

Analýza struktury obrazu karotidového plátu s použitím deskriptorů a hlubokého učení

Bc. Vladyslav Sherstobitov

Diplomová práce
2024



Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky

Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky
Ústav informatiky a umělé inteligence

Akademický rok: 2023/2024

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: Bc. Vladyslav Sherstobitov
Osobní číslo: A21505
Studijní program: N0613A140022 Informační technologie
Specializace: Softwarové inženýrství
Forma studia: Kombinovaná
Téma práce: Analýza struktury obrazu karotidového plátu s použitím deskriptorů a hlubokého učení
Téma práce anglicky: Carotid Plaque Image Structure Analysis Using Descriptors and Deep Learning

Zásady pro vypracování

1. Popište frekvenční a intenzitní deskriptory v analýze obrazů z plátů karotid.
2. Analyzujte členitosti a kompaktnosti části plátů.
3. Popište využití deskriptorů pro odhad rizika ulomení plátu a způsobení náhlé příhody.
4. Popište využití hlubokého učení pro odhad rizika ulomení plátu a způsobení náhlé příhody s využitím deskriptorů z bodu 4.
5. Zhodnoťte výsledky predikce ulomení plátu a způsobení náhlé příhody.

Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

1. SZELISKI, Richard. Computer Vision: Algorithms and Applications. Springer London Ltd, 2011.1.
2. ZHANG, DENGSHENG. Fundamentals of image data mining: analysis, features, classification and retrieval. Second edition. Cham: Springer, [2021]. Texts in computer science. ISBN 978-3-030-69250-6.
3. ELGENDY, Mohamed. Deep Learning for Vision Systems. Manning Publications Co., 2020.
4. GUPTA, Ajay, et al. Plaque echolucency and stroke risk in asymptomatic carotid stenosis: a systematic review and meta-analysis. Stroke, 2015, 46.1: 91-97.
5. NIXON, Mark; MAHMOODI, Sasan; ZWIGGELAAR, Reyer (ed.). Medical Image Understanding and Analysis: 22nd Conference, MIUA 2018, Southampton, UK, July 9-11, 2018, Proceedings. Springer, 2018.

Vedoucí diplomové práce: **doc. Ing. Zdenka Prokopová, CSc.**
Ústav počítačových a komunikačních systémů

Konzultant diplomové práce: **doc. Ing. Petr Čermák, Ph.D.**

Datum zadání diplomové práce: **5. listopadu 2023**
Termín odevzdání diplomové práce: **13. května 2024**

doc. Ing. Jiří Vojtěšek, Ph.D. v.r.
děkan



prof. Mgr. Roman Jašek, Ph.D., DBA v.r.
ředitel ústavu

Ve Zlíně dne 5. ledna 2024

Vladyslav Sherstobitov

Analýza struktury obrazu karotidového plátu s použitím deskriptorů a hlubokého učení

Prohlašuji, že

- beru na vědomí, že odevzdáním diplomové práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby;
- beru na vědomí, že diplomová práce bude uložena v elektronické podobě v univerzitním informačním systému dostupná k prezenčnímu nahlédnutí, že jeden výtisk diplomové práce bude uložen v příruční knihovně Fakulty aplikované informatiky Univerzity Tomáše Bati ve Zlíně;
- byl/a jsem seznámen/a s tím, že na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- beru na vědomí, že podle § 60 odst. 1 autorského zákona má UTB ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- beru na vědomí, že podle § 60 odst. 2 a 3 autorského zákona mohu užít své dílo – diplomovou práci nebo poskytnout licenci k jejímu využití jen připouští-li tak licenční smlouva uzavřená mezi mnou a Univerzitou Tomáše Bati ve Zlíně s tím, že vyrovnání případného přiměřeného příspěvku na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše) bude rovněž předmětem této licenční smlouvy;
- beru na vědomí, že pokud bylo k vypracování diplomové práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tedy pouze k nekomerčnímu využití), nelze výsledky diplomové práce využít ke komerčním účelům;
- beru na vědomí, že pokud je výstupem diplomové práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá. Neodevzdání této součásti může být důvodem k neobhájení práce.

Prohlašuji,

- že jsem na diplomové práci pracoval samostatně a použitou literaturu jsem citoval. V případě publikace výsledků budu uveden jako spoluautor.
- že odevzdaná verze diplomové práce a verze elektronická nahraná do IS/STAG jsou totožné.

Ve Zlíně, dne

.....
Vladyslav Sherstobitov, v.r.

ABSTRAKT

Tématem této diplomové práce je analýza struktury obrazu aterosklerotického plátu v karotidě, pro kterou se používají deskriptory a hluboké učení. Hlavním cílem práce je vyhodnocení možností využití hlubokého učení pro odhad rizika ulomení aterosklerotického plátu, které se provádí v rámci vlastního výzkumu. V teoretické části jsou shromážděny informace o segmentaci obrazu, technikách detekce významných bodů v obrazech a postupech měření objektů pro příznakové rozpoznání. Dále jsou také uvedeny příznakové metody analýzy obrazu a je charakterizována vícevrstvá neuronová síť s využitím algoritmu zpětného šíření chyby. Součástí teoretické části je popis karotid a aterosklerotických plátů, které mohou být identifikovány právě prostřednictvím analýzy struktury obrazu. V praktické části je realizován projekt, jehož úkolem je analyzovat soubor snímků karotenových tepen, kde existuje riziko vzniku, případně ulomení aterosklerotických plátů. Na konci práce je uvedeno, jaké algoritmy jsou nejvhodnější pro vyhodnocení rizika ulomení plátů.

Klíčová slova: hluboké učení, deskriptor, ultrazvukový snímek, karotida

ABSTRACT

The topic of this thesis is the analysis of the structure of atherosclerotic plaque in the carotid artery using descriptors and deep learning. The main objective is to evaluate the potential of deep learning for estimating the risk of atherosclerotic plaque rupture, which is done as part of my own research. The theoretical part gathers information on image segmentation, techniques for detecting anomaly points in images, and procedures for measuring objects for feature recognition. Also discussed are feature-based methods of image analysis and the characterization of a multilayer neural network using the backpropagation algorithm. The theoretical part also describes the carotid artery and atherosclerotic plaques, which can be identified through image structure analysis. The practical part involves a project analyzing a set of images of carotid arteries, where there is a risk of the development or rupture of atherosclerotic plaques. Finally, the thesis outlines which algorithms are most suitable for evaluating the risk of plaque rupture.

Keywords: deep learning, descriptor, ultrasound image, carotid artery

PODĚKOVÁNÍ

Chtěl bych poděkovat doc. Ing. Petr Čermákovi, Ph.D. za cenné rady a odborné vedení mé diplomové práce.

OBSAH

UVOD	9
TEORETICKÁ ČÁST	11
I ZPRACOVÁNÍ OBRAZU	12
1.1 SEGMENTACE OBRAZU.....	12
1.2 DETEKCE VÝZNAMNÝCH BODŮ V OBRAZECH	14
1.3 MĚŘENÍ OBJEKTŮ PRO PŘÍZNAKOVÉ ROZPOZNÁNÍ	22
1.4 PŘÍZNAKOVÉ METODY ANALÝZY OBRAZU	32
1.5 VÍCEVRSTVÁ NEURONOVÁ SÍŤ S UČENÍM BACK PROPAGATION	34
2. KAROTIDY A ATEROSKLEROTICKÉ PLÁTY.....	37
2.1 POPIS KAROTID A JEJICH FUNKCE V KARDIOVASKULÁRNÍM SYSTÉMU	37
2.2 POPIS KAROTID A JEJICH FUNKCE V KARDIOVASKULÁRNÍM SYSTÉMU	38
PRAKTICKÁ ČÁST.....	43
3. IMPLEMENTACE	44
4. ZHODNOCENÍ VÝSLEDKŮ	45
ZAVĚR	46
SEZNAM POUŽITÉ LITERATURY	47

ÚVOD

Hluboké učení, které je součástí strojového učení založeného na umělých neuronových sítích, našlo své uplatnění ve mnoha oblastech, ať už se jedná o automatizované výrobní procesy, chytrou domácnost či personalizovaná doporučení v internetových obchodech. Role hlubokého učení je však zvláště patrná v úkolech souvisejících se zpracováním velkého množství dat a s rozpoznáváním obrazů. Zejména v lékařském průmyslu poskytují technologie hlubokého učení nové možnosti pro diagnostiku, léčbu a sledování zdravotního stavu pacientů. Jejich prostřednictvím je možné výrazně zlepšit kvalitu a přesnost lékařských snímků, rozpoznat patologické změny a prognózovat pravděpodobnost vývoje onemocnění. Navíc je umělá inteligence schopna analyzovat lékařská data rychleji a přesněji než lékaři, což přispívá k rychlejšímu rozhodování při navržení vhodného kurzu zdravotní péče.

Jednou z nejslibnějších oblastí aplikace hlubokého učení v medicíně je predikce a prevence vývoje onemocnění v rané fázi. Pomocí algoritmů hlubokého učení lze analyzovat anamnézu, životní styl pacientů a na jejich základě vytvořit modely schopné předpovídat riziko onemocnění, jako třeba cukrovka, kardiovaskulární poruchy nebo onkologická onemocnění. Díky tomu mohou lékaři včas přijmout preventivní opatření a předepsat léčbu předtím, než se onemocnění naplno projeví.

Specifickým příkladem aplikace hlubokého učení v medicíně je analýza struktury plátu v karotických tepnách, které jsou hlavní příčinou vzniku aterosklerózy. Tyto pláty mohou být podrobně prozkoumány právě pomocí moderních metod zpracování obrazu a analýzy dat. Aplikace deskriptorů a algoritmů hlubokého učení dovoluje přesně kategorizovat jednotlivé typy plátů a vyhodnotit jejich stav, což je zásadní pro prevenci závažných kardiovaskulárních onemocnění včetně infarktu a mrtvice. Tento přístup otevírá nové perspektivy pro včasnou diagnostiku a účinnou prevenci aterosklerózy, tudíž i zvyšuje šance na úspěšnou léčbu.

Hlavním cílem této diplomové práce je vyhodnotit možnosti využití hlubokého učení pro odhad rizika ulomení aterosklerotického plátu, a to na základě analýzy struktury obrazů s těmito pláty s použitím deskriptorů. Dílčím cílem práce je vyhodnotit výsledky predikce ulomení plátu pro jejich následné využití v praxi.

V teoretické části práce jsou metodou literární rešerše shrnuty informace na téma zpracování obrazu a jednotlivých fází, kterými je v tomto procesu potřeba projít. Poté je v práci představena charakteristika karotid a aterosklerotických plátů. V praktické části je předložen vlastní projekt zaměřený na využití deskriptorů a hlubokého učení pro odhad rizika ulomení

plátu a způsobení náhlé příhody. Na konci práce jsou zhodnoceny získané výsledky a jsou identifikovány nejúčinnější metody pro predikci.

