


UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



# DETEKCIA NÁDOROV PROSTATY V MR SNÍMKACH

Diplomová práca

2022

Bc. Dáša Keszeghová

UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



# DETEKCIA NÁDOROV PROSTATY V MR SNÍMKACH

Diplomová práca

Študijný program: Aplikovaná informatika  
Študijný odbor: 2511 Aplikovaná informatika  
Školiace pracovisko: Katedra aplikovanej informatiky  
Školiteľ: RNDr. Zuzana Černeková, PhD.

Bratislava, 2022

Bc. Dáša Keszeghová



Univerzita Komenského v Bratislave  
Fakulta matematiky, fyziky a informatiky

---

## ZADANIE ZÁVEREČNEJ PRÁCE

**Meno a priezvisko študenta:** Bc. Dáša Keszeghová  
**Študijný program:** aplikovaná informatika (Jednoodborové štúdium, magisterský II. st., denná forma)  
**Študijný odbor:** informatika  
**Typ záverečnej práce:** diplomová  
**Jazyk záverečnej práce:** slovenský  
**Sekundárny jazyk:** anglický

**Názov:** Detekcia nádorov prostaty v MR snímkach  
*Prostate tumor detection in MR images*

**Anotácia:** Detegovať nádory prostaty z multiparametrického MR vyšetrenia metódou neurónových sietí. Naštudovať problematiku spracovania medicínskych dát pomocou neurónových sietí. Analyzovať existujúce riešenia publikované v dostupnej odbornej literatúre. Navrhnuť sieť vhodnú na detekciu tumorov prostaty v MR snímkach. Túto sieť otestovať a vyhodnotiť výsledky.

**Cieľ:** Detegovať nádory prostaty z multiparametrického MR vyšetrenia metódou neurónových sietí. Naštudovať problematiku spracovania medicínskych dát pomocou neurónových sietí. Analyzovať existujúce riešenia publikované v dostupnej odbornej literatúre. Navrhnuť sieť vhodnú na detekciu tumorov prostaty v MR snímkach. Túto sieť otestovať a vyhodnotiť výsledky.

**Vedúci:** RNDr. Zuzana Černeková, PhD.  
**Katedra:** FMFI.KAI - Katedra aplikovanej informatiky  
**Vedúci katedry:** prof. Ing. Igor Farkaš, Dr.  
**Dátum zadania:** 30.09.2020

**Dátum schválenia:** 08.10.2020

prof. RNDr. Roman Ďurikovič, PhD.  
garant študijného programu

.....  
študent

.....  
vedúci práce



# Pod'akovanie

# Abstrakt

Klíčové slová:

# Abstract

Keywords:

# Obsah

Úvod	1
<b>1 Medicínska terminológia</b>	<b>3</b>
1.1 Medicínska terminológia . . . . .	3
1.2 MRI snímky . . . . .	4
<b>2 Konvolučné neurónové siete</b>	<b>7</b>
2.1 Typy vrstiev . . . . .	9
2.1.1 Konvolučná vrstva . . . . .	9
2.1.2 Poolingová vrstva . . . . .	11
2.1.3 Plne prepojená vrstva . . . . .	12
2.2 Aktivačné funkcie . . . . .	12
2.3 U-Net . . . . .	13
2.3.1 Model siete . . . . .	14
2.4 Stratové funkcie . . . . .	15
2.5 Matica zámen . . . . .	16
<b>3 Prehľad problematiky</b>	<b>19</b>
<b>4 Návrh riešenia</b>	<b>20</b>
4.1 Dataset . . . . .	20



<i>OBSAH</i>	ix
4.2 Návrh siete . . . . .	21
4.3 Detekcia prostaty . . . . .	21
4.4 Detekcia nádorov . . . . .	21
<b>5 Implementácia</b>	<b>22</b>
5.1 Model . . . . .	22
5.2 Trénovanie . . . . .	22
<b>6 Výsledky</b>	<b>23</b>
6.1 Detekcia prostaty . . . . .	23
6.2 Detekcia rakoviny . . . . .	24
<b>Záver</b>	<b>25</b>

# Úvod

Rakovina prostaty je druhý najčastejšie sa vyskytujúci typ rakoviny u mužov. Ešte pred niekoľkými rokmi sa prítomnosť rakoviny zisťovala pomocou biopsie tkaniva, avšak tento prístup bol invazívny a vedela sa preskúmať len malá oblasť. Magnetická rezonancia (MRI) umožňuje hľadať výskyt rakoviny naraz v celej prostate a oproti bipsii sa nezasahuje do ľudského tela.

