


VYSOKÉ UČENÍ TECHNICKÉ
V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A
KOMUNIKAČNÍCH
TECHNOLOGIÍ

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND
COMMUNICATION

DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE SIGNÁLU EKG

ECG SIGNAL CLASSIFICATION

Diplomová práce
MASTER'S THESIS

Autor práce
AUTHOR

Bc. Tomáš Smělý

Vedoucí práce
SUPERVISOR

Ing. Jan Hruběš

BRNO, 2008

ZDE VLOŽIT ORIGINALNÍ ZADÁNÍ DIPLOMOVÉ PRÁCE

LICENČNÍ SMLOUVA

POSKYTOVANÁ K VÝKONU PRÁVA UŽÍT ŠKOLNÍ DÍLO

uzavřená mezi smluvními stranami:

1. Pan/paní

Jméno a příjmení: Tomáš Smělý
Bytem: Miřetín 36, Proseč 539 44
Narozen/a (datum a místo): 22. července 1984 v Chrudimi
(dále jen „autor“)

a

2. Vysoké učení technické v Brně

Fakulta [elektrotechniky a komunikačních technologií](#)
se sídlem [Údolní 53, Brno, 602 00](#)
jejímž jménem jedná na základě písemného pověření děkanem fakulty:
[prof. Ing. Jiří Jan, CSc, předseda rady oboru Biomedicínské a ekologické inženýrství](#)
(dále jen „nabyvatel“)

Čl. 1

Specifikace školního díla

1. Předmětem této smlouvy je vysokoškolská kvalifikační práce (VŠKP):

- disertační práce
 - diplomová práce
 - bakalářská práce
 - jiná práce, jejíž druh je specifikován jako
- (dále jen VŠKP nebo dílo)

Název VŠKP: Klasifikace signálu EKG
Vedoucí/ školitel VŠKP: Ing. Jan Hrubeš
Ústav: Ústav biomedicínského inženýrství
Datum obhajoby VŠKP: _____

VŠKP odevzdal autor nabyvateli*:

- v tištěné formě – počet exemplářů: 2
- v elektronické formě – počet exemplářů: 2

2. Autor prohlašuje, že vytvořil samostatnou vlastní tvůrčí činností dílo shora popsané a specifikované. Autor dále prohlašuje, že při zpracovávání díla se sám nedostal do rozporu s autorským zákonem a předpisy souvisejícími a že je dílo dílem původním.
3. Dílo je chráněno jako dílo dle autorského zákona v platném znění.
4. Autor potvrzuje, že listinná a elektronická verze díla je identická.

* hodící se zaškrtněte

Článek 2

Udělení licenčního oprávnění

1. Autor touto smlouvou poskytuje nabyvateli oprávnění (licenci) k výkonu práva uvedené dílo nevýdělečně užít, archivovat a zpřístupnit ke studijním, výukovým a výzkumným účelům včetně pořizování výpisů, opisů a rozmnoženin.
2. Licence je poskytována celosvětově, pro celou dobu trvání autorských a majetkových práv k dílu.
3. Autor souhlasí se zveřejněním díla v databázi přístupné v mezinárodní síti
 - ihned po uzavření této smlouvy
 - 1 rok po uzavření této smlouvy
 - 3 roky po uzavření této smlouvy
 - 5 let po uzavření této smlouvy
 - 10 let po uzavření této smlouvy
(z důvodu utajení v něm obsažených informací)
4. Nevýdělečné zveřejňování díla nabyvatelem v souladu s ustanovením § 47b zákona č. 111/ 1998 Sb., v platném znění, nevyžaduje licenci a nabyvatel je k němu povinen a oprávněn ze zákona.

Článek 3

Závěrečná ustanovení

1. Smlouva je sepsána ve třech vyhotoveních s platností originálu, přičemž po jednom vyhotovení obdrží autor a nabyvatel, další vyhotovení je vloženo do VŠKP.
2. Vztahy mezi smluvními stranami vzniklé a neupravené touto smlouvou se řídí autorským zákonem, občanským zákoníkem, vysokoškolským zákonem, zákonem o archivnictví, v platném znění a popř. dalšími právními předpisy.
3. Licenční smlouva byla uzavřena na základě svobodné a pravé vůle smluvních stran, s plným porozuměním jejímu textu i důsledkům, nikoliv v tísní a za nápadně nevýhodných podmínek.
4. Licenční smlouva nabývá platnosti a účinnosti dnem jejího podpisu oběma smluvními stranami.

V Brně dne: 30. května 2008

.....
Nabyvatel

.....
Autor

Abstrakt

Tato diplomová práce se zabývá klasifikací různých průběhů EKG signálů. Úkolem bylo rozpoznat normální cykly od různých typů arytmií a určit, o jaké poruchy se jedná. Klasifikace byla provedena pomocí neuronových sítí v nadstavbě programového prostředí Matlab (Neural Network Toolbox). Výsledkem této práce je aplikace, která po načtení EKG signálu z databáze provede jeho předzpracování a následnou klasifikaci jednotlivých kvaziperiod do pěti různých tříd. Procentuální výsledky klasifikace jsou uvedeny v závěru práce.

Klíčová slova

Elektrokardiogram, klasifikace EKG, neuronové sítě, NS, srdce, arytmie, normální cyklus, extrasystoly, BPRT, BPLT, kardiostimulace, VPS, BP, tansig, filtrace, Matlab, Guide.

Abstract

This thesis deals with classification of different types of time courses of ECG signals. Main objective was to recognize the normal cycles and several forms of arrhythmia and to classify the exact types of them. Classification has been done with usage of algorithms of Neural Networks in Matlab program, with its add-on (Neural Network Toolbox). The result of this thesis is application, which makes possible to load an ECG signal, pre-process it and classify its each cycle into five classes. Percentage results of this classification are in the conclusion of this thesis.

Key words

Electrocardiogram, ECG classification, Neural Networks, NN, arrhythmia, heart, normal contraction, extra systole, BPRT, BPLT, cardio stimulation, MLP, BP, filtration, tansig, Matlab, Guide.

SMĚLÝ, T. *Klasifikace signálu EKG: diplomová práce*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008. 55 s. Vedoucí diplomové práce Ing. Jan Hruběš.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Klasifikace signálu EKG 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 jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 30. května 2008

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Janu Hruběšovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce. Taktéž bych chtěl poděkovat Ing. Dině Kičmerové, která byla vedoucím semestrálního projektu, na který diplomová práce navazovala.

Velký dík náleží také všem mým blízkým a přátelům, především pak mým rodičům Dagmar a Milošovi Smělým a mé přítelkyni Larise Kiričenkové, kteří mě po všech stránkách podporovali po celou dobu mého studia.

V Brně dne 30. května 2008

.....
podpis autora

Obsah

1	Úvod	13
2	EKG signál	14
2.1	Anatomický úvod	14
2.2	Základy elektrofyziologie	15
2.3	Geneze elektrického pole srdečního	16
2.4	Snímání elektrické aktivity srdce	17
2.5	Typy průběhů EKG signálů.....	19
2.5.1	Normální cyklus EKG signálu.....	19
2.5.2	Předčasné stahy (Extrasystoly).....	20
2.5.3	Raménkové blokády.....	22
2.5.4	EKG signál po kardiostimulaci.....	23
3	Neuronové sítě	24
3.1	Úvod.....	24
3.2	Vlastnosti neuronových sítí.....	24
3.3	Rozdělení neuronových sítí.....	25
3.4	Biologický neuron.....	26
3.5	Klasifikace vzorů	27
3.6	Lineární klasifikace.....	28
3.7	Neuronové sítě se zpětným šířením chyby	30
4	Klasifikace EKG signálu	33
4.1	Klasifikace Dvou typů průběhů EKG signálu	33
4.1.1	Nahrání vstupních dat.....	33
4.1.2	Předzpracování signálů pomocí filtrace.....	34
4.1.3	Vytvoření vstupního vektoru pro neuronovou síť.....	35
4.1.4	Klasifikace pro dva záznamy 106 a 200.....	36
4.1.5	Klasifikace pro celou databázi.....	37
4.2	Klasifikace pro více typů signálů	42
4.2.1	Využití jednoho výstupního neuronu	42
4.2.2	Využití více výstupních neuronů.....	43
4.2.3	Klasifikace pomocí souboru neuronových sítí	44
5	Závěr	53
6	Použitá literatura.....	54
	Příloha A	55

Seznam Obrázků

Obrázek 1: Anatomie srdce	14
Obrázek 2: Šíření akčního potenciálu	16
Obrázek 3: Končetinové svody dle Einthovena.....	17
Obrázek 4: Semiunipolární Goldbergovy svody.....	18
Obrázek 5: Uložení jednotlivých elektrod 6 hrudních unipolárních svodů.....	18
Obrázek 6: Normální stah EKG signálu	19
Obrázek 7: Předčasný komorový stah	21
Obrázek 8: Blokáda levého Tawarova raménka	22
Obrázek 9: Blokáda pravého Tawarova raménka.....	23
Obrázek 10: EKG signál po kardiostimulaci.....	23
Obrázek 11: Biologický neuron.....	26
Obrázek 12: Klasifikace dvou vzorů.....	27
Obrázek 13: Vztah hraniční přímky a váhového vektoru.....	28
Obrázek 14: Model neuronu	30
Obrázek 15: Architektura sítě typu back-propagation	30
Obrázek 16: Model neuronu	31
Obrázek 17: Výstupní funkce neuronů v MatLabu	32
Obrázek 18: Blokové schéma klasifikace EKG pomocí neuronových sítí	33
Obrázek 19: Signál EKG - normální stah a předčasná komorová kontrakce	33
Obrázek 20: Filtrace signálu 121 pomocí Lynnova filtru	34
Obrázek 21: Blokové schéma navrženého filtru.....	34
Obrázek 22: Výsledky klasifikace pro záznam 106.....	36
Obrázek 23: Výsledky klasifikace pro záznam 200.....	37
Obrázek 24: Výstupní funkce neuronů v Matlabu	37
Obrázek 25: Chyby simulace pro záznam 105	39
Obrázek 26: Chyby simulace pro záznam 233	39
Obrázek 27: Chyby simulace pro záznam 222	40
Obrázek 28: Chyby simulace pro záznam 214	41
Obrázek 29: Rozhodovací úrovně pro tři různé typy EKG signálů	42
Obrázek 30: Výsledky simulace pro tři různé typy EKG signálů	42
Obrázek 31: Principiální schéma použití více výstupních neuronů	43
Obrázek 32: Neuronová síť s jedním výstupním neuronem.....	44
Obrázek 33: Blokové schéma principu učení neuronové sítě	44
Obrázek 34: Klasifikace pomocí aplikace v Guide	47
Obrázek 35: Grafické znázornění klasifikace záznamu 214	48
Obrázek 36: Grafické znázornění klasifikace záznamu 207	49
Obrázek 37: Grafické znázornění klasifikace záznamu 107	50
Obrázek 38: Grafické znázornění klasifikace záznamu 116	52

Seznam tabulek

Tabulka 1:	Deklarace vstupního vektoru.....	35
Tabulka 2:	Výsledky simulace pro signály, které obsahují oba typy signálů	38
Tabulka 3:	Výsledky simulace pro signály, které obsahují pouze normální cyklus	40
Tabulka 4:	Výsledky simulace pro signály, které obsahují pouze V	41
Tabulka 5:	Způsob naučení neuronové sítě na binární hodnoty 0 a 1	43
Tabulka 6:	Označení jednotlivých typů EKG signálů.....	45
Tabulka 7:	Výsledky po simulaci celé neuronové sítě.....	45
Tabulka 8:	Kódování jednotlivých typů EKG signálu.....	46
Tabulka 9:	Výsledky klasifikace pro signály, které obsahují L.....	48
Tabulka 10:	Výsledky klasifikace pro signály, které obsahují R	49
Tabulka 11:	Výsledky klasifikace pro signály, které obsahují P	50
Tabulka 12:	Výsledky klasifikace pro signály, které neobsahují L, R, P	51
Tabulka 13:	Dosažené výsledky klasifikace pomocí neuronové sítě.....	52
Tabulka 14:	Seznam všech záznamů z databáze [1].....	55

Seznam použitých zkratk

aVR – označení unipolárního končetinového svodu pravé ruky
aVL – označení unipolárního končetinového svodu levé ruky
aVF – označení unipolárního končetinového svodu levé nohy
ARF – absolutní refrakterní fáze
BP – back-propagation
BPRT – blokáda pravého Tawarova raménka
BPLT – blokáda levého Tawarova raménka
ECG – elektrokardiogram
EKG – elektrokardiogram
eV – elektronvolty
HP – horní propust
CH – chronaxie
L – typ průběhu EKG signálu blokáda levého Tawarova raménka
MLP – multi Layer Perceptron
N – typ průběhu EKG signálu normální cyklus
NN – neural network
NS – neuronová síť
NNT – Neural Network Toolbox
P – typ průběhu EKG signálu po kadriostimulaci
QRS – komplex vln EKG signálu
R – typ průběhu EKG signálu blokáda pravého Tawarova raménka
RE – reobáze
RR – interval EKG signálu
RRF – relativní refrakterní fáze
SA – sinoatriální uzel
T – vlna T
U – vlna U
V1 – označení prvního hrudního svodu
V2 – označení druhého hrudního svodu
V3 – označení třetího hrudního svodu
V4 – označení čtvrtého hrudního svodu
V5 – označení pátého hrudního svodu
V6 – označení šestého hrudního svodu
VPS – vrstevnatá perceptronová síť
V – typ průběhu EKG signálu předčasná komorová kontrakce
W – váhový vektor


1 Úvod

Elektrokardiografie je velmi jednoduché, nenáročné a hlavně nebolestivé vyšetření, díky kterému má lékař přehled o elektrické aktivitě srdce. Každý stah srdečního svalu je doprovázen vznikem slabého elektrického napětí, které se šíří až na povrch lidského těla, kde ho lze snímat EKG přístrojem. Právě proto je důležité EKG signál zkoumat, analyzovat a klasifikovat pomocí stále nových algoritmů, mezi které zajisté patří i neuronové sítě. Neuronové sítě jsou jednou z oblastí, které se v posledních letech věnuje zvýšená pozornost. Je to zapříčiněno tím, že mají mnoho vlastností, které lze s úspěchem využít v řadě oborů, kde je kladen důraz na univerzálnost, jednoduchost použití, systematický návrh. Sem právě patří známý a ve školství pravděpodobně nejrozšířenější nástroj pro práci s umělými neuronovými sítěmi - knihovna Neural Network Toolbox (NNT), nadstavba matematického prostředí MATLAB. Práce s tímto výkonným prostředkem je námět tohoto projektu. NNT byl použit ke klasifikaci EKG signálu z dostupné databáze physionetu [1].

2 EKG signál

2.1 Anatomický úvod

Srdce je uloženo v hrudní dutině, ve střední rovině, odkud vybíhá příčně dopředu, mírně dolů vlevo. Jeho zadní stěna naléhá na jícn, dolní stěna leží na bránici a hrot srdeční (apex) směřuje jeden až dva cm pod levou prsní bradavku (páté mezižebří).



