

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2019

Bc. Bohdan Tyshchenko



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE PATOLOGICKÝCH OBRATLŮ V CT SNÍMCÍCH PÁTEŘE S VYUŽITÍM METOD STROJOVÉHO UČENÍ

DETECTION OF PATHOLOGICAL VERTEBRAE IN SPINAL CTS UTILISED BY MACHINE LEARNING
METHODS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Bohdan Tyshchenko

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Chmelík

BRNO 2019



Diplomová práce

magisterský navazující studijní obor **Biomedicínské a ekologické inženýrství**
Ústav biomedicínského inženýrství

Student: Bc. Bohdan Tyshchenko

ID: 192508

Ročník: 2

Akademický rok: 2018/19

NÁZEV TÉMATU:

Klasifikace patologických obratlů v CT snímcích páteře s využitím metod strojového učení

POKyny PRO VYPRACOVÁNÍ:

1) Nastudujte problematiku existujících metod strojového učení a proveďte literární rešerši jejich využití pro klasifikaci objektů v medicínských datech. 2) Navrhnete metodu vhodnou pro klasifikaci různých typů patologií z dostupné databáze CT snímků páteří. 3) Realizujte a otestujte navrženou metodu v libovolném programovacím prostředí. 4) Metodu dle pokynů vedoucího otestujte na dostupných databázích. 5) Proveďte optimalizaci metody pro maximální úspěšnost klasifikace. 6) Dosažené výsledky vhodně prezentujte a diskutujte.

DOPORUČENÁ LITERATURA:

[1] LECUN, Yann, BENGIO Yoshua a HINTON Geoffrey. Deep learning. Nature. 2015-5-27, 521(7553), 436-444. DOI: 10.1038/nature14539. ISSN 0028-0836.

[2] THEODORIDIS, Sergios a KOUTROUMBAS Konstantinos. Pattern recognition. 4th ed. Burlington, Mass.: Academic Press, 2009, xvii, 961 s. ISBN 978-1-59749-272-0.

Termín zadání: 4.2.2019

Termín odevzdání: 17.5.2019

Vedoucí práce: Ing. Jiří Chmelík

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato diplomová práce se zaměřuje na detekci patologických obratlů v CT snímcích páteře s využitím metod strojového učení. V rámci teoretické části je popsána anatomie páteře, výskyt patologií v CT obrazových datech, je vypracován přehled existujících metod určených pro automatickou detekci patologických obratlů. Praktická část je věnována návrhu počítačového systému, který realizuje detekci patologie obratlů a určuje jejich typ. Jako klasifikátor se používá neuronová síť. Aplikace analýzy hlavních komponent (PCA) zajišťuje redukci počátečního počtu příznaků. Pro řešení daného zadání byla získána reálná data. Závěr obsahuje hodnocení dosažených výsledků.

KLÍČOVÁ SLOVA

Neuronová síť, Klasifikace, CT data, Strojové učení, Patologie páteře, Analýza hlavních komponent, Obratel

ABSTRACT

This master's thesis focuses on detection of pathological vertebrae in spinal CT utilized by machine learning. Theoretical part describes anatomy of the spine and occurrence of pathologies in CT image data, contains an overview of existing methods intended for automated detection of pathological vertebrae. Practical part devotes to design a computer aided detection systems to identify pathological vertebrae and to classify a type of pathology. Designed classification system is based on using neural network, which performs classification step and on principal component analysis (PCA), which is used to reducing the original number of observation features. For completing this task were used real data. Conclusion contains evaluation of obtained results.

KEYWORDS

Neural network, Classification, CT data, Machine learning, Pathologies of spine, Principal component analysis, Vertebra

TYSHCHENKO, Bohdan. *Klasifikace patologických obratlů v CT snímcích páteře s využitím metod strojového učení*. Brno, 2019, 42 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Jiří Chmelík

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Klasifikace patologických obratlů v CT snímcích páteře s využitím metod strojového učení“ jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Jiřímu Chmelíkovi za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Brno

.....

podpis autora

Obsah

Úvod	8
1 Teoretická část	9
1.1 Anatomický přehled obratle	9
1.2 Přehled dosavadních metod	11
1.3 Úvod do klasifikace	12
1.4 Umělé neuronové sítě	14
1.4.1 Struktura a funkce biologického neuronu	14
1.4.2 Matematický model neuronu	15
1.4.3 Umělá neuronová síť	17
1.5 Analýza hlavních komponent	20
2 Návrh algoritmu	22
2.1 CT data	22
2.2 Příznaky a odůvodnění jejich volby	23
2.3 Příprava dat	26
2.4 Počáteční model	27
2.5 Zlepšení modelu	28
2.5.1 Aplikace PCA pro redukci příznaků	29
2.5.2 Aplikace korelační analýzy pro redukci příznaků	30
2.6 Finální klasifikační model	31
3 Dosažené výsledky a jejich diskuze	32
3.1 Finální klasifikační model a jeho charakteristiky	32
3.2 Vizuální hodnocení výsledků	34
3.3 Chybovost a její zdroje	36
4 Závěr	37
Literatura	38
Seznam symbolů, veličin a zkratk	40
Seznam příloh	41
A Seznam příznaků a výstup PCA analýzy	42

Seznam obrázků

1.1	Přední a boční zobrazení páteře a obratle [3]	9
1.2	Ukázka zdravé kosti a napadené osteoporózou [4]	10
1.3	CT snímky obratlů bez (A) a s (B) osteoporózou [3]	10
1.4	Výskyt metastáz obratle v CT snímcích	10
1.5	Obecné schéma zpracování biosignálů	12
1.6	Klasifikátor	12
1.7	Definice klasifikačních tříd v obrazovém prostoru	14
1.8	Schéma typické nervové buňky [8]	15
1.9	Schéma umělého neuronu	16
1.10	Přenosové funkce neuronu	16
1.11	Obecné schéma neuronové sítě	17
1.12	Příklady cyklické (vlevo) a acyklické (vpravo) architektury	17
1.13	Obecná struktura vícevrstvé dopředné sítě	18
1.14	Schéma výpočtu hlavních komponent	21
2.1	Ukázka učebních dat (vlevo), výsledky předzpracování (vpravo)	23
2.2	Zastoupení výskytu jednotlivých klasifikačních tříd v původních datech	23
2.3	Normalizované histogramy zdravého a patologického obratlů z CT snímku	24
2.4	Postup výpočtu příznaků podskupiny číslo 1	24
2.5	Porovnání původní masky a erodované	25
2.6	Postup výpočtu příznaků podskupiny číslo 2	25
2.7	Postup výpočtu příznaků podskupiny číslo 3	26
2.8	Postup výpočtu příznaků podskupiny číslo 4	26
2.9	Postup výpočtu příznaků podskupiny číslo 5	26
2.10	Postup předzpracování dat	27
2.11	Zastoupení výskytu klasifikačních tříd v pomocných množinách	28
2.12	Redukce počtu příznaků pomocí PCA	29
2.13	Rozložení variance původních dat v hlavních komponentách	29
3.1	Porovnání úspěšností klasifikace sítí za různých počtů příznaků	32
3.2	Učební množina po PCA transformaci	33
3.3	Maticе úspěšnosti	34
3.4	Topologie finální neuronové sítě	34
3.5	Ukázka výsledků chybné klasifikace obratlů (axiální řez)	35
3.6	Ukázka výsledků správné klasifikace obratlů (axiální řez)	35

Úvod

Stanovení diagnózy je důležitou součástí kvalitního vyšetření a základem pro návrh nevhodnějšího způsobu léčby. V návaznosti na to, že rychlost a přesnost rozhodování je velmi závažným faktorem, v dnešní době se zvyšuje tendence k použití umělé inteligence jako podpory v lékařské diagnostice.

Cílem práce je implementovat techniku strojového učení, která by prováděla identifikace patologických obratlů a klasifikaci typu patologie. Základními patologiemi obratle jsou zlomeniny, nádorová onemocnění a jejich kombinace. Charakter jejich projevu je velmi různorodý a popsat ho obecnými pravidly buď není možné anebo je moc náročné. A proto je nutné použít jednu z technik strojového učení, které ze znalostní báze vyvodí pravidla popisující každou klasifikační třídu.

Text se dělí na 3 celky, kdy první je věnován teoretickému úvodu do problematiky, popisu onemocnění kostní tkáně, existujících metod zaměřených na automatické ohodnocení zdravotního stavu obratlů v CT snímcích páteře. Také tato část zahrnuje úvod do klasifikace, podstatu analýzy hlavních komponent, koncepci neuronových sítí, zejména dopředných, se stručným popisem jejich typů, vlastností, metod učení.

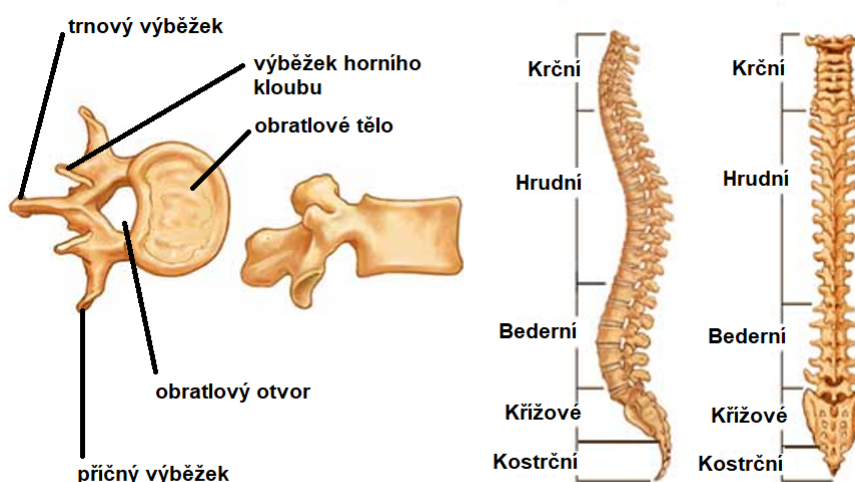
Druhá kapitola má praktický charakter a zahrnuje detailní popis základních kroků celého algoritmu, volby a odůvodnění příznaků, návrhu neuronové sítě, aplikaci PCA, implementaci naprogramované techniky na konkrétních datech.

Třetí část je věnována hodnocení dosažených výsledků a zkoumání vlastností klasifikátoru.

1 Teoretická část

1.1 Anatomický přehled obratle

Páteř člověka – složitý mechanismus, funkčnost kterého ovlivňuje činnost ostatních systémů lidského organismu. Skládá se z 33-34 obratlů: 7 krčních ($C_1 - C_7$), 12 hrudních ($Th_2 - Th_{12}$), 5 bederních ($L_1 - L_5$), 5 křížových sestavující křížovou kost a 4-5 kostrčních tvořící kost kostrční, mezi kterými se nachází meziobratlové ploténky. Základním stavebním prvkem je obratel. Jeho stavba zobrazena na Obr. 1.1. Součástími jsou obratlové tělo, oblouk a výběžky. V otvorech oblouků je uložena mícha [8].