Po vykonaní magnetickej rezonancie dostávame snímky prostaty, na ktorých doktor lokalizuje prostatu a hľadá prípadné lézie, ktoré môžu predstavovať nádory. Včasný záchytenie rakoviny môže pacientovi zachrániť život. Avšak analýza snímok z magnetickej rezonancie si vyžaduje veľkú precíznosť a je časovo veľmi náročná záležitosť. Keby doktori mali nejaký nástroj, ktorý im uľahčí diagnostiku tak dokážeme vyšetriť viac pacientov a tým pádom aj včas diagnostikovať rakovinu, čo môže viesť k lepšej prognóze liečby.

Cieľom našej práce je pomocou metód strojového učenia vyvinúť nástroj, ktorý zjednoduší prácu lekárom. Nástroj bude schopný po predložení MRI snímok lokalizovať prostatu a prípadne lézie. Dáta, ktoré získame sa vkladajú do softvéru, ktorý uľahčuje lekárom klasifikáciu typu a štádia rakoviny.

Práca je rozdelená do viacerých kapitol, na začiatok si priblížime medicínsky základ, ktorý v práci využívame a technológie s ktorými budeme pracovať. V ďalšej kapitole sa zadefinujeme problémy, ktoré chceme riešiť a pozrieme sa na existujúce riešenia. Potom sa dostávame k časti práce kde

prezentujeme naše navrhované riešenie a použitý dataset. Po popise nášho navrhovaného riešenia sa presunieme k implementácii a interpretácii výsledkov, ktoré sme dosiahli. Na koniec si zhrnieme čo sme v našej práci dosiahli a aký prínos naša práca predstavuje.

# Kapitola 1

## Medicínska terminológia

V tejto kapitole si zavedieme medicínsku terminológiu, popíšeme formát MRI snímok a priblížime si princíp ako MRI snímky vznikajú.

### 1.1 Medicínska terminológia

Prosta je rozdelená na tri hlavné zóny: periférnu, centrálnu a prechodnú. Rakovina sa vo väčšej miere väčšinou nachádza v periférnej zóne. Na klasifikáciu typu rakovina sa používajú rôzne skórovacie systémy podľa toho či bola rakovina klasifikovaná na základe biopsie alebo z MRI snímok.

Z biopsie sa prevažne typ rakoviny určuje pomocou *Gleason score*, ktoré udáva nakoľko sa tkanivo podobá zdravému tkanivo. *Gleason score* sa udáva na stupnici od 1 po 10, pričom až stupeň 6 určuje pravdepodobnosť nízkeho štádia rakoviny a stupeň 10 najvyššiu pravdepodobnosť. Avšak keďže sa stupne od 1 po 5 nepoužívajú tak sa zaviedlo klasifikovanie rakoviny prostaty pomocou *Grade Group*. *Grade Group* má stupne od 1 po 5, pričom stupeň 1 predstavuje malé až veľmi malé riziko rakoviny, stupne 2 a 3 stredné riziko a stupne 4 a 5 vysoké až veľmi vysoké riziko rakoviny.

Typ rakoviny z MRI snímok určujeme pomocou *PI-RADS* skórovania. Pomenovanie je z anglického názvu *Prostate Imaging-Reporting and Data System* a je to špeciálne skórovanie zavedené na vyhodnocovanie nájdených lézií v MRI snímkoch prostaty. Skórovanie má 5 stupňom, a každý stupeň určuje ako klinicky významná rakovina môže byť. Stupeň 1 je najnižší a predstavuje veľmi malú pravdepodobnosť, stupeň 2 malú, stupeň 3 stredú, stupeň 4 vysokú a stupeň 5 veľmi vysokú.

## 1.2 MRI snímky


Rakovina prostaty sa najčastejšie analyzuje zo snímok z magnetickej rezonancie. Skrátene sa používa názov MRI, ktorý pochádza z anglického *magnetic resonance imaging*. MRI je sa používa v rádiológii a je to metóda zobrazovania medicínskych snímok o anatómii pacienta bez zásahu do ľudského tela. Magnetická rezonancia sa dá využiť okrem detekcie rakoviny na detekciu opuchu, zápalu, infekcie a mnoho ďalších chorôb. Dôležitým faktorom čo je základom pre správny výstup zo skenovania pacienta, je že pacient musí byť v kľude počas celej doby skenovania čo je nie vždy dosiahnuteľné.