I. TEORETICKÁ ČÁST

1 ZPRACOVÁNÍ OBRAZU

První kapitola bakalářské práce je zaměřena na proces zpracování obrazu, jeho podstatu a jednotlivé fáze. Na počátku se pozornost věnuje segmentaci obrazu, dále se popisují způsoby detekce významných bodů v obrazech, a to prostřednictvím jednotlivých transformací. Následně se probírá postup měření objektů pro příznakové rozpoznání, jsou zmíněny příznakové metody analýzy obrazu a je popsána vícevrstvá neuronová síť s učením back propagation.

1.1 Segmentace obrazu

Segmentace obrazu je jednou z technik zpracování obrazu, která dělí digitální obraz do několika segmentů s cílem zjednodušit jeho analýzu a zlepšit výkon následného zpracování. V praxi se segmentace používá pro rozpoznání a oddělení různých objektů v obraze, aby bylo možné analyzovat konkrétní jeho části. Zpravidla začíná segmentace extrakcí objektů, které se v obraze nacházejí, a to prostřednictvím detekce hran ohraničujících jednotlivé objekty, respektive detekce celých oblastí, jimiž jsou objekty v obraze reprezentovány. Vzhledem k tomu, že výchozí obrázky se odlišují vlastními specifiky, může být segmentace provedena různými metodami. Výsledkem by se však měla stát mapa obrazových segmentů, kde každý segment reprezentuje různé objekty nebo oblasti, které mají podobné vizuální charakteristiky (Sojka, 2000, s. 73).

1) Detekce hran

Jak již bylo zmíněno v předchozím textu, detekce hran je základním krokem v procesu segmentace obrazu, který se zaměřuje na identifikaci v obraze těch bodů, kde dochází k výrazné změně jasu nebo barvy. Tyto body představují hranice mezi různými objekty nebo různými charakteristikami objektu, jako jsou například textury nebo kontury. Proces detekce hran začíná aplikací různých matematických operátorů, které vypočítávají úroveň změny intenzity mezi sousedními pixely.

Gradientní metody detekce hran patří mezi nejpoužívanější přístupy k detekci změn jasu v obraze a jsou založeny na tom, že v místě hrany má absolutní hodnota první derivace průběhu jasu vysokou hodnotu. Tím pádem výpočet první derivace obrazové funkce umožní identifikovat místa, kde dochází k náhlým změnám v intenzitě, tudíž identifikovat potenciální hranice. Další často používanou metodou je detekce hran hledáním průchodu druhé derivace nulou. Někdy se také používají parametrické modely hrany, jejichž klíčovou

odlišností je to, že využívají předdefinované modely, které popisují očekávaný tvar a vlastnosti hrany. Zmínit je také třeba Cannyho detektor hran, který se vyznačuje možností efektivně identifikovat hrany s vysokou přesností a s nízkou pravděpodobností falešných detekcí. Nakonec stanovení hran na základě textury vychází z analýzy variability vzorců intenzity či barev v obraze, které umožňuje odlišovat texturované oblasti od homogenních (Sojka, 2000, s. 74-83).

2) Spojování hran

Proces spojování hran následuje rovnou po jejich detekci a má za cíl propojit segment hran, které jsou geograficky blízké a mají podobnou orientaci. Ke spojování se obvykle používají souvislé přímky nebo křivky, které umožňují vytvořit obrys objektů. Pro čistější a přesnější reprezentaci hran v obraze je možné aplikovat různé přístupy. Základní mezi nimi je Heuristické sledování hrany. Jejím prostřednictvím je možné vyplnit mezery mezi segmenty hran na základě jejich předpokládaných vlastností a okolních textur. Proložení přímky a křivky je jiný matematický přístup, v jehož rámci je zapotřebí najít nejlepší přímku nebo křivku, která se co nejvíce blíží k detekovaným bodům hrany (Sojka, 2000, s. 83-85).

Pokud jsou již některé body obrazu považovány za body hran, pak lze provést Houghovu transformaci. Tato metoda se používá pro převod bodů detekovaných hran z obrazového prostoru do prostoru parametrů. Díky tomu je možné snadněji identifikovat parametry pro geometrické tvary, jako jsou přímky nebo kružnice, které těmto hranám odpovídají. Houghova transformace je zvláště efektivní v situacích, kdy je potřeba najít hranice objektů s jasně definovanými geometrickými charakteristikami (Byron, 2013, s. 131).

3) Detekce oblastí

Detekce oblastí je proces v segmentaci obrazu, který se zaměřuje na identifikaci a vymezení jednotlivých oblastí na základě jejich společných charakteristik, jako jsou intenzita, textura nebo barva. Cílem tohoto procesu je rozdělit obraz na smysluplné části, což by mělo usnadnit jeho další analýzu a lépe interpretovat výsledky segmentace. Mezi základní metody detekce oblastí patří prahování, metoda spojování oblastí a metoda dělení oblastí. Prahování je technika, která zpracovává obraz tak, že nastaví určitou hranici (práh) pro intenzitu pixelů, podle které se pixely rozdělí na objekty a pozadí. Prahování přináší nejlepší výsledky tehdy, když je mezi objekty a jejich pozadím vysoký kontrast. Jinými slovy, při aplikaci této metody je nutné vycházet z předpokladu, že body hledaných oblastí budou mít stejný či velmi podobný jas (Sojka, 2000, s. 87-88).

Metoda spojování oblastí, známá také jako region growing, začíná pracovat s několika malými oblastmi a postupně přidává sousední pixely k podobným oblastem na základě předem definovaných kritérií, jako je třeba podobnost barvy, textury, jasů atd. Oproti tomu metoda dělení oblastí neboli split-and-merge začíná celým obrazem jako jednou oblastí a postupně ji dělí do menších segmentů. Tyto segmenty pak mohou být zase spojeny do větších homogenních oblastí (Sojka, 2000, s. 88-89). Pro dosažení optimálních výsledků v různých typech obrazových dat se mohou tyto metody detekce oblastí kombinovat.

4) Detekce rohů

Přestože jsou tři výše zmíněné fáze klíčovými v procesu segmentace obrazu, někdy se také používá detekce rohů. Tato metoda je zaměřena na identifikaci v obraze bodů, kde se setkává dvě nebo více hran. Tyto body jsou důležité pro rozpoznávání objektů proto, že obvykle naznačují významné změny ve struktuře obrazu. Nejčastěji se k tomu využívá Harrisův detektor rohů a Kitchen-Rosenfeldův detektor rohů (Sojka, 2000, s. 89).

1.2 Detekce významných bodů v obrazech

Detekce významných bodů, která je často označovaná jako detekce klíčových bodů nebo *feature points*, je proces identifikace a lokalizace bodů v obraze, jež mají výrazné vizuální charakteristiky. Dané body slouží jako referenční body, které se dají snadno vyhledat v obraze. Obvykle takovými body jsou rohy, koncové body hran, specifické textury či jiné výrazné prvky v obraze. Významné body se mohou používat například pro porovnání obrazů, sledování objektů v průběhu času, rozpoznávání objektů nebo získání hloubkových map. Detekce se přitom provádí pomocí různých algoritmů, mezi které patří například SIFT, SURF, FAST, ORB, RIFF aj.

1.2.1 Scale-Invariant Feature Transform (SIFT)

Scale-Invariant Feature Transform (SIFT) je algoritmus pro detekci a popis významných bodů v obrazech, který byl vyvinut Davidem Loweem v roce 1999. Klíčovou charakteristikou této metody je to, že je odolná vůči změnám měřítka, rotace a částečně i vůči změnám perspektivy a osvětlení. To je důvod, proč se SIFT široce využívá pro rozpoznávání objektů. Body a deskriptory se běžně extrahují v následujících krocích.

1) Detekce extrémů v měřítkovém prostoru

První fází SIFT algoritmu je vytvoření měřítkového prostoru, který se dá provést postupným rozostřením původního obrazu a snižováním jeho rozlišení. K tomu se obvykle využívá konvoluce obrazu s Gaussovým filtrem různé síly, která bude vystupovat škálovacím parametrem. Prostřednictvím porovnávání každého pixelu s jeho sousedy ve stejném měřítku a v sousedních měřítcích se pro každý z nich vyhledají lokální maxima a minima. Tím pádem bude označovat Gaussovské jádro s větší hodnotou větší bod a jádro s menší hodnotou menší bod. Z nich se pak vyberou ty, co mohou spadat do kategorie významných bodů.

2) Lokalizace významných bodů

Ve druhé fázi je potřeba přesněji lokalizovat nalezené extrémy. Pro provedení tohoto kroku je nutné odstranit body s nízkým kontrastem a body, které se nachází na hranách, aby se zvýšila spolehlivost detekce. U každého bodu je zapotřebí vyhodnotit intenzitu prostřednictvím Taylorovy řady a pak vyřadit body s nedostatečným kontrastem nebo se špatnou lokalizací na hranách. Obvykle se k tomu využívá Harrisův detektor rohů.

3) Přiřazení orientace

Každému klíčovému bodu je přiřazena jedna nebo více orientací na základě lokálních gradientů intenzit v jeho okolí, což je důležité pro zajištění invariance vůči rotaci. Orientace se určuje pomocí histogramu gradientů, který se vytváří ze sousedního okolí kolem bodu a který může mít různou velikost a směr v závislosti na měřítku. Histogram má délku 36 polí a pokrývá 360 stupňů. Pak se vezme nejvyšší hrot histogramu a pro výpočet orientace se vezmou i další hroty nad 80 %. To dovlí získat klíčové body se stejným měřítkem a lokací, ale s odlišnými směry.

4) Generování deskriptorů

Pro každý klíčový bod se následně vytváří deskriptor, který efektivně popisuje lokální gradienty intenzit v okolí bodu. Deskriptor je reprezentován jako vektor, který obsahuje informace o orientaci a velikosti gradientů v malých oblastech kolem klíčového bodu. Běžně se jedná o okolí 16x16 rozdělené na 16 dílčích částí 4x4. To znamená, že se pro každou část vytváří histogram orientace, který má délku 8 polí. Celkem tak vznikne 128 hodnot, které slouží jako vektor pro vytvoření deskriptorů klíčových bodů.

1.2.2 Speeded-Up Robust Features (SURF)

Speeded-Up Robust Features (SURF) je další často používanou metodou pro detekci významných bodů v obrazech, která byla vyvinuta jako rychlejší a efektivnější alternativa k

metodě SIFT. SURF využívá několik technik pro zvýšení rychlosti a robustnosti, kam patří integrální obrazy pro rychlý výpočet sum a filtry založené na Hessově matici pro detekci bodů.