Obr. 1.1: Přední a boční zobrazení páteře a obratle (převzato a upraveno ze: [3])

Tělo je uloženo vpředu a je nosnou částí obratle. Nahoře a dole je ukončeno téměř rovnou krycí plochou, která navazuje na meziobratlovou ploténku. Obratlové tělo je složeno plástovou vrstvou (tzv. kompakta), a houbovitou částí (tzv. spongiózou). Kompakta zajišťuje pevnost a mechanickou odolnost, a spongióza realizuje látkovou výměnu, remodelaci a částečně přenáší zatížení působícího na obratel. Nejnižší a nejtěplejší je obratlové tělo v oblasti krční páteře a nejvyšší a nejmohutnější v bederní páteři.


Oblouk obratle je určen pro chránění míchy, zezadu nasedá na obratlové tělo a s ním vytváří páteřní kanál. Výběžky jsou připojeny k oblouku a upínají se na ně vazy a svaly, což umožňuje pohyb obratle. Výběžky jsou trnové, příčné a kloubní [8][5].

Nejčastější patologií obratle je zlomenina obratle. To se může stát z důvodů abnormálního působení na páteř, například pády, dopravní nehody, sport. Anebo může být následkem snížení mechanické odolnosti obratle. Příčinou je osteoporóza způsobená přirozenými věkovými změnami. Projevuje se redukcí normálně mineralizované

kostní hmoty, která vzniká kvůli převažování úbytku kostní hmoty nad novotvorbou a nedostatku minerálních látek v organismu (viz Obr. 1.2). Jelikož obsah minerálů ovlivňuje kostní denzitu, lze odhalit tuto nemoc pomocí výpočetní tomografie (viz Obr. 1.3).



Obr. 1.2: Ukázka zdravé kosti a kosti postižené osteoporózou (převzato a upraveno z: [4])



Obr. 1.3: CT snímky obratlů bez (A) a s (B) osteoporózou (převzato z: [21])

Závažným problémem jsou nádorová onemocnění (viz Obr. 1.4). Objevují se vzácně a projevují se neřízeným růstem buněk vedoucím ke zvětšení postižené tkáně. Ve většině případů se jedná o metastázu jiného nádoru, například z prsu, plic či zažívacího ústrojí.



Obr. 1.4: Výskyt metastáz obratle v CT snímcích

1.2 Přehled dosavadních metod

Přehled vědeckých článků souvisejících s automatickou detekcí patologií obratlů ukázal, že v dnešní době toto téma je oblastí zájmu mnoha vědeckých institucí. Jak se prokázalo, pro řešení tohoto zadání mnozí vědci používali různé postupy, jako například statistický přístup, texturní analýzu, segmentaci, metody strojového učení atd., ale společným pro většinu článků je to, že uspokojivé výsledky byly dosaženy zejména kombinací odlišných metod. Následující odstavce obsahují stručný popis vybraných publikovaných metod, které byly použity pro detekci buď metastáz nebo abnormálních anatomí.

Kombinovaný přístup, který se skládá ze dvou metod založených na statistice, použil a ve svém článku [11] zveřejnil Jiří Jan a jeho kolegové. Cílem práce byla detekce poškození páteře, zejména metastázami. První metoda – tvarová a texturní analýza. Obě se prováděly nezávisle. Bylo zvoleno značné množství příznaků a pak pomocí genetické optimalizace byla získána sada nejvýznamnějších, které se předkládaly na vstup klasifikátoru. Druhá metoda, graph-cut klasifikace, využívá statistické analýzy normalizovaného histogramu a následné segmentace voxelů na 3 třídy, což identifikuje výskyt osteoblastické nebo osteolytické léze. Výsledky výzkumu ukázaly dostatečně vysokou hladinu přesnosti a efektivity.


Řešení podobného cíle bylo popsáno ve dalším článku [19] zveřejněným Jianhua Yao a jeho týmem. Jimi navržený algoritmus realizuje automatickou segmentaci obratlů a detekci výskytu kostní metastázy. Klasifikace obratlů na zdravé a nemocné provádí vypočtením 26 kvantitativních příznaků, které jsou složené ze 3 kategorií: lokace, tvar, hustota. Další krok rozděluje všechny příznaky na 7 podskupin. Každá z nich má stejnou sílu vlivu na výsledek klasifikace. Jako rozhodovací funkce vystupuje dvoufaktorová ANOVA. Algoritmus byl testován na datech obsahující případy metastáz v různých etapách rozvoje. Celková úspěšnost je přes 85% (hodnota senzitivity) a ukázala se přímá úměrnost správnosti klasifikace na rozměrech léze.

Holger R. Roth v spolupráci s jinými vědci se zabýval návrhem automatizovaného systému detekce abnormálních anatomí a patologií spjatých s rakovinou pomocí konvolučních neuronových sítí [16]. Zvláštnost metody – dvouvrstvý systém. První vrstva odhaduje s vysokou citlivostí (senzitivita $\approx 100\%$) na úkor vysokému počtu falešně pozitivních výsledků a jejím výstupem jsou předzpracovaná data - oblast zájmu výzkumu. Z těchto dat se sbírají vzorky (2 nebo 2,5 dimenzionální), které po transformaci škály, náhodné rotace sestavují trénovací množinu pro konvoluční neuronovou síť. Druhá vrstva selektivně probírá vstup a eliminuje falešně pozitivní případy. Takový postup zajistil schopnost klasifikátoru zobecňovat různá vstupní medicínská data a přizpůsobovat se k jejich různorodosti. Testování na několika množinách prokázalo o zvýšení celkové senzitivity metody průměrně o 25%.

Další článek [17] popisuje algoritmus realizující detekci obratlů s metastázami a autorství kterého patří Sheng-Fang Huang a Kuo-Hsien Chiang. Jejich kompletně automatizovaný systém vysegmentovuje obratle a detekuje přítomnost nádoru. Etapa klasifikace je založená na výpočtu 11 Haralick texturních příznaků a 2 lokálních statistických parametrů ze CT snímku. Rozdíly mezi hodnotami příznaků aktuálního snímku a hodnotami předchozího i následujícího dávají ještě 22 příznaky. Klasifikátorem je dopředná neuronová síť. Ona zpracovává všechny 33 příznaky a poskytuje binární odpověď. Na učební množině, která je daná 392 zdravými a 192 obratli s nádorovým onemocněním, tento klasifikační model má takové charakteristiky: senzitivita = 85.4%, specificita = 91.8%, přesnost klasifikace = 89.7%.


1.3 Úvod do klasifikace

Jednou ze základních etap zpracování signálů je klasifikace, cílem které je zařazení objektu (signálu nebo obrazu) do definované skupiny. Tyto skupiny se jmenují klasifikační třídy. Objekty v každé této třídě mají určité společné vlastnosti a existuje etalon, který co nejlépe reprezentuje vlastnosti třídy a její odlišnosti od ostatních.



Obr. 1.5: Obecné schéma zpracování biosignálů

Zařízení nebo blok algoritmu zpracování (viz Obr. 1.5), který provádí zatřídění do kategorie, se nazývá klasifikátor. Jak lze vidět na Obr. 1.6, klasifikátor může mít tolik vstupů, kolik elementů obsahuje formální popis zpracovávaného signálu, který se vytváří během analýzy, a výstupů – jeden, diskretní. Výstupní signál udává třídu, do které klasifikátor zařadí vstupní obraz, a může nabývat hodnot, které korespondují s počtem tříd. Občas výstup může nabývat ještě další hodnoty, které signalizují o neschopnosti klasifikovat, ale snaží se vyhýbat této možnosti [6, 7].



Obr. 1.6: Klasifikátor

Klasifikátor funguje na základě rozhodovacího pravidla, které popisuje vztah mezi vstupem a výstupem. Z matematického hlediska toto pravidlo lze definovat jako skalární funkce d vektorového argumentu \mathbf{x}

$$w_r = d(\mathbf{x}), \quad (1.1)$$

kde \mathbf{x} – je vektor příznaku, primitiv a relací (závisí na klasifikační metodě), w – identifikátor klasifikační třídy [6].

Jestli rozhodovací pravidlo předem není známé a klasifikace se realizuje automaticky, dá se říct, že tato úloha patří do oblasti umělé inteligence. V těchto případech možnost realizace klasifikace je dosažena učením klasifikátoru. Podle způsobu poskytnutí informace o požadované klasifikaci rozlišujeme následující způsoby učení:

- a) učení s učitelem;
- b) učení bez učitele.

Základní myšlenka učení s učitelem spočívá ve využití trénovací množiny, která se skládá ze vstupních hodnot a známých odpovědí. Klasifikátor se na těchto datech trénuje tím, že upravuje vlastní váhy na základě porovnání skutečné odpovědi s žádoucí. Trénování trvá, dokud nebude dosaženo stanovené kritérium efektivity [10].

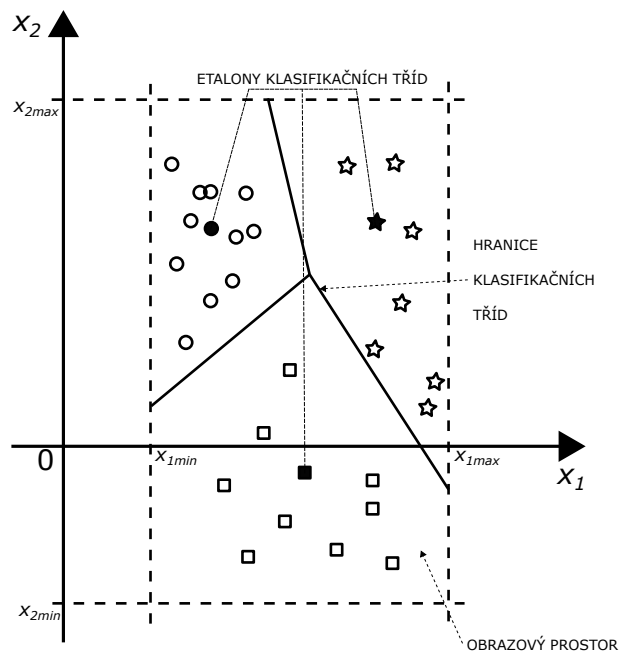
U učení bez učitele nejsou známé odpovědi k dispozici a klasifikátor si sám odvozuje správnost výstupu zpětnou vazbou.

Podle druhu formálního popisu objektu metody klasifikace se dělí na příznakové a strukturální [6].

Příznakový přístup je založen na získání n -rozměrného sloupcového vektoru, jehož složky tvoří konkrétní hodnoty elementárních vlastností zpracovávaného signálu. Tyto hodnoty nazýváme příznaky. Ony mohou popisovat kvantitativní a kvalitativní vlastnosti.

Každému tomuto vektoru odpovídá bod v N -dimenzionálním obrazovém prostoru. V návaznosti na to, že body podobných objektů leží blízko sebe, úloha klasifikace spočívá ve správném stanovení hranic klasifikačních tříd, tím pádem dochází k dělení prostoru na tolik částí, kolik je klasifikačních tříd. Názorný příklad výše uvedeného je vidět na Obr. 1.7.

