

Analýza biomedicínských snímků plic

Jiří Soukup*

Abstrakt

Rakovina plic patří celosvětově mezi jednu z nejčastějších příčin úmrtí. Včasné odhalení přitom představuje jednu z nejlepších cest ke zvýšení naděje dožití. Tato práce se zaměřuje na trénování modelu umělé inteligence, který by mohl sloužit jako pomocný nástroj pro radiology při detekci rakovinných uzlů a odhadu jejich malignity. Testování probíhá na screeningových CT snímcích plic, které poskytují lepší rozlišení než snímky z RTG. Práce přináší poznatky o možnostech použití umělé inteligence při asistenci v diagnostice rakoviny plic. Výstupem je aplikace s implementovaným modelem, která poskytuje rozhraní pro uživatele.

*xsouku17@stud.fit.vut.cz, *Fakulta informačních technologií, Vysoké učení technické v Brně*

1. Motivace

Celosvětově vysoká incidence rakoviny a úmrtnost na ní, jak znázorňuje statistika [\[Obrázek 1\]](#), vedla v mnoha zemích k zavedení screeningových vyšetření pro nejrizikovější skupiny. Obdobný program je zaveden také v České republice [\[1\]](#). Spuštění plošného screeningu však zároveň vede k vyšší zátěži radiologů, kteří musí dané snímky vyhodnocovat. Tento nárůst požadavků na diagnostiku vytváří prostor pro využití podpůrných nástrojů založených na umělé inteligenci, které mohou lékařům pomoci včas a přesně identifikovat podezřelé nálezy.

2. Úvod do problematiky

Jedním z průvodních znaků rakoviny plic mohou být plicní uzly. Tyto útvary zpravidla dosahují velikosti v průměru do 3 cm. Vzhledem k velikosti plicní tkáně se tedy jedná o relativně malé oblasti. Na základě těchto vlastností je v praxi pro vyšetření využíváno nízkodávkové CT, pokud to situace umožňuje [\[2\]](#).

Hlavní výzvy v oblasti podpůrných nástrojů diagnostiky pomocí umělé inteligence představuje dostupnost dostatečného množství vhodně anotovaných dat. V praxi se mohou lišit také anotace na stejném datasetu provedené více odborníky.

3. Existující řešení

V definované oblasti existuje několik řešení, která se zaměřují na různé přístupy k dané problematice, přičemž nejčastěji používanou architekturou jsou konvoluční neuronové sítě. Výčet některých těchto řešení je včetně krátké charakteristiky uveden níže:

- **Nodule Detection** – detektor plicních uzlů založený na RTG snímcích hrudníku zaměřený na porovnání vhodnosti jednotlivých modelů pro tento úkol [\[3\]](#),
- **YOLO-Lung** – detektor plicních uzlů z 2D CT řezů, zaměřený na velmi malé uzly a jejich odhalení [\[4\]](#),
- **C-Lung-RADS** – komplexní klasifikátor CT řezů a jejich kombinací propojující informace ze snímků s diagnostickými záznamy z lékařských zpráv [\[5\]](#).

Nevýhody stávajících řešení spočívají nejčastěji v chybějící klasifikaci nebo nepropojení procesu detekce s klasifikací.

4. Implementované řešení

Navrhované řešení propojuje detekci a klasifikaci uzlů do jednoho kroku. Za tímto účelem byl využit transformerový model RT-DETR skrze API Ultralytics [\[6\]](#).

Proces byl založen na zpracování CT řezů, kdy pro trénink a jeho validaci byl použit dataset s anotací do systému Lung-RADS [\[7\]](#). Tento systém poskytuje

oporu pro určování tříd s pravděpodobností malignity na základě vizuálních vlastností a informací z anamnézy [8].

Dosažené výsledky byly porovnány se souběžně trénovaným modelem YOLOv11 [9] se zaměřením na hodnotu falešné negativy (FN). Při porovnání vychází přesněji hodnoty pro použitý model RT-DETR, konkrétně 5,5 % vůči 17,2 % v případě modelu YOLO.

Výsledný model byl implementován do aplikačního rozhraní, které poskytuje oporu pro využití v reálném prostředí.

V rámci práce byly prováděny také pokusy s využitím 3D přístupu a provázáním informací uložených v jednotlivých řezech mezi sebou. Na základě kombinace posloupnosti řezů vytvářejících 3D objem byly prováděny pokusy klasifikační a detekční/segmentační. Klasifikace byla zaměřena na rozlišení pěti tříd pravděpodobnosti malignity vycházejících z použitého datasetu LIDC-IDRI [10]. Klasifikace v této oblasti byla průkazná pouze po redukci počtu tříd na dvě (benigní/maligní). Tento stav byl dosažen sjednocením původních tříd jedna a dva do třídy benigní. Třída maligní byla vytvořena obdobným způsobem z původních tříd čtyři a pět. Segmentace probíhala pomocí modelu SwinUNETR z knihovny MONAI [11] bylo pro účely detekce plicních uzlů dosaženo hodnoty FN rovné 11 % na kontrolních datech. Ukázka výstupu pro konkrétní řez je znázorněna v sekci [Obrázek 3](#).