1) Integrální obraz a jeho výpočet

Prvním krokem aplikace SURF metody je výpočet integrálního obrazu. Jedná se o základní operaci, při které se provádí rychlé a efektivní sumarizace a průměrování hodnot pixelů v libovolných obdélníkových oblastech obrazu. Tento krok je důležitý pro zlepšení výpočetní efektivity následujících kroků v SURF algoritmu (Ehsan a kol., 2015, s. 2-5).

Pod pojmem integrální obraz (*sum table* nebo *summed-area table*) se rozumí struktura dat, která pro každý pixel (x, y) v původním obraze ukládá sumu hodnot všech pixelů v obdélníku od $[0,0]$ do $[x,y]$. Matematicky je integrální obraz $I(x,y)$ definován následovně:

$$I(x, y) = \sum_{i=0}^x \sum_{j=0}^y f(i, j)$$

kde $f(i,j)$ je intenzita pixelu na pozici (i, j) v původním obraze.

Obrázek 1. Originální vs. integrální obraz

5	2	5	2	5	7	12	14
3	6	3	6	8	16	24	32
5	2	5	2	13	23	36	46
3	6	3	6	16	32	48	64

Zdroj: vlastní zpracování

Pro efektivní výpočet digitálního obrazu se obvykle používá dynamické programování. Pro každý pixel (x, y) se tedy vypočítává hodnota $I(x,y)$, a to pomocí hodnot předchozích pixelů:

$$I(x, y) = f(x, y) + I(x - 1, y) + I(x, y - 1) - I(x - 1, y - 1)$$

Tento vzorec využívá hodnoty přímo nad, vlevo a diagonálně vlevo nahoru od aktuálního pixelu, aby se eliminovalo dvojitě započítávání oblastí, které se mezi sebou překrývají. Jakmile je integrální obraz vytvořen, sumarizace hodnot pixelů v jakémkoliv obdélníku lze provést pomocí několik operací bez ohledu na velikost obdélníku. Zpracování obrazu tak probíhá mnohem rychleji, obzvlášť pokud se jedná o větší obrazy a rozsáhlé oblasti.

2) Detekce významných bodů pomocí Hessovy matice

Detekce významných bodů pomocí Hessovy matice je zásadní pro identifikaci potenciálně významných bodů v obraze a je založena na využití druhých derivací intenzity obrazu. Díky tomu je možné lokalizovat oblasti s vysokým stupněm variace podle intenzity, které často odpovídají rohům a jiným významným rysům v obraze. Pro získání druhých derivací funkce (v tomto případě intenzity obrazu) se používá takový matematický nástroj jako Hessova matice. Pro pixel v měřítkovém prostoru σ je Hessova matice definována následně (Bay, Tuytelaars a Van Gool, 2006, s. 407-409):

$$H(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix}$$

kde L_{xx} , L_{xy} a L_{yy} jsou druhé derivace aplikované pomocí Gaussovského kernelu v bodě x a při měřítku σ . Tyto derivace reprezentují změny intenzity v obraze ve směrech x a y a jejich kombinace:

- $L_{xx}(x, \sigma)$ je druhá derivace ve směru x ,
- $L_{xy}(x, \sigma)$ je smíšená derivace ve směrech x a y ,
- $L_{yy}(x, \sigma)$ je druhá derivace ve směru y .

Druhé derivace se vypočítávají konvolucí obrazu s Gaussovským kernelem, který se přizpůsobí danému měřítku σ . Tento nástroj je efektivní proto, že snižuje šum v obraze, ale zároveň zachovává jeho významné rysy, což je závažné pro spolehlivou detekci významných bodů.

Pro identifikaci významných bodů se následně vyhodnocuje determinant Hessovy matice, který je definován dle tohoto vzorce:

$$\det(H) = L_{xx}L_{yy} - L_{xy}^2$$

Vysoké hodnoty determinantu poukazují na oblasti s výraznou variací intenzity v obou směrech, což je charakteristické právě pro významné body. Ujistit se v tom, zda se jedná o významný bod či nikoli, může napomoci kontrola hodnoty. Pokud je determinant lokálním maximem v porovnání s ostatními body ve stejném měřítku a v sousedních měřítkových vrstvách, pak je tento bod významný.

3) Lokalizace a invariance

Když jsou významné body identifikovány pomocí determinantu Hessovy matice, následuje proces jejich přesné lokalizace. V jeho průběhu se určuje přesná poloha bodu a také dochází

ke stanovení odpovídajícího měřítka, ve kterém byl bod detekován. Přesná lokalizace je důležitá pro další výpočty a zvyšuje spolehlivost rozpoznání objektů v obraze.

Je důležité také zajistit invarianci, a to jak měřítkovou, tak i vůči rotaci. Měřítková invariance znamená, že algoritmus bude detekovat významný bod na stejném objektu bez ohledu na jeho velikost v obraze. Při aplikaci SURF algoritmu je této invariance dosaženo prostřednictvím pyramidy měřítek. Jde o sérii obrazů, kde každý následující obraz je lehce rozmazanější a menší než předchozí. Takový přístup umožňuje algoritmu prozkoumat různá měřítka a identifikovat, ve kterém měřítku jsou rysy nejvýraznější.

Invariance vůči rotaci se zajišťuje tím, že se každému významnému bodu přiřazuje orientace na základě směru gradientů v jeho okolí. Pro každý bod se vypočítává orientovaný histogram gradientů z okolní oblasti, přičemž každý pixel v této oblasti přispívá k histogramu hodnotou svého gradientu, která je vážena jeho velikostí a je upravena pomocí Gaussovy funkce závislé na vzdálenosti od centrálního významného bodu. Prostřednictvím tohoto postupu lze určit dominantní orientaci gradientů v okolí daného bodu, což právě zajišťuje jeho invarianci vůči rotaci.

4) Vytvoření deskriptoru

Proces vytvoření neboli konstruování deskriptoru je důležitý pro vytvoření robustního a informativního popisu každého významného bodu. Tento deskriptor se vytváří s využitím Haarových vlnkových filtrů (někdy také Haarovy wavelety) a je navržen tak, aby byl invariantní vůči změnám v osvětlení a také robustní vůči změnám měřítka. Podle Porwika a Agnieszky (2004, s. 2) jsou Haarové vlnkové filtry jednoduché, ale efektivní nástroje pro analýzu obrazu. V SURF algoritmu se tyto filtry používají pro rychlou extrakci informativních rysů z oblasti kolem významného bodu. Tyto filtry měří rozdíly v intenzitě mezi sousedními oblastmi obrazu. Zpravidla jsou dvěma základními formy Haarových filtrů horizontální filtry a vertikální filtry.

Postup konstruování deskriptoru je následující. Na počátku se pro každý významný bod vymezí okolní oblast, která je škálována podle měřítka, v němž byl bod nalezen. Dále dochází k rozdělení oblasti na menší čtvercové podoblasti. Obvykle se k tomu využívá mřížka o velikosti 4x4, čímž vzniká 16 podoblastí. V každé podoblasti se dále aplikují Haarové vlnkové filtry, a to v horizontálním a vertikálním směru. Je také možné použití Gaussovy funkce, která zváží výsledky na základě jejich vzdálenosti od centrálního významného bodu, aby se zvýraznil vliv blíže umístěných pixelů. Následně se pro každou podoblast vypočítají sumy

absolutních hodnot pro danou oblast, stejně jako jejich absolutní hodnoty. Výsledkem se stane vektor obsahující čtyři hodnoty. V celé oblasti tak vznikne deskriptor o velikosti 64 prvků, tj. 4 hodnoty pro každou z 16 podoblastí.

Matematicky může být deskriptor vyjádřen jako vektor D o 64 prvcích, kde každý prvek D_i představuje takzvaný bin:

$$D_i = \left[\sum H_h, \sum H_v, \sum |H_h|, \sum |H_v| \right] i$$

kde H_h a H_v jsou horizontální a vertikální biny v i -té podoblasti.

1.2.3 Features from Accelerated Segment Test (FAST)

Features from Accelerated Segment Test (FAST) je rychlý algoritmus, který se používá pro detekování vlastností obrazu. Tento algoritmus se vyznačuje svou schopností pracovat na úloze v reálném čase, a to díky prozkoumávání okolí pixelu a srovnání intenzit. Jeho podstatou je tedy identifikace významných bodů ve vizuálním obsahu obrazu prostřednictvím hodnocení intenzity vybraného pixelu v porovnání s jeho okolím (Biadgie a Sohn, 2015, s. 493-496).

Prvním krokem tohoto algoritmu je výběr testovaného pixelu. To znamená, že algoritmus prozkoumá každý pixel v obraze jako potenciální významný bod. Dále se vytvoří kružnice s poloměrem tři pixely kolem každého testovaného pixelu, která bude obsahovat 16 pixelů na obvodu. Následně se provede rychlý test vybraného segmentu. Algoritmus definuje pixel v centru jako významný bod, pokud na kružnici bude existovat dostatečný počet kontinuálních pixelů ($N = 12$ z 16). Tyto pixely musí být výrazně světlejší nebo tmavší než centrální pixel o prahu t :

$$I_p + t \leq I_n \text{ nebo } I_p - t \geq I_n$$

kde I_p je intenzita centrálního pixelu a I_n jsou intenzity sousedních pixelů na kružnici (Biadgie a Sohn, 2015, s. 496-498).

Zjevnou výhodou tohoto algoritmu je jeho rychlost, ale také efektivita zdrojů, protože FAST je méně výpočetně náročný než jiné komplexní algoritmy. Nicméně jeho jednoduchost může způsobit chybnou detekci významných bodů v obrazech s vysokou úrovní šumu. Jinou jeho nevýhodou je absence měřítkové invariance a invariance vůči rotaci.

1.2.4 Oriented FAST and Rotated BRIEF (ORB)

Oriented FAST and Rotated BRIEF (ORB) je moderní algoritmus pro detekci a popis významných bodů v obrazech, který kombinuje dva jiné nástroje, a to Oriented FAST pro detekci bodů a Rotated BRIEF (rBRIEF) pro popis těchto bodů. ORB byl vyvinut s cílem nabídnout efektivní alternativu jiným populárním algoritmům, jako SIFT nebo SURF, která by prokazovala stejný výkon, ale která by byla výpočetně méně náročná a zpracovávala obrazy v reálném čase. Postup aplikace ORB je následující (Rublee a kol., 2011, s. 2564-2567).

1) Detekce významných bodů pomocí OFAST

OFAST je vylepšená verze FAST algoritmu, která se vyznačuje svou schopností určovat orientaci významných bodů. Díky tomu bude detekce bodů invariantní vůči rotaci obrazu. Na počátku je tedy zapotřebí použít standardní FAST algoritmus pro nalezení potenciálních významných bodů. Dále se pro každý detekovaný bod vypočítá moment založený na intenzitě pixelů v malém okně kolem bodu. Výsledek tohoto výpočtu pak určí hlavní orientaci bodu, která se používá pro rotaci lokálních popisů bodů. Právě díky tomu bude dosaženo invariance vůči rotaci.