MRI je založené na pôsobení magnetického pola na molekuly vody. Máme dva typy molekúl vody, také ktoré sa zosynchronizujú s pôsobiacim magnetickým polom (molekuly vody s vysokým obsahom energie) a také, na ktoré magnetické pole nemá žiadny vplyv a zostanú vo svojej pozícii (molekuly vody s nízkym obsahom energie). Na začiatok pôsobí na pacienta silne magnetické pole, ktoré rozhybe molekuly vody s vysokým obsahom energie. Zároveň pôsobia na pacienta aj gradienty magnetického poľa, ktoré určujú, na ktorú oblasť prípadne orgán pacienta sa chceme zamerať. Následne sú vyslané rádiové vlny, ktoré rozpohybujú molekuly s nízkym obsahom energie,

donútia ich rezonovať. Tento stav je pozorovaný zobrazovacím zariadením a keď prestanú pôsobiť rádiové vlny tak molekuly s nízkym obsahom energie sa vrátia na svoju pozíciu a vznikne okolo nich voľná energia. Túto energiu v podobe signálu zachytí zobrazovacie zariadenie a vygeneruje sekvenciu snímok. Snímky sú čiernobiele a na snímkach sa výška signálu predstaví buď tmavším alebo bledším odtieňom šedej.

MRI nám poskytuje snímky v rôznych sekvenciách a podľa typu sekvencie sa rakovina môže prejaviť buď ako tmavšia alebo svetlejšia oblasť. Takéto zmeny sú ťažko badateľné pre bežného človeka a dokážu to rozpoznať len vedci, ktorý sa danej problematike venujú. Existuje veľa typov sekvencií, v ktorých môžeme získať snímky z magnetickej rezonancie avšak pre riešenie našej problematiky si uvedieme len tri typy sekvencií.

Prvým typom sekvencie je T2 vážená (budeme označovať T2-weighted) sekvencia, ktorá sa veľmi často používa. Bunky s väčším obsahom vody majú vyšší (svetlejší) signál a častice ako vzduch a kosti majú nižší (tmavší) signál. Ďalšími typmi sú DWI (*Diffusion Weighted Imaging*) sekvencia a ADC mapa (*Apparent diffusion coefficient*). DWI sekvencia využíva rozptyl molekúl vody na generovanie kontrastu v MRI snímkach. ADC mapa taktiež využíva rozptyl molekúl vody len s vyšším kontrastom.



Obr. 1.1: Rôzne typy sekvencie MRI snímkov. Postupne zľava: T2-weighted, ADC mapa a DWI sekvencia (zdroj [MHGS13])

Na obrázku 1.1 môžeme vidieť ak sa nádor zobrazuje na jednotlivých

snímkach. Na T2-weighted sekvencii sa nádor zobrazuje ako tmavšia oblasť na ADC mape ako svetlejšia oblasť a na DWI sekvenciu znovu ako svetlejšia oblasť. Čo je ale dôležité si všimnúť, že ADC mapa a DWI sekvencia odhaľujú ešte jeden nádor, ktorý nie je pozorovateľný na T2-weighted sekvencii, označený prerušovanou šípkou.

Ďalším faktorom, podľa ktorého vieme zadeliť MRI snímky je typ rezu pod, ktorým boli vytvorené. Máme 3 typy: axial, coronal a sagittal. Najpoužívanejším typom je rez axial, ktorý sa sníma horizontálne k stojacemu pacientovi. Rez coronal je braný z vertikálne a postupuje od prednej časti pacienta smerom k pozadiu a rez sagittal je taktiež vertikálny, ale postupuje z ľavej strany pacienta smerom k pravej.

# Kapitola 2

## Konvolučné neurónové siete

V tejto kapitole si priblížime technológie, s ktorými budeme pracovať v našej práci. Taktiež si zdefinujeme odbornú terminológiu, ktorú budeme používať pri interpretovaní výsledkov v našej práci.

Konvolučná neurónová sieť je typ neurónovej siete, ktorá bola vytvorená na spracovanie obrázkov. Dokáže pracovať s 2D aj 3D štruktúrami a tak ako aj ostatné neurónové siete bola inšpirovaná biologickými procesmi, ktoré prebiehajú v ľudskom mozgu. Existuje veľa architektúr v konvolučných neurónových sieťach, medzi najznámejšie patrí AlexNet, ktorá popularizovala konvolučné neurónové siete. Ďalšími známymi architektúrami sú VGGNet a ResNet. Konvolučné neurónové siete pracujú hlavne s obrázkami a práca s obrázkami je výpočtovo náročná. Vďaka grafickým kartám môžeme pracovať s takýmito dátami a vytvárať rôzne modely.

Skôr ako sa pozrieme na konvolučné neuronové siete tak si povieme niečo vo všeobecnosti k neurónovým sieťam. Neurónové siete boli navrhnuté tak aby pripomínali prepojenia neurónov v ľudskom mozgu. Teda keď konkrétny neurón prijme nejaký signál tak ho rozpošle ďalším neurónom. To ako ďalšie neuróny zareagujú súvisí na prepojeniach medzi neurónmi a túto vlastnosť



sa snažíme replikovať v neurónových sieťach. Chceme aby sa siete naučili aký signál majú vysielat' a kam majú signál preposielat'.


