



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 SIGNÁLŮ DENNÍ AKTIVITY

CLASSIFICATION OF FREE LIVING DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Martin Rychtárik

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Radovan Smíšek

BRNO 2019

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Martin Rychtářík

ID: 184267

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Klasifikace signálů denní aktivity

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou snímání biosignálů pomocí nositelných zařízení. 2) Seznamte se s problematikou klasifikace denní aktivity pomocí dat ze senzorů chytrého mobilního telefonu (akcelerometr, gyroskop apod.). 3) Nasnímejte pomocí senzorů chytrého mobilního telefonu denní aktivitu alespoň 10 osob. Anotujte nasnímaná data, zahrňte alespoň 8 druhů aktivit. 4) Realizujte v programovém prostředí MATLAB algoritmus určující denní aktivitu ze získaných dat. 5) Dle výsledků algoritmus optimalizujte. 6) Diskutujte dosažené výsledky klasifikace.

DOPORUČENÁ LITERATURA:

[1] DEL ROSARIO, Michael, Stephen REDMOND a Nigel LOVELL. Tracking the Evolution of Smartphone Sensing for Monitoring Human Movement. *Sensors*. 2015, 15(8), 18901-18933. ISSN 1424-8220.

[2] KHAN, Adil Mehmood, Ali TUFAIL, Asad Masood KHATTAK a Teemu H. LAINE. Activity Recognition on Smartphones via Sensor-Fusion and KDA-Based SVMs. *International Journal of Distributed Sensor Networks*. 2014, 10(5), 503291. ISSN 1550-1477.

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Radovan Smíšek

Konzultant:

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

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské 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

Tématem této bakalářské práce je klasifikace signálů denní aktivity nasnímaných pomocí akcelerometrického senzoru chytrého mobilního telefonu. První část práce se zabývá seznámením s možnostmi záznamu denní aktivity pomocí akcelerometru a následné klasifikace neuronovou sítí. V další části byla na desíti osobách nasnímana data osmi různých denních aktivit. K datům byl v programovacím prostředí MATLAB vytvořen algoritmus obsahující neuronovou síť pro automatické rozpoznání daných aktivit. V poslední části práce byla klasifikace vytvořeným algoritmem porovnána s manuálně zaznamenanou referencí a výsledky byly statisticky vyhodnoceny.

Klíčová slova

klasifikace denní aktivity, denní aktivita, nositelná zařízení, chytrý mobilní telefon, akcelerometr, neuronová síť

Abstract

The topic of this bachelor thesis is classification of free living data, captured by the accelerometer sensor of a smart phone. The first part of the thesis deals with the possibilities of recording daily activity using accelerometer and subsequent classification by neural network. In the next section, the data of eight different daily activities were recorded on ten people. An algorithm containing a neural network was created for the data in the MATLAB programming environment to automatically identify the activities. In the last part of the work the algorithm classification was compared with manually recorded reference and the results were statistically evaluated.

Keywords

free living data classification, daily activity, wearable devices, smartphone, accelerometer, neural network

Bibliografická citace

RYCHTÁŘIK, Martin. *Klasifikace signálů denní aktivity*. Brno, 2019. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/118308>. Bakalářská práce. 43s. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Radovan Smíšek.

Prohlášení o původnosti práce

Prohlašuji, že svou diplomovou práci na téma „Klasifikace signálů denní aktivity“ 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 bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské 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., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne

.....

Podpis autora

Poděkování

Rád bych poděkoval vedoucímu bakalářské práce panu Ing. Radovanu Smíškovi za odborné vedení, konzultace a podnětné návrhy k práci.

Obsah

Úvod	7
1 Problematika snímání biosignálů pomocí nositelných zařízení	8
1.1 Nositelná zařízení	8
1.2 Akcelerometrický senzor.....	8
2 Metody klasifikace denní aktivity z dat mobilních senzorů	12
2.1 Obecný postup klasifikace.....	12
2.2 Příznaky (features)	12
2.3 Neuronové sítě.....	14
2.3.1 Neuron.....	15
2.3.2 Klasifikace pomocí neuronu	16
2.3.3 Učení neuronové sítě	17
3 Snímání dat	18
3.1 Metodika snímání	18
3.2 Surová akcelerometrická data aktivit.....	19
4 Realizace algoritmu klasifikace v programovém prostředí MATLAB	22
4.1 Úprava dat	22
4.2 Výpočet příznaků	22
4.3 Neuronová síť	25
5 Optimalizace algoritmu	27
6 Výsledky a diskuze	32
Závěr	38
Seznam použitých zdrojů	40
Seznam obrázků.....	42
Seznam příloh.....	43

Úvod

Snímání a klasifikace (určování) denní aktivity má různá praktická využití. Jedním z nich je poskytnutí informace o fyzické aktivitě snímané osoby, pro lékařské účely. Dále je možné získaná data použít pro statistické účely nebo je využít k osobním účelům snímané osoby.