1. oblouk aorty
2. plicní žíly
3. vzestupná část aorty
4. cévní kmen plicnice
5. věnčité tepny
6. žíly srdce
7. sestupná část aorty
8. horní dutá žíla
9. dolní dutá žíla

Obrázek 1: Anatomie srdce

Srdce (cor, kardia) (viz obrázek 1) je svým původem céva. Stavba srdeční stěny proto v principu odpovídá stavbě stěny velkých cév. Lidské srdce má čtyři dutiny - dvě síně (atria) a dvě komory (ventriculi). Pravá síň a pravá komora tvoří tzv. pravé srdce, oddělené síňovou a komorovou přepážkou (septem) od levé síně a komory, které vytvářejí tzv. levé srdce. Mezi pravou síní a pravou komorou je dvojčipá chlopeň, mezi levou síní a komorou je dvojčipá chlopeň (mitrální). Do pravé srdeční síně přitéká horní a dolní dutou žilou odkysličená krev z orgánů a tkání těla. Smrštěním pravé síně je krev vypuzena do pravé komory a po jejím smrštění plicnicovým kmenem a plicními tepnami do plic. Z plic se vrací okysličená krev čtyřmi plicními žilami do levé srdeční síně. Při stlačení levé síně je krev přečerpána do levé komory. Z levé komory začíná srdečnice (aorta) rozvádět krev do celého těla. Srdeční sval má dvě základní vlastnosti - dráždivost a stažlivost. Dráždivostí rozumíme schopnost srdečního svalu se na vhodný podnět zkrátit, smrstit se. Za normálních okolností je podnětem ke smrštění (kontrakci) elektrický impuls vycházející ze zvláštních oblastí srdeční svaloviny (myokardu). Stažlivost způsobuje, že srdce je pružná svalová pumpa, jejíž čtyři dutiny se v navazujícím sledu plní krví a vyprazdňují se. Naplnění krví se nazývá diastola, vypuzení krve do oběhu – systola. Hodnoty naplnění a vypuzení zjišťujeme měřením krevního tlaku.

Normální (fysiologické) srdce by mělo mít tyto parametry:

- Norma systoly je 120-140 mmHg, norma diastoly 80-90 mmHg. Vysoký tlak krve - hypertenze je více jak 160/95 mmHg. Nízký krevní tlak - hypotenze je nižší než 100/60 mmHg.

- Tepová frekvence určuje počet srdečních stahů – tepů za minutu. U dospělého člověka v klidu je 70 – 80 tepů za minutu. Zrychlení tepové frekvence (tachykardie) je více jak 100 tepů za minutu v klidu. Zpomalení (bradykardie) je pod 60 tepů za minutu v klidu. Kvalita tepu může být různá: při normální akci je puls pravidelný, jasný. Dále může být tep nitkovitý při hypotenzi a v šoku nebo střídavý při poruše srdečního rytmu (arytmii) či při selhávání levé srdeční komory.
- Tepový srdeční objem je množství krve vypuzené jednou srdeční systolou. Toto množství je v klidu asi 60-80 ml. Klidová hodnota minutového objemu je asi 5600 ml/min. (80ml x 70 tepů/min).
- Elektrická aktivita srdce se měří pomocí elektrokardiogramu – EKG. Lidské srdce je z technického hlediska obdivuhodným orgánem, který je schopen pracovat bez přestávky 24 hodin denně po celý život člověka. Srdce se přitom stáhne zhruba 100 000 krát denně, přečerpávající v klidu okolo 5 - 7 000 litru krve, při běžné zátěži až jednou tolik a při těžším cvičení až 5krat tolik krve v průběhu 24 hodin.

2.2 Základy elektrofyziologie

Za klidových podmínek je buněčná membrána prakticky pro všechny ionty pasivně nepropustná. Jen kalium proniká v nepatrné míře z buňky ven. Prostupuje-li některý iont buněčnou membránou, znamená to, že přes ní protéká el. proud. Pro přiblížení složitých elektrofyziologických jevů při průtoku proudu přes buněčnou membránu, byl zaveden pojem "kanál". Za klidových podmínek je přiotevřen kanál "draslíkový". Mezi vnitřkem a vnějškem buněčné membrány můžeme změřit napětí okolo 60-90 mV. Dále můžeme zjistit rozdílnou koncentraci iontů kalia a natria vně a uvnitř buňky.


Při podráždění, které může být spontánní nebo navozené ze zevnějšku, dochází ke změně propustnosti membrány pro ionty, změní se jejich koncentrační rozdíly a napětí na buněčné membráně. Průběh změny polarizačního napětí označujeme jako akční potenciál. Podráždění způsobí otevření rychlého sodíkového kanálu a influx Na^+ dovnitř buňky způsobí pokles polarizace z původních -90mV na hodnotu okolo -60mV, označovanou jako prahová hodnota. Od tohoto okamžiku pozitivní zpětnou vazbou dochází k dalšímu prudkému vtoku iontů natria dovnitř buňky, což způsobí další pokles polarizačního napětí, hovoří se o depolarizaci buněčné membrány. Rychlý sodíkový kanál se uzavírá, membrána se pro sodíkové ionty stává nepropustnou. Po skončení depolarizace se stává propustnou pro vápníkové ionty, které vnikají do nitra buňky. Otvírá se pomalý vápníkový kanál. Celý průběh akčního potenciálu zakončuje opětovné otevření kanálu pro draslík.

Důležitou vlastností srdce a některých srdečních struktur je dráždivost, což je schopnost tkáně, orgánu reagovat na podráždění. Podráždíme-li buňku, dojde k reakci jejího membránového napětí. Dráždíme-li srdce, dojde k šíření fronty podráždění srdečních struktur s jeho mechanickým projevem, kterým je přísně synchronní kontrakce síní a komor. Původní podráždění srdce může být přirozené, vycházející z nejrychlejší automatické buňky sinoatrikulárního uzlíku, ale i nepřirozené, kterým může být dodaný elektrický impuls, ale také mechanické podráždění, jakými jsou údery do hrudníku známé z resistutační praxe. Na

podráždění srdce svou reakcí odpoví nebo neodpoví. Velikost podráždění, která vede k reakci nazýváme nadprahové. Při dráždění srdce elektrickými impulsy zjistíme, že není lhostejné, zda jsou dráždící impulsy krátkého či dlouhého trvání. Práh podráždění bude na délce stimulačních impulsů závislý a to tak, že čím je dráždící impuls delšího trvání, tím je potřebná intenzita proudu menší a naopak (Hoorweg-Weissova křivka). Pro měření dráždivosti byly vypracovány metodiky a zvoleny dvě veličiny - reobáze (RE), což je nejmenší potřebná intenzita proudu, kterou srdce ještě podráždíme při velmi dlouhém dráždícím impulsu, a chronaxie (CH), což je taková délka stimulačního impulsu, která odpovídá dráždícímu proudu, který je dvojnásobkem reobáze. Dráždivost je také závislá na klidovém napětí membrány, čím je polarizační napětí membrány větší, tím větší energii musí mít i dráždící impuls. Po podráždění jsou vlákna kontraktálního myokardu i vlákna převodového systému dočasně zcela nedráždivá, jde o absolutní refrakterní fázi (ARF). Později se začne dráždivost obnovovat, vlákna přechází do relativní refrakterní fáze (RRF), kdy je pro podráždění zapotřebí větší energie dráždícího impulsu, pak následuje oblast supranormality, kdy lze podráždění vyvolat podstatně nižší energií. Během RRF lze také vymezit úsek takové vulnerability, kdy lze snadno vyvolat fibrilaci komor. Vulnerabilní fáze komorové svaloviny je přibližně ve vrcholu vlny T elektrokardiogramu. Dráždivost a refrakternita není stálá, je závislá na srdeční frekvenci a na nervovém působení.

2.3 Geneze elektrického pole srdečního

K tomu, aby srdce mohlo plnit tuto svoji hlavní úlohu, tj. pumpovat krev bohatou na kyslík k ostatním orgánům lidského těla, potřebuje být rytmicky poháněno elektrickými impulsy. Ty vznikají normálně ve shluku buněk specializovaného převodního systému srdce, který se nazývá sinusový uzel a nachází se v horní části pravé srdeční síně. Odtud se elektrický vzruch šíří svalovinou obou síní do síňokomorového uzlu, který je umístěn v dolní části přepážky mezi oběma síněmi.



Obrázek 2: Šíření akčního potenciálu

Také tento shluk speciálních buněk dokáže tvořit spontánně elektrické vzruchy, avšak pomaleji než uzel sinusový. Proto se za normálních okolností jeho automatická činnost nijak neprojevuje a slouží pouze k regulovanému převodu

elektrického podráždění na svalovinu komor. Tento převod se děje přes tzv. Hisův svazek, který je pokračováním síňokomorového uzlu a který je jediným elektrickým spojením mezi síněmi a komorami. Dále se šíří vzruch svalovinou komor a způsobuje jejich koordinovaný stah. Tak je zajištěno, že srdce pracuje jako systém dvou paralelních čerpadel - nejprve se stáhnou obě síně a naplní tak obě komory, poté dojde ke stahu svaloviny komor a k vypuzení krve z pravé komory do plic a z levé komory k orgánům a tkáním celého těla.


Mezi určitými místy kůže na lidském těle vznikají při periodické aktivaci srdce registrovatelné elektrické potenciály. Jejich velikost se měří řádově v elektronvoltech (eV) a jejich časový průběh je obrazem dějů, probíhajících v srdci při jeho dráždění podněty, normálně vycházejícími ze sinoatriálního uzlu v pravé srdeční síni. Elektrokardiogram je důležitou informací o frekvenci, rytmu, původu a způsobu šíření dráždivého podnětu.

2.4 Snímání elektrické aktivity srdce

Srdce si lze schematicky představit jako dvě pumpy zapojené v sérii. Jeho činnost je řízena bioelektrickými signály vznikajícími v sinoatriálním uzlu umístěném v pravé síni. Rytmičké stahy komorové svaloviny vypuzují krev do velkého (tělního) a malého (plicního) krevního oběhu. Četnost těchto stahů závisí na tvorbě sinoatriálních impulsů, která je ovlivněna řadou faktorů (např. vegetativním nervstvem, potřebou O₂ apod.). Celá činnost srdce je doprovázena vznikem elektrického signálu, jehož grafický záznam se nazývá elektrokardiogram (EKG). Nejčastěji bývá tento signál snímán pomocí elektrod umístěných na povrchu těla pacienta. Umístění elektrod je normalizováno. Méně častým způsobem snímání potenciálů vznikajících při činnosti srdce je snímání z jeho jednotlivých částí.

Pokud dojde k poruše tvorby a vedení vzruchu, projeví se tento stav nejen v jeho mechanické činnosti, ale i změnou tvaru elektrického signálu. Vzhledem k tomu, že existuje rozsáhlý slovník průběhů s příslušnými diagnostickými výroky získaný na základě dlouholetých výzkumů, má EKG signál svoje nezastupitelné místo.


Při snímání elektrické aktivity srdce se v současné době nejvíce používá systém dvanácti elektrokardiografických svodů, které jsou založeny na měření napětí mezi různými místy na jednotlivých končetinách a hrudníku vyšetřované osoby. Do této skupiny nejvíce používaných svodů patří: bipolární končetinové svody dle Einthovena, které jsou označovány římskými číslicemi I, II, III, semiunipolární svody dle Goldbergera, označované symboly aVR, aVL, aVF a unipolární svody hrudní dle Wilsona, které jsou označovány symboly V1, V2, V3, V4, V5 a V6.



Obrázek 3: Končetinové svody dle Einthovena


Končetinové svody dle Einthovena jsou bipolární. Elektrická informace vždy ze dvou elektrod uložených na končetinách je přímo vedena ke vstupním svorkám zesilovače. Čtyři elektrody uložíme nad zápěstí a kotníky. Z elektrod jsou vedeny signály, tak jak ukazuje obrázek 3. Svod I zesiluje napěťový rozdíl mezi horními končetinami, svod II mezi pravou horní a levou dolní končetinou a svod III pak zesiluje rozdíl napětí mezi levou horní a dolní končetinou. Mezi bipolárními končetinovými svody platí vztahy: $I+II=III$ a $II+III=I$ a $I+III=II$.

Semiunipolární Goldbergovy svody registrují potenciálový rozdíl mezi jednou elektrodou končetinovou a průměrem napětí dvou elektrod zbylých, jak schematicky zobrazuje obrázek.



Obrázek 4: Semiunipolární Goldbergovy svody

Průměr napětí zbylých dvou končetinových elektrod je vytvořen jejich spojením do uzlu přes rezistory. Svod aVR zesiluje potenciálový rozdíl mezi pravou rukou a průměrem napětí z levé ruky a levé nohy. Svod aVL zesiluje napětí mezi levou rukou a průměrem napětí z pravé ruky a levé nohy. Svod aVF zesiluje napěťový rozdíl mezi levou nohou a průměrem napětí z obou horních končetin. Unipolární hrudní svody zavedl Wilson. Invertující vstup diferenciálního zesilovače je veden na tzv. Wilsonovu svorku, kterou její autor vytvořil vzájemným spojením všech tří končetinových elektrod. Běžný 12-ti svodový záznam používá 6 hrudních unipolárních svodů, které jsou označeny symboly V1 až V6. Místa pro uložení jednotlivých elektrod jsou vyznačena na obrázku 5.




- V1 - leží ve 4. mezižebří těsně vpravo u hrudní kosti
- V2 - leží ve 4. mezižebří těsně vlevo u hrudní kosti
- V3 - leží uprostřed mezi V2 a V4
- V4 - leží v 5. mezižebří v čáře Medioklavikulární vlevo
- V5 - leží mezi V4 a V6
- V6 - leží ve stejné výši jako V4 ve střední axilární čáře vlevo

Obrázek 5: Uložení jednotlivých elektrod 6 hrudních unipolárních svodů

2.5 Typy průběhů EKG signálů

2.5.1 Normální cyklus EKG signálu

Na obrázku 6 je zobrazen signál ze svodu II. Části signálu jsou na obrázku označeny podle současných zvyklostí.



Obrázek 6: Normální stah EKG signálu

Jednotlivé části EKG signálu mají tyto vlastnosti:

P-vlna - Vzniká při činnosti sinoatriálního uzlíku. Je projevem elektrické dipolarizace síní. Normální P-vlna má rozličný tvar, od plochého do ostřejší špičky s amplitudou od 0 do 0.3 mV (dolní mez znamená, že P-vlna není pozorovatelná), s dobou trvání do 100 ms.

P-R interval - Interval P-R začíná od počátku depolarizace síní a končí s počátkem depolarizace komor. Normální doba trvání tohoto intervalu je od 120 do 200 ms. Na délce tohoto intervalu se projevuje věk a tepová frekvence. U starších lidí může být tento interval fyziologický do 220 ms. Sinusová tachykardie může tento interval zkrátit na 110 ms. Je obrazem síňokomorového vedení.

Q-vlna - Je to první negativní výchylka komplexu QRS. Normální vlna Q má amplitudu v rozsahu 0 až 25% vlny R. Normální doba trvání je menší než 30 ms. Není to standardní výchylka.

