfometriai, fiziológiai és mechanikai jellemzők heterogén eloszlását. A HRM adatokból a megfelelő modellparaméterek megtalálásának problémáját egy optimalizálási problémává alakították át, ahol a költségfüggvény leírja a HRM adatok és a modellkimenetek közötti különbséget, és a cél ennek az különbségnek a csökkentése.

A [13] cikk szerzői a rendellenes nyelések azonosítása érdekében számos osztályozási módszert vizsgáltak, mint például a mesterséges neurális hálózatokat (ANN - artificial neural networks), a többrétegű perceptront (MLP - multilayer perceptron), a tanulási vektor kvantálást (LVQ - learning vector quantization) és a tartó vektor gépeket (SVM - support vector machines). Minden módszer magas osztályozási pontosságot produkált, az MLP, az SVM és az LVQ 96,44%, 91,03% és 85,39% pontosságot ért el.

A [14] cikkben a szerzők felügyelet nélküli mélytanulási megoldást javasoltak annak érdekében, hogy automatikusan azonosítsanak új jellemzőket és tulajdonságokat a nyelőcső motilitásának diagnosztizálásához. Egy variációs automatikus kódolót (VAE - Variational Autoencoder) képeztek ki annak érdekében, hogy a képeket 7 fő kategóriába csoportosítsák a nyelés típusa alapján, és 3 kategóriába a nyomástípus alapján. A képek csoportosítása után LDA-t (Linear discriminant analysis), majd PCA-t (Principal component analysis) használtak, hogy csökkentsék az adatok méretét, és megtalálják a legfontosabb attribútumokat, amelyek alapján a csoportosítás történt.

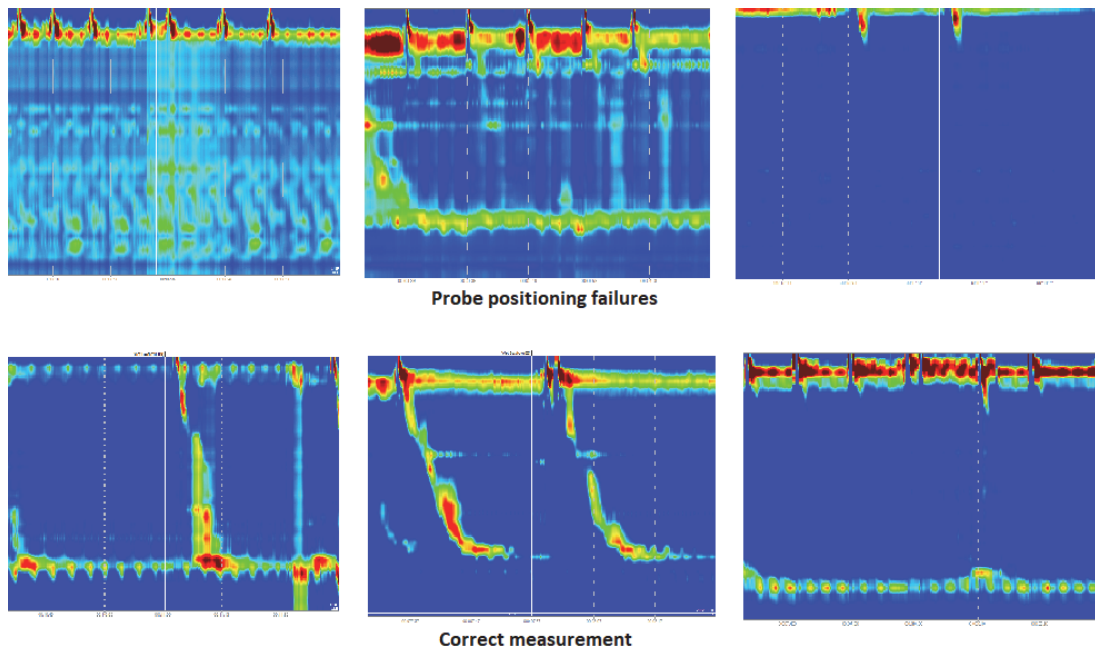
A fent bemutatott megoldásokkal szemben végső célunk a Chicago Classification (CC) algoritmus teljes mértékű automatizálása. Ez azt jelenti, hogy a végső megoldás képes lesz a nyelőcső-rendellenességek osztályozására képek alapján, szakember közreműködése nélkül. Ez a cikk a végső algoritmus első része, és a CC algoritmus alkalmazása előtt az egyik legfontosabb lépésre összpontosít, nevezetesen a szonda pozicionálási hiba észlelésére. A cél az, hogy a HRM képeket két kategóriába, érvényes vagy érvénytelen képek kategóriájába osztályozzuk, ahol az érvénytelen azt jelenti, hogy a katétert nem megfelelően helyezték el.