Nositelná zařízení byla jako záznamová a potenciálně i klasifikační zařízení vybrána pro jejich bezproblémovou a pohodlnou manipulaci. Na rozdíl od specializovaných senzorů, které je nutné komplikovaně připevňovat na tělo snímané osoby pomocí upínacích pásků apod. Ne každý by také chtěl každodenně nosit samostatný senzor, určený pouze k detekci denní aktivity. Z uvedených důvodů byl pro potřeby této bakalářské práce vybrán jako zástupce nositelných zařízení chytrý mobilní telefon, který je snadno dostupný – v dnešní době jej vlastní téměř každý, a je možné jej využít k řadě dalších aktivit vyjma samotné klasifikace denní aktivity. Zároveň umožňuje pohodlné nošení na těle, například v kapse u kalhot. Smartphone také disponuje dostatečně výkonným hardware pro potenciální klasifikaci.

Vzhledem k rozvoji moderních technologií, sedavému způsobu života a působení dalších nežádoucích faktorů, dochází k tomu, že má naše populace čím dál větší sklony k obezitě. Proto lze uvést konkrétní příklad využití zkoumané metody, kdy by pacient trpící obezitou, vysokým krevním tlakem, popř. diabetem 2. typu, každý den pomocí mobilní aplikace snímal svou denní aktivitu a ta by byla následně klasifikována. Ošetřující lékař by ze záznamu rozeznal fyzických aktivit vyhodnotil, kolik pacient spotřeboval energie, jaké pohybové partie zapojil apod. Podle získaných hodnot by bylo možné upravit jídelníček sledované osoby, popř. její cvičební a pohybový plán. Dalším praktickým využitím by mohlo být zobrazení statistiky o vykonávaných denních aktivitách v telefonu běžných uživatelů, kteří by přesně věděli, jaký energetický výdej měli a kolik času jaké aktivitě věnovali. Tato zpětná vazba by mohla mít psychologické motivační účinky (možnost vidět své konkrétní výsledky - osobní zpětná vazba podporující např. touhu zlepšit se, možnost sdílení na sociální síti). Statistické výstupy získané klasifikací by také mohly být použity pro tzv. „big data“, tedy sledování denní aktivity většího množství uživatelů. Podle získaných informací by bylo možné například vhodně zacílit reklamu.

1 Problematika snímání biosignálů pomocí nositelných zařízení

1.1 Nositelná zařízení


Nositelná zařízení (wearable devices, wearables) jsou elektronická zařízení, navržena tak, aby mohla být člověkem běžně nošena. Řadíme mezi ně fitness náramky, chytré hodinky, chytré brýle apod. Za nositelné zařízení lze také považovat chytrý mobilní telefon (smartphone), umístěný v sportovním pouzdře nebo např. v kapse u kalhot. Díky své multifunkčnosti, možnosti bezproblémového každodenního nošení a dostupnosti jsou tato zařízení stále populárnější. Nositelná zařízení mohou obsahovat celou řadu senzorů: akcelerometr, gyroskop, GPS, mikrofon, barometr, senzor tepu, senzor přiblížení apod. Na rozdíl od speciálních samostatných senzorů jsou nositelná zařízení běžně použitelná a pohodlná. Tato práce se bude dále zabývat chytrými mobilními telefony.

1.2 Akcelerometrický senzor


Akcelerometrické senzory byly do chytrých telefonů přidávány jako jedny z prvních [1]. Staly se tak, na rozdíl od gyroskopů, běžnou výbavou i levnějších smartphonů.

Akcelerometr měří zrychlení zařízení, ve kterém je umístěn. Princip akcelerometru lze vysvětlit na modelu skládajícím se ze dvou základních částí: schránky a pohyblivé, tzv. seismické hmoty [2], umístěné na dvou pružinách (viz obrázek 1.1). Když modelem akcelerometru zrychleně pohneme směrem nahoru, působením seismické hmoty se dole umístěná pružina stlačí, nahoře umístěná se natáhne a na stupnici můžeme odečíst hodnotu zrychlení [3]. Vznikne tak jednoosý akcelerometr.