Strukturální metoda na popis signálu využívá relační strukturu, která se skládá z primitiv – elementárních popisných částí signálu a vzájemných vztahu mezi nimi – relací. Takový přístup se umožňuje dozvědět o skladbě signálu a vzájemných souvislostech mezi jeho jednotlivými úseky. Nejčastěji se využívá při analýze dvourozměrných signálů, totiž obrazů, kdy klasifikační informace získaná pomocí příznaků nepostačují pro rozhodování o zařazení do konkrétní třídy [6][20].



Obr. 1.7: Definice klasifikačních tříd v obrazovém prostoru

1.4 Umělé neuronové sítě

Koncept umělých nervových sítí byl v minulosti inspirován a vytvořen na základě analogie s činností biologických neuronů nervového systému. Jejich hlavním cílem je simulovat a implementovat některé funkce lidského mozku, což z technického hlediska lze považovat za zpracování signálů. Díky podobnosti k lidské nervové soustavě, a to nejen stavbou, ale i procesem řešení úloh, umělá neuronová síť má schopnost adaptace a učení. Právě tyto vlastnosti ji odlišují od klasických algoritmů.

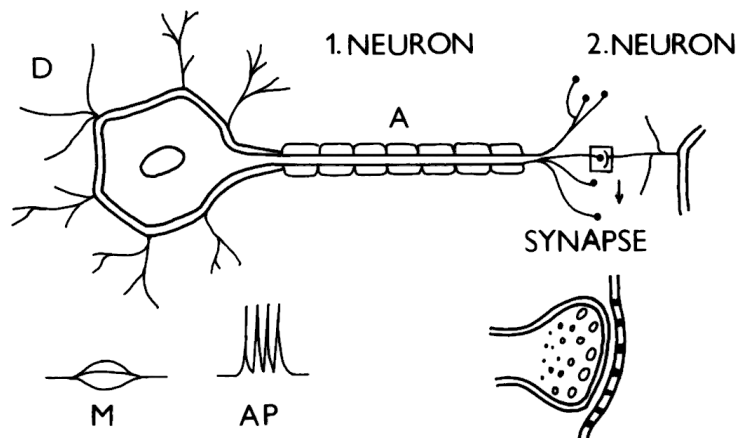
1.4.1 Struktura a funkce biologického neuronu

Základním stavebním elementem nervové soustavy je neuron, činnost kterého spočívá v přenosu a zpracování signálů. Každý neuron se skládá z těchto částí (viz Obr. 1.8):

- a) dendrity, které představují signálové vstupy do těla neuronu;
- b) tělo buňky, nebo soma, hlavní buněčná část, ve které se sčítají vzruchy od okolních neuronů;
- c) axon, který vede signál od těla neuronu;
- d) synapsy, které napojují výstup axonu na dendrity dalších neuronů.

V těle člověka je 15-25 miliard nervových buněk. Každá z nich má průměrně 10 000 dendritů. Takové množství neuronů zajišťuje robustnost nervové soustavy a umožňuje správné fungování organismu při úrazech.

Funkce neuronu je podmíněna chemickými ději, které mají za následek jak excitační (budící), tak inhibiční (tlumící) vliv, a tím pádem mohou vést buď k posílení, nebo k potlačení odezvy na přicházející podnět [15].



Obr. 1.8: Schéma typické nervové buňky. A – axon, D – dendrity, M – místní podráždění na dendritech a těle neuronu, AP – akční potenciály, šířící se axonem (převzato z: [8])

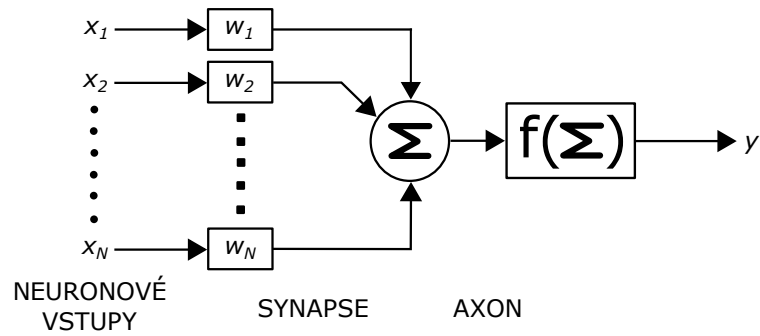
1.4.2 Matematický model neuronu

Podobně biologickému neuronu, matematický neuron je základním, procesním prvkem umělé neuronové sítě. Je systémem typu MISO (Multi-Input-Single-Output), protože může mít jeden nebo několik vstupů a vždy má jenom jeden výstup. Jak je ukázáno na Obr. 1.9, neuronové vstupy převádějí vstupní hodnoty do těla neuronu, předem vynásobené s odpovídajícími vahami. Po vstupu do těla, všechny hodnoty se sčítají a součet, který překročí práh, podobně jako akční potenciál vyvolává výstup přenosové funkce [15].

Matematická formulace výše uvedeného procesu je charakterizována rovnicí

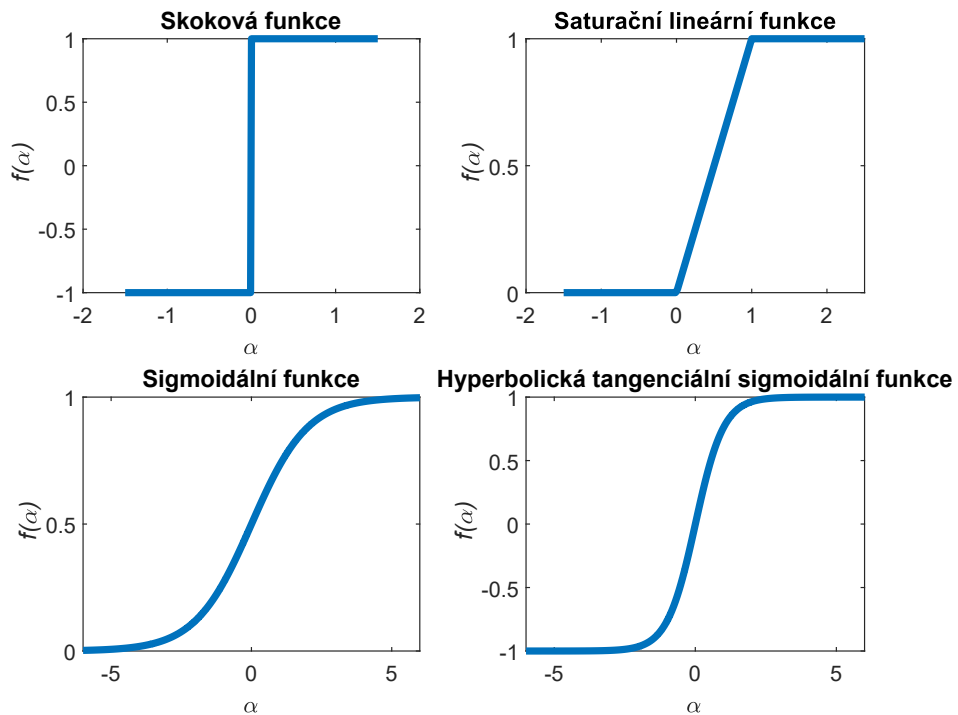
$$y = f\left(\sum_{i=1}^N w_i x_i - \vartheta\right), \quad (1.2)$$

kde \mathbf{x} – vstupní vektor, \mathbf{w} – vektor aktuálních vah, ϑ - aktuální práh neuronu a $f(\alpha)$ – charakteristika neuronu, může být lineární funkcí ale zpravidla je nelineární. Níže jsou uvedeny příklady klasických nelineárních aktivačních funkcí (Obr. 1.10). Definičním oborem neuronu je N-rozměrný prostor reálných čísel. Jestli se rozmezí



Obr. 1.9: Schéma umělého neuronu

hodnot jednotlivých vstupů výrazně liší, je rozumné nejprve normalizovat vstupy. Často se tento krok dělá automaticky a je zahrnut do bloku předzpracování. Toto závisí na knihovně a programovém prostředí, které se používá. Výstupem je zpravidla nějaký interval hodnot nebo v případě logického neuronu – binární množina $\{0,1\}$. Poznamenejme, že aktivační funkce se může lišit od popsaných, jako například neuron s radiální bází, a nebo za potřeby být upravena změnou strmosti pro nějaké ad-hoc zadání [2][10].



Obr. 1.10: Přenosové funkce neuronu

1.4.3 Umělá neuronová síť


Z hlediska přenosu a zpracování signálu lze umělou neuronovou síť představit schématem, uvedeným na Obr. 1.11. Tato síť realizuje zobrazení ze vstupního vektorového prostoru do vektorového prostoru výstupního, $\{\mathbf{x}\} \rightarrow \{\mathbf{y}\}$, přičemž dimenze těchto prostorů mohou být různé. Cílem vytváření neuronových sítí je získání systémů, které by měly svým chováním napodobovat svoje biologické vzory a být aplikovatelný jako signálové procesory, klasifikátory, systémy optimalizace [10][15].



Obr. 1.11: Obecné schéma neuronové sítě

Rozlišujeme tři fáze (dynamiky) ustavení a provozu umělé neuronové sítě: *organizační*, *adaptační* a *aktivní dynamika*.


Organizační dynamika specifikuje architekturu (topologii) neuronové sítě. Nejčastěji topologie je pevná, totiž nemění se v čase, ale v rámci adaptivního režimu může docházet k přidání dalšího neuronu nebo spoje. Rozlišujeme 2 typy topologií: cyklická, acyklická.



Obr. 1.12: Příklady cyklické (vlevo) a acyklické (vpravo) architektury

Cyklická architektura je tvořena skupinou neuronů spojených v kruhu. Propojení je uděláno takovým způsobem, že topologie obsahuje cykly. Nejjednodušším příkladem cyklu je zpětná vazba neuronu, kdy jeho výstup je zároveň jeho vstupem. Příklad obecné cyklické neuronové sítě je uveden na Obr. 1.12 (vlevo), kde jsou vyznačeny všechny možné cykly. Acyklické sítě cykly neobsahují a šíření signálu probíhá jednosměrně (na Obr. 1.12 vyznačena nejdelší cesta). Acyklickou lze vždy rozdělit do jednotlivých vrstev [18][7].

Sít, ve které jsou neurony uspořádány do několika vrstev nad sebou, se nazývá dopředná neuronová síť nebo vícevrstvý perceptron (viz Obr. 1.13). První vrstva je vstupní, kterou lze chápat jako pasivní prvky s jednotkovým přenosem, poslední – výstupní, realizuje celkový výsledek, a mezilehlé vrstvy se nazývají skryté, napomáhají samotnému výpočtu výstupu. Signál se šíří jenom jedním směrem – od vstupu k výstupu. Neurony v jedné vrstvě jsou nezávislé, pracují paralelně, a výstupy jsou propojeny s každým neuronem další vrstvy. K označení architektury sítě se používají číslce rozděleny pomlčkami. Například, síť s topologií 5-8-8-2 je síť s 5 vstupními a 2 výstupními neurony, a v každé ze 2 skrytých vrstev je 8 neuronů [10].