3. MEGOLDÁS A SZONDA POZICIONÁLÁSI HIBÁINAK ÉSZLELÉSÉRE

3.1 BEMENTI adatok elemzése

Az adathalmazokat a romániai „Iuliu Hațieganu” Orvostudományi és Gyógyszerészeti Egyetem 2.-ik Orvosi Tanszékének orvosai készítették és címkézték fel Kolozsváron.

A szonda pozicionálási hibájának észlelésére szolgáló adatkészlet összesen 2437 képet tartalmaz, amelyekből 2370 kép a normál, helyes pozicionálás kategóriájába tartozik, és csak 67 képen található pozicionálási hibát. Az 1-es ábra példákat mutat be mindkét kategória esetében. Amint ezeken a példákon láthatjuk, néha teljesen nyilvánvaló, hogy a szonda rossz helyzetben van, mert a nyomásértékek szokatlan helyeken magasak, amint azt a bal felső képen láthatjuk. Ebben az esetben az egész képet zöld borítja (zöld szín közepes nyomást jelent), ami azt jelenti, hogy hiba történt a katéter elhelyezésében. Az igazi kihívás az, amikor a hibás képek nagyon hasonlítanak a megfelelő méréseket ábrázoló képekhez. Ezt láthatjuk például a felső-középső kép vagy a jobb felső kép esetében. A gépi tanulás ilyen helyzetekben segíthet a hibák, rendellenességek automatikus azonosításában.




1. ábra. Példák normál és rossz szonda pozícionálásra

3.2 A bemeneti adatok előfeldolgozása


Az eredeti bemeneti képek több információt tartalmaznak, mint amennyi egy mesterséges neurális hálózat képzéséhez szükséges, például a margók nem tartalmaznak hasznos információt, tehát zajnak minősíthetők.

A 2-es ábrán fekete vonalakkal határuztuk el a kép azon részét, amely pontosan egy nyelés pillanatát ábrázolja. Tehát mindegyik képből csak a függőleges fehér vonaltól jobbra eső részt kell megtartsuk.



2. ábra. Egyetlen nyelés pillanata

Ahhoz, hogy automatikusan megtaláljuk pontosan a nyelést határoló fehér függőleges vonalat, először binarizáltuk a képet, ezáltal a 3-as ábrán bemutatott eredményt kaptuk. A következő lépésben a függőleges fehér vonal megkeresése érdekében hisztogramját készítettünk a fehér pontok számával az x tengely minden pontja esetében. Végül azt az x pontot választottuk ki, amely esetén a fehér pontok száma maximális, így megtaláltuk a függőleges fehér vonal x koordinátáját.




3. ábra. Bináris kép

Mivel az osztályozáshoz használt konvolúciós neurális hálózat (CNN) bemeneti alakja $299 \times 299 \times 3$, és -1 és 1 közötti értékekkel működik, az összes képet átméreteztük és normalizáltuk, hogy minden érték a $[-1, 1]$ intervallumban mozogjon. A teljes adatkészletet három részre osztottuk, 70%-ot képzésre használtunk, 15%-ot tesztelésre és 15%-ot a végső model kiértékelésére használtuk.