V moderních chytrých telefonech jsou používány miniaturní akcelerometry. Jedná se o tzv. MEMS (MicroElectroMechanical Systems), jejichž komponenty nabývají velikosti v řádu mikrometrů. Základní schéma MEMS akcelerometru je zobrazeno na obrázku 1.2. Jeho fungování je, podobně jako u předchozího příkladu, založeno na pohybu seismické hmoty. Vychýlení seismické hmoty způsobí změnu kapacitní mezery, která změní hodnotu elektrické kapacity. Zrychlení 1 g přibližně odpovídá změně mezery $3 \cdot 10^{-8}$ m, což odpovídá změně kapacity pouhých $15 \cdot 10^{-15}$ F [3].

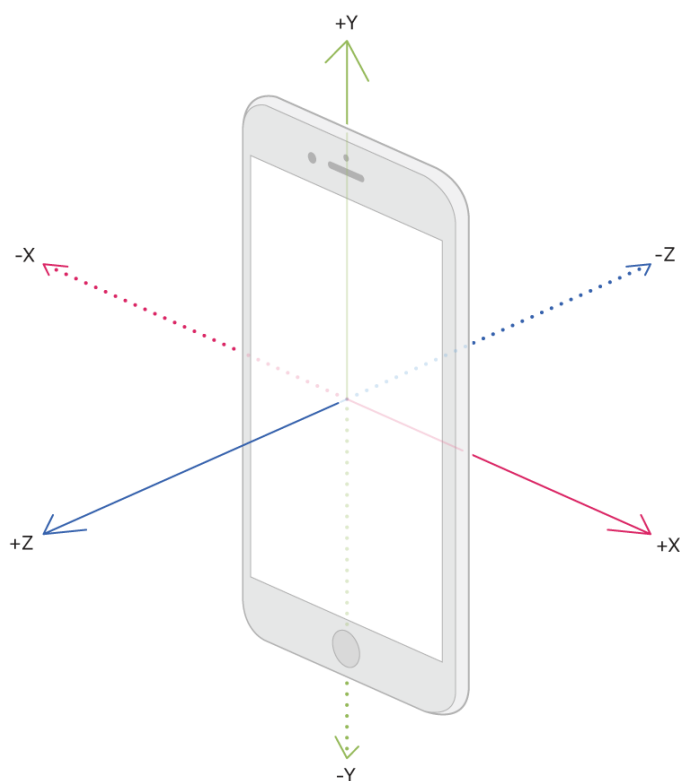


Obrázek 1.1: Schéma mechanického akcelerometru



Obrázek 1.2: Schéma MEMS akcelerometru

Výstupem akcelerometru je zrychlení a v m/s^2 , ideálně ve všech třech osách trojrozměrného světa. Poté se jedná o tzv. trojosý akcelerometr. Pokud osa x směřuje na smartphonu směrem vpravo (nejčastější orientace), poté osa y směřuje směrem nahoru a osa z směrem před telefon. Osa x tedy měří zrychlení při pohybu doleva/doprava, osa y při pohybu nahoru/dolů a osa z při pohybu dopředu/dozadu (viz obrázek 1.3).



Obrázek 1.3: Orientace os akcelerometru ¹

Na akcelerometrický senzor působí, kromě zrychlení samotného chytrého telefonu, také gravitační síla. Zjednodušeně řečeno, i když je telefon v klidu, gravitační síla vychýlí seismickou hmotu právě svislého akcelerometru tak, že tento akcelerometr naměří zrychlení odpovídající tíhovému zrychlení (přibližně $9,81 \text{ m/s}^2$). Podle toho, na které ose bude v klidu zrychlení vychýleno, lze zjistit orientaci telefonu. Tedy to, jestli je telefon na výšku, na šířku, jestli leží na zádech apod. Pokud je telefon nějakým způsobem nakloněn, gravitační síla se rozloží mezi jednotlivé osy podle goniometrických funkcí následovně:

$$F_x = F_g \cos \alpha; F_y = F_g \cos \beta; F_z = F_g \cos \gamma \quad (1.1)$$

$$F_g = \sqrt{F_x^2 + F_y^2 + F_z^2},$$

kde α, β, γ jsou úhly mezi F_g a příslušnými osami.