2) Popis bodů pomocí rBRIEF

Rotated BRIEF (rBRIEF) je adaptace původního BRIEF deskriptoru, který je upraven tak, aby byl invariantní vůči rotaci. Prvním krokem je zde generování binárního popisu významných bodů prostřednictvím porovnání intenzit náhodně rozmístěných párů pixelů v okolí každého bodu. To umožní vytvořit kompaktní deskriptor, který bude možné jednoduše porovnat. Dalším krokem je určení orientace deskriptoru. Aby bylo dosaženo invariance vůči rotaci se deskriptory otáčejí podle předem určené orientace bodu, která je definována v prvním kroku. Deskriptory tak bude možné porovnávat i mezi obrazy, kde došlo k rotaci objektů.

Zjevnou výhodou ORB algoritmu je jeho rychlost, vysoká efektivita a invariance. Při jeho aplikaci je však třeba počítat s omezenou odolností vůči změnám měřítka. I když tento algoritmus má určité prvky, které by se s těmito změnami měly vypořádat, není v tomto ohledu ORB tak robustní jako například SIFT. Navíc, podobně jako ostatní binární deskriptory, může být rBRIEF citlivý na šum v obraze a na změny osvětlení, které mohou ovlivnit jeho výkon.

1.2.5 Rotation-Invariant Fast Features (RIFF)

Rotation-Invariant Fast Features (RIFF) je další metoda vyvinutá pro detekci a popis významných bodů v obraze, která se odlišuje invariancí vůči rotaci. Díky tomu se RIFF často využívá pro detekci bodů na obrazech, kde jsou objekty zobrazeny pod různými úhly (Takacs a kol., 2013, s. 334).

Proces detekce významných bodů začíná výběrem těchto bodů v obraze. Body jsou identifikovány na základě jejich charakteristických vlastností, které je odlišují od okolních pixelů a činí vhodnými pro další zpracování. K detekci těchto bodů se využívají různé metody, z nichž každá má své specifické výhody a nevýhody v závislosti na typu aplikace a na vlastnostech obrazu (Takacs a kol., 2013, s. 334-336). Obvykle se jedná o následující metody:

- Metoda FAST. Detekce významných bodů probíhá prostřednictvím ověření každého pixelu v obraze. Aby byl bod významný, musí být na kružnici kolem tohoto pixelu dostatečný počet sousedních pixelů s intenzitou, která je výrazně odlišná od intenzity zkoumaného pixelu (Biadgie a Sohn, 2015, s. 493).
- Harrisův detektor rohů. Pro detekci rohů využívá tato metoda změny intenzity obrazu ve více směrech, což jsou obvykle body s vysokou variabilitou gradientu (Kenney, Zuliani a Manjunath, 2005, s. 191).
- Shi-Tomasiho detektor rohů. Tento detektor je modifikací Harrisova detektoru rohů, který určuje významné body podle jednoho základního kritéria. Jedná se o to, že minimální vlastní hodnota (stanovená z vlastních hodnot Hessovy matice) musí být větší než zadaný práh (Kenney, Zuliani a Manjunath, 2005, s. 191).

Dále je zapotřebí provést výpočet orientovaných gradientů, což znamená, že se pro každý detekovaný bod vypočítají gradienty v jeho okolí. Aby bylo dosaženo invariance vůči rotaci, RIFF dále normalizuje gradienty takovým způsobem, že se hlavní orientace každého bodu upraví na standardní referenční úhel. Tím pádem gradientní oblast každého bodu bude otočena tak, aby byla jeho hlavní orientace zarovnána vertikálně nebo podle jiného předem definovaného směru (Takacs a kol., 2013, s. 337).

Následně dochází k výpočtu a popisu deskriptorů. Pro normalizaci orientace musí být každý deskriptor sestaven z vektoru gradientů nebo jiných lokálních charakteristik extrahovaných z okolí bodu. Jeho popis může proběhnout s využitím různých metod jako například následující:

- Histogram orientovaných gradientů (HOG). Jedná se o populární techniku pro popis textury a tvaru v okolí bodu. Histogramy se vytváří z gradientů, které jsou seskupeny do binů podle jejich orientace, což zajišťuje robustní reprezentaci výsledků.
- Local Binary Patterns (LBP). Tato metoda je vhodná pro popis lokálních texturních vzorů a je založena na porovnání každého pixelu se sousedními pixely v okolí. LBP pak vytváří binární kód, který popisuje, zda jsou sousední pixely světlejší nebo tmavší než centrální pixel.
- Scale-Invariant Feature Transform (SIFT). SIFT deskriptory popisují lokální gradienty s měřítkovou invariancí, což poskytuje možnost robustního rozpoznání vlastností obrazu bez ohledu na měřítko.
- Gaborovy filtry. Jde o takové typy konvolučních filtrů, které jsou optimalizovány pro zachycení specifických frekvencí a orientací v obraze.
- Speeded-Up Robust Features (SURF). Podobně jako SIFT, využívá SURF rychlejší algoritmy pro výpočet, které jsou založené na aproximacích Hessovy matice pro detekci významných bodů a jejich následné popisování.

Každá z těchto technik může být součástí RIFF deskriptoru v závislosti na konkrétních požadavcích aplikace a na charakteristice zpracovávaných obrazů. V případě kombinace několika technik se může vytvořit mnohem účinnější algoritmus pro detekci významných bodů. Příkladovým vzorcem pro RIFF deskriptor může být následující:

$$D = \left[\sum_{i=1}^n |\nabla I(x_i)| \cdot \cos(\theta - \theta_i), \sum_{i=1}^n |\nabla I(x_i)| \cdot \sin(\theta - \theta_i) \right]$$

kde $|\nabla I(x_i)|$ je magnituda gradientu v bodě x_i , θ_i je orientace gradientu a θ je referenční orientace pro normalizaci.

1.3 Měření objektů pro příznakové rozpoznání

Poté, co byl obraz segmentován a došlo k úspěšné separaci objektů na tomto obraze, je potřeba přistoupit k příznakovému rozpoznání objektů, tedy k jejich rozpoznání na základě vhodných číselných hodnot neboli příznaků. Obvykle je však nutné k tomu využít více příznaků, aby se z nich vytvořil vektor, který obsahuje všechny důležité informace o objektu. Nicméně jediná univerzální metoda, která by dovolila využít stejné veličiny k rozpoznání

různých objektů podle jejich příznaků, neexistuje. Stejně tak není ani manuál, který by dovolil tento problém vyřešit (Sojka, 2000, s. 93).

Právě proto se vychází z toho, že by se měly zvolit ty příznaky a v takovém rozsahu, aby mohly od sebe spolehlivě odlišit objekty různých tříd. Počet příznaků by ale měl být adekvátní, tedy nepřesahovat cca 10-20 příznaků. Při řešení problému je také zapotřebí věnovat pozornost nejen teoretickému návrhu zvolených příznaků, ale také jejich praktickému ověření. Příznak by tedy měl být považován za užitečný, pokud vychází jeho hodnoty podobnými pro objekty jedné třídy a jsou naopak dostatečně odlišnými pro objekty různých tříd. Vedle toho hodnoty jednotlivých příznaků musí být nezávislé na hodnotách jiných příznaků použitých pro rozpoznání, pokud to řešení problému dovoluje (Sojka, 2000, s. 93).

Nejčastěji se pro rozpoznání používají takové příznaky jako momenty, pravoúhlost a podlouhlost, kruhovost, energie hranice, průměrná vzdálenost pixelu od hranice, popis tvaru objektu s pomocí průběhu křivosti jeho hranice, Eulerovo číslo, atributy odvozené z histogramu jasu a atributy odvozené z frekvenčního spektra jasu.

1.3.1 Momenty

V praxi se pro rozpoznávání objektů často využívají momenty různého stupně, které jsou užitečné z hlediska výpočtu a které snadno rozlišují od sebe objekty různých tříd. Jedná se o základní matematické výrazy, které poskytují souhrnné informace o rozložení intenzity pixelů v obrazu, které lze rozdělit na několik typů (Mercimek, Gulez a Mumcu, 2005, s. 765-767):

- Geometrické momenty definované pro binární obrazy, které se vypočítávají jako vážené součty pixelů, kde jsou váhové koeficienty souřadnice pixelů, a které jsou vhodné pro identifikaci polohy, velikosti a orientaci objektů.
- Centrálně umístěné momenty představující modifikaci geometrických momentů, kde jsou souřadnice normalizovány vůči těžišti objektu, což dělá objekt invariantním vůči natočení.
- Normalizované momenty, které se škálují takovým způsobem, aby byly nezávislé na velikosti a oblasti objektu. Díky tomu jsou pak užitečné pro analýzu tvaru, která je invariantní k měřítku.

Pro výpočet momentů je potřeba získat obrazovou matici, v níž reprezentuje každý pixel určitou intenzitu. Pro binární obraz se moment m_{pq} vypočítá jako (Mercimek, Gulez a Mumcu, 2005, s. 765):

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y)$$

kde x a y jsou souřadnice pixelů, p a q určují řád momentu, a $f(x,y)$ je hodnota pixelu na souřadnicích x,y .

Podle Sojky (2000, s. 93) vedle samotných momentů, které se mohou přímo používat pro rozpoznání objektů, k tomuto účelu mohou sloužit i různé hodnoty odvozené z momentů.

1.3.2 Pravoúhlost a podlouhlost

Pravoúhlost R a podlouhlost S jsou dalšími kvantitativní metrikami, které se používají pro popis tvaru a orientace objektů v digitálním zpracování obrazu. Jsou charakteristické tím, že analyzují a porovnávají geometrické vlastnosti objektů (Rosin, 1999, s. 1). Pravoúhlost lze definovat jako poměr plochy objektu A_O k ploše nejmenšího pravoúhelníku, který objekt obepíná, po jeho rotaci tak, aby byl rovnoběžný se stranami obrazu. Pravoúhelník se přitom nalezne rotací obrazu v rozsahu $0-90^\circ$ s přihlédnutím k tomu, aby se krok rotace volil v jednotkách stupně (obvykle 5°). Pravoúhlost je pak vyjádřena následujícím vztahem (Sojka, 2000, s. 94):

$$R = \frac{A_O}{A_R}$$

kde A_R je plocha pravoúhelníku. Vysoká hodnota R poukazuje na to, že má objekt tvar blízký pravoúhlému obdélníku, zatímco nižší hodnota naznačuje, že pravděpodobně má objekt složitější tvar.