3.3 Az algoritmus bemutatása

A CNN zéróról való képzése több ezer képet igényelne, viszont nagyon nehéz ilyen nagy mennyiségű címkézett orvosi képet beszerezni. A kis adatok problémájának hatékony megoldása a Transfer Learning vagy transzfer tanulás használata. A transzfer tanulásban a HRM képminősítés problémájának megoldásához kiindulópontként egy másik modellt használtunk, melyet egy másik osztályozási feladatra képezték ki és amelyhez sokkal több címkézett adat állt rendelkezésre. Megoldásunkban az InceptionV3 CNN modellt használtuk, amely az Imagenet adatkészlet segítségével volt előzetesen kiképezve. Az Imagenet adatkészlet körülbelül 1 millió képet és 1000 osztályt tartalmaz.

A 4-es ábra bemutatja az algoritmus lépéseit. Az első lépések között találjuk az előfeldolgozást, amelyet már az előző alfejezetben bemutattunk, majd az átdolgozott adatok segítségével kiképeztünk egy InceptionV3 modellt. Ahoz, hogy az InceptionV3-at a mi problémánkra szabjuk, a modell végéről a teljesen kapcsolt réteget a saját teljesen kapcsolt rétegünkkel helyettesítettük. A modellünket Adam optimalizálóval képeztük ki 32 kép kötegméretet alkalmazva, és az adatokat minden korszakban megkevertük.



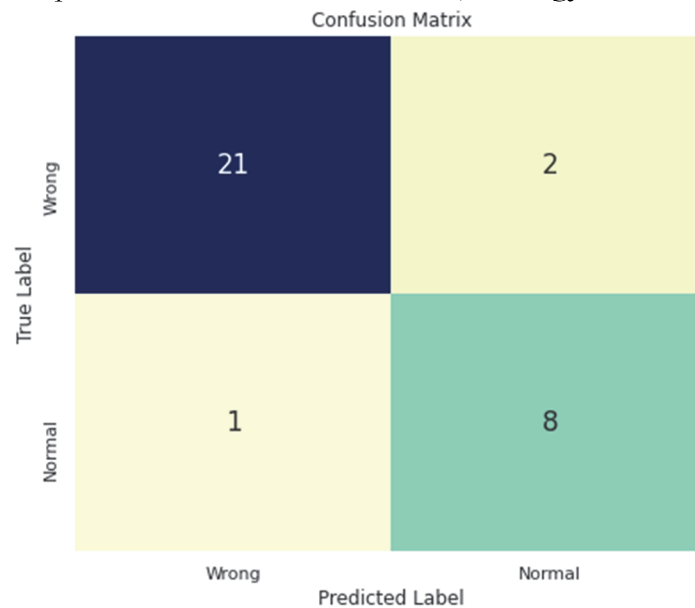
4. ábra. A megoldás lépései

4. KÍSÉRLETI EREDMÉNYEK

Miután előfeldolgoztuk a képek teljes adatkészletét, a CNN modellünket betanítottuk a normál vagy hibás katéter pozicionálási képek osztályozására. A képzett neurális hálózat eredményei nagyon ígéretesek és a következő értékelési pontszámokat érte el:

- **Pontosság:** 90,67%
- **F1-pontszám:** 84,21%

A konfúziós mátrix, amelyet a tesztkészlet alapjá generáltunk, az 5-ös ábrán látható. Amint láthatjuk ebben a mátrixban, a 32 képből csak 3 volt tévesen besorolva, ami nagyszerű eredménynek számít.



5. ábra. Szonda pozicionálási hiba észlelés konfúziós mátrixa

5. KÖVETKEZTETÉSEK

Ebben a cikkben bemutattunk egy megoldást a katéter pozicionálási hibájának automatikus kimutatására nagy felbontású nyelőső manometria esetén. A cikk első részében definiáltuk a nagy felbontású nyelőső manometria fogalmát, és bemutattuk az eljárás lépéseit, a kapott képeket és a vele kimutatható rendellenességeket. A második részben a CNN modellek bemeneti adatainak előkészítéséhez szükséges előfeldolgozási lépéseket ismertettük, majd bemutattuk a végső megoldáshoz vezető lépéseket. A cikk utolsó részében bemutattuk a kísérleti eredményeket. Ezek az eredmények lenyűgözőek, hiszen 90% feletti pontosságot és 84% feletti f1 pontszámot értek el, amely a specialisták számára is igazi kihívást jelent.