R-vlna - Je to pozitivní výchylka následující po vlně Q. Amplituda je závislá na místě snímání. Může dosahovat až několik mV, může i chybět. Normální doba trvání do 100 ms.

S-vlna - Je to druhá negativní výchylka následující po vlně R. Chybí-li vlna R, označujeme tuto výchylku jako QS. Normální vlna S má amplitudu od 0 do 0.8 mV a dobu trvání do 50 ms, není standardní výskyt, závisí na lokalizaci diferentní elektrody.

QRS komplex - Je to v podstatě trojúhelníkový kmit doprovázející depolarizaci komor. Doba normálního komplexu QRS je od 50 do 110 ms.

S-T segment - Ohraničuje interval od konce QRS komplexu po začátek vlny T. Normální pokles nebo vzrůst oproti isoelektrické linii je do 0.1 mV.

Q-T interval - Reprezentuje elektrickou systolu. Je měřen od začátku QRS komplexu po konec vlny T. Tento interval se mění s tepovou frekvencí, věkem a pohlavím pacienta, metabolismem minerálů (Ca^{++} , K^{+}), je ovlivňován léky (např. digitalis). Průměrné hodnoty kolísají od 0,34 do 0,42s.

T-vlna - T vlna reprezentuje repolarizaci komorové svaloviny. Tabulky elektrokardiografických měření ukazují proměnlivý rozsah amplitud pro normální T-vlnu. Napěťový rozsah je do 8,8 mV, doba trvání normální vlny T je od 100 do 250 ms. Je konkordantní (souhlasně výkyvná) s QRS komplexem, tedy většinou jde o pozitivní výchylku. Je velmi citlivým indikátorem stavu srdeční svaloviny.

U-vlna - U-vlna je malá pozitivní výchylka, která je někdy zaznamenávána po vlně T. Její výskyt je závislý na tonusu vegetativního nervstva, minerálního metabolismu (K^{+}) a celé řady dalších faktorů. Výše uvedený popis je pouze všeobecný a má sloužit k získání názoru o rychlosti změn v jednotlivých částech signálu EKG.

Shrňme-li výše uvedené údaje, je možno říci, že elektrokardiogram je komplexně vypovídající diagnostickou metodou nezastupitelnou při získávání informací o stavu tvorby vzruchů, převodního systému, funkčních a morfologických změnách srdečního svalu. Nejrychleji se amplituda mění u QRS komplexu, zatímco změny dalších částí elektrokardiogramu jsou pomalejší.

2.5.2 Předčasné stahy (Extrasystoly)

Klinicky se extrasystoly dělí:

Podle místa svého vzniku:

- supraventrikulární – síňové – nodální
- komorové
- sinusové - z SA uzlu (velmi vzácné)

Podle častosti výskytu:


- ojedinělé (sporadické)
- nakupené (v salvách, kupletech až paroxysmální tachykardie)
- vázané (bigeminie, trigeminie, kvadrigeminie apod.)

Podle počtu ektopických center:

- monotopní - mají stále stejný tvar, jsou z jednoho centra
- polytopní - jsou z více center, mají různý tvar

Komorové předčasné stahy

Komorové předčasné stahy (viz obrázek 7) mají svůj původ v ektopických centrech komor. Vznikají nejčastěji ve svalovině komor nebo v Purkyňových vláknech. Jsou závažnější než supraventrikulární extrasystoly.



Obrázek 7: Předčasný komorový stah

Komorové extrasystoly, které vznikají v pravé komoře, mají tvar bloku levého raménka, extrasystoly z levé komory se podobají bloku pravého raménka (křížové pravidlo). QRS komplex komorových extrasystol je vždy rozšířený nad 0,11 s (tím se liší od supraventrikulárních extrasystol, kde je QRS komplex štíhlý, pokud není současně blok raménka). Komorová extrasystola se obvykle nešíří zpět na síně, a proto není narušen sled sinusových vzruchů. Po komorových extrasystolách bývají komory v době příchodu následujícího normálního podráždění ještě v refrakterní fázi, takže na tento impuls nemohou reagovat, a proto dojde k jejich stahu až při dalším normálním impulsu. Tím vzniká u komorových extrasystol tzv. úplná kompenzační pauza, tzn. součet pre-extrasystolického a post-extrasystolického intervalu je roven dvěma normálním, obvykle sinusovým stahům ($R - R^* + R^* - R = 2 RR$). U supraventrikulárních extrasystol je kompenzační pauza neúplná, neboť extrasystolický impuls vybíjí sinusový uzel, který poté vyšle další vzruch za obvyklou dobu.

Výskyt:


- jsou i u zdravých lidí, často s neurovegetativní labilitou, v důsledku stresu, abúzu alkoholu nebo nikotinu
- u celé řady srdečních onemocnění: ICHS, akutní IM, myokarditida, kardiomyopatie, aorto-mitrální srdeční vady, defekt septa síní
- při srdeční katetrizaci nebo u srdečních operací, kde přicházejí často v salvách
- endokrinní nemoci (tyreotoxikóza, feochromocytom)
- lékové intoxikace
- iontová dysbalance, zejména draslíku

2.5.3 Raménkové blokády

Raménkové blokády se z poruch vedení vzruchu vyskytují na EKG nejčastěji. Dělí se na blokádu levou a pravou. Při blokádě jednoho z ramének dochází k pozdější aktivaci příslušné komory, tzn. u blokády pravého Tawarova raménka (BPRT) nastává pozdější aktivace pravé komory. Tato pozdější aktivace jedné z komor vede k charakteristickým tvarovým změnám na QRS komplexu, které se vyskytují jak u bloku levého, tak pravého raménka.

Blokáda levého Tatarova raménka

Z důvodu bloku levého Tawarova raménka jsou mezikomorová přepážka a levá komora aktivovány impulsy, které přicházejí z pravého raménka (fyziologická aktivace mezikomorové přepážky zleva doprava je nahrazena aktivací opačnou, zprava doleva). Depolarizace levé komory je opožděna, z toho důvodu je délka QRS komplexu prodloužena na více jak 0,12 s. Na obrázku 8 je znázorněn průběh EKG signálu z druhého svodu z přiložené databáze.




Obrázek 8: Blokáda levého Tawarova raménka

Příčiny:

- kardiomiopatie a degenerativní onemocnění
- ischemická choroba srdeční (dysfunkce levé komory)
- arteriální hypertenze
- pokročilé chlopenní vady
- vrozené srdeční vady

Blokáda pravého Tatarova raménka


Typický průběh EKG signálu blokády pravého Tawarova raménka (BPRT) ze svodu dva je na obrázku 9. Od normálního průběhu se průběh v druhém svodu liší abnormálně velikou zápornou vlnou S a zápornou vlnou T. Typický průběh, podle kterého se pozná, že jde o BPRT, je však v svodu V₁. QRS komplex se projevuje jako písmeno M. Příčiny vzniku blokády pravého Tawarova raménka jsou obdobné jako u levého.



Obrázek 9: Blokáda pravého Tawarova raménka

2.5.4 EKG signál po kardiostimulaci

Jako poslední typ EKG signálu je zde uveden EKG signál po stimulaci pomocí kardiostimulátoru (viz obrázek 10). Kardiostimulace slouží ke stimulaci srdce pomocí malých impulsů, jenž vůbec navenek nepociťujeme. Aktivuje se při poruchách srdečního rytmu a umožňuje často pacientovi, kromě záchrany života, vést prakticky normální život.



Obrázek 10: EKG signál po kardiostimulaci

Výše uvedené typy průběhů EKG signálů jsou zde uvedeny z důvodu seznámení se s nimi, seznámení se s typickými průběhy s důvodem vzniku jednotlivých arytmií a s příčinami. Tyto jednotlivé signály budou sloužit jako vstupní data pro neuronovou síť, pomocí které se je budeme snažit s nejvyšší přesností klasifikovat.

3 Neuronové sítě

3.1 Úvod

Neuronové sítě jsou jednou z oblastí, které se v posledních letech věnuje zvýšená pozornost. Je to zapříčiněno tím, že mají mnoho vlastností, které lze s úspěchem využít v řadě oborů. První náznaky teorie neuronových sítí se objevily již během druhé světové války. V roce 1943 vznikl díky McCullochovi a Pittsovi první matematický popis neuronu. Roku 1949 navrhl Donald Hebb na základě studií reálných nervových systémů pravidlo, které umožňuje tento jednoduchý neuron učit. Postupem času zaznamenalo toto pravidlo určité změny, ale princip pravidla zůstal stejný, a proto i dnes takovému typu učení říkáme Hebbovo učení [5].

Další vývoj v oblasti umělých neuronových sítí pokračoval teprve počátkem šedesátých let. Dalším objevitelem se stal Frank Rosenblatt, jehož zásluhou vznikla v roce 1962 propojením základních neuronů první neuronová síť. Chování takto vytvořené sítě přineslo nové vlastnosti, neboť se zjistilo, že chování sítě jako celku je odlišné od chování jednoho jediného neuronu. Frank Rosenblatt se tak stal průkopníkem počítačových simulací neuronových sítí a zakladatelem jejich formální analýzy.

Vlastnosti neuronových sítí se ukázaly perspektivní v mnoha oborech. Hlavní uplatnění našly v oblasti automatického řízení a kybernetiky, umělé inteligence, při zpracování obrazu a řeči, v ekonomice při predikcích směnných kurzů apod.

3.2 Vlastnosti neuronových sítí

Neuronové sítě mají celou řadu dobrých vlastností. Především je to schopnost sítě učit se, tj. měnit své parametry i strukturu na základě určité informace tak, aby lépe vyhovovala zadaným požadavkům. Musí mít tedy zavedenou zpětnou vazbu, která jí říká, jak dobře splnila svůj úkol a podle toho pak změnila své parametry. Učení neuronové sítě může probíhat buď s učitelem nebo bez něj. Je-li síť navržena tak, aby se mohla učit na příkladech, říkáme, že je to síť s učitelem. V opačném případě, kdy není učitel k dispozici, se musí síť učit z chyb, které udělala a snažit se vyhovět nějakému zadanému kritériu. V obou případech si neuronová síť snaží vytvořit svůj vlastní vnitřní model, který by napodoboval skutečný systém. Touto schopností přibývá neuronové síti další výborná vlastnost a to možnost predikce.

Hlavní rozdíl mezi neuronovými sítěmi a klasickým počítačovým programem je v reagování na chyby. Když vznikne v klasickém programu chyba, celý systém se zhroutí. Neuronové sítě však na chyby reagují jinak. Drobné odchylky nijak nenaruší jejich funkci. Jsou tedy dostatečně robustní vůči chybám. Druhým podstatným rozdílem je, že neuronové sítě zpracovávají informaci paralelně a to zvyšuje jejich rychlost. Paralelní zpracování signálů je typickou vlastností neuronových sítí mozku.

3.3 Rozdělení neuronových sítí

Neuronové sítě můžeme rozdělit na tři skupiny:

- asociativní paměti
- klasifikátory
- aproximátory

Asociativní paměti jsou takové sítě, které odpovídají vzorem, který je asociován (logicky spojen) se vstupním vzorem. Podle druhu asociace rozdělujeme paměti na autoasociativní (vstupní i výstupní vzor je podobný. Můžeme je použít k rozpoznávání poškozených vzorů) a heteroasociativní (vstup i výstup jsou různé). Na daný podnět si vybavíme něco jiného, i když to se vstupem souvisí). Nejznámější asociativní paměť je Hopfieldova síť.

Klasifikátory jsou sítě, které rozpoznají vstupní vzor a zařadí ho do vybrané třídy. Na výstupu je tato třída zastoupena např. logickou jedničkou na příslušném výstupu, zatímco ostatní výstupy jsou nulové. Úlohou klasifikátorů je tedy zařadit vzor na základě podobnosti. Typickým zástupcem tohoto druhu sítí je např. Hammingova síť.

Posledním druhem neuronových sítí jsou aproximátory. Jejich funkce spočívá ve vytvoření vlastního vnitřního modelu na základě vstupních informací, který aproximuje skutečný systém. Tato vlastnost dovoluje síti predikovat události. Aproximátory je samozřejmě možné použít jako klasifikátory, ale je to zbytečně mohutný nástroj. Nejznámějším zástupcem tohoto druhu sítí je vícevrstvá perceptronová síť, pro kterou se někdy používá označení BP-síť (síť se zpětným šířením signálu) [5].

Dělení neuronových sítí podle způsobu učení:

- S učitelem
- Bez učitele

Sítě, které pracují s učitelem se snaží napodobit předkládané vzory. Učí se tedy z příkladů. Naproti tomu sítě bez učitele si musí najít svou vlastní reprezentaci pouze ze známých vstupních dat a s pomocí zadaného kritéria, kterému se snaží vyhovět. Mezi sítě s učitelem patří např. Hopfieldova síť a mezi sítě bez učitele řadíme např. Kohonenovu síť.


Rozdělení neuronových sítí podle druhu zpracovávaného signálu:

- Diskrétní
- Spojitý

Posledním možným rozdělením neuronových sítí je druh zpracovávaného signálu. Ten může být buď diskrétní nebo spojitý. Diskrétní signály zpracovává např. Hammingova nebo ART (ART-1) síť a spojitě signály může zpracovávat např. BP-síť nebo Kohonenova síť. Protože většina implementací neuronových sítí je ve formě počítačových programů, pracujeme vesměs s diskrétně kódovanými signály. Existují však i hardwarové struktury nebo optické sítě, které umí zpracovávat spojitě signály.

3.4 Biologický neuron

Neurony jsou základními stavebními prvky nervové soustavy, převážně mozku. Jsou to živé buňky, které se zaměřují na sbírání, uchovávání, zpracování a přenos informací. Existuje celá řada různých druhů neuronů. Ve všech případech se neuron skládá z těla (somatu), do kterého přicházejí informace po vstupních větvích (dendritech), kterých je kolem deseti tisíc na každý neuron, a z kterého informace vycházejí po jediném výstupu (axonu), který je však na svém konci bohatě rozvětven. Výstupní signál na axonu odpovídá vstupům, které jsou zpracovány uvnitř neuronu. Výstup neuronu tedy závisí na vstupech, které do něho přicházejí. Průměr těla neuronu je různý. Bývá od několika μm až do několika desítek μm . Délka dendritů je maximálně dva až tři mm. Naopak délka axonu může být přes jeden metr (to platí zvláště pro axony motoneuronů). Aby mozek správně plnil svoji funkci, musí být neurony vhodně navzájem propojeny do neuronových sítí. Toto propojení je uskutečňováno právě pomocí dendritů, které se pomocí speciálních výběžků (synapsí) připojují na dendrity jiných neuronů nebo přímo na těla těchto neuronů nebo dokonce ve výjimečných případech přímo na axony. Na jeden neuron připadá v průměru asi 10 až 100 tisíc spojů s jinými neurony. Inteligentní a výkonné chování mozku (obecně neuronových sítí) je tedy z velké části dáno právě dokonalostí vzájemného propojení. Neurony v neuronových sítích mozku jsou uspořádány tak, že výpadek jednoho neuronu nemůže ohrozit funkci celku. Na obrázku 11 je biologický neuron znázorněn.