Neurón prijme nejaký signál, to bude predstavovať vstup do siete a následne neurón spracuje signál a aplikuje nelineárnu operáciu čo budú u nás predstavovať aktivačné funkcie. Prepojenia medzi vrstvami sú úplne a teda každý neurón na ľubovoľnej vrstve ma prepojenie na každý neurón na predchádzajúcej aj nasledujúcej vrstve. To ako jednotlivé signály vplývajú na neurón z predchádzajúcich vrstiev nám reprezentuje vektor váh.

Viacvrstvový perceptrón je model, ktorý sa snaží túto štruktúru replikovať. Skladá sa z viacerých vrstiev a každá vrstva má vlastné prepojenie na predchádzajúcu a nasledujúcu vrstvu.

V konvolučnej neurónovej sieti je neurón zoradený do 3 dimenzií: šírka, výška a hĺbka. Hĺbka vstupu je daná formátom obrázku, napríklad pri RGB obrázku bude hĺbka 3. Vnútri sieti hĺbka reprezentuje počty filtrov, ktoré sme na tej ktorej vrstve aplikovali. Pri konvolučných neurónových sieťach sa používajú 3 hlavné typy vrstiev: konvolučná vrstva, poolingová vrstva a plne prepojená vrstva. Tieto vrstvy potom tvoria architektúru konvolučnej neurónovej siete. Skôr než si bližšie popíšeme tieto vrstvy tak si zdefinujeme kľúčové pojmy, ktoré budeme používať. Cieľom konvolučných neurónových sietí je sa pomocou operácie konvolúcie naučiť komplikované črty. Architektúra siete sa skladá zo vstupnej vrstvy, niekoľkých skrytých vrstiev, ktoré majú za úlohu extrahovať príznaky a na výstupe máme zväčša plne prepojenú vrstvu, ktorá nám klasifikuje vstup do rôznych tried.

Pri práci s konvolučnými neurónovými sieťami si potrebujeme zdefinovať kľúčové pojmy.

- Kernel/filter - predstavuje okienko veľkosti  $k \times k$ , ktoré aplikujeme na vstup do siete a získavame výsledok. Toto okienko posúvame postupne



Obr. 2.1: Architektúra konvolučnej neurónovej siete (zdroj [JP17])

po celom vstupe.

- Padding alebo vypchávka nám určuje či pred spracovaním vstupu vstup obložíme nulami, padding je dôležitý lebo jeho veľkosť nám hovorí či sa stane s krajnými pixelmi a ako sa zmení dimenzia výstupu oproti vstupu.
- Stride alebo krok nám hovorí o aký krok mám kernel po vstupe posúvať.

## 2.1 Typy vrstiev

### 2.1.1 Konvolučná vrstva

Konvolučná vrstva je najdôležitejší typ vrstvy v konvolučnej neurónovej sieti. Táto vrstva vykonáva operáciu konvolúcie, ktorá z matematického hľadiska reprezentuje matematickú operáciu dvoch funkcií. V neurónovej sieti to predstavuje aplikovanie násobenie matic na časť vstupu s kernelom a získaný výsledok zapísať do výstupu vrstvy. Padding nám povie ako máme pracovať s krajnými pixelmi a stride nám hovorí ak máme kernel posúvať.

Filter je zadaný šírkou a výškou, hĺbka filtru je daná hĺbkou vstupu.

Postupne filter posúvame po vstupe (kovolvujeme) a tak dostaneme výstup. Máme 3 hyperparametre, ktoré ovplyvňujú dimenzie výstupu:

- Hĺbka: predstavuje počet filtrov, ktoré aplikujeme v jedenej vrstve. Každý filter môže byť zodpovený za hľadanie konkrétnej vlastnosti v obrázku (napríklad hrany)
- Stride (alebo posun) vieme, že nám hovorí ako máme posúvať filtre po vstupe. Keď je stride rovný 1 tak sa posúvame po jednom pixeli, keď 2 tak po dvoch. Čím je stride väčší tým viac sa redukuje dimenzia výstupu.
- Padding nám hovorí akú výplň pridávame vstupnému obrázku, najčastejšie sa používajú ako výplň 0, padding veľkosti 1 nám udržiava rovnaký dimenziu výstupu ako mal vstup.

Každý filter sa naučí rozpoznávať inú štruktúru z obrázku, napríklad hrany. Výhodou neurónových sietí je, že štruktúry, ktoré jednotlivé filtre rozpoznávajú sa naučia rozpoznávať siete samé. Najčastejšie sa používajú filtre veľkosti  $3 \times 3$  a  $5 \times 5$ .