Podlouhlost charakterizuje, jak je objekt podlouhlý nebo válcovitý, a je definována jako poměr delší strany a obepínajícího pravoúhelníku k jeho kratší straně b po rotaci objektu, která byla provedena pro nalezení nejmenšího obepínajícího pravoúhelníku. Tím pádem je vzorec pro výpočet podlouhlosti následující (Sojka, 2000, s. 94):

$$S = \frac{a}{b}$$

Podlouhlost měří proporce objektu. Vyšší hodnoty S hovoří o větší protáhlosti objektu, kdyžto hodnoty blíží se jedné mluví o tom, že je objekt méně podlouhlý (Stojmenović a Žunić, 2008, s. 73).

1.3.3 Kruhovost

Kruhovost vyjadřuje míru, do jaké se tvar objektu přibližuje ke kruhu. Je definována vztahem mezi P a A , kde je P obvodem (délkou hranice) objektu a A je jeho plochou. Vztah pro kruhovost C lze představit následně (Sojka, 2000, s. 94):

$$C = \frac{P^2}{A}$$

Pokud se jedná o perfektní kruh, pak bude hodnota C činit 4π , což je teoretické maximum kruhovosti. Pro jiné geometrické tvary, jako jsou čtverce nebo obdélníky, bude hodnota C nižší, (například pro čtverec $C = 16$). Naopak u objektů nepravidelného tvaru budou hodnoty vyšší. Hodnota kruhovosti tedy roste podle toho, jak moc se tvar objektu přibližuje ke tvaru kruhu a snižuje se spolu s jeho odchylkou od této ideální formy.

Důležité je také brát v úvahu, že v praxi může být skutečná délka hranice objektu v digitálním obrazu odlišná od jeho teoretické délky. Je to spojeno s tím, že je kruhovost ovlivněna rozlišením obrazu a metodou měření obvodu, což je třeba brát v úvahu při interpretaci výsledků (Sojka, 2000, s. 95).

1.3.4 Energie hranice

Energie hranice se používá pro hodnocení průběhu křivosti $k(s)$ podél hranice objektu. Je definována jako integrovaná kvadratická hodnota křivosti po celém obvodu P objektu a vyjadřuje se následujícím vzorcem:

$$E = \frac{1}{P} \int_0^P [k(s)]^2 ds$$

kde $k(s)$ je křivost hranice v bodě s , a P je celkový obvod objektu.

Tento vzorec si klade za cíl kvantifikovat oscilaci zakřivení hranice objektu. Proto jsou tyto informace převedeny do jediné hodnoty, která charakterizuje, jak je „energeticky složitý“ tvar objektu ve vztahu k udržení své hranice. Pokud jsou hodnoty energie nižší, pak má objekt hladší a pravidelnější hranici. Může se tedy podobat kruhu, který má nejnižší možnou

kde je A plochou objektu. Jejím prostřednictvím lze vyjádřit koncentrovaný vztah mezi plochou objektu a jeho vnitřní strukturou (Sojka, 2000, s. 95).

1.3.6 Popis tvaru objektu s pomocí průběhu křivosti jeho hranice

Matematické charakteristiky křivosti také mohou být použity pro detailnější analýzu tvaru. Hlavní z nich je křivost $k(s)$ podél hranice objektu, kterou lze vyjádřit pomocí Fourierovy řady, kde s je oblouková délka podél hranice objektu a P je celková délka hranice. Křivost lze tedy označit jako:

$$k(s) = \sum_{n=-\infty}^{\infty} c_n \exp\left(\frac{i2\pi ns}{P}\right)$$

kde c_n jsou Fourierovy koeficienty, které charakterizují průběh křivosti hranice a které lze získat prostřednictvím následujícího vzorce:

$$c_n = \frac{1}{P} \int_0^P k(s) \exp\left(-i \frac{2\pi ns}{P}\right) ds$$

Při využití této metody lze hlavní tvar objektu popsat pomocí amplitud jistého počtu nejnižších frekvenčních složek křivosti. Vyšší frekvenční složky jsou nápomocné pro popis drobnějších tvarových detailů, ale mohou zahrnovat také šumy. Nižší frekvence dávají informace o obecném tvaru objektu. Průběh křivosti se tedy v praxi nalezne tak, že prostřednictvím skupin po sobě jdoucích pixelů, které tvoří hranici objektu, bude možné proložit kruhové oblouky či jinou vhodnou křivku. Například, pokud se jedná o kruhový oblouk, pak mezi jeho poloměrem a křivostí platí jednoduchý vztah $k=1/r$. V případě obecnějších křivek bude tento vztah složitější (Sojka, 2000, s. 95-96).


1.3.7 Eulerovo číslo

Eulerovo číslo je další metrika, která kvantifikuje strukturu objektu prostřednictvím popisu vztahu mezi počtem nesouvisejících částí objektu C a počtem děr H v těchto částech. Eulerovo číslo χ je definováno jako (Spiliotis a kol., 2022, s. 92-93):

$$\chi = C - H$$

Eulerovo číslo je obzvlášť vhodné v situacích, kdy segmentační metody rozpoznávají více samostatných částí objektu jako individuální celky, ačkoli jsou součástí jednoho většího celku. Ku příkladu, objekt s dvěma nesouvisějícími částmi a třemi děrami by měl Eulerovo číslo $\chi=2-3=-1$. Z tohoto důvodu je Eulerovo číslo užitečné při analyzování složitějších struktur, kde může být jednoduchý počet částí a děr zavádějícím (Spiliotis a kol., 2022, s. 93).

Obrázek 3. Příklad objektu s dvěma nesouvislými částmi a třemi děrami



Zdroj: Sojka, 2000, s. 96

1.3.8 Atributy odvozené z histogramu jasu

Atributy odvozené z histogramu jasu se obvykle používají v situacích, kdy je potřeba rozpoznat objekty, pro které je charakteristické jisté rozložení jasu po objektové ploše, případně které jsou pokryty texturou. Mezi tyto atributy patří střední hodnota, variance, šikmost, energie a entropie histogramu. Střední hodnota jasu μ_b je váženým průměrem hodnot jasu v histogramu, který poskytuje informaci o celkové světlosti objektu (Sojka, 2000, s. 96):

$$\mu_b = \sum_{b=0}^m bp(b)$$

kde b jsou hodnoty jasu a $p(b)$ je pravděpodobností toho, že má pixel objektu jas právě b .

Variance σ_b^2 měří rozptyl jasů od jejich středních hodnot a poukazuje na kontrast objektu (Sojka, 2000, s. 96):

$$\sigma_b^2 = \sum_{b=0}^m (b - \mu_b)^2 * p(b)$$

Šikmost S_b poskytuje informace o asymetrii rozložení jasu v histogramu (Sojka, 2000, s. 96):

$$S_b = \frac{1}{\sigma_b^3} \sum_{b=0}^m (b - \mu_b)^3 * p(b)$$

Vyšší hodnoty šikmosti hovoří o tom, že má histogram výrazný špičatý tvar s dlouhým ocasem na jedné straně.

Energie E_b je vyjádřena sumou kvadrátů pravděpodobností jasů, které poukazují na hladkost histogramu (Sojka, 2000, s. 96):

$$E_b = \sum_{b=0}^m p(b)^2$$

Variabilita jasů v obraze je menší, pokud je ukazatel energie vyšší. To také znamená, že obraz je méně texturovaný.

Entropie T_b měří míru nejistoty nebo nepravidelnosti v rozložení jasu (Sojka, 2000, s. 96):

$$T_b = - \sum_{b=0}^m p(b) \log(p(b))$$

Vyšší hodnoty entropie ukazují na větší složitost, případně nepravidelnost v rozložení jasu v objektu.

1.3.9 Atributy odvozené z frekvenčního spektra jasu

Pokud se jedná o objekty s texturou, pak je pro jejich rozpoznání vhodné využít příznaků, které jsou odvozené z frekvenčního spektra jasu. Na počátku je potřeba provést Fourierovu transformaci obrazové funkce nad oblastí, která je zaujata rozpoznávaným objektem. Problém zde však představuje to, že může rozpoznávaný objekt mít libovolný tvar. Aplikace běžných algoritmů Fourierovy transformace může být realizována prostřednictvím vepsání obdélníku či čtverce vhodných rozměrů a pak provedením transformace obrazové funkce nad obdélníkem. Tím se získá vzorek textury, kterou je tento objekt pokrytý. Pak je potřeba koncentrovat informaci obsaženou ve Fourierově obraze do malého počtu příznaků, pro které lze použít tyto veličiny (Sojka, 2000, s. 97):

$$U_{p,q} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) du dv, V_{p,q} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) du dv$$

kde p, q jsou vybranými reálnými hodnotami. Hodnoty $U_{p,q}$ a $V_{p,q}$ ukazují, jaké frekvence dominují v obraze a mohou přispět k rozlišení mezi různými typy textur. Alternativně je možné hodnotu $F(u, v)$ integrovat nad jinou vhodnou oblastí. V tomto případě budou u, v v polárních souřadnicích vyjádřeny jako $u = \rho \cos \varphi$, $v = \rho \sin \varphi$, takže jako příznaky budou použity následující hodnoty (Sojka, 2000, s. 97):

$$A_{p,q} = \int_p^q \int_0^{2\pi} F(\rho, \varphi) d\varphi d\rho, B_{p,q} = \int_0^t \int_s^t F(\rho, \varphi) d\varphi d\rho$$

kde $A_{p,q}$ naznačuje zastoupení frekvencí v mezikruží o šířce $|p-q|$, což hovoří o specifických vzorech nebo struktuře v obraze. $B_{s,t}$ reprezentuje zastoupení frekvencí v klinu o šířce $|s-t|$ úhlových jednotek, které může poukazovat na orientované vzory nebo textury.