Obrázek 11: Biologický neuron

Hustota neuronů v lidském mozku je asi 7 až $8 \cdot 10^4$ na 1mm^3 . Během života organismu je mnoho buněk nahrazováno po odumření buňkami novými. U neuronových buněk to neplatí. Denně odumře asi 10 tisíc buněk, které již nejsou nahrazeny. To se zdá na první pohled hodně, ale asi za 75 let se sníží počet neuronů jen o 0,2 až 0,5%. Avšak synapse na dendritech se vytvářejí během celého života a dochází tak ke vzniku nových spojů (respektive k oživení dosud nefunkčních synapsí). Toto vytváření spojů je základem učících schopností neuronových sítí.

3.5 Klasifikace vzorů


Velkou oblastí, kde se používají umělé neuronové sítě, je rozpoznávání obrázců. Je to široká oblast zasahující nejen do neuronových sítí, ale i do fuzzy logiky a jiných oblastí, jako je např. filtrace a úprava obrazu. Neuronové sítě jsou jednou z možností, jak vyřešit otázku rozpoznávání obrázců.

S potřebou něco rozpoznávat se setkáváme každodenně. Patří sem např. čtení (je to rozpoznávání jednotlivých písmen) nebo slyšení (zde naopak potřebujeme rozlišit jednotlivé zvuky). Každou informaci, kterou vstřebáváme, musíme získat na základě nějakého poznání, tj. musíme vidět nějaké rozdíly, abychom byli schopni přijmout novou informaci, a tedy se něco naučit. Vrátime-li se k čtení, jedná se o rozpoznávání jednotlivých písmen, která jsou seskupena do řetězců, slov. Kromě toho jsou pokaždé napsána trochu jinak, např. ručně nebo na stroji, mají různou velikost a sklon. Přesto jsme schopni je rozlišit a tedy správně přečíst. Kromě základní informace o tom, jak má graficky vypadat určité písmeno, musíme mít i nějaký vnitřní algoritmus, který nám umožňuje převést libovolný napsaný text do správné formy. Máme tedy schopnost správně klasifikovat daná písmena a slova.

V poslední době je kladen velký důraz na rozpoznávání psaného textu pomocí počítače. Vyřešení tohoto problému by samozřejmě umožnilo snadněji přenášet velké množství psaného textu do počítačové podoby a tedy celkově zrychlit práci. Jiný výzkum je zaměřen na zpracování mluvené řeči. Je zřejmé, že je lepší dopis nadiktovat než ho ručně přepsat.

Vlastní klasifikace, tedy rozpoznání a správné zařazení daného vzoru do odpovídající třídy, probíhá ve dvou fázích. První fáze je vlastní získání informace o předloženém vzoru, to znamená nalezení jeho základních vlastností. Druhá fáze je použití získaných vlastností pro správnou klasifikaci, tj. pro správné přiřazení vzoru k odpovídající skupině vzorů - třídě. Často potřebujeme pro správnou klasifikaci získat několik jeho vlastností (závislostí). Zjištěné vlastnosti pro určitý vzor nám vytvářejí tzv. vektor vlastností. Dimenze neboli délka vektoru je určena počtem měřených vlastností N a odpovídá dimenzi prostoru, ve kterém provádíme klasifikaci.

Uvažujme pouze dvoudimenzionální případ ($N = 2$). Budeme se tedy pohybovat v rovině. Vzor je určen svým vlastním vektorem vlastností, který bude mít dva prvky. Jeden prvek bude určovat hodnotu na ose x a druhý prvek bude jemu odpovídající y -ová hodnota. Vzorem bude tedy libovolný bod v rovině, x -ová a y -ová souřadnice bodu (vzoru) jsou tudíž jeho vlastnosti.

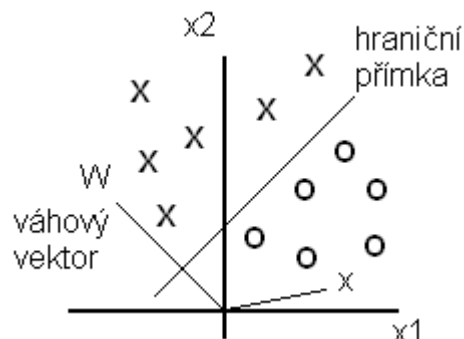


Obrázek 12: Klasifikace dvou vzorů

Na obrázku 12 je zobrazeno několik bodů, ale jen dvou druhů - kolečka a křížky. Každý bod musí mít své souřadnice $X = (x, y)$. Z obrázku je vidět, že budeme mít pouze dvě třídy, protože máme jen dva druhy vzorů. Naším úkolem, resp. úkolem neuronové sítě - klasifikátoru, je nalézt hranici mezi těmito dvěma skupinami. Tato hranice je popsána tzv. diskriminační funkcí a je znázorněna na obrázku. V tomto případě jsme ji nakreslili pouze intuitivně. Správné určení hranice bude důležité pro budoucí správné zařazení nového vzoru, neboť příslušnost vzoru do některé třídy bude testována pomocí této diskriminační funkce. Pro nalezení hranice musíme najít vhodný algoritmus. Právě různými algoritmy se liší jednotlivé neuronové sítě.

3.6 Lineární klasifikace

Při této klasifikaci musíme vyřešit problémy jak implementovat hranici a jak ji správně nastavit. Na obrázku 13 jsme přidali nový vektor. Tento vektor budeme nazývat váhovým vektorem W . Vektor W je vždy kolmý na hraniční rozdělovací čáru a bude nám sloužit k určení hraniční přímky. Nalezení hranice bude spočívat v nalezení odpovídajícího váhového vektoru.



Obrázek 13: Vztah hraniční přímky a váhového vektoru

Hraniční přímka definovaná pomocí váhového vektoru je určena diskriminační funkcí $f(X)$:

$$f(X) = W \cdot X^T = \sum_{i=1}^N w_i x_i \quad (1)$$

kde w_i jsou jednotlivé elementy vektoru W a x_i jsou elementy vzoru X a N je počet elementů vektoru, tedy dimenze prostoru. Pro náš případ je $N=2$. Hodnota diskriminační funkce bude buď kladná nebo záporná. Znaménko funkce určuje, ke které třídě předložený vzor patří. Jak si zvolíme příslušnosti ke třídám to závisí na nás. Předpokládejme, že:

jestliže $f(X) > 0$ potom, vzor X patří do třídy A
 jestliže $f(X) < 0$ potom, vzor X patří do třídy B

Problémem ovšem zůstává nalezení správného váhového vektoru W . Nejprve rozšířme naši diskriminační funkci o člen θ , který se nazývá práh a který byl dosud nulový. Obecně totiž neporovnáváme diskriminační funkci oproti nule, ale právě oproti tomuto prahu. Práh je obsažen v každém neuronu a určuje nám hodnotu, kterou je nutno překročit, aby se zaktivoval výstup.

Jinými slovy součet vážených signálů na vstupech neuronu musí být větší než tato prahová hodnota, aby se neuron aktivoval. Platí, že:

$$f(X) = \sum w_i x_i - \theta \quad (2)$$

a test na příslušnost k dané třídě je následující:

jestliže $f(X) > \theta$ potom vzor X patří do třídy A
 jestliže $f(X) < \theta$ potom vzor X patří do třídy B

Nyní máme definovanou diskriminační funkci a můžeme se věnovat vlastnostem váhového vektoru. Zaměříme se opět jen na dvourozměrný případ. Jestliže chceme získat rovnici hraniční přímky, musí platit

$$f(X) = \sum w_i x_i - \theta = 0 \quad (3)$$

což pro náš dvourozměrný případ je

$$w_1 x_1 + w_2 x_2 - \theta = 0 \quad (4)$$

Po úpravě získáme rovnici

$$x_2 = -\frac{w_1}{w_2} \cdot x_1 + \frac{\theta}{w_2} \quad (5)$$

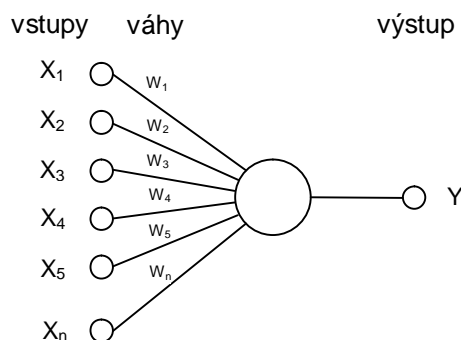
což je rovnice hledané přímky. Obecná rovnice jakékoliv přímky je $y = kx + q$ a z toho tedy vyplývá, že sklon přímky je určen směrnici $-w_1/w_2$ a posuv na ose v respektive x_2 je dán členem θ/w_2 . Je vidět, že posuv přímky po ose x_2 , je dán právě prahem.

V některých publikacích se tento práh nazývá bias nebo offset. Vraťme se ještě k případu, kdy byl práh nulový. V tom případě jsme mohli hraniční přímku otáčet kolem počátku, ale nikoliv ji libovolně posouvat. Bez prahu bychom tedy nemohli např. odlišit dvě třídy, které by byly rozloženy kolem osy x_2 , nad sebou.

Proces, kterým se snažíme nalézt vhodné váhy pro váhový vektor W se nazývá učení. Aby byla síť schopna v budoucnosti správně rozlišovat nové vzory, musíme ji natrénovat na takových vzorech, ke kterým známe i správnou odpověď, tj. víme o nich předem, do které třídy patří. Pomocí vzorů, resp. jejich vektorů X (tedy souřadnic) a ze znalosti tříd, ke kterým patří, můžeme nalézt hraniční přímku. Učení je interaktivní, což znamená, že po přiložení trénovacího vzoru provedeme v každém kroku adaptaci vah tak, aby lépe odpovídaly skutečnosti, tj. aby co nejlépe oddělovaly jednotlivé skupiny vzorů. Při učení je třeba dbát, aby vzory z různých tříd byly předkládány náhodně. Nikdy nesmíme učit síť nejprve jeden typ vzorů a potom druhý. V praxi existuje celá řada metod, jak přizpůsobovat váhy. Převážně vycházejí z hodnoty chybové funkce, která neudává nic jiného než „vzdálenost“ mezi výstupem klasifikátoru a požadovaným výstupem pro předložený vzor.


3.7 Neuronové sítě se zpětným šířením chyby

Tyto neuronové sítě (NS) patří k nejpoužívanějším a to z důvodu jednoduchosti a flexibility. Častěji se používá jejich anglický název back-propagation (BP). Název je odvozen z principu učení NS. Základním stavebním kamenem je neuron (viz obrázek 14).



Obrázek 14: Model neuronu

Model neuronu má obecně n vstupů n vah a jeden výstup. Spojením jednotlivých neuronů vznikne topologie sítě, která má vstupní vrstvu, skrytou(é) vrstvu(y) a vrstvu výstupní. Pro klasifikaci je nejčastěji používána vrstevnatá perceptronová síť (VPS), jejíž anglický název je Multi Layer Perceptron – (MLP) v kombinaci s učícím algoritmem Backpropagation (BP), či v poslední době novějším a rychlejším algoritmem Marquardt-Levenberg (ML). Architektura neuronové sítě je uvedena na obrázku 15.



Obrázek 15: Architektura sítě typu back-propagation

Neuronová síť na obrázku 15 obsahuje celkem tři vrstvy:

- vstupní vrstvu s n neurony
- skrytou vrstvu s n neurony (většinou obsahující nelineární výstupní funkci).
- výstupní vrstvu s n neurony (většinou obsahující lineární výstupní funkci pro identifikaci nebo většinou obsahující nelineární výstupní funkci pro klasifikační aplikace).

Parametry sítě jsou:

- počet vrstev - síť se dvěma vnitřními vrstvami je schopna modelovat většinu systémů, síť s jednou vnitřní vrstvou je brána jako univerzální aproximátor
- počet neuronů v každé vrstvě - počet neuronů ve výstupní vrstvě je dán počtem požadovaných výstupů sítě. Správný počet záleží na tom, jak složitý problém chceme řešit. Příliš málo neuronů má za následek, že síť není schopna se naučit chování daného systému, příliš mnoho neuronů (tzv. overtraining) zvyšuje riziko, že síť bude mít spoustu stupňů volnosti a učící algoritmus nemusí najít nejlepší řešení nebo síť se může naučit i šum.
- výstupní funkce neuronů - nejběžněji používaná výstupní funkce je sigmoida, v teorii řízení se často potkáte s funkcí hyperbolický tangens.

Tyto neuronové sítě patří do skupiny učení s učitelem. To znamená, že se síti předkládají vzory (trénovací množina) a učí se na hodnotu, která je limitována výstupní funkcí neuronu. Při následné simulaci by měla mít NS na výstupu hodnotu, na kterou se učila. Sítě typu back-propagation mají největší přednost v tom, že zpětným šířením chyb upravují váhy a tím zlepšují účinnost klasifikace. Učení neuronové sítě probíhá takto [2].


- předložení vektoru \mathbf{x}_p síti a zjištění její odezvy \mathbf{y}_p ,
- výpočet chybového vektoru $\mathbf{e}_p = \mathbf{d}_p - \mathbf{y}_p$ kde \mathbf{d}_p je požadovaný výstup,
- výpočet rozpočtených chyb jednotlivých neuronů zpětným šířením chyb,
- oprava vektoru vah každého jednotlivého neuronu lokálně podle δ - pravidla s využitím známé aktivace tohoto neuronu při ukázaní \mathbf{x}_p síti.

Vztah pro výpočet chyby j -tého neuronu $n-1$ vrstvy je

$${}^{n-1}e_p = \sum_{j=1}^M [{}^n e_p \cdot f' \cdot ({}^n \alpha_p) \cdot {}^n w_i] \quad (6)$$

kde n značí vrstvu, M počet neuronů v n -té vrstvě a i je index neuronu, na jehož výstupu chybu počítáme.

Model neuronu implementovaný do Matlabu je zobrazen na obrázku 16.




Obrázek 16: Model neuronu

kde \mathbf{u} ... je vstup neuronu (vektor), \mathbf{w} ... jsou váhy neuronu (vektor), \mathbf{b} ... je bias (offset) neuronu, \mathbf{F} ... výstupní funkce neuronu, \mathbf{y} ... výstup neuronu

Bias je tedy u tohoto modelu oddělen od vektoru vah a nevyskytuje se v něm. Pozornost si zaslouží výstupní funkce neuronu, která je definována uživatelem. NN Toolbox nabízí následující funkce :

- **hardlim** - limita s ostrým skokem z hodnoty 0 na hodnotu 1
- **hardlims** - limita s ostrým skokem z hodnoty -1 na hodnotu 1
- **logsig** - limita s plynulým přechodem z hodnoty 0 na hodnotu 1
- **tansig** - limita s plynulým přechodem z hodnoty -1 na hodnotu 1
- **purelin** - limita s lineárním přechodem
- **radbas** - radiální funkce
- **satlin** – lineární saturace z 0 na 1
- **satlins** - lineární saturace z -1 na 1


Průběhy těchto funkcí jsou zobrazeny na obrázku 17.