Obr. 1.13: Obecná struktura vícevrstvé dopředné sítě

Počet vstupních neuronů je vždy dán počtem vstupů matematického modelu, počet výstupních je ovlivněn kódováním výstupu. Co se týká skrytých vrstev - jejich počet nikdy není dán předem, a proto může být jakýkoliv. Není také přesně definováno pravidlo, pomocí kterého by bylo možné toto určit. Robustnost sítě, totiž větší množství neuronů a vrstev, také neznamená záruku přesnějšího výsledku a dokonce může přispět k přeučení, což docela komplikuje návrh sítě. Avšak lze využít důsledek Kolmogorovy věty. Podle této věty (rovnice 1.3) každou vícerozměrnou reálnou spojitou funkci $f(x_1, \dots, x_n)$ N -proměnných lze přesně vyjádřit jako lineární kombinaci konečného počtu spojitých nelineárních funkcí jedné proměnné,

$$f(x_1, \dots, x_n) = \sum_{q=1}^{2n+1} \psi_q \left(\sum_{p=1}^n \phi_{pq}(x_p) \right), \quad (1.3)$$

kde ψ, ϕ jsou nelineární funkce proměnné x .

Důsledek Kolmogorovy věty pro vícevrstvý perceptron můžeme shrnout tak, že vícevrstvý perceptron se dvěma skrytými vrstvami (n – počet neuronů první skryté vrstvy, $2n+1$ - druhé) a jedním výstupním neuronem, kde aktivačními funkcemi jsou

spojité monotónně rostoucí funkce, může být univerzálním aproximátorem libovolné funkce N proměnných [7].

Adaptační dynamika. Pod tímto pojmem rozumíme proces učení sítě, kdy dochází k nastavení vah a prahů jednotlivých neuronů, což zajišťuje dosažení požadované transformace vstupní množiny do množiny výstupní. Často je používána adaptační metoda „*back propagation*“ (BP) – metoda „*zpětného šíření*“. Cílem metody je minimalizace chybové funkce, střední kvadratické odchylky, která je vyjádřena vztahem

$$\varepsilon = E\{\varepsilon_p\} \text{ pro } \forall \varepsilon_p \quad (1.4)$$

kde ε_p – okamžitá kvadratická odchylka pro p -tý vektor učební množiny a je definována jako

$$\varepsilon_p = \sum_{j=1}^N (j e_p)^2, \quad (1.5)$$

kde N - počet vstupních vektorů, a e_p – vektor rozdílu mezi skutečnou a požadovanou odpovědí po předložení p -tého vektoru [7].

Metoda BP zahrnuje 3 etapy. První spočívá ve dopředním šíření trénovacího signálu, získání odezvy sítě a chybového vektoru ε_p . Další etapa stanovuje míru úpravy vah každého neuronu.

Lze říct, že úprava vah je optimalizační proces, kdy zadanou funkcí je střední kvadratická odchylka, která evidentně závisí na konfiguraci sítě \mathbf{w} :

$$\varepsilon = f(\mathbf{w}). \quad (1.6)$$

Vzhledem k tomu se používá nejjednodušší gradientní metoda, podle které můžeme stanovit iterační vztah pro úpravu jednotlivých vah:

$$w_i^k(t) = w_i^k(t-1) + \mu \cdot \text{grad}(w_i^k(t-1)), \quad (1.7)$$

kde t - aktuální iterace, μ - koeficient, který určuje rychlost konvergence, k - číslo vrstvy, i - číslo neuronu příslušné vrstvy, a gradient můžeme definovat jako

$$\text{grad}(w_i^k) = \frac{\partial E_i}{\partial w_i^k} = \frac{\partial E_i}{\partial x_i^k} \cdot \frac{\partial x_i^k}{\partial \alpha_i} \cdot \frac{\partial \alpha_i}{\partial w_i^k} = \delta_i \cdot \frac{\partial f(\alpha_i)}{\partial \alpha_i} \cdot x_i^k, \quad (1.8)$$

kde E - střední kvadratická odchylka, $f(\alpha)$ - výstup neuronu, α - aktivace neuronu, x - vstupní vektor příslušného neuronu.

Je vidět, že přenosové funkce pro neuronovou síť s adaptační metodou BP musí být spojitá, diferencovatelná a monotónně neklesající. Takové vlastnosti mají sigmoida a hyperbolický tangens, a právě proto se nejčastěji používají [10][18].

Aby bylo možné upravit váhy vnitřních vrstev je nutné znát lokální chyby, totiž chyby odezvy každého neuronu v aktuální iteraci. Pro odhad těch chyb se používá

heuristický přístup, který říká o tom, že chyba ${}^k_i e_p$ kteréhokoli (i -tého) neuronu ve vrstvě k se rozdělí mezi všechny neurony předchozí vrstvy ($k-1$) v poměru vah příslušných propojení. Chyby výstupní vrstvy jsou známé, a odchylky od požadovaných odezev předchozích vrstev se počítají směrem od vrstev vyšších k vrstvám nižším. Což se nazývá *zpětným šířením chyb* [10].

Poslední třetí etapou je samotná úprava vah. Celkově etapy sestavují jednu iteraci učení, které se zastaví po splnění podmínky ukončení učení.

Přeučení sítě. Jednou ze specifických dopředných sítí je schopnost přeučení. Projevuje se to efektivnější minimalizací chybové funkce ale na úkor zobecnění. Fakticky to znamená, že se síť adaptuje na nepodstatné detaily, a to vede k poklesu výkonosti. Proto je důležité včasné zastavit učení. Je několik způsobů zabránění přeučení, které lze používat zvláště i v jejich kombinaci.

1. Nesnažit se dosáhnout absolutního minima chybové funkce. Stačí zvolit přijatelnou prahovou hodnotu kvadratické odchylky, po dosažení které se učení zastaví.

2. Podmínkou ukončení může být náhlý pokles hodnoty chybové funkce nad trénovací množinou, což signalizuje začátek přeučení.

3. Zavedení validační množiny také napomáhá stanovit začátek přeučení.

4. K metodám předcházejícím přetrénování se patří "úzké hrdlo". Je to skrytá vrstva s relativně malým počtem neuronů. Omezuje reprezentace detailu v síti.

5. Zašumění dat. Umožňuje zabránit adaptaci na detaily.

6. Omezit počet epoch učení.

Výsledkem procesu učení jsou nastavené váhy umělé neuronové sítě, které vstupují do aktivní dynamiky sítě. V této fázi se všechny prvky sítě nacházejí v definovaném stabilním stavu a síť je připravena ke splnění stanoveného zadání [7][10].

1.5 Analýza hlavních komponent

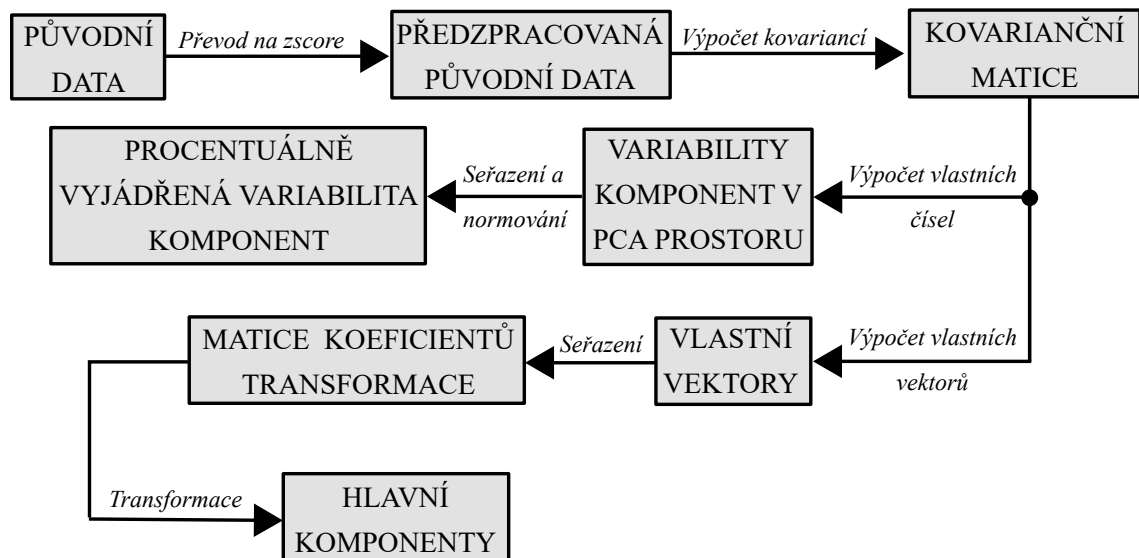
Analýza hlavních komponent nebo PCA (z angl. Principal Component Analysis) je jedna z nejvíce použitelných metod vícerozměrné analýzy. Cíli metody je zjednodušení popisu datového souboru užitím pouze prvních několika hlavních komponent, například pro vizualizaci dat, a zachování co největší složky informace pomocí minimálního množství proměnných. Podstata metody spočívá v transformaci původních znaků na nové, nekorelované proměnné, nazvané hlavní komponenty. Každá hlavní komponenta představuje lineární kombinaci původních znaků. Jejich základní charakteristikou je míra variability čili rozptyl. Algoritmus je navržen takovým způsobem, aby variabilita původních dat byla rozdělena mezi komponentami sestupně, totiž většina informace o variabilitě je soustředěna do první komponenty a nejméně informace je obsaženo v poslední. Klíčové pravidlo této analýzy říká, že má-li nějaký

původní znak malý či dokonce nulový rozptyl, není schopen přispívat k rozlišení mezi objekty [13].

Schéma výpočtu hlavních komponent je zobrazena na Obr. 1.14. Nejprve se znaky podléhají standardizaci. Uspořádání datového souboru A je takovým: sloupce korespondují znakům, řádky - jednotlivé objekty. Dál následuje výpočet kovarianční matice C . Její vlastní čísla D vyjadřují variability hlavních komponent v nových souřadnicích, a vlastní vektory V - koeficienty transformace dat. Seřazení vlastních čísel sestupně a jejich následující normování ukáže procentuálně vyjádřenou variabilitu komponent. Transformace původních dat se realizuje násobením matice vlastních vektorů na transponovanou matici vstupních dat, totiž:

$$O = V \cdot A^T, \quad (1.9)$$

kdy O - výstupní matice se novými souřadnicemi objektů [13].



Obr. 1.14: Schéma výpočtu hlavních komponent

Vlastnosti hlavních komponent:

1. hlavní komponenty jsou ortogonální;
2. rozptyly hlavních komponent se rovnají vlastním číslům kovarianční matice příznaků;
3. součet rozptylů příznaků se rovná součtu vlastních čísel kovarianční matice;
4. první hlavní komponenta má největší varianci.

2 Návrh algoritmu


Složitost návrhu klasifikátoru je způsobená tím, že podle zadání by klasifikátor měl být schopný určovat patologie kteréhokoliv obratle (C_3 až L_5), které jsou svými rozměry a strukturou podobné ale nejsou úplně stejné. Další komplikace spočívá v nemožnosti popsat patologie jednoznačnými pravidly. Tyto specifčnosti kladou určité požadavky na klasifikátor.