Uvedených vztahů lze pro určení naklonění a orientace telefonu využít pouze pokud je smartphone v klidu, nebo je z naměřených hodnot v jednotlivých osách vyfiltrováno samotné zrychlení způsobené gravitací.

¹ Zdroj obrázku:

https://developer.apple.com/documentation/coremotion/getting_raw_accelerometer_events


Dle Rosaria a kol. [1] poskytují akcelerometry společně s gyroskopy nejvíce informace o vykonávané pohybové aktivitě, protože jsou přímo spojeny s pohybem. Při použití akcelerometru jako jediného senzoru, bylo různými autory dosaženo vysokých úspěšností klasifikace (v závorkách jsou uvedeny klasifikované aktivity): 99 % [5] (Chůze, Pomalý běh, Sed, Stoj, Chůze do schodů, Chůze ze schodů), 91,15 % [8] (Tanec, Chůze do schodů, Chůze ze schodů, Pomalá chůze, Rychlá chůze, Běh), 82,8 % až 100 % [1] (autor shrnuje více různých studií). Rozdíly vyplývají také z použití rozdílných metod klasifikace pomocí různých klasifikátorů.

Z důvodu dostupnosti (akcelerometrický senzor, na rozdíl od gyroskopu obsahují téměř všechny chytré mobilní telefony všech cenových kategorií – potenciální aplikaci pro klasifikaci může používat každý), vysoké výpovědní hodnoty o pohybu telefonu a vysokých úspěšností klasifikace v uvedených studiích, byl akcelerometr vybrán jako senzor pro klasifikaci denní aktivity.

2 Metody klasifikace denní aktivity z dat mobilních senzorů

2.1 Obecný postup klasifikace

Obecný postup určení denní aktivity může být rozdělen do tří částí: Snímání signálu, Extrakce informace a Klasifikace aktivity (viz obrázek 2.1).



Obrázek 2.1: Obecný postup klasifikace

2.2 Příznaky (features)

Příznaky jsou hodnoty extrahované (vypočítané apod.) z naměřených dat, popisující danou aktivitu. Slouží jako vstup klasifikátoru, kterým může být například neuronová síť. Jsou počítány z okna posouvajícím se po naměřeném signálu. Okno má obvykle délku několik sekund [1][6][7], aby byl nasbírána dostatek hodnot pro výpočet daného příznaku. Příliš dlouhé okno neumožňuje dostatečně rychle reagovat na změnu aktivity, příliš krátké okno nenasbírá dostatek hodnot pro výpočet příznaků, založených například na počítání z periody signálu. Jednotlivá okna mají mezi sebou přesahy, aby byl plynule pokryt celý signál a nedocházelo ke ztrátě informace na okrajích oken.

Mezi vhodné příznaky (získané ze signálu s) patří [1][7][5][7][8]:

Název příznaku	Vzorec výpočtu
Aritmetický průměr	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$
Směrodatná odchylka	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$
Maximum	$\max(s)$
Minimum	$\min(s)$
Rozdíl maxima a minima	$\max(s) - \min(s)$
Mediánová absolutní odchylka	$\text{median}(s_i - \text{median}(s))$

Efektivní hodnota (RMS)	$\sqrt{\frac{1}{N}(s_1^2 + s_2^2 + \dots + s_N^2)}$
SMA (signal magnitude area)	$\frac{1}{3} \sum_{i=1}^3 \sum_{j=1}^N s_{ij} $
Korelace (mezi osami)	$s_1(n) \star s_2(n) = \sum_{k=-\infty}^{+\infty} s_1(-k)s_2(n-k)$
Autokorelace	$s_1(n) \star s_1(n) = \sum_{k=-\infty}^{+\infty} s_1(-k)s_1(n-k)$
Perioda	ze vzdálenosti „peaků“ autokorelace
Četnost „peaků“ autokorelace	z autokorelace
Hlavní frekvence	z FFT (Rychlá Fourierova Transformace)
Četnost nejčastější frekvence	z FFT
Množství „peaků“ v okně	-