Obrázek 17: Výstupní funkce neuronů v MatLabu

4 Klasifikace EKG signálu

Cílem této diplomové práce je seznámit se s problematikou využití neuronových sítí pro klasifikaci EKG signálu. Realizovat klasifikační algoritmus v prostředí MATLAB tak, aby klasifikoval výše uvedené typy EKG signálů (normální cykly, blokádu levého či pravého Tawarova raménka, předčasné komorové cykly a signál po kardiostimulaci). Poté jeho funkčnost ověřit na záznamech z databáze [1]. Nakonec porovnat výsledky klasifikace s výsledky uvedenými v databázi. Realizace výše uvedené metody je vytvořena v programovém prostředí MATLAB verze R2007b. Na obrázku 18 je uvedeno blokové schéma, které ukazuje postup klasifikace.




Obrázek 18: Blokové schéma klasifikace EKG pomocí neuronových sítí

4.1 Klasifikace Dvou typů průběhů EKG signálu

4.1.1 Nahrání vstupních dat

Pro načtení dat byla použita funkce `loadfile`, která je přiložena jako `loadfile.m`. Díky této funkci jsme mohli pracovat s daty v programovém prostředí. Jako vstupní matice dat byly použity soubory z [1]. Databáze obsahuje 48 záznamů EKG signálu od 48 různých pacientů. Každý záznam se skládá ze dvou svodů, má 650000 vzorků a trvá 30 sekund. Je výhodou, že u signálů z databáze není třeba detekovat R-vlny, protože jsou v databázi obsaženy vzorky, v kterých se R-vlna nachází.


Na obrázku 19 je uveden příklad signálu z databáze, který obsahuje normální cyklus i předčasnou komorovou kontrakci. První kvaziperioda EKG je normální cyklus, poté následují dvě předčasné komorové kontrakce. Jak již bylo uvedeno dříve, cílem je tyto dva typy EKG signálů pomocí neuronové sítě rozpoznat.



Obrázek 19: Signál EKG - normální stah a předčasná komorová kontrakce

4.1.2 Předzpracování signálů pomocí filtrace


Po nahrání vstupních dat a jejich následovné analýze bylo nutné signály vyfiltrovat. Pro filtraci byl zvolen Lynnův filtr, což je typ hřebenových filtrů. Jejich hlavní přednost je lineární fázová charakteristika. Cílem filtrace bylo odstranit nízké frekvence pod 2Hz (viz obrázek 20).



Obrázek 20: Filtrace signálu 121 pomocí Lynnova filtru
nahore vstupní signál, uprostřed odfiltrovaný signál, dole výsledek po filtraci

Návrh filtru

Filtr byl navržen jako horní propust s mezní frekvencí 2Hz. Tato frekvence byla zvolena tak, aby se neztratily důležité informace o signálu, ale aby odstranil stejnosměrnou složku a pohybové artefakty. Blokové schéma filtru je uvedeno na obrázku 21.



Obrázek 21: Blokové schéma navrženého filtru

Obecný vztah pro Lynnův filtr,

$$Data = \frac{1}{N} \cdot \frac{1 - z^{-N}}{(1 - z^{-1})} \quad (7)$$

řád filtru získáme z vzorkovací a mezní frekvence,

$$N = \frac{f_{vz}}{f_m} = \frac{360}{2} = 180 \quad (8)$$

nyní můžeme dosadit do vztahu (7) a psát,

$$Data = \frac{1}{N} \cdot \frac{1 - z^{-N}}{(1 - z^{-1})} = \frac{1}{180} \cdot \frac{1 - z^{-180}}{(1 - z^{-1})} = \frac{1}{180} \cdot \frac{z^{180} - 1}{z^{180} - z^{179}} \quad (9)$$

Nakonec určíme zpoždění τ ze známého vztahu.

$$\tau = \frac{2 \cdot N}{2} = \frac{2 \cdot 180}{2} = 180 \quad (10)$$

Realizace filtru v prostředí MATLAB

Ukázka zdrojového textu: (algoritmus je implementován v souboru filtr.m)

```
rad=180; % zpoždění  $\tau$  viz. (13)
% .....
drift=filter(1/180*[1 zeros(1,rad-1) -1],[1 -1 zeros(1,rad-1)],x); %Lynn
drift=filter(1/180*[1 zeros(1,rad-1) -1],[1 -1 zeros(1,rad-1)],drift); %Lynn
data=x(1:end-(rad-1))-drift(rad:end); % odečtení signálů
% .....
```

4.1.3 Vytvoření vstupního vektoru pro neuronovou síť

Po předzpracování signálů pomocí filtrace bylo dalším krokem vytvoření vstupního vektoru, což je vektor vstupních dat z databáze, na který se bude neuronová síť trénovat (viz tabulka 1). Vstupní vektor se určil ze znalostí průběhu EKG, pozice R-vlny a vzorkovací frekvence, jež byla $f_{vz} = 360\text{Hz}$.

Tabulka 1: Deklarace vstupního vektoru

EKG(i)	EKG(i+1)	EKG(i+2)	.	.	EKG(i+n)
R(i)-m	R(i+1)-m	R(i+2)-m	.	.	R(i+n)-m
.
.
R(i)-2	R(i+1)-2	R(i+2)-2	.	.	R(i+n)-2
R(i)-1	R(i+1)-1	R(i+2)-1	.	.	R(i+n)-1
R(i)	R(i+1)	R(i+2)	.	.	R(i+n)
R(i)+1	R(i+1)+1	R(i+2)+1	.	.	R(i+n)+1
R(i)+2	R(i+1)+2	R(i+2)+2	.	.	R(i+n)+2
.
.
R(i)+k	R(i+1)+k	R(i+2)+k	.	.	R(i+n)+k

EKG – Jednotlivý EKG signál

R(i) – Pozice vzorku R-vlny

m – počet odečtených vzorků, který určuje minimální vzorek

k – počet přičtených vzorků, který určuje maximální vzorek

n – počet EKG signálů

Hodnoty \underline{m} a \underline{k} vypočítáme ze vzorkovací frekvence

$$m = f_{vz} \cdot t_1 = 360 \cdot 0,2 = 72 \text{ vzorků} \quad (11)$$

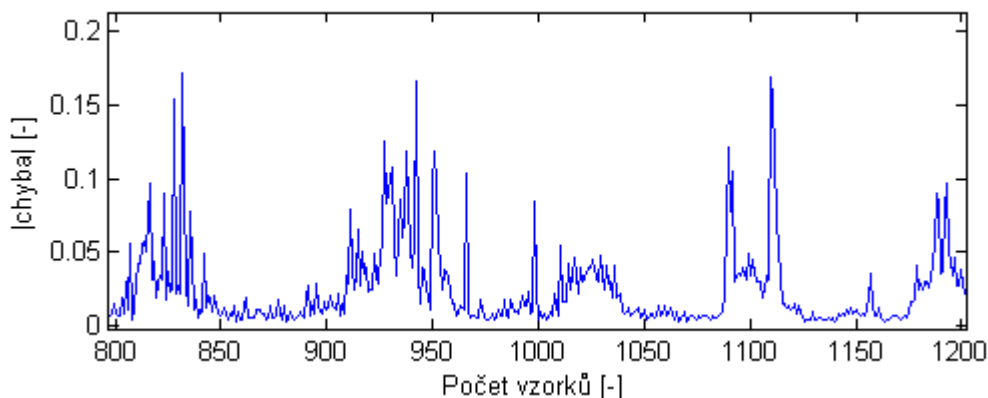
$$k = f_{vz} \cdot t_2 = 360 \cdot 0,355 = 128 \text{ vzorků} \quad (12)$$

Hodnoty 200ms a 355ms byli zvoleny na základě znalostí průběhu EKG tak, aby každý sloupec vstupního vektoru představoval jednu kvaziperiodu EKG signálu. Výsledný vstupní vektor bude tedy mít \underline{n} sloupců a 200 řádků.

4.1.4 Klasifikace pro dva záznamy 106 a 200

Pro nejjednodušší případ, kdy uvažujeme pouze dva záznamy z databáze 106 a 200, tedy $n = 2$ vyšla klasifikace velmi dobře a nebylo nutné vstupní signály filtrovat. Z obou signálů se vezme 100 kvaziperiod EKG normální cyklus a 100 kvaziperiod EKG předčasné komorové kontrakce jako trénovací množinu (Vstupní vektor). Výsledky klasifikace jsou uvedeny na obrázku 22 a obrázku 23. V prvním případě bylo špatně klasifikováno 10 kvaziperiod EKG z 2050, čemuž odpovídá procentuální chyba 0,48 %, viz (13).

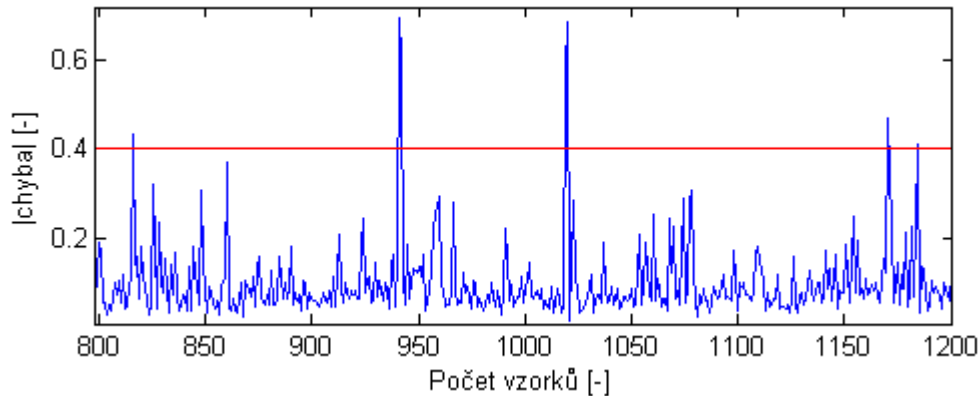
$$\delta = \frac{10}{2050} \cdot 100\% = 0,48 \text{ \%} \quad (13)$$



Obrázek 22: Výsledky klasifikace pro záznam 106

a v druhém případě bylo špatně klasifikováno 54 kvaziperiod EKG z 2565 což je procentuální chyba 2,1 % viz, (14).


$$\delta = \frac{54}{2565} \cdot 100\% = 2,1 \text{ \%} \quad (14)$$



Obrázek 23: Výsledky klasifikace pro záznam 200

Neuronová síť byla nastavena na tyto parametry:

Počet vrstev: Dvě vrstvy po 20 neuronech + jedna výstupní
 Výstupní funkce neuronů: *logsig*



Obrázek 24: Výstupní funkce neuronů v Matlabu

Trénování funkce: *traingdx*

Počet epoch: 50

Práh úspěšnosti byl nastaven na hodnotu 0.4, tzn. všechny hodnoty v absolutní hodnotě větší než 0.4 jsou detekovány jako chybné (viz obrázek 23).

4.1.5 Klasifikace pro celou databázi

Po načtení a filtraci všech signálů z databáze, které obsahovali vzorky normální stah a předčasnou komorovou kontrakci byl zapotřebí deklarovat vstupní vektor. První deklarace vstupního vektoru obsahuje z každého záznamu 20 vzorků (kvaziperiod) normálního cyklu a 20 vzorků předčasně komorové kontrakce. Po vytvoření neuronové sítě a simulaci vyšla u signálů 105, 106, 108, 203, 213 a 233 chyba více než 10 % tudíž bylo nutné u těchto signálů dát více trénovacích vzorů. Výsledný vstupní vektor poté obsahuje celkem 1555 vzorů. Z toho 960 vzorů pro normální cyklus a 595 vzorů pro předčasnou komorovou kontrakci.

Ukázka zdrojového textu: (algoritmus je implementován v souboru Vytvoření vstupního a simulačního vektoru.m)

```
InputVectormin = pozice_R-72;    % vytvoření vektoru min. hodnot
a=0; b=zeros(200,40);
for i = 1:40                    % vytvoření kvaziperiod signálu EKG
    for a = 1:200                % o délce 200 vzorků
        b(a,i) = data(InputVectormin(i)+a);
    end
end
end
```

Neuronová síť byla nastavena na tyto parametry:

Počet vrstev: Dvě vrstvy po 50 neuronech + jedna výstupní

Výstupní funkce neuronů: *logsig*

Trénování funkce: *trainscg*

Počet epoch: 300

Práh úspěšnosti byl nastaven na hodnotu 0,4, tzn. všechny hodnoty v absolutní hodnotě větší než 0,4 jsou detekovány jako chybné (viz obrázek 25).

Výstupní funkce neuronů byla zvolena tak, že na hodnotu 1 se trénují normální cykly a na hodnotu 0 předčasné komorové kontrakce. Jako trénování funkce byla zvolena *trainscg* a to z důvodu nejlepších dosažených výsledků. Jedná se o velice rychlou trénovací funkci, kdy stačí pro naučení malý počet epoch s velmi dobrou účinností klasifikace.

Výsledky klasifikace byly rozděleny do 3 podskupin. V první z nich se nacházejí vstupní záznamy, které obsahují oba klasifikované signály (viz tabulka 2).

Tabulka 2: Výsledky simulace pro signály, které obsahují oba typy signálů

Záznam	N_1 [vz]	$Ch(N)_1$ [vz]	$\delta(N)_1$ [%]	V_1 [vz]	$Ch(V)_1$ [vz]	$\delta(V)_1$ [%]
	960	0	0,00	642	2	0,34
105	2466	129	5,15	21	2	10,00
106	1480	0	0,00	480	24	5,00
108	1680	52	3,10	8	1	12,50
114	1800	7	0,39	23	0	0,00
116	2282	3	0,13	90	2	0,08
119	1520	0	0,00	420	0	0,00
200	1721	69	4,01	806	11	1,36
201	1605	0	0,00	176	1	0,57
202	2041	0	0,00	10	0	0,00
203	2465	309	12,54	405	17	4,21
205	2551	0	0,00	51	1	1,96
208	1566	24	1,53	972	2	0,21
210	2399	4	0,17	170	12	6,90
213	2620	30	1,14	179	1	0,56
215	3175	51	1,61	114	12	10,53
217	224	0	0,00	142	5	3,52
219	2062	5	0,24	45	2	4,44
221	2011	0	0,00	376	1	0,27
223	2010	16	0,80	452	7	1,55
228	1668	19	1,14	342	5	1,46
233	2169	9	0,41	809	11	1,36

$N(vz)$ – celkový počet vzorků normálního stahu

$Ch(N)$ [vz] – chyba vzorků normálního stahu

$\delta(N)$ [%] – procentuální chyba vzorků normálního stahu

$V(vz)$ – celkový počet vzorků předčasné komorové kontrakce

$Ch(V)$ [vz] – chyba vzorků předčasné komorové kontrakce

$\delta(V)$ [%] – procentuální chyba vzorků předčasné komorové kontrakce

První řádek tabulky 2 obsahuje výsledné hodnoty pro trénovací množinu, $\delta(N)_1$ je nulová a $\delta(V)_1$ je rovna 0,34 %. Průměrná procentuelní chyba pro signály z databáze je rovna:


Pro normální cyklus,

$$\delta(N)_1 = \frac{\sum Ch(N)_1}{\sum N_1} \cdot 100 \% = \frac{727}{41515} \cdot 100 \% = 1,75 \% \quad (15)$$


pro předčasnou komorovou kontrakci,

$$\delta(V)_1 = \frac{\sum Ch(V)_1}{\sum V_1} \cdot 100 \% = \frac{117}{6091} \cdot 100 \% = 1,92 \% \quad (16)$$

grafické znázornění chyb je na obrázku 25 a obrázku 26.