Operácia konvolúcie matematicky:

$$\begin{array}{|c|c|c|} \hline a & b & c \\ \hline d & e & f \\ \hline g & h & i \\ \hline \end{array} \times \begin{array}{|c|c|} \hline x & y \\ \hline z & w \\ \hline \end{array} = \begin{array}{|c|c|} \hline A & B \\ \hline C & D \\ \hline \end{array}$$

Pričom:

$$A = (a \times x) + (b \times y) + (d \times z) + (e \times w)$$

Ako vyzerá operácia konvolúcie sa môžeme pozrieť na nasledujúcom príklade. Máme vstup rozmeroch  $5 \times 5$ , nepoužívame padding čiže sa nám dimenzia výstupu zredukuje a stride máme o veľkosti 1. Používame filter o

veľkosti  $3 \times 3$  a postupne násobíme okienka veľkosti  $3 \times 3$  s filtrom. Po aplikovaní konvolúcie na modré okienko zo vstupu a filtru, ktorý môžeme vidieť na obrázku v strede dostaneme číslo čo je označené žltou farbou.

$$\begin{array}{|c|c|c|c|c|} \hline 5 & 4 & 3 & 1 & 2 \\ \hline 6 & 2 & 7 & 9 & 5 \\ \hline 2 & 1 & 0 & 6 & 0 \\ \hline 1 & 5 & 6 & 4 & 2 \\ \hline 3 & 9 & 2 & 7 & 3 \\ \hline \end{array} \times \begin{array}{|c|c|c|} \hline 0 & 3 & 1 \\ \hline 2 & 1 & 0 \\ \hline 1 & 0 & 1 \\ \hline \end{array} = \begin{array}{|c|c|c|} \hline 31 & 28 & 28 \\ \hline 25 & 41 & 46 \\ \hline 15 & 38 & 39 \\ \hline \end{array}$$

### 2.1.2 Poolingová vrstva

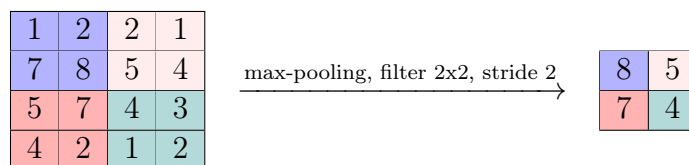
Poolingová vrstva je veľmi dôležitou súčasťou architektúry konvolučnej neurónovej siete. Táto vrstva umožňuje redukovať vnútorné rozmery siete čo vedie k redukcii počtu parametrov a zníženiu náročnosti na výpočet.

Poolingová vrstva si vyžaduje 2 parametre a tými sú veľkosť filtrov a veľkosť kroku (stride), následne je aplikovaná poolingová operácia ktorá nám zredukuje dimenziu pre ďalšiu vrstvu. Najčastejšie sa používa max-poolingová vrstva, ktorá sa pozrie na okienko dané veľkosťou filtru a vyberie najväčšiu hodnotu. Ďalším typom je napríklad average-poolingová vrstva, ktorá vyberá priemer z okienka.

Čo sa týka zmeny rozmerov siete, tak si to vieme matematicky zapísať. Poolingová vrstva dostáva na vstupe 3 rozmery: šírku, výšku a hĺbku. Označme si ich postupne  $W_1$ ,  $H_1$  a  $D_1$ . A poolingová vrstva má dva parametre filter o veľkosti  $F$  a stride  $S$ . Potom na výstupe vráti rozmery  $W_2 \times H_2 \times D_2$ , pričom jednotlivé parametre vieme vypočítať nasledovne:

$$W_2 = \frac{(W_1 - F)}{S} + 1 \quad H_2 = \frac{(H_1 - F)}{S} + 1 \quad D_2 = D_1$$

Ako vyzerá poolingová operácia si ukážeme na nasledujúcom obrázku:



Aplikovali sme filter veľkosti 2 s kormom 2, príslušné okná, ktoré sme analyzovali sú znázornené farebne. Po aplikovaní max-pooling sme dostali výsledok rozmeru 2x2, ktorý môžeme vidieť vpravo.

Najčastejšie používané poolingové vrstvy sú s filtrom veľkosti 3 a stridom 2 alebo s filtrom veľkosti 2 s stridom 2, takýto typ sme použili aj v príklade.