Tabulka 2.1: Příznaky

Signál z akcelerometru je součtem tíhového zrychlení g - zapříčiněného gravitací Země a zrychlení těla snímané osoby. Vzhledem k tomu, že tíhové zrychlení je snímáno jako nízkofrekvenční signál, lze jej odfiltrovat filtrem typu horní propust, s mezní frekvencí 0,3Hz [5] [7]. Tíhové zrychlení g lze pak získat odečtením původního signálu a signálu vyfiltrovaného. Příznaky mohou být počítány pro každou z os akcelerometrického signálu (a_x, a_y, a_z), (získá se tak trojnásobek příznaků, protože každá osa má výpovědní hodnotu), pro zrychlení g získané z každé osy (g_x, g_y, g_z), pro signál s vyfiltrovaným účinkem g a také celkové vektory a, g, a -vyfiltrované. Průměrná hodnota zrychlení v jednotlivých osách akcelerometrického signálu může pomoci odlišit klidnější aktivity, založené převážně na odlišné pozici těla s telefonem (stoj, sed, psaní zpráv atp.), protože aritmetický průměr zde přibližně odpovídá působení gravitační síly a tím i orientaci telefonu, viz kapitola 1.2. Maxima, minima, rozdíly maxima a minima, RMS, SMA apod. pomáhají odlišit aktivity v závislosti na velikosti dosaženého zrychlení, což může pomoci odlišit vysoce aktivní aktivity od méně aktivních, popř. statických (běh a chůze, psaní zpráv s drobnými výkyvy při úderu prstů, položení na stole). Opakující se (periodické) aktivity jako je chůze, běh a chůze do schodů může pomoci odlišit korelace (mezi osami) a autokorelace, která odhaluje periodicitu v signálu.

2.3 Neuronové sítě


Neuronové sítě jsou jednou z oblastí umělé inteligence, která svými zajímavými vlastnostmi, které se dají uplatnit v celé řadě oborů, upoutává stále více pozornosti. Základním principem neuronových sítí je napodobení fungování biologických neuronů- základních prvků nervové soustavy, pomocí jejich matematického popisu. Jako první popsali neuron McCulloch a Pitts v roce 1943. V roce 1949 navrhl Donald Hebb pravidlo, jak tento jednoduchý neuron učit, vycházel přitom ze studia reálných nervových systémů. Frank Rosenblatt, průkopník počítačových simulací neuronových sítí, v roce 1962 sestrojil propojením základních neuronů první neuronovou síť. Od konce šedesátých, do začátku osmdesátých let se vývoj neuronových sítí téměř zastavil. Až začátkem osmdesátých let, se díky počítačovému boomu, začaly opět rozvíjet, a jejich zrychlený vývoj trvá až do současnosti [4].

Důležitou vlastností neuronových sítí, je schopnost učit se, tzn. měnit svou strukturu a parametry, tak aby lépe vyhovovaly zadaným požadavkům. Učení může probíhat s učitelem nebo bez něj. Při učení s učitelem jsou sítě předloženy příklady (například data určená ke klasifikaci, společně se známými výsledky klasifikace, tj. známe vstup i výstup) a na nich je síť naučena. Toho lze využít při klasifikaci denní aktivity, kdy jsou sítě poskytnuta anotovaná data ze senzoru (je známo v jakém okamžiku byla vykonávána jaká aktivita). Pokud se síť učí bez učitele, nejsou jí poskytnuty příklady a síť se musí samoorganizovat, např. tím, že se snaží vyhovět zadanému kritériu [4].

Neuronové sítě můžeme rozdělit do tří skupin: asociativní paměti, klasifikátory a aproximátory. U asociativních pamětí jsou do neuronové sítě uloženy vzory, které jsou na základě asociací (logických spojení) vyvolávány vzory na vstupu. Podle druhu asociace mohou být paměti autoasociativní (vstupní i výstupní vzor je podobný, využívají se např. při rozpoznávání poškozených vzorů) a heteroasociativní (vstup a výstup je rozdílný, síť si k zadanému vzoru vybaví nějaký související vzor). Typickým příkladem asociativní paměti je Hopfieldova síť. Klasifikátory jsou sítě, které vzor na vstupu přiřadí do určité třídy. Tato třída na výstupu může být reprezentována například jedničkou a nulou – při klasifikaci do dvou tříd. Při klasifikaci do více tříd můžeme na výstupu dostávat hodnoty, udávající s jakou pravděpodobností daný vstup odpovídá dané třídě. Příkladem klasifikátoru je Hammingova síť. Aproximátory jsou sítě, v nichž dochází k vytvoření vnitřního modelu na základě vstupních informací. Tento model aproximuje skutečný systém a síť je schopna predikovat. Aproximátory je možné využít jako klasifikátory, jsou však složitější. Nejznámějším zástupcem aproximátorů je vícevrstevná perceptronová síť označovaná jako síť BP (back propagation- zpětné šíření chyby)[4].