Obrázek 25: Chyby simulace pro záznam 105



Obrázek 26: Chyby simulace pro záznam 233

V druhé skupině se nacházejí nahrávky, které obsahují pouze normální cyklus (viz tabulka 3).


Tabulka 3: Výsledky simulace pro signály, které obsahují pouze normální cyklus

Nahrávka	N_2 [vz]	$Ch(N)_2$ [vz]	$\delta(N)_2$ [%]
100	2219	1	0,05
101	1840	2	0,11
102	79	0	0,00
103	2062	0	0,00
104	143	0	0,00
112	2517	47	1,87
113	1769	0	0,00
115	1933	0	0,00
117	1514	4	0,26
121	1841	10	0,54
122	2456	2	0,08
123	1495	0	0,00
209	2601	2	0,08
212	903	1	0,11
220	1934	0	0,00
222	2042	19	0,93
230	2235	4	0,18
231	294	0	0,00
234	2680	0	0,00

Průměrná procentuální chyba je rovna:

$$\delta(N)_2 = \frac{\sum Ch(N)_2}{\sum N_2} \cdot 100 \% = \frac{92}{32557} \cdot 100 \% = 0,28 \% \quad (17)$$

grafické znázornění chyb je na obrázku 27.




Obrázek 27: Chyby simulace pro záznam 222

V poslední skupině se nacházejí vstupní nahrávky, které obsahují pouze předčasnou komorovou kontrakci (V) (viz tabulka 4).

Tabulka 4: Výsledky simulace pro signály, které obsahují pouze V

Nahrávka	V_3 [vz]	$Ch(V)_3$ [vz]	$\delta(V)_3$ [%]
107	19	0	0,00
109	18	0	0,00
118	8	0	0,00
124	27	0	0,00
207	65	2	3,08
214	216	14	6,48

Grafické znázornění chyb je na obrázku 28.



Obrázek 28: Chyby simulace pro záznam 214

Průměrná procentuální chyba je rovna:

$$\delta(V)_3 = \frac{\sum Ch(V)_3}{\sum V_3} \cdot 100 \% = \frac{16}{353} \cdot 100 \% = 4,53 \% \quad (18)$$

Celková průměrná procentuální chyba pro normální cyklus je rovna:

$$\delta(N) = \frac{\sum Ch(N)_1 + \sum Ch(N)_2}{\sum N_1 + \sum N_2} \cdot 100 \% = \frac{819}{74072} \cdot 100 \% = 1,11 \% \quad (19)$$

Celková průměrná procentuální chyba předčasnou komorovou kontrakci je rovna:


$$\delta(V) = \frac{\sum Ch(V)_1 + \sum Ch(V)_3}{\sum V_1 + \sum V_3} \cdot 100 \% = \frac{133}{6444} \cdot 100 \% = 2,06 \% \quad (20)$$

4.2 Klasifikace pro více typů signálů

Po úspěšné klasifikaci dvou typů průběhů EKG signálů, zdravého EKG a předčasné komorové kontrakce stojíme před otázkou, zda by daný algoritmus dokázal klasifikovat i více tříd. Touto problematikou se budeme zabývat v této kapitole.

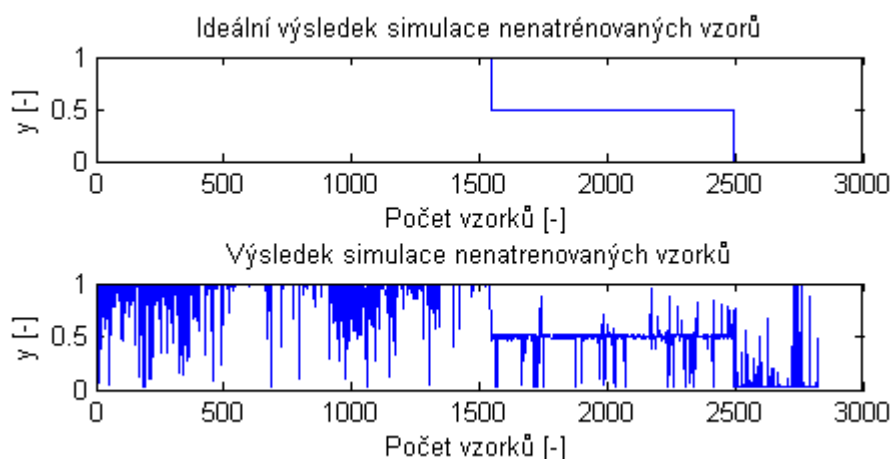
4.2.1 Využití jednoho výstupního neuronu

V předchozí situaci, kdy jsme klasifikovali pouze 2 typy průběhů EKG signálů jsme využívali k naučení a následné simulaci krajní hodnoty výstupní funkce neuronů a to hodnoty 0 a 1, při klasifikaci více signálů musíme vytvořit více rozhodovacích úrovní viz obrázek 29.



Obrázek 29: Rozhodovací úrovně pro tři různé typy EKG signálů

Z obrázku 29 je patrné, že na hodnotu jedna budeme trénovat množinu průběhu signálu prvního typu, na hodnotu 0,5 množinu druhého a nakonec na nulu množinu poslední. Touto metodou by šlo teoreticky klasifikovat nekonečně mnoho signálů, ale v praxi je tomu jinak. Důvod je prostý, při simulaci takto naučené sítě je velikost chyby úměrná počtu klasifikačních úrovní, protože u reálných signálů nevyjdou přesně hodnoty, na které je signál natrénovaný, ale hodnoty jim blízké. Z toho vyplývá, že čím více rozhodovacích úrovní dáme, tím bude větší chyba klasifikace. Výsledky simulace pro tři různé typy signálů jsou na obrázku 30.

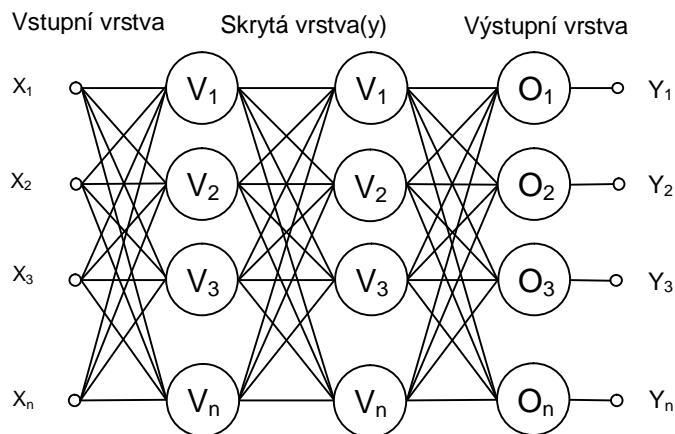


Obrázek 30: Výsledky simulace pro tři různé typy EKG signálů

Neuronová síť byla nastavena na stejné parametry jako v předchozím případě výstupní funkce byla *logsig* a trénování *trainscg*. Práh úspěšnosti byl zvolen na hodnoty 0,33 a 0,66. Touto metodou se dají klasifikovat s dostatečnou přesností maximálně 3 typy signálů, pro více signálů dosahuje chyba více jak 20 procent. Účelem této diplomové práce je klasifikovat více typů EKG signálů a proto se touto metodou dále již nebudeme zabývat.

4.2.2 Využití více výstupních neuronů

V této podkapitole se budeme věnovat problematice využití více výstupních neuronů a jejich možných použití pro klasifikaci více jak 3 typů průběhů EKG signálů. Princip této metody je jasný a pochopitelný z obrázku 31.



Obrázek 31: Principiální schéma použití více výstupních neuronů

V předchozích kapitolách jsme měli jen jeden výstupní neuron, tzn., že jeden jediný neuron nám udával výstup neuronové sítě. Zde je situace odlišná. Použijeme tolik neuronů, kolik typů chceme klasifikovat například pro čtyři arytmie použijeme pět neuronů, kdy pátý neuron je pro zdravý EKG signál. Výstupní neurony jsou naučeny podle tabulky 5.


Tabulka 5: Způsob naučení neuronové sítě na binární hodnoty 0 a 1

	zdravý signál	arytmie 1	arytmie 2	arytmie 3	arytmie 4
O1	1	0	0	0	0
O2	0	1	0	0	0
O3	0	0	1	0	0
O4	0	0	0	1	0
O5	0	0	0	0	1

Neuronovou síť naučíme pomocí tabulky 5 na binární hodnoty 0 a 1. Když předložíme neuronové síti například arytmiu typu jedna, pak se bude výstupní neuron O1 učit na hodnotu nula, výstupní neuron O2 se bude učit na hodnotu jedna, atd. pomocí zvýrazněného sloupečku tabulky 5. To znamená, že při následné simulaci by jsme měli pro první arytmiu dostat posloupnost hodnot 0, 1, 0, 0, 0. Když byla tato metoda aplikována na celou databázi, stejně jako v předchozím případě, dosahovala dobrých výsledků pouze pro tři a méně různých typů signálů. Opět platí pravidlo čím více typů, tím horší klasifikace. Tato metoda přesto, ve srovnání s předešlou, dosahuje lepších výsledků. Jeden z hlavních důvodů je, že v předchozím případě byl na výstupu jeden neuron, který má výstupní rozsah nula až jedna. Mezi tyto hodnoty se muselo nastřádat pět rozhodovacích úrovní. Zatímco v případě použití více výstupních neuronů se neurony učili buď na logickou hodnotu jedna nebo nula. Ve výsledné simulaci pak jasně vidíme, že pro jeden výstupní neuron a více výstupních úrovní se nám chyba násobí s počtem hladin (viz obrázek 30). Zatímco při metodě využití více neuronů tomu tak není. Touto metodou se také nebudeme dále v této diplomové práci zabývat.

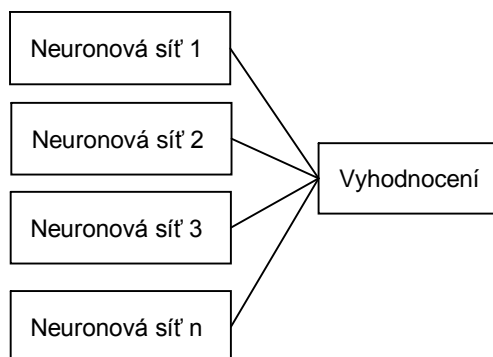
4.2.3 Klasifikace pomocí souboru neuronových sítí

Jako nejlepší metoda pro klasifikaci více než tří typů průběhů EKG signálů se ukázala metoda, při které použijeme více neuronových sítí, kdy každá síť má ve výstupní vrstvě jeden neuron. Každá síť se natrénuje na jeden typ průběhu EKG signálu. To znamená, že pro náš případ, kdy klasifikujeme pět různých průběhů, použijeme pět neuronových sítí podobného typu, s tím rozdílem, že každá bude natrénovaná na jiný signál. Trénovat budeme podle jednoduchého pravidla.



Obrázek 32: Neuronová síť s jedním výstupním neuronem

Na obrázku 32 je zobrazena jedna část celkové neuronové sítě. Této síti předložíme všechny typy EKG signálů, na které budeme chtít síť natrénovat. Rozdíl od předchozích metod je ten, že danou síť budeme trénovat tím způsobem, že na jeden typ EKG signálu bude naučena na logickou jedničku a na všechny ostatní na logickou nulu. Například první arytmií natrénujeme na hodnotu jedna a všechny ostatní signály na hodnotu nula. Takto se bude pokračovat dále druhou arytmií zase na hodnotu jedna a všechny ostatní na hodnotu nula, až do té doby, než se natrénuje neuronová síť na všechny klasifikované typy průběhů signálů (viz obrázek 33). Hlavní výhoda této metody oproti předešlým je, že se výstupní neuron neuronové sítě učí pouze na dvě výstupní hodnoty, hodnoty nula a jedna, a zároveň se učí na všechny typy signálů. Tato skutečnost otevřela možnosti klasifikace téměř neomezenému počtu typů vstupních signálů.



Obrázek 33: Blokové schéma principu učení neuronové sítě

Před vytvořením sítě neuronových sítí se nesmí samozřejmě zapomenout na správné načtení a předzpracování vstupních EKG signálů. Bude se opět postupovat podle blokového schématu, které je na obr.18. Načtení a filtrace je totožná s metodou, kdy bylo úkolem klasifikovat pouze dva typy EKG signálů. Tato problematika je popsána v kapitolách 4.1.1. a 4.1.2. Vstupní vektor, na který se bude neuronová síť učit, je nutno doplnit o chybějící vzorky EKG signálů. Konkrétně o blokádu levého a pravého Tawarova raménka a signál při Kardiostimulaci. Deklarace Vstupního vektoru se provede pomocí tabulky 6. Vstupní vektor, na který se bude neuronová síť učit, bude tedy obsahovat pět typů EKG signálů.

Tabulka 6: Označení jednotlivých typů EKG signálů

normální cyklus	N
blokáda levého Tawarova raménka	L
blokáda pravého Tawarova raménka	R
předčasná komorová kontrakce	V
stah po kardiostimulaci	P

Po úspěšném natrénování všech pěti neuronových sítí pomocí trénovací funkce *trainscg*, což je gradientní metoda backpropagation, je nutné síť odsimulovat. Jak je psáno výše, každá neuronová síť, resp. každý výstupní neuron by měl mít ideálně na výstupu hodnotu nula nebo jedna. Simulace probíhá tak, že se simuluje každá neuronová síť zvlášť na vstupní vektor, na který byla natrénována. Každá neuronová síť by po simulaci měla mít na výstupu ideálně jedničku pro daný typ EKG signálu, na který se trénovala a na ostatní nulu. Simulace neuronové sítě však není ideální, ale chyby jsou minimální, maximální odchylka v absolutní hodnotě je rovna 0,05. Po simulaci všech pěti neuronových sítí na vstupní trénovací signály, obdržíme hodnoty, které uvádí tabulka 7.

Tabulka 7: Výsledky po simulaci celé neuronové sítě

	1	2	3	4	5	6	.	.	n
NS1	sim N1	sim N2	sim N3	sim N4	sim N5	sim N6	.	.	sim Nn
NS2	sim L1	sim L2	sim L3	sim L4	sim L5	sim L6	.	.	sim Ln
NS3	sim R1	sim R2	sim R3	sim R4	sim R5	sim R6	.	.	sim Rn
NS4	sim A1	sim A2	sim A3	sim A4	sim A5	sim A6	.	.	sim An
NS5	sim V1	sim V2	sim V3	sim V4	sim V5	sim V6	.	.	sim Vn

V prvním řádku tabulky 7 jsou výsledné hodnoty simulace první neuronové sítě, tato síť je natrénována na normální cyklus. To znamená, v pozici jedniček je ideálně klasifikován normální stah a v pozici nula ostatní signály. V druhém je síť naučena na blokádu levého Tawarova raménka, atd. Následné vyhodnocení typu EKG signálu se realizuje pomocí jednoduchého pravidla. Nejvyšší hodnotě prvního sloupce přiřadíme hodnotu jedna a ostatním hodnotu nula. Tímto způsobem se bude pokračovat pro všechny sloupce pro celou tabulku. V takto získané tabulce jsou již jednotlivé typy průběhu EKG signálu kódovány. Kódovací tabulka je na následující straně (viz tabulka 8).