Ez a munka csak az első lépése annak a megoldásnak, amely teljes mértékben automatizálja a Chicago klasszifikációs algoritmust, így segítve a kórházakat és az orvosokat a mindennapi munkájukban, csökkentve a költségeket és az ismétlődő feladatokra pazarolt időt.

KÖSZÖNETNYILVÁNÍTÁS

This paper was financially supported by the Project "Entrepreneurial competences and excellence research in doctoral and postdoctoral programs - ANTREDOC", project co-funded by the European Social Fund financing agreement no. 56437/24.07.2019.

IRODALMI HIVATKOZÁSOK

- [1]. Kahrilas P. J., Bredenoord A. J., Fox M., Gyawali C. P., Roman S., Smout A. J., Pandolfino J. E., *The Chicago Classification of esophageal motility disorders, v3.0*. Neurogastroenterol Motility, 2015
- [2]. Lappas B. M., Patel D. A., Vaezi M. F., *An Overview of Achalasia and Its Subtypes*, PubMed, 2017
- [3]. Sirinawasatien A., Sakulthongthawin P., *Manometrically jackhammer esophagus with fluoroscopically/endoscopically distal esophageal spasm: a case report*, BMC Gastroenterology, 2021
- [4]. Wu J., Hicks C., *Breast Cancer Type Classification Using Machine Learning*, PubMed, 2021
- [5]. Amrane M., Oukid S., Gagaoua I., Ensari T., *Breast cancer classification using machine learning*, Bio-medical Engineering's Meeting (EBBT), 2018
- [6]. Irmak E., *Multi-Classification of Brain Tumor MRI Images Using Deep Convolutional Neural Network with Fully Optimized Framework*, Iranian Journal of Science and Technology, Transactions of Electrical Engineering, 2021
- [7]. Khan M. Ashraf A., Alhaisoni I., M., *Multimodal Brain Tumor Classification Using Deep Learning and Robust Feature Selection: A Machine Learning Application for Radiologists*, Diagnostics (Basel, Switzerland), 2020
- [8]. Dai L., Wu L., Li H., *A deep learning system for detecting diabetic retinopathy across the disease spectrum*. Nature Communications 12, 2021
- [9]. Alyoubi L. W., W. Shalash M., Abulkhair M. F., *Diabetic retinopathy detection through deep learning techniques: A review*, Informatics in Medicine Unlocked, 2020
- [10]. Czako Z., Sebestyen G., Hangan A., *Colorectal Image Classification with Transfer Learning and Adaptive Artificial Intelligence Platform*, Trends and Innovations in Information Systems and Technologies, 2020
- [11]. Sánchez-Peralta L. F., Bote-Curiel L., Picón A., Sánchez-Margallo F. M., Pagador J. B., *Deep learning to find colorectal polyps in colonoscopy: A systematic literature review*, Artificial Intelligence in Medicine, 2020
- [12]. Frigo A., Costantini M., C. Fontanella G., Salvador R., Merigliano S., Carniel E. L., *A Procedure for the Automatic Analysis of High-Resolution Manometry Data to Support the Clinical Diagnosis of Esophageal Motility Disorders*, IEEE Transactions on Bio-medical Engineering, 2018
- [13]. Hoffman M. R., Mielens J. D., Omari T. I., Rommel N., Jiang J. J., McCulloch T. M., *Artificial neural network classification of pharyngeal high-resolution manometry with impedance data*, Laryngoscope, 2013
- [14]. Kou W., Carlson D. A., Baumann A. J., Donnan E., Luo Y., Pandolfino J. E., Etemadi M., *A deep-learning-based unsupervised model on esophageal manometry using variational autoencoder*, Artificial Intelligence in Medicine, 2021