Vhodnou metodou řešení daného úkolu, totiž klasifikace obratlů, je použití neuronových sítí. Oproti obecným metodám strojového učení, neuronové sítě mají řadu výhod. Například schopnost sítí se učit umožňuje ze znalostní báze vyvést pravidla, která popisuje každou klasifikační skupinu. Je to velmi důležité, protože charakter projevu těch patologií je velmi různorodý a popsat ho obecnými pravidly buď není možné anebo je moc náročné. Další výhodou této metody je to, že neuronová síť dokáže popsat nelineární vztah mezi vstupem a výstupem a zobecnit rozhodovací pravidlo.

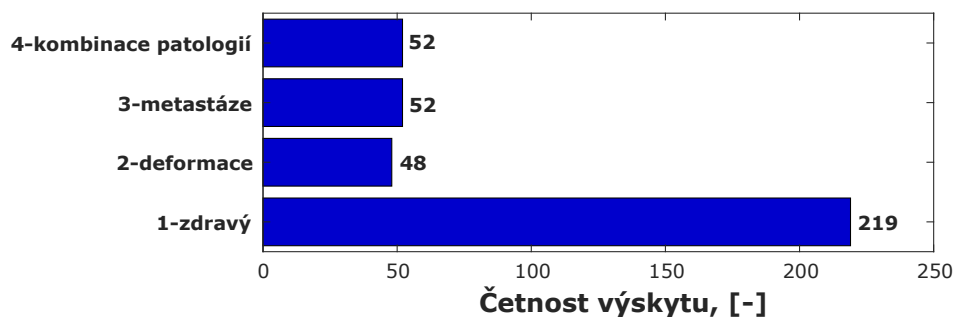
2.1 CT data

Požadavkem pro návrh neuronové sítě je učební množina. Pro vytvoření této množiny byla využita sada CT snímků páteře 18 pacientů, zdravých a nemocných, která byla získána ústavem Biomedicínského inženýrství VUT Brno v rámci spolupráce s jinými vědeckými institucemi. Tato data byla předzpracována, anonymizována a obsahovala 371 obratlových těl. Pomocí algoritmu popsaného v [9], bylo provedeno předzpracování. Obrazová data každého pacienta se skládala ze dvou objektů: prvním byla matice, která reprezentovala trojrozměrný snímek páteře (hodnoty voxelů korespondují s Hounsfieldovými jednotkami a jsou lineárně transformovány přičtením 1000 HU), a druhý - matice stejné velikosti jako první reprezentující indexační masky, které určují meze obratlových těl (je vidět na Obr. 2.1). Což umožnilo zpracovávat obratle jednotlivě.

Každé obratlové tělo bylo předem posouzeno lékařským expertem a byl určen jeho patologický stav. Dále na základě tohoto posudku do učební množiny byl přidán atribut informující do které klasifikační třídy patří příslušný obratel. Celkem jsou 4 třídy: zdravý obratel (1), deformovaný (2), s metastázemi (3), deformovaný a zároveň postižený metastázemi (4). Zastoupení výskytu jednotlivých klasifikačních tříd v původních datech lze vidět na Obr. 2.2. Poměr zdravých obratlů k patologickým je $219/152=1,44$.



Obr. 2.1: Ukázka učebních dat (vlevo), výsledky předzpracování (vpravo)



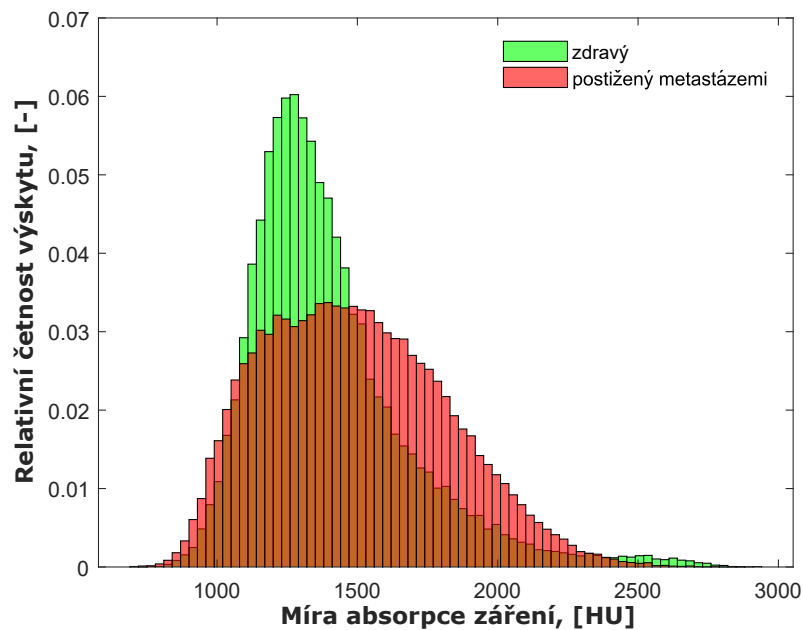
Obr. 2.2: Zastoupení výskytu jednotlivých klasifikačních tříd v původních datech

2.2 Příznaky a odůvodnění jejich volby


Celá sada zvolených příznaků se skládá z pěti podskupin. První čtyři jsou založeny na deskriptivní statistice, a pátá - na geometrii.

První podskupina. Histogram snímku zdravého obratle má asymetrické rozdělení s kladnou šikmostí, které můžeme vidět na Obr. 2.3 (zelená část grafu). Takový

tvár histogramu je způsoben spongiózní částí, která je prostorově větší a relativně homogenní (tvorí levou část histogramu), a kortikální částí – hraniční a s vyšší denzitou, která formuje pravý postupnější sklon. Změna tvaru histogramu v případě nádorového onemocnění je představena červeným histogramem (Obr. 2.3). První podskupina příznaků je zaměřena na odhalení tvarových změn histogramu, které jsou způsobeny patologiemi, a zahrnuje následující statistické příznaky: entropie, geometrický průměr, harmonický průměr, aritmetický průměr, medián, interkvartilní rozsah, průměrná absolutní odchylka, rozsah, směrodatná odchylka, koeficient špičatosti, šikmosti a modus. Postup výpočtu je uveden na Obr. 2.4,




Obr. 2.3: Normalizované histogramy zdravého a patologického obratlů z CT snímku




Obr. 2.4: Postup výpočtu příznaků podskupiny číslo 1

Druhá podskupina. Je zaměřena na detekci strmých změn absorpce záření způsobenými drobnými shluky nádorových buněk ve spongiózní části obratle. Proto se nejprve provádí eroze binární masky, která odstraňuje kortikální část. Pro erozi byla

použita maska 5x5x5. Obr. 2.5 je ukázkou výsledku erodování. V případě neprovedení eroze by nebylo možné rozeznat, které vysoké hodnoty v gradientním obrazu jsou způsobeny změnou hustoty v kortikální části, a které nádory. Dále se statistické příznaky (12 stejných příznaků jako u první podskupiny) počítají z gradientního obrazu voxelových hodnot spongiózní části obratlového těla (viz Obr. 2.6).




Obr. 2.5: Porovnání původní masky a erodované (rozdíl je označený zelenou barvou)




Obr. 2.6: Postup výpočtu příznaků podskupiny číslo 2

Třetí a čtvrtá podskupina. Počítají se obdobně jako druhá, ale na rozdíl od ní jsou vstupem do funkce výpočtu statistických znaků parametrické prostory lokálních směrodatných odchylek s různou velikostí okna. Pro podskupinu číslo tři byla použita maska $3 \times 3 \times 3$, a pro čtvrtou – maska $9 \times 9 \times 9$. Tento přístup umožňuje prozkoumat a odhalit drobné patologické prvky, jako například nádor v počáteční etapě. Ukázky postupů výpočtů jsou znázorněny v Obr. 2.7 a 2.8.

Pátá podskupina. Je zaměřena na popis geometrických vlastností obratlů. Tato sada příznaků zajišťuje detekci klasifikátorem zlomenin a deformací. Jelikož oblastí zájmu je pouze tvar obratle, pro výpočet příznaků se používá binární maska. Pomocí příkazu *regionprops3* se spočítají další vlastnosti: těžiště, váhované těžiště,




Obr. 2.7: Postup výpočtu příznaků podskupiny číslo 3



Obr. 2.8: Postup výpočtu příznaků podskupiny číslo 4

rozdíl mezi váhovaným a běžným těžištěm, Eulerovy úhly (úhly vycházejí z pravidla pravice), délky (ve voxelech) hlavních os elipsoidu, které mají stejné normalizované druhé centrální momenty (seřazeno od nejvyšší).



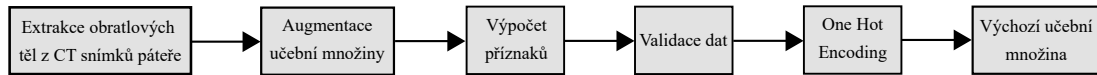
Obr. 2.9: Postup výpočtu příznaků podskupiny číslo 5

Kompletní seznam použitých příznaků je uveden v příloze na straně 42.

2.3 Příprava dat

Etapa přípravy dat je představená řetězcem kroků zobrazeným na Obr. 2.10. Nejprve se provádí extrakce voxelů, které reprezentují jednotlivá obratlová těla, z CT snímků páteře a rozšíření (augmentace) učební množiny přidáním šumu, který byl vygenerován jako matice náhodných hodnot (celá čísla) normálního rozložení s nulovou střední hodnotou a rozptylem 50 HU. Dále následuje výpočet příznaků. Navazující krok, validace, ukázal nepřítomnost chybějících hodnot a abnormální hodnoty geometrického a harmonického průměrů u 11 obratlů ($geommean=0$, $harmmean=0$). Na základě vzorců výpočtu těchto statistických příznaků lze udělat závěr, že výskyt nulové hodnoty je způsoben obsahováním nulových hodnot ve vstupních vektorech. Voxel s hodnotou 0 HU znamená, že absorpce a rozptyl záření v tomto bodu prostoru jsou stejné kdyby by záření procházelo vzduchem. Existence bubliny vzduchu nebo prostředí s vlastnostmi blízkými ke vzduchu je malopráděpodobná. A proto důvodem může být buď artefakt měření nebo následek přidání šumu. Tento problém

byl odstraněn nahrazením nulové hodnoty voxelu střední hodnotou absorpce záření voxelů z celého obratle. Závěrečným krokem je One Hot Encoding. Jelikož učební množina obsahuje kategorickou proměnnou (typ patologie), převedeme tu proměnnou na binární formu, která umožní učení modelu. V důsledku výchozí učební množina obsahuje 742 případů a 60 příznaků.