2.3.1 Neuron

Schéma jednotlivého neuronu sítě, také nazývaného *perceptron*, je zobrazeno na obrázku 2.2.




Obrázek 2.2: Schéma jednotlivého neuronu (převzato z [4])

Matematicky je popsán následovně [4]:

$$y = f \left[\sum_{i=1}^N w_i x_i - \vartheta \right] = f \left[\sum_{i=0}^N w_i x_i \right], \text{ kde } x_0 = 1 \text{ } w_0 = -\vartheta. \quad (2.1)$$

Tento neuron napodobuje biologický neuron. Vstupy x_i (příznaky) jsou vynásobeny příslušnými váhami w_i a sečteny, je od nich odečten práh ϑ a aktivační funkce tomuto výsledku přidělí výstupní hodnotu y (viz obrázek 2.3).



Obrázek 2.3: Příklad aktivační funkce

2.3.2 Klasifikace pomocí neuronu

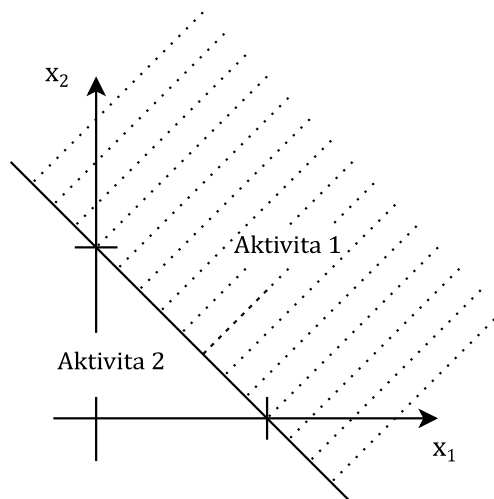
Klasifikace pomocí neuronu lze vysvětlit na následujícím příkladu neuronu se dvěma vstupy a jedním binárním výstupem, nabývajícím hodnot -1 nebo 1. Vstupy reprezentují dva příznaky získané např. z dat akcelerometru a výstup -1 a 1 představuje např. dvě klasifikované aktivity (obrázek 2.4).

$$y = w_1x_1 + w_2x_2 - \vartheta = 0 \quad (2.2)$$

Rovnice 2.2 [4] popisuje hraniční přímku z obrázku 2.4, která po úpravě dává rovnici přímky:

$$x_2 = -\frac{w_1}{w_2}x_1 + \frac{\vartheta}{w_2}, \quad (2.3)$$

kde $-\frac{w_1}{w_2}$ je směrnice přímky a $\frac{\vartheta}{w_2}$ určuje posun po ose x_2 .



Obrázek 2.4: Klasifikace pomocí neuronu

Při N vstupech (viz rovnice 2.1 [4]) budou klasifikované aktivity rozděleny N -rozměrnou nadrovinou. Prostorová představa je možná jen do $N=3$, kdy aktivity budou rozděleny rovinou. Při složitějších rozděleních je zapotřebí propojení více neuronů určujících přímky a neuronů vykonávajících průniky, sjednocení apod., do vrstev za sebou. Podle [4] lze dokázat, že pro vyřešení jakéhokoliv problému týkajícího se klasifikace, dostačuje třívrstvá perceptronová síť.

2.3.3 Učení neuronové sítě

Učení neuronové sítě je proces, kterým se snažíme najít ideální váhy w a prahy θ tak, aby síť správně reagovala na vstupy. Síť je naučena na vstupních vektorech, u kterých známe správný výstup (výsledek klasifikace). Učení probíhá v iteracích, kde se jedna iterace skládá z předložení učební dvojice (vstupní vektor, požadovaná odezva) a následné úpravy vah. K úpravě vah se používá tzv. *δ -pravidlo*, podle kterého je úprava vah závislá na velikosti odchylky výstupu y od požadovaného známého výstupu. Vzory různých tříd musí být předkládány náhodně. Učení probíhá v *epochách*. Jednou epochou je předložení všech učebních dvojic. Po skončení každé epochy je hodnoceno kolik učebních vektorů síť správně klasifikovala. Z hodnocení se poté vyvodí, zdali se bude v učení pokračovat další epochou nebo se učení ukončí.