### 2.1.3 Plne prepojená vrstva

Neuróny v plne prepojenej vrstve majú spojenie na každú aktiváciu z predošlej vrstvy, tým pádom ich aktivácie vedia byť vypočítané maticovým násobením. Plne prepojené vrstvy sa zväčša používajú vrstve dokážu nám predpovedať pre každú triedu jej skóre. Známym datasetom je napríklad CIFAR-10 a plne prepojená vrstva na poslednej vrstve nám vie pre každú triedu predpovedať s akou pravdepodobnosťou tam vstup patrí.

## 2.2 Aktivačné funkcie

Aktivačné funkcie sú nevyhnutnou súčasťou vrstiev v neurónových sieťach, hovoria nám ako sa neurón zobrazí na výstupe podľa vstupu, ktorý dostane. Do modelu nám pridávajú nelinearitu, po vynásobení vstupu s filtrom, aplikujeme na výsledok násobenia aktivačnú funkcia a dostávame výstup. Existuje veľmi veľa aktivačných funkcií a každá má svoju jedinečnú funkcionality.

- Softmax:

$$\frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}} \text{ pre } i = 1, \dots, J$$

- Sigmoid:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

- Rectified linear unit (ReLU):

$$\max(0, x)$$

- Hyperbolický tangens (tanh):

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

- Exponential linear unit (ELU) s parametrom  $\alpha$ :


$$\begin{cases} \alpha(e^x - 1) & \text{ak } x \leq 0 \\ x & \text{ak } x > 0 \end{cases}$$

## 2.3 U-Net

U-Net je konvolučná neurónová sieť, ktorá bola navrhnutá pracovníkmi z oddelenia informatiky na nemeckej univerzite *University of Freiburg*. Cieľom siete bolo vytvoriť model, ktorý dokáže efektívne využiť aj menšiu vzorku dobre anotovaných dát. Teda dokáže pracovať aj na menšom datasete a dokáže presne lokalizovať nález na vstupnom obrázku. Dimenzia výstupu siete je tým pádom rovnaká ako dimenzia vstupu čo umožňuje lokalizovať presnú pozíciu na vstupe. Takáto vlastnosť je veľmi dobrá pri spracovaní biomedicínskych dát a dokáže veľmi dobre detekovať objekty na biomedicínskych snímkoch.

### 2.3.1 Model siete

Model siete U-Net môžeme vidieť na obrázku 2.2. Sieť sa skladá z 2 častí: zo zužujúcej sa a rozširujúcej sa časti. Zužujúcu sa časť siete môžeme vidieť na ľavej strane obrázku kde sa dimenzie konvolučných vrstiev postupne zmenšujú. Rozširujúcu časť siete môžeme vidieť na pravej časti obrázku, kde sa dimenzie konvolučných zväčšujú až nakoniec dostaneme dimenziu výslednej vrstvy. Z obrázku 2.2 môžeme vidieť prečo sieť dostala charakteristický názov U-Net, lebo jej zužujúca a rozširujúca časť vytvára písmeno “U”.



Obr. 2.2: U-Net: model siete (zdroj [RFB15])

Sieť využíva konvolúciu s kernelom o veľkosti  $3 \times 3$ , nevyužíva padding a teda dimenzia sa po konvolúci zmenší a ako aktivačnú funkciu využíva ReLU. Pri redukování dimenzie je použitá max poolingová vrstva s filterom rozmeru  $2 \times 2$ . V rozširujúcej sa časti siete je použitá up-konvolučná vrstva s filtrom o veľkosti  $2 \times 2$ . Sieť využíva redukciu a expanziu na štyroch úrovniach. Výstup z up-konvolučnej vrstvy sa spája z posledných výstupom z konvolúcie na danej úrovni a tým pádom dostávame viac vstupných kanálov do konvolúcie.

Nakoniec ja na výstup z poslednej konvolúcie s filtrom  $3 \times 3$  aplikovaná konvolúcia s filtrom  $1 \times 1$ , ktorá nám vráti výstup zo siete v podobe segmentačnej mapy, ktoré reprezentuje rozpoznané útvary na vstupnom obrázku.

## 2.4 Stratové funkcie

Stratové funkcie nám slúžia na to aby sme vedeli povedať ako úspešnú je model. Stratové funkcie nám povedia ako sa aktuálny výstup z modelu pre konkrétny vstup líši od požadovaného výstupu. Bez toho aby sme použili stratové funkcie nevieme povedať či model funguje správne a ako dobre sa dokáže učiť. Stratové funkcie nám vracajú nejaké číslo, ktoré sa buď snažíme minimalizovať alebo maximalizovať. Väčšinou sa snažíme toto číslo minimalizovať, teda chceme dosiahnuť aby rozdiel predikovaných parametrov a požadovaných výstupov bol čo najmenší. Existuje veľa stratových funkcií a každá je vhodná na riešenie konkrétneho problému. Uvedieme si tie stratové funkcie, ktoré sú najznámejšie a tie, s ktorými budeme pracovať. Vstup do siete si budeme označovať  $x$ , predikovaný výstup zo siete  $f(x)$  a očakávaný výstup to siete  $y$ .