Obr. 2.10: Postup předzpracování dat

2.4 Počáteční model

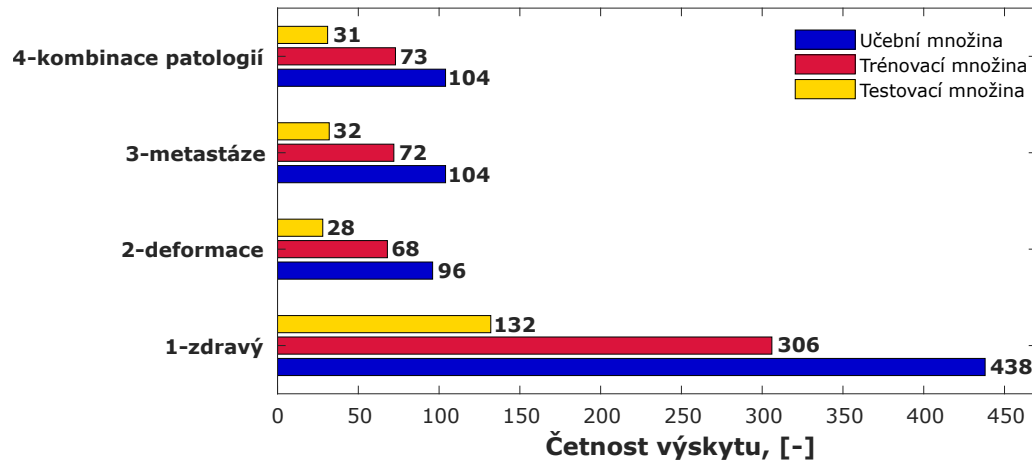
Počáteční model využívá všechny příznaky. Jako klasifikační algoritmus slouží dopředná neuronová síť. Důvodem této volby je nepotřebnost předem definovaných vah, nejsou omezení pro vstupní data.

Největší problém návrhu - volba počtu skrytých vrstev, neuronů, přenosové funkce a adaptačního algoritmu. Jak bylo zmíněno v teoretickém úvodu, neuronová síť se skládá ze třech oblastí. Vstupní vrstva je definována počtem příznaků vstupujících do sítě. Počet neuronů ve výstupní vrstvě závisí na počtu klasifikačních tříd.

Současně se navrhují dvě sítě s různými topologiemi. První je založena na důsledku z Kolmogorovy věty (rovnice 1.3), o které se zmiňovalo v oddílu 1.4.3, a podle ní síť bude mít následující topologii: 60-60-121-4-4, kdy první a poslední čísla reprezentují počet neuronů ve vstupní a výstupní vrstvě, a čísla mezi nimi – počet neuronů ve vnitřních vrstvách. Druhá má heuristický charakter a idea její návrhu vychází z rozsekání N -dimenzionálního prostoru příznaků (kdy N - počet příznaků) na větší množství subprostorů a následného slučování těch subprostorů, které obsahují objekty stejné klasifikační třídy. Prakticky to znamená navýšit počet neuronů v první skryté vrstvě (navýšení se bude skládat polovinu počtu příznaků) a postupným zmenšením počtu neuronů v dalších vrstvách bude realizováno slučování. Tudiž druhá síť bude mít topologii 60-90-50-16-4-4.

V obou modelech se jako přenosová funkce používá hyperbolická tangenciální sigmoidální funkce, optimalizační algoritmus – Resilient Backpropagation. Před učením sítě se učební množina dělí do dvou množin (70% – trénovací, 30% – testovací, viz Obr. 2.11) takovým způsobem, aby byl zachován stejný poměr výskytů klasifikačních tříd. Kritériem úspěšnosti je F-score. 1000×krát byla provedena inicializace a učení každé topologie. Kvůli náhodnému nastavení počátečních hodnot vah a prahů,

konvergence probíhala jinak a dosaženy výsledky byly různé. Výsledky této etapy jsou uvedeny v Tab. 2.1, nejlepší score má síť číslo 1, a score druhé je o 0.0265 menší. Hodnota směrodatné odchyly F-score ukazuje, že adaptační dynamika první sítě je silně ovlivněna počáteční inicializací vah.



Obr. 2.11: Zastoupení výskytu klasifikačních tříd v pomocných množinách

Tab. 2.1: Porovnání navržených počátečních neuronových sítí


Název sítě	Topologie	F-score nejlepší sítě	Průměr F-score ze všech 1000 sítí	Směrodatná odchylna F-score ze všech 1000 sítí
Sít č. 1	60-60-121-4-4	0,9551	0,5332	0,2675
Sít č. 2	60-90-50-16-4-4	0,9286	0,6923	0,0758

2.5 Zlepšení modelu

Tento krok má za cíl snížení výpočetní náročnosti a zabránění komplikace klasifikačního modelu identifikováním nevýznamných příznaků a jejich následujícím vyloučením za podmínky zachování dosažené síly klasifikace. Pro tento účel je využita Principal Component Analysis (PCA), díky které budou vyloučeny příznaky s minimální informační silou, a korelační analýza, na základě které se vyloučí korelované příznaky. Co se týká PCA tak je důležité vést v patrnosti to, že přístup vychází z předpokladu, že nejvíce se měnící příznaky jsou klíčové, což nemusí vždy platit.

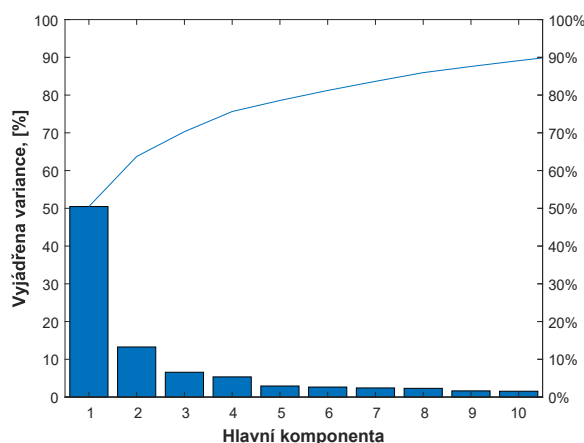
2.5.1 Aplikace PCA pro redukci příznaků

Tento oddíl popisuje postup redukce původních příznaků s využitím PCA, který má heuristický charakter. Přístup vychází z vlastností hlavních komponent. Jak se uvádělo v oddílu 1.5, první hlavní komponenty obsahují největší množství informace. A proto se vybírají několik prvních komponent, aby součet normovaných variabilit, které vyjadřují tyto komponenty, dosáhl požadované hodnoty (90%), a dál pracujeme jenom s těmi vybranými. Koeficienty transformace příznaku ukazují na informační příspěvek pro každou komponentu a na jejich základě se vypočítá váha informační síly a určuje se významnost tohoto příznaku. Detailní postup je uveden na Obr. 2.12.



Obr. 2.12: Redukce počtu příznaků pomocí PCA

Nejprve se provádí standardizace příznaků učební množiny, dále následuje PCA. Zvolí se 11 prvních komponent, jejichž součet vyjádřených variancí je 90,57% (viz Obr. 2.13). Absolutní hodnoty koeficientů (hodnoty z vlastních vektorů), které se používají pro transformaci příznaku do PCA prostoru, se sčítají a podléhají standardizaci. Tímto způsobem vzniká vektor hodnot informační síly každého příznaku. Všechny prediktory s hodnotou přínosu pod 0,2 se vylučují (hodnota prahu byla zjištěna empiricky). Důsledkem je redukce o 15 příznaků.



Obr. 2.13: Rozložení variance původních dat v hlavních komponentách

Podobně jako v kapitole 2.4 se navrhuje nové sítě a provádí se učení za účelem hodnocení vlivu redukce příznaků na klasifikační sílu. Úspěšnost první sítě se značně nezměnila a klesla o 0,0131 (viz Tab. 2.2). V případě sítě číslo 2 má redukce pozitivní vliv, protože F-score se zvýšilo o 0,0241.

Tab. 2.2: Porovnání neuronových sítí, které využívají 45 příznaků

Název sítě	Topologie	F-score nejlepší sítě	Průměr F-score ze všech 1000 sítí	Směrodatná odchylka F-score ze všech 1000 sítí
Sít č. 1	45-45-91-4-4	0,9420	0,6776	0,1642
Sít č. 2	45-68-34-17-4-4	0,9527	0,6825	0,0805

2.5.2 Aplikace korelační analýzy pro redukci příznaků

Vyloučení korelovaných příznaků dovoluje eliminovat ty prediktory, které popisují stejnou vlastnost obratle. Ještě jedním pádným důvodem použití korelační analýzy je optimalizace procesu učení neuronové sítě. V případě, kdy máme na vstupu nekorelovaná data, během učení hodnota váhy w_1 minimalizuje chybu nezávisle na hodnotě váhy w_2 [14]. V opačném případě je v hodnotách vah i -tého neuronu zakódovaná vzájemná závislost, která musí být během trénování naučena. Toto zbytečně komplikuje řešení klasifikačního problému.

Pro výpočet korelace se využívá Spearmanův korelační koeficient. Jako neparametrická metoda má menší sílu, ale oproti parametrickému Pearsonovu korelačnímu koeficientu, není náchylný k odlehlým hodnotám a neklade požadavek na normalitu rozložení vstupních dat [1].

Po získání korelační matice označíme páry korelovaných příznaků, jejichž absolutní hodnoty jsou vyšší než 0,8. Dále se provádí eliminování příznaků následujícím způsobem:

1. nejprve se vylučují příznaky s největším počtem nadprahových korelací;
2. ze dvou příznaků se stejným počtem nadprahových korelací bude vyloučen právě ten, jehož průměr absolutních hodnot korelačních koeficientů je vyšší;
3. pokud průměry ze druhého kroku budou stejné, volba pro vyloučení bude provedena náhodně.

V důsledku ze 45 příznaků zůstalo 20.

2.6 Finální klasifikační model

Podobně počátečním sítím se navrhuje finální. Tab. 2.3 ukazuje klasifikační vlastnosti výsledných modelů. Vyloučení korelovaných příznaků značně zhoršilo úspěšnost klasifikace, což ukazuje na ztrátu příznaků s vysokou klasifikační silou.


Tab. 2.3: Porovnání finálních neuronových sítí

Název sítě	Topologie	F-score nejlepší sítě	Průměr F-score ze všech 1000 sítí	Směrodatná odchylka F-score ze všech 1000 sítí
Sít č. 1	20-20-41-4-4	0,8550	0,6688	0,0584
Sít č. 2	20-30-23-12-4-4	0,8085	0,6619	0,0575

3 Dosažené výsledky a jejich diskuze

3.1 Finální klasifikační model a jeho charakteristiky

Počáteční modely neuronových sítí, které využívaly všechny 60 příznaků, demonstrovaly výbornou úspěšnost klasifikace (viz Obr. 3.1). Vysoká úroveň přesnosti ukazuje na správnou a účelnou volbu příznaků.