Jedním z důvodů výběru neuronových sítí je právě možnost učit se. Uživatel by v potenciální aplikaci zaznamenal ukázkový průběh aktivity, síť by se jí naučila a dále ji byla schopna rozpoznávat. Touto možností neuronové sítě disponují například na rozdíl od rozhodovacích stromů, kde je přidání nové aktivity složité [6].

3 Snímání dat

3.1 Metodika snímání

Bylo snímáno celkem 8 různých aktivit (v závorce je uveden zkrácený název používaný v některých částech textu):

1. Chůze
2. Běh
3. Chůze do schodů (Schody)
4. Stoj
5. Sed
6. Telefonování (Volání)
7. Psaní zpráv (Zprávy)
8. Položení na stole (Stůl)

Aktivity chůze, běh a chůze do schodů byly zahrnuty, protože se jedná o nejčastější fyzicky náročnější aktivity vykonávané během dne. Jsou v určitém množství také zdraví prospěšné. Stoj a sed jsou jako jedny z častých aktivit a své vhodnosti k detekci (převažuje tíhové zrychlení v jedné ose) zahrnuty také. Telefonování a psaní zpráv bylo zahrnuto z toho důvodu, že tyto dvě činnosti patří k nejčastěji vykonávaným aktivitám s mobilním telefonem a mají vliv na zdraví uživatele (pasivita, zdraví očí, možné ozáření při telefonování). Položení mobilního telefonu na stole bylo zahrnuto, protože tuto pozici telefon zaujímá velkou část dne (spánek apod.). Pokud by nebyla zahrnuta, byla by v praxi při celodenní detekci zaznamenána velká neurčená oblast.

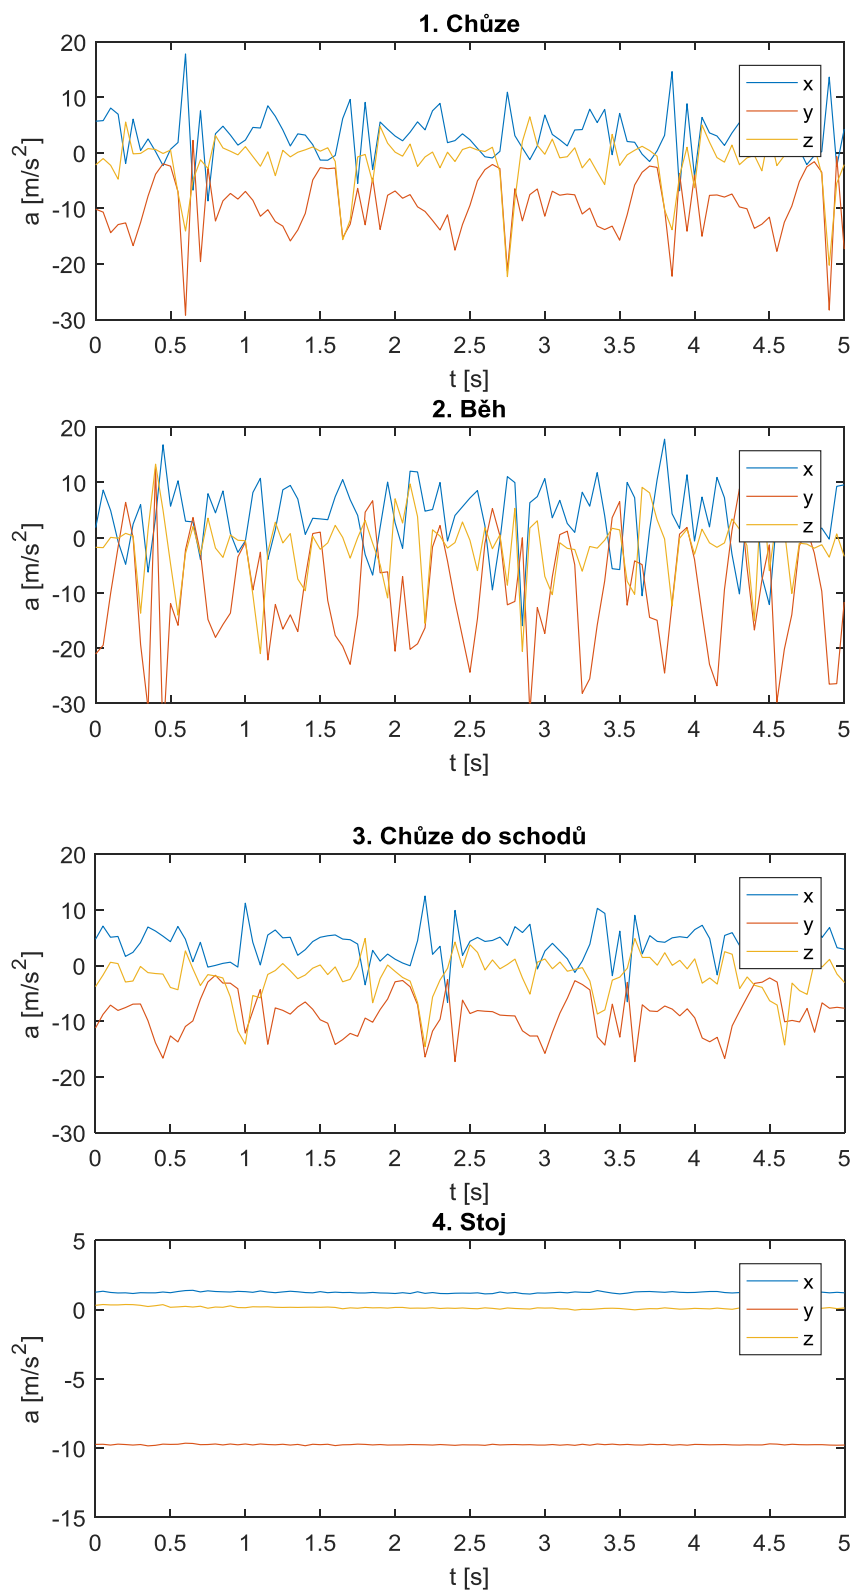
Ke snímání byl použit trojosý akcelerometr, který o aktivitách spojených s pohybem poskytuje nejvíce informace [1] a je dostupný téměř ve všech chytrých mobilních telefonech. Použití jednoho samotného senzoru také šetří baterii telefonu při použití klasifikace v potenciální aplikaci. Pro samotné snímání dat byla použita aplikace Android Sensors, která je volně dostupná na Google Play. Data byla snímána se vzorkovací frekvencí 20 Hz. Aplikace ukládá naměřená data ve formátu csv (comma-separated values, hodnoty oddělené čárkami), což umožňuje jejich další zpracování. Data byla snímána na 10 osobách - 5 mužích a 5 ženách a byla anotována. Průměrný věk měřených osob byl 30,2 roku, v celkovém rozmezí 22 až 53 let. Ke snímání byl použit chytrý mobilní telefon Huawei P10 - vlajková loď značky Huawei z roku 2017 (čemuž by měla odpovídat kvalita senzoru) a Honor 10.