1.3.10 Algoritmus výpočtu plochy, obvodu a Eulerova čísla

Pro implementaci výpočtu příznaků, které byly uvedeny v předchozích podkapitolách, je možné využít jednoduchý postup aplikovaný hlavně při výpočtu plochy, obvodu a Eulerova čísla. Jeho hlavní odlišností je to, že nevyžaduje explicitní určení hranice, což ho dělá vhodným v situacích, kdy byly prostřednictvím segmentace definovány přímo ty plochy, které náleží jednotlivým objektům. Zásadou postupu je zjišťování toho, kolikrát mohou být do různých míst objektu umístěny matice, které jsou obsaženy v dále uvedených množinách Q_1, Q_2, Q_3, Q_4, Q_D (Sojka, 2000, s. 97).

$$Q_1 = \left\{ \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 0 \\ 0 & 1 \end{bmatrix}, \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix} \right\}, Q_2 = \left\{ \begin{bmatrix} 1 & 1 \\ 0 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 1 \\ 0 & 1 \end{bmatrix}, \begin{bmatrix} 0 & 0 \\ 1 & 1 \end{bmatrix}, \begin{bmatrix} 1 & 0 \\ 1 & 0 \end{bmatrix} \right\}$$

$$Q_3 = \left\{ \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}, \begin{bmatrix} 0 & 1 \\ 1 & 1 \end{bmatrix}, \begin{bmatrix} 1 & 0 \\ 1 & 1 \end{bmatrix}, \begin{bmatrix} 1 & 1 \\ 1 & 0 \end{bmatrix} \right\}, Q_4 = \left\{ \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \right\}, Q_D = \left\{ \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \right\}$$

Plocha objektu je vypočtena pomocí kombinace počtů výskytů různých matic Q_1, Q_2, Q_3, Q_4, Q_D v obraze. Plocha je dána vztahem:

$$A = \frac{1}{4} [n(Q_1) + 2n(Q_2) + 3n(Q_3) + 4n(Q_4) + 2n(Q_D)]$$

kde $n(Q_i)$ označuje počet výskytů matice Q_i v obraze. Obvod objektu se vypočítává na základě počtů výskytů jednotlivých matic, kde tyto matice reprezentují různé konfigurace hranic objektu (Sojka, 2000, s. 98):

$$P = n(Q_1) + n(Q_2) + n(Q_3) + 2n(Q_D)$$

Eulerovo číslo objektu, které charakterizuje topologii objektu (například, počet děr) je pak možné vypočítat pomocí následujícího vzorce (Sojka, 2000, s. 98):

$$E = \frac{1}{4}[n(Q_1) - n(Q_3) + 2n(Q_D)] \text{ (pro čtyřsousednost)}$$

$$E = \frac{1}{4}[n(Q_1) - n(Q_3) - 2n(Q_D)] \text{ (pro osmisousednost)}$$

V případě, že byly objekty určené k rozpoznání původně hladké, pak může být zkreslení velikosti plochy a obvodu kvůli digitalizaci kompenzováno prostřednictvím použití modifikovaných vztahů pro obvod a plochu (Sojka, 2000, s. 98).

1.3.11 Hodnocení vhodnosti zvolené množiny příznaků

Hodnocení vhodnosti zvolené množiny příznaků pro rozpoznávání objektů je závažným krokem v procesu zpracování obrazu. Na počátku je třeba stanovit, že jsou dva příznaky označené jako x a y , ale také vhodná trénovací množina. V návaznosti na to je možné vypočítat střední hodnoty $\hat{\mu}_{x,i}$ a $\hat{\mu}_{y,i}$, stejně jako variance obou příznaků $\hat{\sigma}_{x,i}^2$ a $\hat{\sigma}_{y,i}^2$ v jednotlivých třídách podle následujících vzorků (Sojka, 2000, s. 99):

$$\hat{\mu}_{x,i} = \frac{1}{N_i} \sum_{j=1}^{N_i} x_{i,j}$$

$$\hat{\mu}_{y,i} = \frac{1}{N_i} \sum_{j=1}^{N_i} y_{i,j}$$

$$\hat{\sigma}_{x,i}^2 = \frac{1}{N_i} \sum_{j=1}^{N_i} (x_{i,j} - \hat{\mu}_{x,i})^2$$

$$\hat{\sigma}_{y,i}^2 = \frac{1}{N_i} \sum_{j=1}^{N_i} (y_{i,j} - \hat{\mu}_{y,i})^2$$

kde N_i je počet vzorků ve třídě i . S ohledem na to, že musí být hodnoty příznaků pro objekty, které patří ke stejným třídám, podobné, měly by být hodnoty variancí ve vztazích co nejmenší a zvolené příznaky co nejméně závislé. Právě závislost či nezávislost je popsána pomocí kovariance. Její normalizovaná podoba může být vypočítána prostřednictvím následujícího vzorce (Sojka, 2000, s. 99):

$$\hat{\sigma}_{x,y,i}^2 = \frac{1}{N_i} \sum_{j=1}^{N_i} (x_{i,j} - \hat{\mu}_{x,i})(y_{i,j} - \hat{\mu}_{y,i})$$

Tato hodnota kovariance ukazuje, zda jsou příznaky nezávislé (když se hodnota blíží k 0) nebo závislé (když se blíží k 1 nebo -1).

Schopnost příznaků rozlišovat mezi jednotlivými třídami lze hodnotit pomocí normalizované vzdálenosti mezi třídami i a j , která je vyjádřena následujícími vztahy:

$$\hat{D}_{x,i,j} = \frac{|\hat{\mu}_{x,i} - \hat{\mu}_{x,j}|}{\sqrt{\hat{\sigma}_{x,i}^2 + \hat{\sigma}_{x,j}^2}}, \quad \hat{D}_{y,i,j} = \frac{|\hat{\mu}_{y,i} - \hat{\mu}_{y,j}|}{\sqrt{\hat{\sigma}_{y,i}^2 + \hat{\sigma}_{y,j}^2}}$$

Tyto ukazatele reprezentují kvantitativní míru toho, jak dobře lze třídy od sebe oddělit na základě daných příznaků. Vyšší hodnoty separační vzdálenosti naznačují lepší rozlišovací schopnost příznaku mezi třídami.


1.4 Příznakové metody analýzy obrazu

Jak je již patrné z názvu, příznakové metody analýzy obrazu využívají příznaky pro identifikaci a klasifikaci objektů v obrazech. Předpokládají, že výzkumník má k dispozici popis rozpoznávaného objektu, který je představen ve formě vektoru příznaků $x = (x_1, x_2, \dots, x_m)^T$. Jako jednotlivé složky tohoto vektoru vystupují hodnoty vhodně zvolených příznaků, které se dělí na spojité, diskrétní a binární příznaky. Každý objekt v obraze je tak reprezentován jako bod ve vícedimenzionálním prostoru příznaků X^m (příznakový prostor), kde každý rozměr odpovídá jednomu příznaku. Pokud jsou hodnoty všech vybraných příznaků reálné, pak je X^m prostorem reálných m -tic. Nicméně v praxi je hodnota příznaků při řešení nějaké úlohy omezena, takže hodnoty příznaků nemusí nabývat všech teoreticky možných hodnot z X^m .

V příznakovém prostoru jsou objekty (vektory příznaků) rozděleny do různých tříd, které jsou odděleny pomocí rozhodovacích pravidel nebo klasifikačních algoritmů. Rozdělení do

tříd může být vizualizováno jako shluky v příznakovém prostoru, kde každý shluk reprezentuje objekty stejné třídy. Rozpoznávání objektů pak spočívá v určení toho, do kterého shluku nový patří objekt na základě jeho příznaků, tedy ve stanovení třídy objektu (viz Obrázek 4).

Obrázek 4. Shluky v příznakovém prostoru vytvořené z obrazů objektů tříd




Zdroj: Sojka, 2000, s. 101

1.5 Vícevrstvá neuronová síť s učením back propagation

Neuronové sítě se často využívají pro rozpoznávání objektů na obrazech. Jedna z nejrozšířenějších metod takového rozpoznání předpokládá aplikování vícevrstvé (třívrstvé) sítě s učením back propagation. Vícevrstvé neuronové sítě obvykle obsahují vnitřní vrstvu, jednu či několik skrytých vrstev a výstupní vrstvu (Li a kol., 2012, s. 553-555).

Schéma třívrstvé neuronové sítě je představeno tak, že se do vrstvy vstupních uzlů zavádějí jednotlivé složky vektoru příznaků. To znamená, že se počet vstupních uzlů shoduje s počtem příznaků. Následně se ze vstupní vrstvy odebírá identifikátor třídy a používá se kódování 1 z n . Tím pádem se počet neuronů ve vstupní vrstvě shoduje s počtem rozpoznávaných tříd. Co se týká počtu neuronů ve střední vrstvě (nebo vrstvách), pak se vybírá na základě zkušeností a celkové schéma tedy má následující podobu (viz Obrázek 5).

Obrázek 5. Schéma třívrstvé neuronové sítě



Zdroj: Sojka, 2000, s. 107

Učení v neuronových sítích probíhá metodou zpětného šíření chyby (back propagation), která představuje formu gradientního sestupu a která je založena na minimalizaci chyby mezi výstupy sítě a požadovanými hodnotami (cíli). Pro aplikaci této metody je potřeba provést několik kroků (Li a kol., 2012, s. 555).

V prvním kroku dochází k dopřednému šíření signálu od vstupní vrstvy přes skryté vrstvy až k výstupní vrstvě. Každý neuron ve vrstvě přijímá vážený součet vstupů z předchozí vrstvy, který se dále zpracovává aktivační funkcí. Nejčastěji používanou funkcí je tedy logistická sigmoidní funkce, která je definována jako:

$$y_i = \frac{1}{1 + e^{-\lambda_i s_i}}$$

kde s_i je váženým součtem vstupů do neuronu i , a λ_i je parametr ovlivňující strmost funkce. Po výpočtu výstupů sítě je třeba vypočítat chybu každého výstupního neuronu ve vztahu k jeho cílové hodnotě. Chyba celé sítě je běžně kvantifikována pomocí kvadratické funkce:

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - t_i)^2$$

kde t_i jsou cílové hodnoty pro výstupní neurony.

Podstatou učení neuronové sítě je nalezení vah, při kterých se chyba co nejvíce minimalizuje. Metoda zpětného šíření chyby začíná výpočtem gradientu chybové funkce pro každou váhu v síti:

$$w_{i,j}^{(k+1)} = w_{i,j}^{(k)} - n \frac{\partial E}{\partial w_{i,j}}$$

Gradienty se dále vypočítávají pomocí řetězového pravidla derivace, které propaguje chyby zpět od výstupních neuronů k vstupním neuronům. Pro výstupní vrstvu platí následující vztah:

$$\frac{\partial E}{\partial w_{i,j}} = \frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial s_i} \frac{\partial s_i}{\partial w_{i,j}}$$

kde první derivace je $\frac{\partial E}{\partial y_i} = y_i - t_i$ a druhá derivace (z aktivační funkce) je $\frac{\partial s_i}{\partial w_{i,j}} = x_j$

Váhy jsou následně aktualizovány tak, aby se chyba co nejvíce snížila:

$$w_{ij} = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}}$$

Pak je potřeba provést tyto kroky pro každou iteraci dat z trénovací množiny. Proces se cyklicky opakuje, přičemž v jeho rámci se ukončení kontroluje prostřednictvím zjišťování velikosti chyby (Sojka, 2000, s. 108).