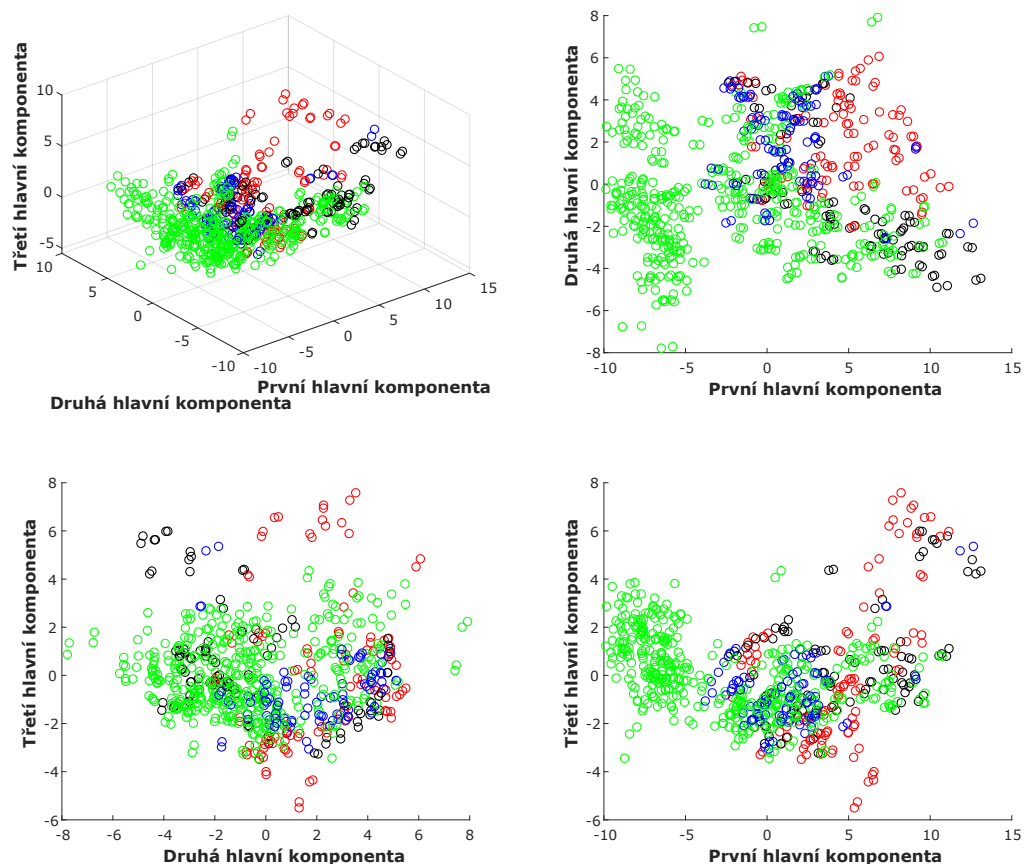
Obr. 3.1: Porovnání úspěšností klasifikace sítí za různých počtů příznaků

Aplikace PCA umožnila nejenom zredukovat počet původních příznaků, snížit výpočetní náročnost, ale i zlepšit úspěšnost klasifikace. Tento jev pozorujeme v případě sítě číslo 2: F-score stoupl o 0,0241. Ztráta exaktnosti klasifikace první sítě je neznatelná (0,0131). Toto znamená, že se pomocí PCA podařilo správně identifikovat příznaky s nízkou klasifikační silou, které způsobují šum v datech.

Následné vyloučení korelovaných příznaků mělo nevhodný vliv. F-score obou sítí značně klesla, průměrně o 0,12. Úloha identifikace patologických obratlů patří k té oblasti, kde cena chyby může stát závažné problémy se zdravím. Je nutné se vyhýbat krokům, které významně snižují úspěšnost klasifikace. A proto je vhodnější nepoužívat korelační analýzu a omezit se jenom PCA. Tudíž finální model pro klasifikace bude potřebovat 45 příznaků.

Je důležité konstatovat, že použití neuronové sítě pro tuto klasifikační úlohu je účelné. Jestli se podíváme na Obr. 3.2, kde pomocí PCA jsou zobrazena učební data, je vidět, že se klasifikační třídy překrývají. Navzdory tomu si neuronová síť dokázala identifikovat hranice klasifikačních tříd a zachovat úspěšnost klasifikace na akceptovatelné úrovni.

Ná základě charakteristik danými maticemi úspěšnosti zvolíme nejlepší síť. Další pomocné kritérium - přesnost klasifikace, poměr počtu správných klasifikovaných k celkovému počtu obratlů. Je vyšší u sítě č. 2 (viz Obr. 3.3, zelená hodnota v pravém



Obr. 3.2: Učební množina po PCA transformaci. Zelený kroužek - zdravý obratel, modrý - deformovaný, černý - s metastázami, červený - kombinace patologií.

dolním rohu). Jelikož pro tuto úlohu falešná pozitivita patologických obratlů má nižší váhu, než falešná pozitivita zdravých, pro porovnání modelů lze použít další metriku - průměr True Positive Rate (TPR) patologických tříd. Tímto způsobem lze porovnat schopnost sítí identifikovat patologie. Zelené hodnoty dolního řádku jsou TPR pro každou třídu. Spočítáme aritmetické průměry hodnot pro 2., 3. a 4. třídy. Pro síť č. 1 se tento parametr rovná 93,07 %, pro síť č. 2 - 94,5 %. Tudíž, druhá síť je citlivější na patologie.


Tudíž, finálním klasifikátorem je neuronová síť s architekturou uvedenou na Obr. 3.4, která pro třídění potřebuje 45 příznaků a má takové charakteristiky:

F-score = 0,9527,
sensitivity = 95,30%,
pozitivní prediktivní hodnota = 95,25%,
přesnost = 96,40%.

		Síť č. 1									
		1	2	3	4						
Predikovaná třída	1	128 57.4%	3 1.3%	0 0.0%	1 0.4%	97.0%					
	2	2 0.9%	24 10.8%	0 0.0%	0 0.0%	92.3%					
	3	2 0.9%	0 0.0%	32 14.3%	1 0.4%	91.4%					
	4	0 0.0%	1 0.4%	0 0.0%	29 13.0%	96.7%					
		97.0%	85.7%	100%	93.5%	95.5%					
		3.0%	14.3%	0.0%	6.5%	4.5%					
		Skutečná třída									

		Síť č. 2									
		1	2	3	4						
Predikovaná třída	1	129 57.8%	2 0.9%	1 0.4%	0 0.0%	97.7%					
	2	1 0.4%	26 11.7%	2 0.9%	0 0.0%	89.7%					
	3	1 0.4%	0 0.0%	29 13.0%	0 0.0%	96.7%					
	4	1 0.4%	0 0.0%	0 0.0%	31 13.9%	96.9%					
		97.7%	92.9%	90.6%	100%	96.4%					
		2.3%	7.1%	9.4%	0.0%	3.6%					
		Skutečná třída									

Obr. 3.3: Matice úspěšnosti




Obr. 3.4: Topologie finální neuronové sítě


3.2 Vizuální hodnocení výsledků

Na Obr. 3.5 jsou případy, kdy neuronová síť špatně identifikuje stav obratle (popisky obsahují opravdové diagnózy). Obratel T6 (a) klasifikátor chybně považuje za zdravý, i když tam je malý shluk nádorových buněk. Obdobné selhání má obratel L2 (b), ale na rozdíl od T6 (a) je zaříděn do skupiny 'Deformovaný'. Je možné, že malá deformace kortikální části (vpravo na obrázku) přispěla k nesprávnému výsledku. Tyto případy upozorňují na poměrně nízkou citlivost klasifikátoru na nádory v počáteční etapě. Obratel L1 (c) byl zařazen do třídy 'Kombinace patologií' i když podle posudku lékaře je označen jako deformovaný. Snad větší útlum záření v pravé dolní části obrázku byl považován za metastáze. Lze říct, že nesprávné výsledky klasifikace nejsou tak úplně náhodné a v některých případech je možné částečně odvodnit, proč na výstupu klasifikátoru je právě toto číslo klasifikační třídy.

Další Obr. 3.6 je věnován správným výsledkům klasifikace. Za úspěch se považuje schopnost sítě neidentifikovat cévní vstupy jako deformace. Je to dobře vidět v případech (a) a (c). Obratel C4 (b) byl korektně klasifikován jako obratel s metastázami, a v T4 (d) navzdory značnému postižení byly rozeznány tvarové změny obratle a výskyt nádorového onemocnění.



Obr. 3.5: Ukázka výsledků chybné klasifikace obratlů (axiální řez)



Obr. 3.6: Ukázka výsledků správné klasifikace obratlů (axiální řez)

3.3 Chybovost a její zdroje

V případě dopracování klasifikačního modelu pro umožnění praktického uplatnění bude nutné značně rozšířit učební data. Aby byla zachována přijatelná úspěšnost klasifikace, probereme co ji může ovlivňovat a čemu se musíme vyhýbat. Faktory vlivu, které jsou uvedeny níže platí a pro získaný model.

1. Různorodost projevu patologií. Existuje řada typů zlomenin a deformací obratlů, nádorová onemocnění v různých etapách různě poškozují obratlová těla. Toto způsobuje velmi velké množství možných projevů patologií, což klade požadavek na úplnost učební množiny. Jestli bude možné získat bohatá učební data, což na jedné straně je dobré, je nutné počítat s nutností upravit topologii, navýšením počtu neuronů a vrstev, aby si síť byla schopná poradit s komplikovanější úlohou. Další možnost úpravy algoritmu - měnit práh informační síly při aplikování PCA (viz oddíl 2.5.1), rozšířit sadu příznaků.

2. Počet obratlů v klasifikačních třídách. Malé množství obratlů v klasifikační třídě nepostačuje pro identifikaci sítí etalonu a může být považováno jako šum v datech. Řešení - snažit se stejně zastoupit každou třídu.

3. Vliv předzpracování obrazových dat. Tento faktor zahrnuje vliv vlastností a nastavení zařízení, která byla použita pro sejmутí CT snímků, vliv artefaktů a metod jejich odstranění, vlastnosti algoritmu segmentace obratlových těl.

4. Nedostatek dalších signifikantních příznaků.

5. Lidský faktor. Při sestavení učební množiny může dojít k zatřídění obratle do té třídy, ke které ten obratel opravdu nepatří.

4 Závěr

V této práci byl navržen, popsán a realizován algoritmus pro detekci patologických obratlů a následnou klasifikaci typu patologie v CT snímcích páteře s využitím metod strojového učení.

První část obsahuje anatomický přehled obratle, popis typů patologií a jejich projev v CT datech, základy teorie klasifikace, stručný přehled dosavadních metod zaměřených na řešení této úlohy, teoretický přehled neuronových sítí, metod a specifičností jejich učení, podstata metody PCA.

Ve druhé části jsou popsána data, která byla použita pro trénování klasifikačního modelu, příznaky a odůvodnění jejich volby, augmentace dat, extrakce příznaků a příprava testovacích a trénovacích množin. Příznaky jsou založené na využití deskriptivní statistiky a geometrie. Navazující kapitola popisuje návrh dopředných neuronových sítí lišící se topologií, jejich charakteristiky a postupy učení. V dalších kapitolách je zahrnut algoritmus aplikace PCA, korelační analýzy pro redukci počtu původních příznaků a vliv těchto obou etap redukce na klasifikační sílu. Jako kritérium hodnocení úspěšnosti klasifikace konkrétní neuronové sítě bylo použito F-score. Navržená metoda byla realizována v programovém prostředí MATLAB[®] s využitím Deep Learning Toolbox[®]. Pomocí PCA byl původní počet příznaků snížen o 25% (z 60 příznaků na 45) se zachováním úspěšnosti klasifikace na akceptovatelné úrovni. Aplikace korelační analýzy byla vyloučena z důvodu značného snížení F-score.