- Stredná absolútna chyba (Mean absolute error - MAE) - taktiež známa aj ako L1 loss je stratová funkcia, ktorá vyjadruje priemer súčtu absolútnych hodnôt rozdielov medzi očakávaným výstupom modelu a skutočným výstupom z modelu  $\rightarrow \overline{|y - f(x)|}$ .
- Stredná kvadratická chyba (Mean squared error - MSE) - taktiež známa aj ako L2 loss nám vyjadruje priemer súčtu rozdielov druhým mocnín medzi očakávaným a predikovaným výstupom z modelu  $\rightarrow \overline{(y - f(x))^2}$ .
- Maximálna pravdepodobnosť (Maximum likelihood) - stratová funkcia,



ktorá nám vracia také parametre modelu aby sa skutočný výstup siete čo najviac podobal predikovanému.

- Binárna krížová entropia (Binary Cross Entropy Loss) - stratová funkcia, ktorá sa využíva pri klasifikačných problémoch, ktoré majú dve triedy.
- Dice loss - stratová funkcia, ktorá sa využíva hlavne v počítačov videní a hovorí nám o vychádza z Dice koeficientu, ktorý hovorí o podobnosti medzi dvoch obrázkov. Keď si zoberieme 2 obrázky  $X$  a  $Y$  a pozrieme sa na ich pixely, tak to počítame ako ako pomer dvojnásobku prieniku obrázkov ku súčtu dimenzií oboch obrázkov  $\rightarrow \frac{2|X \cap Y|}{|X| + |Y|}$ .

## 2.5 Matica zámen

Matica zámen (z anglického *confusion matrix*) nám pomáha interpretovať úspešnosť modelu. Pomocou nej vieme povedať ako dobre sa náš model učí a ako úspešne predikuje dáta.

Pri učení s učiteľom vieme povedať do akej triedy má výstup modelu spadať. Na základe predikcie modelu vieme vypočítať, ako veľmi sa výstup z modelu líši od požadovaného výstupu z modelu. Pre každý výstup čo vystupuje z modelu poznáme skutočnú triedu, do ktorej má patriť a taktiež poznáme aj triedu, ktorú predikoval model. Na základe týchto údajov vieme vytvoriť maticu, ktorá reprezentuje ako úspešný je model.

Matice obsahuje 4 prvky, ktoré reprezentujú nasledujúce údaje:

- TP (true positive) - model správne predikuje, že vstup spĺňa nejakú charakteristiku

- FN (false negative) - model nesprávne predikuje, že vstup nespĺňa nejakú charakteristiku
- FP (false positive) - model nesprávne predikuje, že vstup spĺňa nejakú charakteristiku
- TN (true negative) - model správne predikuje, že vstup nespĺňa nejakú charakteristiku

Matematicky si vieme maticu vyjadriť nasledovne:

$$\begin{pmatrix} TP & FN \\ FP & TN \end{pmatrix}$$

kde riadky predstavujú aktuálnu triedu a stĺpce predikovanú (môže sa to vyskytnúť a transponované).

Môžeme si zobrať konkrétny príklad matice zámen, ktorá bude predpovedať či má pacient rakovinu alebo nie. Ak má pacient rakovinu tak to budeme označovať 1 a keď pacient nemá rakovinu tak to budeme označovať 0. Nech matica vyzerá nasledovne (riadky predstavujú skutočnú triedu a stĺpce predikovanú):

	1	0
1	6	3
0	2	5

Z tejto matice môžeme vidieť, že nejaký model zo 9 pozitívnych prípadov (1 riadok) správne predikoval rakovinu v 6 a nesprávne v 3. A zo 7 negatívnych prípadov ju správne nenašiel v 5 prípadoch a nesprávne označil pacienta bez s rakoviny ako pacienta z rakovinou 2-krát.

Ďalším prínosom čo môžeme analyzovať pomocou matici zámen je presnosť (precision) a citlivosť (recall) modelu. Presnosť modelu nám udáva pomer správne charakterizovaných prípadov ku všetkým kladne charakterizovaným prípadom. Citlivosť modelu nám udáva koľko prípadov je naozaj predikovaných správne, teda je to pomer počtu prípadov, ktoré model predikoval správne, že spĺňajú nejakú charakteristiku ku pomeru všetkých prípadov čo boli modelu poskytnuté a danú charakteristiku spĺňajú.