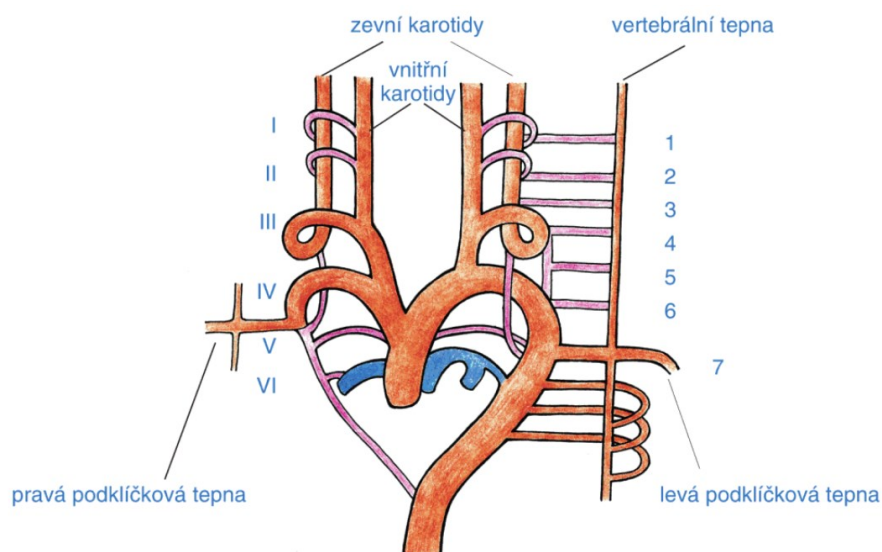
2 KAROTIDY A ATEROSKLEROTICKÉ PLÁTY

V této kapitole práce je uveden popis karotid a jsou zmíněny jejich funkce v kardiovaskulárním systému. Pozornost je také věnována dysfunkcím karotid a jejich důsledkům jako vznik aterosklerotických plátů. V samostatné podkapitole jsou tyto pláty detailně popsány a klasifikovány, a to podle různých kritérií jako progresse vývoje nebo jednotlivé prvky (struktura, echogenita, povrch). Součástí práce také je rozbor technik detekce plátů a možností jejich kvantifikace.

2.1 Popis karotid a jejich funkce v kardiovaskulárním systému

Karotidy neboli krkavice jsou klíčové a největší krční tepny v lidském těle, které hrají důležitou roli v kardiovaskulárním systému. Tyto tepny se nachází na obou stranách krku a jsou hlavními tepnami zodpovědnými za dopravu okysličené krve ze srdce do krku, hlavy a horních končetin. Karotidy jsou umístěny v aortálním oblouku (Merkunová a Orel, 2008, s. 95).

Obrázek 6. Aortální oblouk a jeho větvi



Zdroj: Čertík, Machart a Novák, 2005, s. 14

Existuje několik hlavních typů karotid (viz Obrázek 6). Jsou tu pravá i levá společná krkavice (*a. carotis communis dexter et sinister*), které probíhají na bočních stranách krku a jsou rozděleny na zevní a vnitřní krkavici (*a. carotis interna et externa*). Zevní karotida zásobuje okysličenou krví orgány krku jako štítná žláza, svaly, kůže a hrtan). Vnitřní karotida zásobuje mozek, oko a ucho i vstupuje otvory ve spánkové kosti do lebky. Dále tu jsou také podklíčkové tepny, které zásobují krví oblast ramene, krku a hrudní stěny. Nejvýznamnější

z nich je páteřní tepna (*a. vertebralis dextra et sinistra*) procházející skrz otvory v příčných výběžcích krčních obratlů. Tato tepna vstupuje do mozku a podílí se na jeho zásobování. Podklíčkové tepny následně přecházejí v podpažní tepnu (*a. axillaris*) a v pažní tepnu (*a. brachialis*) (Křivánková a Hradová, 2009, s. 72).

Funkce karotid je nesmírná závažná, protože zajišťují stálý tok kyslíku a živin pro optimální fungování mozku. Jakákoli dysfunkce nebo obstrukce v karotidách tedy může vést k vážným zdravotním komplikacím. Podle Vymazala, Michálka a Klementové (2023, s. 1183) je cévní onemocnění mozku třetí nejčastější příčinou úmrtí v ČR po onemocnění srdce a nádorech. Zároveň s tím je častou příčinou invalidity, protože postihuje 3 % dospělé a 10 % seniorské populace. Důležité přitom je, že je ve více než 90 % případů cévní onemocnění mozku důsledkem aterosklerózy, tj. chronického zánětu, hypertenze a diabetes mellitus. Tyto nemoci postihují extrakraniální a intrakraniální tepny a mají různý stupeň závažnosti.

Tak u čtvrtiny obyvatel se obvykle vyskytuje ztlustění intimy a média < 1 mm. Pak pětina obyvatel se potýká se sklerotickými pláty, které zužují průsvit karotidy < 50 % a stenóza karotidy < 50 % je diagnostikována u 1,5 % obyvatel. Pozoruhodné také je, že počet cévních onemocnění mozku stoupá spolu s věkem, přičemž u mužů je prevalence těchto nemocí vyšší. Vedle stenóz, které často vedou k ischemiím mozku, je také důležitá stabilita plátů, protože je u měkkých nestabilních plátů s lipidovým jádrem riziko důsledků vyšší. Diagnostika cévních onemocnění se realizuje na základě klinických obrazů (Vymazal, Michálek a Klementová, 2023, s. 1183).

2.2 Histologická struktura a klasifikace aterosklerotických plátů

Aterosklerotické pláty se vytváří v důsledku patologického procesu, který se nazývá ateroskleróza, a postihují oblasti s vysokým krevním proudem, jako karotická bifurkace a odstup *a. carotis interna*. Aterosklerotický plát vzniká akumulací lipidů, kalcifikacemi a dalšími složkami krevní plazmy v intime tepen, které vedou k jejich ztlustění a zúžení. Lokálním faktorem, který hraje důležitou roli v patogenezi aterosklerózy, je mechanické napětí stěny tepny. Progresi tohoto onemocnění však také výrazně přispívá arteriální hypertenze, porucha metabolismu cukrů a lipidů, kouření, infekce a jiné faktory. Nicméně genetické a rasové vlivy, stejně jako faktor pohlaví, určují proces aterogeneze ještě více než faktory, které mohou být osobou ovlivněny (Kalvach, 2010, s. 216).

Pro zobrazení a měření aterosklerotických plátů se obvykle používá B-obrazová ultrasonografie. Pokud však jde o měkké a anechogenní pláty, pak se aplikuje barevný nebo energetický mód, kde je možné ohraničit plát pomocí barvy. Pro další sledování aterosklerotického plátu je nezbytné jeho přesné změření. K tomu je vhodné použít příčný řez, který s pomocí časové smyčky dovolí vyhledat místo maximálně šíře plátu. Toto místo lze tedy považovat za nejlépe reprodukovatelné měření velikosti plátu (Kalvach, 2010, s. 216).

Základní dělení aterosklerotických plátů probíhá na základě jejich progresu. Proces aterosklerózy začíná velmi ranou fází, která se nazývá endoteliální dysfunkce. Tuto dysfunkci lze odhalit pouze mikroskopicky a je charakterizována poruchami vnitřní výstelky tepen, tzv. endotelu. Tyto počáteční změny mají funkční povahu a zatím nejsou makroskopicky viditelné. Pokud se nemoc i nadále rozvíjí, dochází k formování tukových proužků, které jsou makroskopicky viditelné jako žluté pruhy na vnitřním povrchu tepen. Tyto pruhy se skládají z pěnových buněk, které jsou bohaté na lipidy, ale zatím nezasahují do lumen arterie, tedy do prostoru tepny, kam protéká krev (Manual-cmp.cz, 2024).

Dalším stupněm jsou fibrózní pláty neboli ateromy, které už mohou pronikat do lumen arterie a přispívat k jejímu zúžení. Fibrózní pláty jsou charakterizovány tužšími ložisky s ostře ohraničenou hranicí, která může být blízko povrchu tepny. Barva těchto plátů je obvykle bílá, trochu žlutá nebo bledě šedá v závislosti na obsahu tuků. Navíc u některých plátů může chybět lipidové jádro a tyto pláty mohou být silně kalcifikované, tj. obsahovat usazeniny vápníku (Manual-cmp.cz, 2024).

Nejvíce rizikovou fází aterosklerotického procesu je vznik komplikovaných lézí, které se formují z fibrózních plátů a obvykle obsahují velké množství lipidů a nekróz. Tyto léze mohou způsobit rupturu plátu, což vede k tvorbě krevní sraženiny (trombu) přímo v místě léze, a tím i k okamžitému uzavření tepny. Tato akutní událost může vést k infarktu myokardu nebo k mozkové mrtvici v závislosti na tom, jaká tepna je postižena (Manual-cmp.cz, 2024).

Na základě ultrazvukového hodnocení se aterosklerotické pláty klasifikují podle tří klíčových kritérií, jimiž jsou struktura, echogenita a povrch. Tyto pláty je možné dále také členit na základě jiných prvků, protože se vyznačují specifickými charakteristikami (Kalvach, 2010, s. 217):

- Podle struktury

Z hlediska struktury mohou být aterosklerotické pláty homogenní a heterogenní. Homogenní pláty mají poměrně uniformní strukturu a charakterizují se nízkou či střední echogenitou. U

takových plátů mohou být ojedinělá ložiska hyperechogenity, tj. kalcifikace. Heterogenní pláty to jsou takové pláty, které mají jasně ohraničené anechogenní oblasti s odpovídajícím krvácením do plátu. Případně zde mohou být hyperechogenní oblasti, které odpovídají kalcifikacím.

- Podle echogenity

Na základě echogenity lze rozdělit na anechogenní, středně echogenní a hyperechogenní. Anechogenní pláty analyzované prostřednictvím B obrazu mají stejnou echogenitu jako lumen tepny. Nicméně pro jejich detekci je zapotřebí aplikace barevného či energetického módu. Takové pláty se vyznačují histologicky vysokým obsahem lipidů či již amorfních ateromových hmot. Středně echogenní pláty mají v B obraze střední echogenitu a v některých případech i tzv. vláknitou strukturu. Histologicky se nejčastěji jedná o fibrózní léze. Hyperechogenní pláty jsou odlišné tím, že je jejich echogenita porovnatelná s echogenitou kostí či kalcifikací. Takové pláty běžně vytváří výrazný akustický stín zhoršující kvalitu zobrazení, a to ve všech modalitách ve směru insonace pod plátem. To znamená, že pláty působí dojemem hypoechogenního či echoprázdného prostoru. Z histologického hlediska se hyperechogenní pláty charakterizují vysokým obsahem kalcia.

- Podle povrchu

Aterosklerotické pláty mohou mít rovný, nerovný nebo exulcerovaný povrch. V prvním případě se jedná o plát s plynulým ohraničením od anechogenního lumenu tepny, a to bez nerovností. V druhém případě mají pláty povrch s nerovnostmi kolem 0,2 mm hloubky. Exulcerované pláty mají v B obraze jasné nepravidelné defekty v povrchu.