Tabulka 8: Kódování jednotlivých typů EKG signálu

N	L	R	V	P
1	0	0	0	0
0	1	0	0	0
0	0	1	0	0
0	0	0	1	0
0	0	0	0	1

Velmi důležité pro následnou simulaci nenatréovaných signálů je dosáhnout co nejmenší chyby klasifikace natréovaných signálů. Platí, že čím se dosáhne menší chyby simulace natréovaných signálů, tím bude přesnější klasifikace pro nenatréované vzory, protože když nebude neuronová síť správně naučena není schopna s velmi dobrou přesností vyhodnotit signály, na které naučena není. Chyby simulace natréovaných signálů jsou uvedeny v následujících vztazích.

Výpočet chyby pro normální cyklus,

$$\delta N = \frac{0}{2540} \cdot 100 \% = 0 \% \quad (16)$$

výpočet chyby blokady levého Tawarova raménka,

$$\delta L = \frac{0}{200} \cdot 100 \% = 0 \% \quad (17)$$

výpočet chyby blokady pravého Tawarova raménka,

$$\delta R = \frac{0}{290} \cdot 100 \% = 0 \% \quad (18)$$

výpočet chyby pro předčasnou komorovou kontrakci,

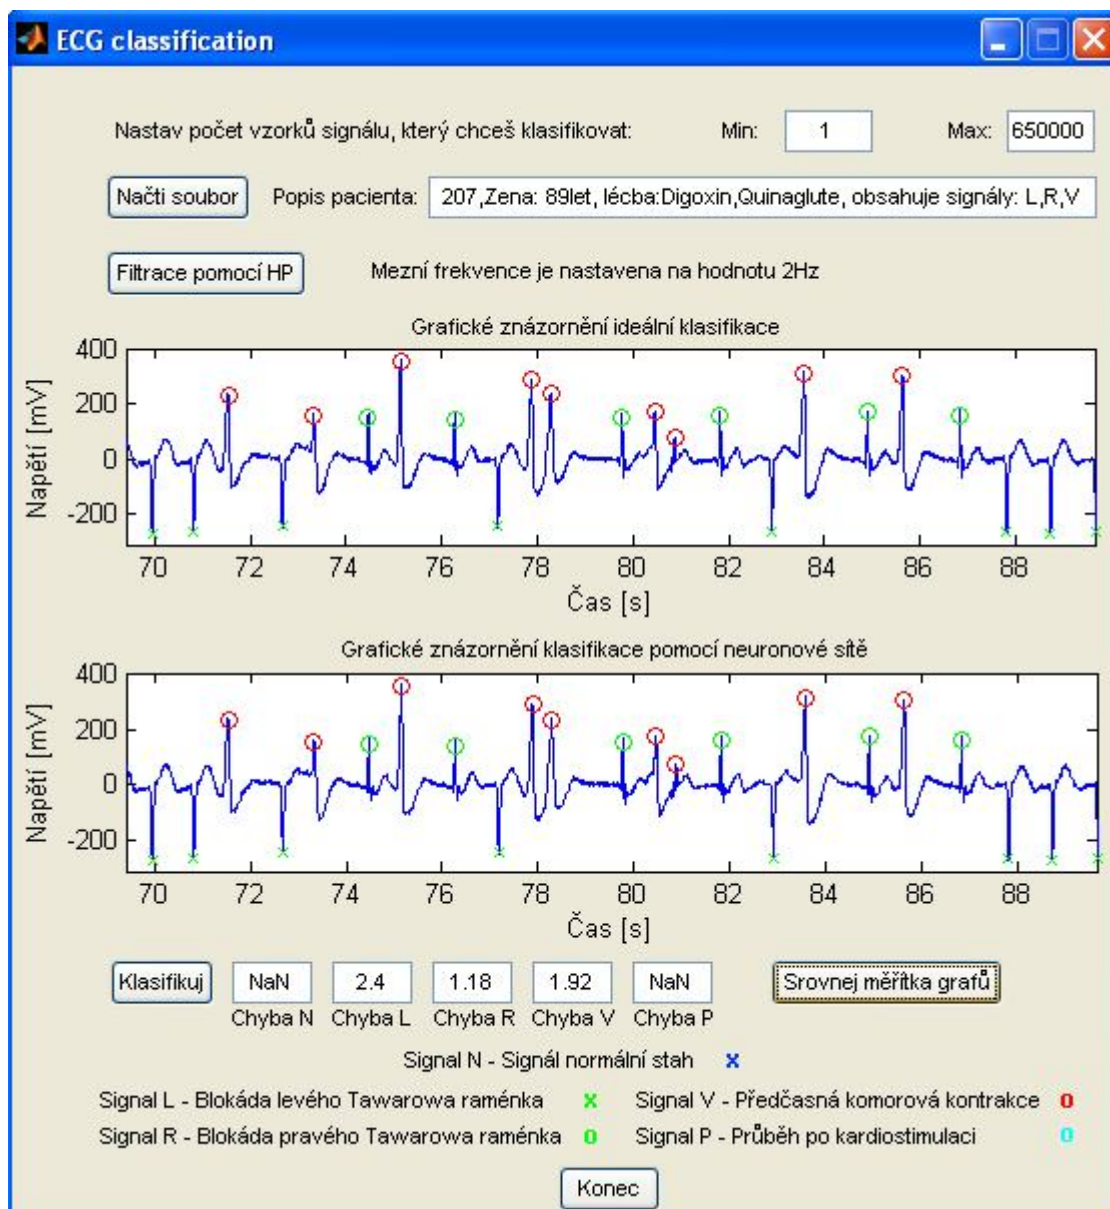
$$\delta V = \frac{0}{1038} \cdot 100 \% = 0 \% \quad (19)$$

výpočet chyby pro signál po kardiostimulaci,

$$\delta P = \frac{0}{100} \cdot 100 \% = 0 \% \quad (20)$$

Výsledný vstupní vektor obsahuje 4168 vzorků EKG signálů z celkových 96000. Všechny procentuální chyby natréovaných signálů jsou nulové, tzn. že jsou neuronové sítě správně naučeny. Nyní zbývá odsimulovat neuronové sítě na nenatréovaných signálech. Seznam všech použitých signálů je přiložen v příloze (viz tabulka 14).

Pro přehlednou simulaci neuronové sítě je vytvořena aplikace v prostředí Guide (viz obrázek 34).



Obrázek 34: Klasifikace pomocí aplikace v Guide

Po spuštění aplikace pomocí příkazu diplomka se zobrazí uživatelské rozhraní obrázek 34. Nejprve se vybere počet vzorků EKG signálu, které chceme klasifikovat. Minimální hodnota je 1 a maximální 650000. Poté pomocí tlačítka „načti soubor“ načteme jeden z přístupných EKG signálů. V kolonce „popis pacienta“ se zobrazí jeho stručný popis. Zobrazí se, o jaký signál jde, pohlaví pacienta, používané léky a typy průběhů EKG signálů, které obsahuje. Načtený EKG signál se zobrazí v horním grafu. Po stisku tlačítka „filtrace“ a následnému stisku tlačítka „klasifikuj“ se zobrazí v horním grafu vyfiltrovaný signál pomocí HP s mezní frekvencí 2Hz s ideálním vyznačením jednotlivých typů průběhů EKG signálů. V dolním grafu jsou zobrazeny výsledky klasifikace pomocí neuronové sítě. Ideálně by se měli oba grafy shodovat. Tlačítko „srovnej měřítko“ slouží k nastavení obou grafů na stejný rozsah, když byla použita funkce zoom. Barevné označení jednotlivých EKG signálů slouží k snadnému vyhodnocení dosažených výsledků na jakémkoliv úseku načteného signálu. Klasifikace pomocí aplikace v *Guide* je velice přehledná a snadná.

Výsledky klasifikace pro celou databázi

Výsledky klasifikace se pro přehlednost rozdělí na několik částí. V první části se budeme věnovat výsledkům klasifikace pro signály, které byly přidány k předešlým, tj. které už dokázala neuronová síť rozeznat. Prvním z těchto signálů je blokáda levého Tawarova raménka, označená jako L. Tuto arytmií obsahují záznamy od pacientů 109, 111, 207 a 214. Výsledky klasifikace jsou zobrazeny v tabulce 9.

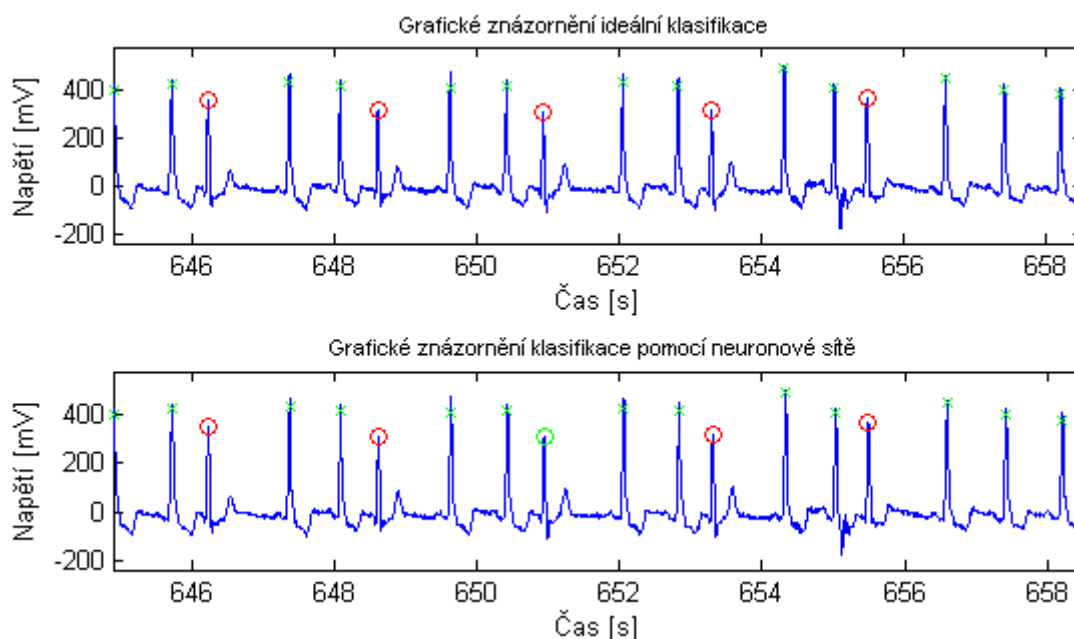
Tabulka 9: Výsledky klasifikace pro signály, které obsahují L

Záznam	$L_{celk}[-]$	$L_{chyb}[-]$	$L[\%]$	$R_{celk}[-]$	$R_{chyb}[-]$	$R[\%]$	$V_{celk}[-]$	$V_{chyb}[-]$	$V[\%]$
109	2488	31	1,25	-	-	-	38	4	10,53
111	2121	92	4,35	-	-	-	-	-	-
207	1457	35	2,4	85	2	2,4	105	2	1,92
214	2000	95	4,76	-	-	-	256	18	7,03

Z procentuálních výsledků je patrné, že se síť natrénovala na tuto arytmií velmi dobře. Maximální chyba klasifikace je pro záznam 214 a je rovna 4,76 %. Výpočet chyby je uveden ve vztahu 21.

$$\delta L_{214} = \frac{L_{chyb}}{L_{celk}} \cdot 100 \% = \frac{95}{2000} \cdot 100 \% = 4,76 \% \quad (21)$$

Na obrázku 35 je zobrazen průběh tohoto signálu. Zde je vidět jednu špatně detekovanou kvaziperiodu EKG signálu, kdy neuronová síť této arytmií přiřadila blokádu pravého Tawarova raménka místo předčasnou komorovou kontrakci. Klasifikace levého Tawarova raménka je znázorněna bez chyb.



Obrázek 35: Grafické znázornění klasifikace záznamu 214

Legenda:
x – blokáda levého Tawarova raménka
o – předčasná komorová kontrakce
o – blokáda pravého Tawarova raménka

Celková chyba klasifikace blokády levého Tawarova raménka se spočítá podle vztahu:

$$\delta L = \frac{\sum L_{chyb}}{\sum L_{celk}} \cdot 100 \% = \frac{253}{8066} \cdot 100 \% = 3,13 \% \quad (22)$$

V druhé části se bude věnovat výsledkům klasifikace pro signály, které obsahují blokádu pravého Tawarova raménka - R. Tuto arytmii obsahují záznamy od pacientů 118, 124, 207, 212, 231 a 232. Výsledky klasifikace jsou zobrazeny v tabulce 10.

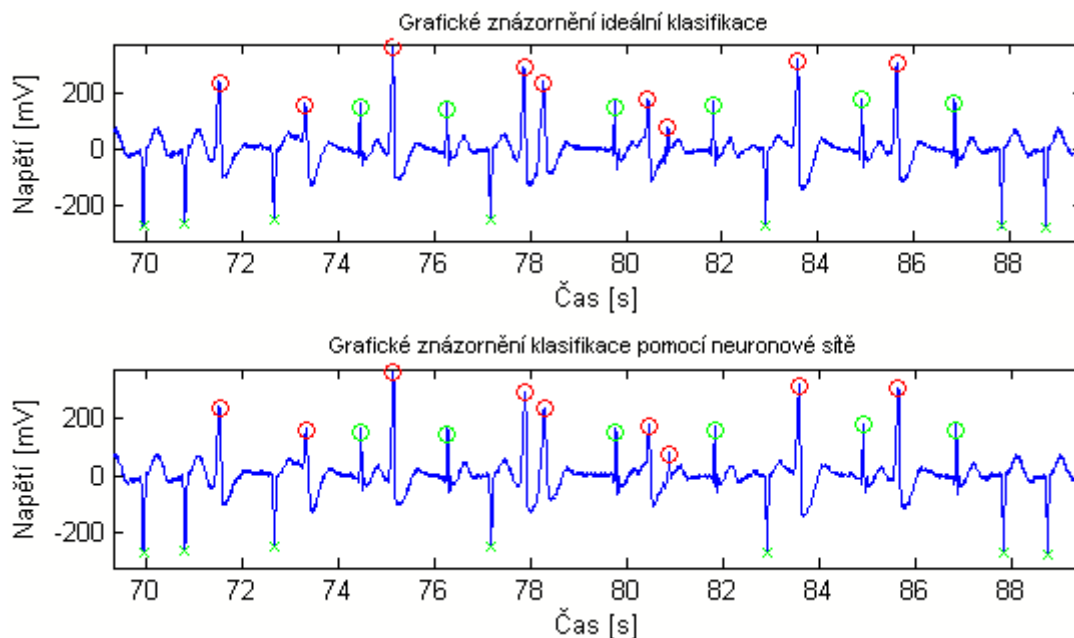
Tabulka 10: Výsledky klasifikace pro signály, které obsahují R

Záznam	R _{celk} [-]	R _{chyb} [-]	R[%]	L _{celk} [-]	L _{chyb} [-]	L[%]	V _{celk} [-]	V _{chyb} [-]	V[%]
118	2164	26	1,20	-	-	-	16	14	87,5
124	1531	5	0,33	-	-	-	-	-	-
207	85	1	1,18	1457	35	2,4	105	18	17,02
212	1825	4	0,22	-	-	-	-	-	-
231	1252	1	0,08	-	-	-	-	-	-
232	1382	3	0,25	-	-	-	-	-	-

Z procentuálních výsledků je patrné, že se neuronová síť natrénovala i na tu to arytmii velmi dobře. Maximální chyba klasifikace je pro záznam 118 a je rovna 1,20 %. Výpočet chyby je uveden ve vztahu 23.

$$\delta R_{118} = \frac{R_{chyb}}{R_{celk}} \cdot 100 \% = \frac{26}{2164} \cdot 100 \% = 1,20 \% \quad (23)$$

Na obrázku 36 je zobrazen průběh signálu 207, všechny zde uvedené kvaziperiody EKG jsou klasifikovány správně.