V poslední části jsou probrány dosažené výsledky, na základě F-score a pomocné metriky (TPR) je vybrána finální neuronová síť, jsou diskutovány zdroje chybovosti a možné metody snížení jejich vlivu.

Výsledkem této diplomové práce je algoritmus extrakce příznaků z CT obrazových dat a následné zpracování neuronovou sítí pro klasifikaci zdravotního stavu obratlového těla. Charakteristiky klasifikátoru: F-score = 0,9527, TPR = 95,30%, pozitivní prediktivní hodnota = 95,25%, přesnost = 96,4%.

Literatura

- [1] BAŠTINEC, J., FAJMON, B., KOLÁČEK, J. *Pravděpodobnost, statistika a operační výzkum*. Brno, 2014. 360 stran.
- [2] BEALE, M., H., DEMUTH, H., B., HAGAN, M., T. *Neural Network Toolbox. User's Guide*. [online], 2015, poslední aktualizace 9. 2015. Dostupné z URL: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.699.4831&rep=rep1&type=pdf>>
- [3] BRIDWELL, Keith. *Vertebral Column*. [online]. Dostupné z URL: <<https://www.spineuniverse.com/anatomy/vertebral-column>>
- [4] CARNEY, Linda. *How the Calcium Paradox Baffles Bone Beliefs*. [online]. Dostupné z URL: <<https://www.drcarney.com/blog/health-issues/how-the-calcium-paradox-baffles-bone-beliefs>>
- [5] DYLEVSKÝ, Ivan. *Funkční anatomie*. Praha: Grada, 2009. ISBN 978-80-247-3240-4.
- [6] HOLČÍK, Jiří. *Analýza a klasifikace signálů*. Brno: Vysoké učení technické, 1992. ISBN 80-214-0450-7.
- [7] HOLČÍK, J., KOMENDA, M. *Matematická biologie: e-learningová učebnice [online]*. 1. vyd. Brno: Masarykova univerzita, 2015. ISBN 978-80-210-8095-9.
- [8] HONZÍK, P., HONZÍKOVÁ, N. *Biologie člověka*. Vysoké učení technické v Brně, Brno, 2003, 134 s.
- [9] JAKUBÍČEK, R., a kol. *Fully Automatic CAD System for Spine Localisation and Vertebra Segmentation in CT Data*. In World Congress on Medical Physics and Biomedical Engineering 2018, IFMBE PROCEEDINGS, Singapore: Springer, 2018. s. 223-226. ISBN: 978-981-10-9034-9. ISSN: 1680-0737.
- [10] JAN, Jiří. *Číslíková filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002. ISBN 80-214-1558-4.
- [11] JAN, J., a kol. *Combined bone lesion analysis in 3D CT data of vertebrae*. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC): August 25-29, 2015. Piscataway, N.J.: IEEE, pp. 6374-6377. ISBN 978-1-4244-9271-8.
- [12] KOZUMPLÍK, Jiří: *Analýza biologických signálů (rozpracovaná skripta)*. Brno: FEKT VUT v Brně, 2007. s. 1-60

- [13] MELOUN, M., MILITKÝ, J.: *Statistická analýza experimentálních dat*. Vyd. 2., upr. a rozš. Praha: Academia, 2004. ISBN 80-200-1254-0.
- [14] MONTAVON, Grégoire. *Neural networks: tricks of the trade*. 2nd ed. Berlin: Springer, 2012. Lecture notes in computer science. ISBN 978-3-642-35288-1.
- [15] POKORNÝ, Miroslav. *Umělá inteligence v modelování a řízení*. Praha: BEN - technická literatura, 1996. ISBN 80-901984-4-9.
- [16] ROTH, H. R., a kol. *Improving Computer-Aided Detection Using Convolutional Neural Networks and Random View Aggregation*. IEEE Transactions on Medical Imaging, Vol. 35, No. 5, pp. 1170-1181, 2015.
- [17] SHENG-FANG, H., KUO-HSIEN, C. *Automatic detection of bone metastasis in vertebrae by using CT images*. Proceedings of the World Congress on Engineering 2012, WCE 2012, 4-6 July, 2012, London, U.K., pp. 1166-1171. ISBN 978-988-19252-1-3.
- [18] VOLNÁ, Eva. *Neuronové sítě 1*. Skriptum. Ostrava: Ostravská univerzita, 2008.
- [19] YAO, J., O'CONNOR, S. D., SUMMERS, R. M. *Computer Aided Detection of Lytic Bone Metastases in the Spine using Routine CT Images*. 2007 4th IEEE International Symposium on Biomedical Imaging—Macro to Nano: April 12-15, 2007. Piscataway, N.J.: IEEE, c2007, pp. 512-515. ISBN 1-4244-0671-4.
- [20] ŽELEZNÝ, M. *Strukturální metody rozpoznávání*. [online]. Dostupné z URL: <<http://www.kky.zcu.cz/uploads/courses/smr/Smr-130924.pdf>>
- [21] *Biomedical Examples (Biomedical Image Analysis)*. [online]. Dostupné z URL: <<http://what-when-how.com/biomedical-image-analysis/biomedical-examples-biomedical-image-analysis-4/>>

Seznam symbolů, veličin a zkratk

ANOVA	analýza rozptylu – Analysis of Variance
BP	zpětné šíření – Back Propagation
CT	výpočetní tomografie – Computed Tomography
MISO	system s mnoha vstupy a jedním výstupem – Multi-Input-Single-Output
PCA	analýza hlavních komponent – Principal Component Analysis
TPR	míra pravdivé pozitivity – True Positive Rate

Seznam příloh

A Seznam příznaků a výstup PCA analýzy

42

A Seznam příznaků a výstup PCA analýzy

Tabulka obsahuje seznam všech příznaků a koeficienty transformace pro první 3 hlavní komponenty PCA.

№	Příznak	PC1	PC2	PC3
1	Entropy	0,176473841	0,023998666	-0,044589357
2	GeometricMean	0,116357561	-0,078662116	0,316284897
3	HarmonicMean	0,104752612	-0,083577194	0,334833813
4	Mean	0,126480865	-0,073109019	0,295546122
5	Median	0,106959281	-0,083602619	0,347437704
6	InterquartileRange	0,175709386	-0,008498787	0,037867925
7	MeanAbsDeviation	0,179001167	0,011657461	-0,015263351
8	Range	0,14758431	0,089024422	-0,144983723
9	StandardDeviation	0,178570284	0,020843173	-0,042980567
10	Kurtosis	-0,14076871	0,021571078	-0,091532882
11	Skewness	-0,122011859	0,058557695	-0,286826562
12	Mode	0,076542218	-0,077826091	0,374316175
13	Gradient_GeometricMean	0,172442142	0,011607843	0,03503708
14	Gradient_HarmonicMean	0,170316796	0,010770843	0,045157681
15	Gradient_Mean	0,173503816	0,014543947	0,020006931
16	Gradient_Median	0,170196942	0,007441512	0,043257453
17	Gradient_InterquartileRange	0,163443395	0,009353907	0,003613736
18	Gradient_MeanAbsDeviation	0,165702543	0,021619	-0,017473067
19	Gradient_Range	0,149821911	0,133209961	-0,092166299
20	Gradient_StandardDeviation	0,165101475	0,032212364	-0,033276136
21	Gradient_Kurtosis	-0,043210482	0,069377647	-0,092189
22	Gradient_Skewness	-0,026690666	0,108881786	-0,15102335
23	Gradient_Mode	0,10134896	-0,01379603	0,074647536
24	STD_3x3x3_GeometricMean	0,172646776	-0,002775108	-0,033782179
25	STD_3x3x3_HarmonicMean	0,168443159	0,003328911	-0,01990589
26	STD_3x3x3_Mean	0,175651503	-0,00573573	-0,051022208
27	STD_3x3x3_Median	0,172573516	-0,020080186	-0,025815964
28	STD_3x3x3_InterquartileRange	0,163561539	-0,037986104	-0,138726068
29	STD_3x3x3_MeanAbsDeviation	0,165180878	-0,008170506	-0,14313422
30	STD_3x3x3_Range	0,146730662	0,079503171	-0,188703882
31	STD_3x3x3_StandardDeviation	0,164865839	0,003337346	-0,143940472
32	STD_3x3x3_Kurtosis	-0,141114756	0,049994591	0,139143203
33	STD_3x3x3_Skewness	-0,150942397	0,079511227	0,105789398
34	STD_3x3x3_Mode	0,126755993	0,080289659	0,000946346
35	STD_9x9x9_GeometricMean	0,179527057	-0,029574253	0,012766482
36	STD_9x9x9_HarmonicMean	0,17804785	-0,03408351	0,020003924
37	STD_9x9x9_Mean	0,180287565	-0,024126384	0,004335038
38	STD_9x9x9_Median	0,179345306	-0,035405393	0,010603456
39	STD_9x9x9_InterquartileRange	0,131724107	0,095690972	-0,077854941
40	STD_9x9x9_MeanAbsDeviation	0,135855169	0,069205535	-0,092322562
41	STD_9x9x9_Range	0,090518212	0,059326537	-0,172576887
42	STD_9x9x9_StandardDeviation	0,131392606	0,052080359	-0,10848202
43	STD_9x9x9_Kurtosis	-0,113694945	-0,052449906	0,048940738
44	STD_9x9x9_Skewness	-0,14205144	-0,009655264	0,018504835
45	STD_9x9x9_Mode	0,111596837	0,082115276	0,046207155
46	Centroid_x	-0,012775459	0,301903088	0,123728986
47	Centroid_y	-0,031501981	0,300489883	0,069862814
48	Centroid_z	0,037253098	0,288794766	0,063995879
49	WeightedCentroid_x	-0,013257442	0,301531297	0,123590526
50	WeightedCentroid_y	-0,033306284	0,301937504	0,071247422
51	WeightedCentroid_z	0,036500099	0,290529718	0,062436822
52	CentroidMinusWeightedCentroid_x	0,012061767	-0,005373278	-0,002532898
53	CentroidMinusWeightedCentroid_y	0,046656529	-0,004423462	-3,03E-02
54	CentroidMinusWeightedCentroid_z	0,021348388	-0,098481278	0,045929395
55	Orientation_alpha	-0,021082423	-0,015390886	-0,026066238
56	Orientation_beta	0,014876906	-1,46E-02	-0,04228899
57	Orientation_gama	0,000813865	-0,010132641	0,050722144
58	PrincipalAxisLength_highest	-0,009058337	0,330099179	0,090364553
59	PrincipalAxisLength	-3,21E-05	0,331065784	0,104774386
60	PrincipalAxisLength_lowest	-0,027964899	0,318238494	0,035935972