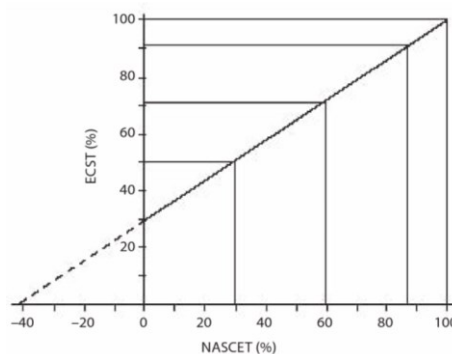
Ačkoli zatím nebylo riziko vzniku ischemické CMP pro jednotlivé typy plátů přesně stanoveno, nejvyšší riziko zpravidla představují pláty s nižší echogenitou, heterogenní a také s nerovným povrchem.

2.3 Techniky detekce plátů a možnosti jejich kvantifikace

Podle Kalvacha (2010, s. 217) patří detekce stenózy v karotidě k nejvýznamnějším úkolům sonografického vyšetření karotidových tepen. Hodnocení stenózy přitom probíhá podle tří základních možností, jimiž jsou redukce průměru tepny (podle studie NASCET nebo ECST), redukce plochy průtokového kanálu a maximální systolická rychlost či rychlostní indexy. Nejčastěji se však využívá první z těchto metod realizovaná podle studie NASCET (North American Symptomatic Carotid Endarterectomy Trial), kde dochází k hodnocení redukce

průměru reziduálního lumina tepny v místě stenózy a také šíře lumina tepny za stenózou. Vzhledem k tomu, že u menších stenóz může při takovém hodnocení stenóza dosahovat záporných hodnot, obvykle se využívá procentuální měření procenta stenóz, které jsou nad 50 %. Respektive je u stenóz do 50 % lépe reprodukovatelná šíře aterosklerotického plátu. Pro lepší přehlednost je orientační srovnání procenta stenózy dle dvou klíčových studií uvedeno na následujícím obrázku (viz Obrázek 7).

Obrázek 7. Orientační srovnání procenta stenózy podle NASCET a ECST (%)



Zdroj: Kalvach, 2010, s. 217

Pro definování závažnosti stenózy se aplikuje kombinace přímých a nepřímých diagnostických kritérií. Přímá kritéria hodnotí nález v oblasti stenotického úseku tepny. K tomu se využívá měření aterosklerotického plátu a také reziduálního lumina tepny v B obraze. Dále dochází k zobrazení lumina tepny v barevném nebo energetickém módu a následně se získává průtoková křivka z oblasti stenózy, a to se změřením průtokových rychlostí. Nepřímá kritéria hodnocení stenózy jsou založena na analýze změn průtoku krve před stenózou, změn průtoku krve v distálnějším úseku vnitřní karotidy a z průkazu kolaterálního oběhu (Kalvach, 2010, s. 217-218).

Nicméně podle Kešnerové (2017, s. 230) v současné době detekce aterosklerotického plátu a určení procenta stenózy nejsou dostačující, protože nestabilita plátu je závislá nejen na procentu stenózy, ale také na jiných faktorech. Jimi jsou:

- celková velikost plátu,
- echogenita plátu,
- anechogenní část vedle povrchu plátu,
- ulcerace a jejich velikost,
- detekce mikroembolizací v periferním řečišti,
- progresse plátu,

- detekce němých ischemií v daném povodí,
- ischemická příhoda v jiném řečišti aj.

Rizikovitost aterosklerotického plátu se pak určuje dalšími terapeutickými postupy. Avšak pokud jde o kvantifikaci stenóz, k tomu se běžně využívá sonografické šetření a zejména duplexní sonografie. Její senzitivita se pohybuje kolem 77-95 % a přesnost může být měřena výše zmíněnými standardizacemi jako NASCET nebo ECST. Pro zjištění tíže stenózy je pak nutné aplikovat tzv. multiparametrický přístup (Kešnerová, 2017, s. 230-231).

Pozornost také může být věnována nestabilitě plátu, která záleží na jeho vlastním složení. Jak uvádí Kešnerová (2017, s. 232), hlavními koreláty rizikovosti plátu zde jsou „*neovaskularizace, zánětlivé změny sinfiltrací makrofágy, vysoký podíl lipidů, krvácení do plátu, nekróza, ulcerace, ztenčení či porušení fibrinové čepičky na povrchu plátu*“. Jinými rizikovými faktory jsou průměrná echogenita plátu a plocha plátu v podélném řezu.

Vysoký počet faktorů, které přispívají k tvorbě aterosklerotických plátů, tak naznačuje potřebu nástroje umožňujícího digitální analýzu plátů s automatickým určením rizikovosti, a to přímo v rámci ultrazvukového vyšetření. Díky tomu bude možné lépe stratifikovat pacienty, pro které bude vhodné intenzifikovat konzervativní terapii, zlepšit indikaci k invazivním výkonům na základě individuálních výsledků vyšetření a také optimálně vybrat intervenční techniky léčby.

II. PRAKTICKÁ ČÁST

3 IMPLEMENTACE

text

4 ZHODNOCENÍ VÝSLEDKŮ

text

ZÁVĚR

text

SEZNAM POUŽITÉ LITERATURY

- [1] BAY, Herbert, Tinne TUYTELAARS a Luc VAN GOOL, 2006. SURF: Speeded Up Robust Features. In: LEONARDIS, Aleš, Horst BISCHOF a Axel PINZ, ed. *Computer Vision – ECCV 2006* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, s. 404-417 [cit. 2024-04-10]. Lecture Notes in Computer Science. ISBN 978-3-540-33832-1. Dostupné z: doi:10.1007/11744023_32
- [2] BIADGIE, Yenewondim a Kyung-Ah SOHN, 2015. Speed-up Feature Detector using Adaptive Accelerated Segment Test. *IETE Technical Review* [online]. 2015-11-30, **33**(5), 492-504 [cit. 2024-04-11]. ISSN 0256-4602. Dostupné z: doi:10.1080/02564602.2015.1103669
- [3] BYRON, Petr, 2013. *Technical Computing Prague 2013: 21th annual conference proceedings = sborník příspěvků 21. ročníku konference: Kongresové centrum ČVUT, Praha*. Prague: Humusoft in co-operation with Institute of Chemical Technology. ISSN 2336-1662.
- [4] EHSAN, Shoaib, Adrian CLARK, Naveed REHMAN a Klaus MCDONALD-MAIER, 2015. Integral Images: Efficient Algorithms for Their Computation and Storage in Resource-Constrained Embedded Vision Systems. *Sensors* [online]. **15**(7), 16804-16830 [cit. 2024-04-10]. ISSN 1424-8220. Dostupné z: doi:10.3390/s150716804
- [5] Hodnocení a klasifikace aterosklerotických plátů, 2024. *Manual-cmp.cz* [online]. [cit. 2024-04-11]. Dostupné z: <https://www.manual-cmp.cz/hodnoceni-a-klasifikace-aterosklerotickych-platu/>
- [6] KALVACH, Pavel, 2010. *Mozkové ischemie a hemoragie*. 3., přeprac. a dopl. vyd. Praha: Grada. ISBN 978-80-247-2765-3.
- [7] KŘIVÁNKOVÁ, Markéta a Milena HRADOVÁ, 2009. *Somatologie*. Praha: Grada. Sestra (Grada). ISBN 978-80-247-2988-6.
- [8] LI, Jing, Ji-hang CHENG, Jing-yuan SHI a Fei HUANG, 2012. Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement. In: JIN, David a Sally LIN, ed. *Advances in Computer Science and Information Engineering* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, s. 553-558 [cit. 2024-05-11]. Advances in Intelligent and Soft Computing. ISBN 978-3-642-30222-0. Dostupné z: doi:10.1007/978-3-642-30223-7_87

- [9] MERCIMEK, Muharrem, Kayhan GULEZ a Tarik Veli MUMCU, 2005. Real object recognition using moment invariants. *Sadhana* [online]. **30**(6), 765-775 [cit. 2024-05-04]. ISSN 0256-2499. Dostupné z: doi:10.1007/BF02716709
- [10] MERKUNOVÁ, Alena a Miroslav OREL, 2008. *Anatomie a fyziologie člověka pro humanitní obory*. Praha: Grada. Psyché (Grada). ISBN 978-80-247-1521-6.
- [11] PORWIK, Piotr a Lisowska AGNIESZKA, 2004. The New Graphic Description of the Haar Wavelet Transform. In: BUBAK, Marian, Geert Dick VAN ALBADA, Peter M. A. SLOOT a Jack DONGARRA, ed. *Computational Science - ICCS 2004* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, s. 1-8 [cit. 2024-04-10]. Lecture Notes in Computer Science. ISBN 978-3-540-22129-6. Dostupné z: doi:10.1007/978-3-540-25944-2_1
- [12] ROSIN, Paul L., 1999. Measuring rectangularity. *Machine Vision and Applications* [online]. 1999-12-16, **11**(4), 191-196 [cit. 2024-05-04]. ISSN 0932-8092. Dostupné z: doi:10.1007/s001380050101
- [13] RUBLEE, Ethan, Vincent RABAUD, Kurt KONOLIGE a Gary BRADSKI, 2011. ORB: An efficient alternative to SIFT or SURF. In: *2011 International Conference on Computer Vision* [online]. IEEE, s. 2564-2571 [cit. 2024-04-11]. ISBN 978-1-4577-1102-2. Dostupné z: doi:10.1109/ICCV.2011.6126544
- [14] SOJKA, Eduard, 2000. *Digitální zpracování a analýza obrazů*. Ostrava: VŠB-Technická univerzita. ISBN 80-7078-746-5.
- [15] SPILIOTIS, Iraklis M., Alexandros S. PEPPAS, Nikolaos D. KARAMPASIS a Yiannis S. BOUTALIS, 2022. Fast Object Extraction and Euler Number on Block Represented Images. *Journal of Data Analysis and Information Processing* [online]. **10**(02), 91-109 [cit. 2024-05-04]. ISSN 2327-7211. Dostupné z: doi:10.4236/jdaip.2022.102006
- STOJMENOVIĆ, Miloš a Joviša ŽUNIĆ, 2008. Measuring Elongation from Shape Boundary. *Journal of Mathematical Imaging and Vision* [online]. **30**(1), 73-85 [cit. 2024-05-04]. ISSN 0924-9907. Dostupné z: doi:10.1007/s10851-007-0039-0
- [16] TAKACS, Gabriel, Vijay CHANDRASEKHAR, Sam TSAI, David CHEN, Radek GRZESZCZUK a Bernd GIROD, 2013. Rotation-invariant fast features for large-scale recognition and real-time tracking. *Signal Processing: Image Communication* [online]. **28**(4), 334-344 [cit. 2024-04-11]. ISSN 09235965. Dostupné z: doi:10.1016/j.image.2012.11.004

[17] VYMAZAL, Tomáš, Pavel MICHÁLEK a Olga KLEMENTOVÁ, 2023. *Anesteziologie (nejen) k atestaci. 2.*, přepracované a doplněné vydání. Praha: Grada Publishing. ISBN 978-80-271-3898-2.