Obrázek 36: Grafické znázornění klasifikace záznamu 207

Legenda:
○ – blokáda pravého Tawarova raménka
x – blokáda levého Tawarova raménka
○ – předčasná komorová kontrakce

Celková chyba klasifikace blokády pravého Tawarowa raménka se spočítá podle vztahu:

$$\delta R = \frac{\sum R_{chyb}}{\sum R_{celk}} \cdot 100 \% = \frac{40}{8239} \cdot 100 \% = 0,49 \% \quad (24)$$

V další části se bude věnovat výsledkům klasifikace pro signály, které obsahují EKG signál po kardiostimulaci (peaced rythm) - P. Tuto arytmiu obsahují záznamy od pacientů 107 a 217. Výsledky klasifikace jsou zobrazeny v tabulce 11.

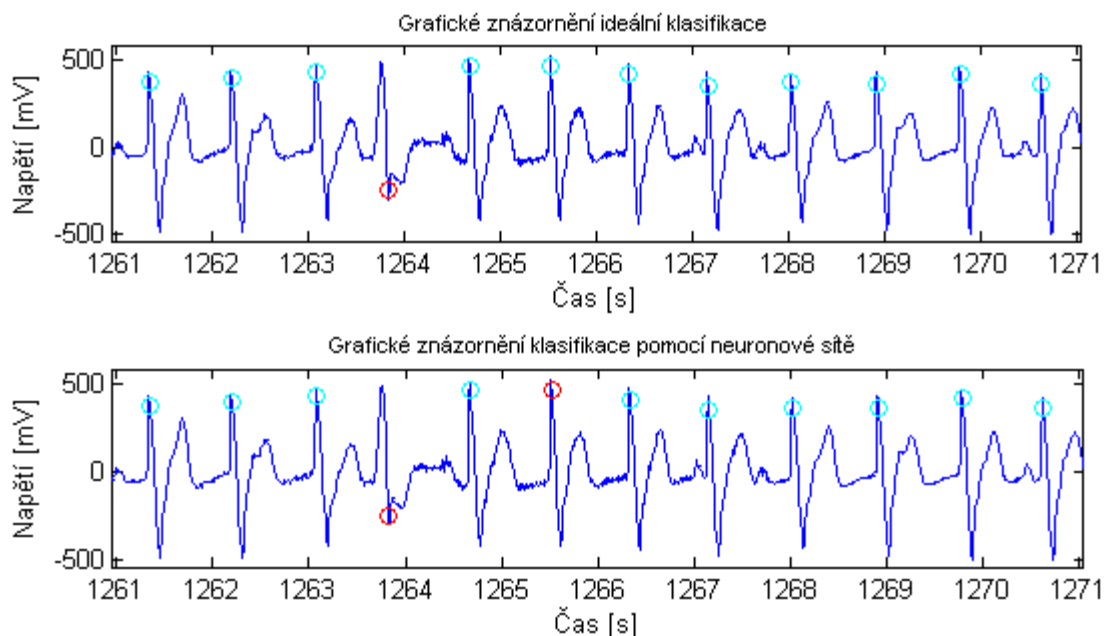
Tabulka 11: Výsledky klasifikace pro signály, které obsahují P

Záznam	P _{celk} [-]	P _{chyb} [-]	P[%]	N _{celk} [-]	N _{chyb} [-]	N[%]	V _{celk} [-]	V _{chyb} [-]	V[%]
107	2076	19	0,92	-	-	-	59	46	77,97
217	1541	8	0,52	244	0	0	-	-	-

Klasifikace signálů 107 a 217 je opět výborná nejvyšší chyba klasifikace pro signál s kardiostimulací je 0,92 % u záznamu 107. Výpočet chyby je uveden ve vztahu 25.

$$\delta P_{118} = \frac{P_{chyb}}{P_{celk}} \cdot 100 \% = \frac{19}{2076} \cdot 100 \% = 0,92 \% \quad (25)$$

Na obrázku 37 je zobrazen průběh signálu 107, jedna ze zde uvedených kvaziperiod EKG není detekována správně.



Obrázek 37: Grafické znázornění klasifikace záznamu 107

Legenda: ○ – EKG po kardiostimulaci
○ – předčasná komorová kontrakce

Celková chyba klasifikace EKG po kardiostimulaci se spočítá podle vztahu:

$$\delta P = \frac{\sum P_{chyb}}{\sum P_{celk}} \cdot 100 \% = \frac{27}{3617} \cdot 100 \% = 0,75 \% \quad (26)$$

Nakonec se budeme věnovat výsledkům klasifikace pro signály, které výše uvedené záznamy neobsahují - tedy normální cyklus a předčasnou komorovou kontrakci. Výsledky klasifikace jsou zobrazeny v tabulce 12.

Tabulka 12: Výsledky klasifikace pro signály, které neobsahují L, R, P

Záznam	N _{celk} [-]	N _{chyb} [-]	N[%]	Záznam	N _{celk} [-]	N _{chyb} [-]	N[%]	V _{celk} [-]	V _{chyb} [-]	V[%]
100	2239	0	0	105	2526	84	3,33	41	2	4,88
101	1860	0	0	106	1500	3	0,2	520	16	3,09
103	2082	1	0,05	116	2300	9	0,39	110	1	0,92
112	2537	8	0,32	119	1540	2	0,13	440	1	0,23
113	1789	0	0	124	-	-	-	47	8	17,02
115	1953	0	0	200	1741	103	5,93	826	24	2,91
117	1534	144	9,36	201	1625	1	0,06	195	1	0,51
121	1861	17	0,92	202	2060	1	0,05	19	0	0
122	2476	0	0	203	2525	394	15,6	445	50	11,26
123	1515	0	0	205	2570	0	0	71	0	0
209	2621	4	0,15	208	1585	14	0,88	990	6	0,61
212	923	0	0	210	2419	6	0,25	190	8	4,15
220	1954	0	0	213	2640	0	0	219	4	1,82
222	2062	30	1,46	215	3195	61	1,91	164	19	11,59
230	2255	24	1,07	217	244	0	0	162	4	2,47
234	2700	0	0	219	2082	4	0,19	64	5	7,94
-	-	-	-	221	2031	0	0	396	1	0,25
-	-	-	-	223	2029	38	1,88	473	55	11,63
-	-	-	-	228	1688	30	1,78	362	2	0,55

Výpočet chyby pro normální cyklus pro záznam 222 je uveden ve vztahu 27:

$$\delta N_{222} = \frac{N_{chyb}}{N_{celk}} \cdot 100 \% = \frac{30}{2062} \cdot 100 \% = 1,46 \% \quad (27)$$

Výpočet pro předčasný komorový cyklus pro záznam 224 je uveden ve vztahu 28:

$$\delta V_{244} = \frac{V_{chyb}}{V_{celk}} \cdot 100 \% = \frac{4}{162} \cdot 100 \% = 2,47 \% \quad (28)$$

Nejhorší klasifikace pro normální stah je rovna 15,6 % pro signál 203 a nejhorší klasifikace pro předčasnou komorovou kontrakci je 17,02 % pro signál 124. Přesto dosáhla neuronová síť i v těchto příkladech velmi dobrých výsledků.


Celková chyba klasifikace EKG pro normální stah se spočítá podle vztahu:

$$\delta N = \frac{\sum N_{chyb}}{\sum N_{celk}} \cdot 100 \% = \frac{978}{68905} \cdot 100 \% = 1,42 \% \quad (29)$$

Celková chyba klasifikace EKG pro předčasnou komorovou kontrakci se spočítá podle vztahu:

$$\delta V = \frac{\sum V_{chyb}}{\sum V_{celkem}} \cdot 100 \% = \frac{285}{5914} \cdot 100 \% = 4,82 \% \quad (30)$$

Na obrázku 38 je zobrazen průběh záznamu 116, tento záznam obsahuje oba výše uvedené typy signálů. Všechny zobrazené kvaziperiody EKG signálu jsou klasifikovány pomocí neuronové sítě správně.



Obrázek 38: Grafické znázornění klasifikace záznamu 116

Legenda: x – normální stah
o – předčasná komorová kontrakce

Dosažené celkové výsledky pro jednotlivé typy EKG signálu jsou přehledně zobrazeny v tabulce 13.

Tabulka 13: Dosažené výsledky klasifikace pomocí neuronové sítě

	Celkem [-]	Chyba [-]	Chyba [%]
Typ N	68905	978	1,42
Typ L	8066	253	3,13
Typ R	8239	40	0,49
Typ V	5914	285	4,82
Typ P	3617	27	0,75

Ve prvním sloupci tabulky 13 se nachází celkový počet kvaziperiod EKG signálu jednotlivých typů. V druhém sloupci počet chybně klasifikovaných kvaziperiod a ve třetím celková procentuální chyba klasifikace.

5 Závěr

V Diplomové práci jsem se seznámil s problematikou využití neuronových sítí pro klasifikaci signálu EKG. V prostředí MATLAB jsem realizoval klasifikační algoritmus, jehož účinnost jsem ověřil na signálech databáze [1]. Po nahrání signálů následovalo předzpracování pomocí filtrace. Použil jsem Lynnův filtr typu horní propust s mezní frekvencí $f_m = 2\text{Hz}$, který odstranil stejnosměrnou složku a frekvence způsobené pohybovými artefakty, které způsobovaly klasifikaci s malou účinností. Vlastní neuronová síť je vytvořena pomocí příkazu *newff*. Jedná se o neuronovou síť typu back-propagation mezi jejíž výhody patří jednoduchost, flexibilita a hlavně výborné klasifikační vlastnosti. Cílem tohoto projektu bylo rozpoznat více jak dva typy průběhů EKG signálů. Nejlépe se osvědčila konfigurace neuronových sítí, kdy se každá síť naučila na daný typ průběhu EKG signálu. Výsledkem této práce je aplikace, která po načtení EKG signálu z databáze provede jeho předzpracování a následnou klasifikaci jednotlivých kvaziperiod do pěti různých tříd. Z výsledných chyb pro jednotlivé typy EKG signálu lze konstatovat, že celkově nejlepší výsledky klasifikace dosahuje neuronová síť při klasifikaci pravé blokády Tawarova raménka a to chybou pouze 0,49 %. A nejhůře klasifikuje předčasnou komorovou kontrakci 4,82%. Všechny chyby jsou přehledně zobrazeny v tabulce 13. Pomocí neuronových sítí by bylo možné klasifikovat i více typů průběhů EKG signálů, kdyby databáze [1] obsahovala větší počet vstupních signálů, nutných pro dostatečné naučení sítě. Chyby klasifikace uvedené v databázi jsou srovnatelné s výsledky této diplomové práce.

6 Použitá literatura

- [1] PhysioNet the research resource for complex physiologic signals. *Physionet*. <http://www.physionet.org/physiobank/database/mitdb/>
- [2] JAN, J.: *Číslicová filtrace, analýza a restaurace signálů*, Vydavatelství VUTIUM, ISBN 80-214-2911-9.
- [3] KVASNIČKA, J., SKAUNIC, V., VOKROUHLICKÝ, L.: *Kardiologie: Učební text pro posluchače lékařské fakulty*, Dotisk, Praha:Univerzita Karlova, 1986. ISBN 60-97-86
- [4] HU, Y.H., TOMPKINS, W., URRUSTU, J.L., ALFONZO, V.X. *Applications of artificial neural network for ECG signal detection and classification*. *Electrocardiol.* 1994
- [5] JIŘINA, M.: *Neuronové sítě*. Praha : Nakladatelství ČVUT, 1995.
- [6] KROSE, B., SMALT, P. *An introduction to Neural Networks*. November 1996.
- [7] HONZÍKOVÁ, N. a HONZÍK, P. *Biologie člověka*. VUT v Brně, 2003.
- [8] JIRSÍK, V. a HRÁČEK, P. *Neuronové sítě, expertní systémy a rozpoznávání řeči*. VUT v Brně.

Příloha A

Tabulka 14: Seznam všech záznamů z databáze [1]
Vlevo počet celkových kvaziperiod EKG signálu, vpravo počet trénovacích

záznam	N	L	R	V	P	N	L	R	V	P
100	2235	-	-	-		50	-	-	-	
101	1857	-	-	-		50	-	-	-	
103	2079	-	-	-		50	-	-	-	
105	2523	-	-	41		50	-	-	20	
106	1505	-	-	520		50	-	-	40	
107	-	-	-	59	2076	-	-	-	40	50
109	-	2488	-	38		-	50	-	20	
111	-	2119	-	-		-	50	-	-	
112	2534	-	-	-		50	-	-	-	
113	1785	-	-	-		50	-	-	-	
115	1950	-	-	-		50	-	-	-	
116	2297	-	-	109		50	-	-	50	
117	1530	-	-	-		50	-	-	-	
118	-	-	2163	16		-	-	50	8	
119	1541	-	-	433		50	-	-	50	
121	1858	-	-	-		50	-	-	-	
122	2473	-	-	-		50	-	-	-	
123	1512	-	-	-		50	-	-	-	
124	-	-	1528	47		-	-	50	20	
200	1741	-	-	825		50	-	-	50	
201	1622	-	-	198		50	-	-	40	
202	2058	-	-	19		50	-	-	10	
203	2527	-	-	444		50	-	-	50	
205	2568	-	-	71		50	-	-	30	
207	-	1457	85	104		-	50	40	40	
208	1584	-	-	991		50	-	-	50	
209	2618	-	-	-		50	-	-	-	
210	2419	-	-	194		50	-	-	50	
212	921	-	1823	-		50	-	50	-	
213	2636	-	-	220		50	-	-	40	
214	-	1998	-	256		-	50	-	40	
215	3192	-	-	164		50	-	-	40	
217	244	-	-	162	1541	40	-	-	40	50
219	2078	-	-	64		50	-	-	30	
220	1950	-	-	-		50	-	-	-	
221	2027	-	-	396		50	-	-	50	
222	2058	-	-	-		50	-	-	-	
223	2025	-	-	473		50	-	-	50	
228	1685	-	-	361		50	-	-	50	
230	2251	-	-	-		50	-	-	-	
231	314	-	1250	-		50	-	50	-	
232	-	-	396	-		-	-	50	-	
233	2226	-	-	830		50	-	-	50	
234	2696	-	-	-		50	-	-	-	