Obe vlastnosti si môžeme zapísať aj matematicky:

$$Precision = \frac{TP}{TP + FP} \qquad Recall = \frac{TP}{TP + FN}$$

# Kapitola 3

## Prehľad problematiky


V tejto kapitole si priblížime úlohy, ktoré musíme riešiť a pozrieme sa na existujúce riešenia nášho problému. Taktiež spomenie aj podobné práce, ktoré boli na našej fakulte napísané.

# Kapitola 4

## Návrh riešenia

V tejto kapitole si najprv popíšeme dataset, s ktorým sme pracovali a následne naše navrhované riešenie na detekciu prostaty a rakoviny prostaty z MRI snímok.

### 4.1 Dataset



Obr. 4.1: MRI snímka postupne s označenou prostatou, označeným nádorom a s prostatou a nádorom spolu (zdroj [Nat20])

## 4.2 Návrh siete

## 4.3 Detekcia prostaty

## 4.4 Detekcia nádorov

# Kapitola 5

## Implementácia

### 5.1 Model

### 5.2 Trénovanie

# Kapitola 6

## Výsledky

V tejto kapitole si popíšeme výsledky, ktoré naša sieť dosiahla. Taktiež porovnáme výkonnosť našej siete s už navrhnutými riešeniami, ktoré boli spomínané v kapitole 3.

### 6.1 Detekcia prostaty

Prvou motiváciou našej práce bolo vyvinúť nástroj, ktorý detekuje prostatu. Modifikovaným sieťou U-Net sa nám podarilo vytvoriť sieť, ktorá bola schopná pracovať s našim prístupným dátastom a zvoleným správnymi stratovými funkciami a hyperparametrami sa nám podarilo vytvoriť model, ktorý dokáže detekovať prostatu.

K voľbe správnej stratovej funkcie, rýchlosti učenia a ďalších parametrov sme dospeli pomocou menšieho datasetu. Zobrali sme si len časť pacientov a na nich sme analyzovali čo sa model učí a ako rýchlo konverguje. Keď sme uvideli dobrý progres tak sme pustili tréning modelu na veľkom datasete.

Výsledky, ktoré sme dosiahli ...



## 6.2 Detekcia rakoviny

# Záver

# Literatúra

- [AN19] Bejoy Abraham and Madhu S. Nair. Automated grading of prostate cancer using convolutional neural network and ordinal class classifier. *Informatics in Medicine Unlocked*, 17(1):100256, 2019.
- [JP17] Adam Gibson Josh Patterson. *Deep Learning*. O’Reilly Media, Inc., 2017.
- [KVG21] Davood Karimi, Serge Vasylechko, and Ali Gholipour. Convolution-free medical image segmentation using transformers, 2021.
- [MHGS13] Gillian Murphy, Masoom Haider, Sangeet Ghai, and Boraiah Sreharsha. The expanding role of mri in prostate cancer. *American Journal of Roentgenology*, 201(6):1229–1238, 2013.
- [Nat20] Natarajan, S., Priester, A., Margolis, D., Huang, J., and Marks, L. Prostate MRI and Ultrasound With Pathology and Coordinates of Tracked Biopsy (Prostate-MRI-US-Biopsy). 10.7937/TCIA.2020.A61I0C1A, 2020. The Cancer Imaging Archive.
- [RFB15] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation, 2015.

- [YGHK19] Sunghwan Yoo, Isha Gujrathi, Masoom A. Haider, and Farzad Khalvati. Prostate cancer detection using deep convolutional neural networks. *Scientific Reports*, 9(1):19518, 2019.
- [ZDT<sup>+</sup>18] Qikui Zhu, Bo Du, Baris Turkbey, Peter Choyke, and Pingkun Yan. Exploiting interslice correlation for mri prostate image segmentation, from recursive neural networks aspect. *Complexity*, 2018(1):4185279, 2018.
- [ZLT<sup>+</sup>21] Li Zhang, Longchao Li, Min Tang, Yi Huan, Xiaoling Zhang, and Xia Zhe. A new approach to diagnosing prostate cancer through magnetic resonance imaging. *Alexandria Engineering Journal*, 60(1):897–904, 2021.

# Zoznam obrázkov

1.1	Rôzne typy sekvencie MRI snímok. Postupne zľava: T2-weighted, ADC mapa a DWI sekvencia (zdroj [MHGS13]) . . . . .	5
2.1	Architektúra konvolučnej neurónovej siete (zdroj [JP17]) . . . . .	9
2.2	U-Net: model siete (zdroj [RFB15]) . . . . .	14
4.1	MRI snímka postupne s označenou prostatou, označeným nádorom a s prostatou a nádorom spolu (zdroj [Nat20]) . . . . .	20