5. Přínos práce

V rámci práce byl natrénován model na detekci plicních uzlů a jejich klasifikaci v rámci systému Lung-RADS. Tento model je implementován do aplikace, která poskytuje uživatelské rozhraní pro zlepšení praktického využití. Součástí výstupu hodnocení daných snímků je kromě vizuálních zobrazení podezřelých lokalit, příklad takového výstupu je uveden v sekci [Obrázek 2](#), také doporučení dalšího postupu na základě přiřazené třídy ve zmíněném systému.

6. Závěr

Při porovnání výsledků jednotlivých metod použitých v práci bylo dosaženo nejlepších výsledků pomocí modelu RT-DETR. Tento model byl následně implementován do aplikačního rozhraní. Postup inference v aplikaci je znázorněn v sekci [Diagram 1](#).

Další možnosti rozvoje představuje propojení 2D a 3D přístupu za účelem zkvalitnění predikce. Případnou další možností vývoje může být využití diagnostických

textových zpráv pro zpřesnění určeného rizika nalezených uzlů. K tomuto ovšem je zapotřebí také vytvoření odpovídajícího datasetu.

Autor práce oceňuje National Cancer Institute a Foundation for the National Institutes of Health a jejich zásadní roli při vytváření bezplatné veřejně dostupné databáze LIDC-IDRI použité v této studii.

Poděkování

Rád bych poděkoval mému vedoucímu Ing. Tomášovi Goldmannovi Ph.D. za pomoc a vedení během tvorby práce. Dále bych chtěl poděkovat všem lékařským pracovníkům, kteří se podíleli na výzkumu a poskytli cenné rady a zpětnou vazbu, jež mi pomohly vylepšit a zdokonalit výsledky této práce. Zároveň bych rád poděkoval rodině a přítelkyni za neutuchající podporu, která mi umožnila pokračovat v dokončení této práce. Jejich trpělivost, povzbuzení a porozumění byly pro mě neocenitelné. Bez jejich pomoci by tento projekt nebyl možný.

Reference

- [1] O. Májek, M. Koziar Vašáková, I. Čierna Petrová, H. Mírka, M. Koudelková, O. Ngo, J. Gregor, L. Dušek, and K. Hejduk. *Prevenceplice.cz – program časného záchytu karcinomu plic*. online, 2022. Praha: Ústav zdravotnických informací a statistiky ČR, verze 1.0, [cit. 2025-04-22].
- [2] A. Cruickshank, G. Stieler, and F. Ameer. Evaluation of the solitary pulmonary nodule. *Internal Medicine Journal*, 49, 2019.
- [3] Finn Behrendt, Marcel Bengs, Debayan Bhattacharya, Julia Krüger, Roland Opfer, and Alexander Schlaefer. A systematic approach to deep learning-based nodule detection in chest radiographs. *Scientific Reports*, 13(1), Jun 2023.
- [4] Sen Mei, HuiQin Jiang, and Ling Ma. Yolo-lung: A practical detector based on improved yolov4 for pulmonary nodule detection. In *2021 14th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, pages 1–6, 2021.
- [5] Chengdi Wang, Jun Shao, Yichu He, Jiaojiao Wu, Xingting Liu, Liuqing Yang, Ying Wei, Xiang Sean Zhou, Yiqiang Zhan, Feng Shi, and et al. Data-driven risk stratification and precision management of pulmonary nodules detected on

chest computed tomography. *Nature Medicine*, Sep 2024.

- [6] Wenyu Lv, Yian Zhao, Qinyao Chang, Kui Huang, Guanzhong Wang, and Yi Liu. Rtdetr2: All-in-one detection transformer beats yolo and dino, 2024.
- [7] Diana Nam, Alexandra Panina, and Alexandr Pak. Lung cancer segmentation dataset with lung-rads class, 2024.
- [8] Jared Christensen, Ashley Elizabeth Prosper, Carol C. Wu, Jonathan Chung, Elizabeth Lee, Brett Elicker, Andetta R. Hunsaker, Milena Petranovic, Kim L. Sandler, Brendon Stiles, and et al. Acr lung-rads v2022: Assessment categories and management recommendations. *Journal of the American College of Radiology*, 21(3):473–488, Mar 2024.
- [9] Glenn Jocher and Jing Qiu. Ultralytics yolo11, 2024.
- [10] S. G. Armato III, G. McLennan, L. Bidaut, M. F. McNitt-Gray, C. R. Meyer, A. P. Reeves, B. Zhao, D. R. Aberle, C. I. Henschke, and E. A. et al. Hoffman. Data from lidc-idri [data set]. The Cancer Imaging Archive, 2015.
- [11] MONAI Consortium. swin_unetr – monai 1.3.0 documentation, 2023. Accessed: 2025-03-14.