Mobilní telefon byl při prvních pěti aktivitách umístěn v pravé kapse kalhot, jedná se totiž o jedno z nejčastějších a nejpraktičtějších míst na nošení, poskytující zároveň dostatek informací o pohybu. Telefon byl do kapsy vkládán vždy


definovaným způsobem: displayem ke stehnu a vrchní částí směrem dolů, což je nejčastější způsob vložení do kapsy při běžném držení v ruce. V potenciální aplikaci určující denní aktivitu, by byl po instalaci aplikace uživatel poučen např. názorným obrázkem, jak telefon vkládat do kapsy. Jako kalhoty byly použity tepláky a rifle. U tepláků se vyskytoval větší šum, kvůli pohybům telefonu ve volnější kapse. Při aktivitě položení na stole byl smartphone pokládán vždy na záda (nejčastější poloha, umožňuje zobrazení notifikací a předchází poškrábání displaye). Každá aktivita (vyjma chůze do schodů), byla u každé osoby snímána zvlášť 1 minutu, chůze do schodů byla u prvních dvou osob měřena 20 sekund a u zbývajících 30 - 40 sekund. Celkem bylo naměřeno přibližně 75 minut surových dat. Dále bylo dvakrát nasnímáno přibližně 8,5 minuty záznamu všech aktivit za sebou, proložených chůzí k jednotlivým stanovištím (schody, židle aj.).

3.2 Surová akcelerometrická data aktivit

Z následujícího zobrazení surových dat (obrázek 3.1 a 3.2) je patrné, že chůze, běh a chůze do schodů vykazují určitou periodicitu. U čtvrté až osmé aktivity se hodnoty zrychlení v jednotlivých osách pohybují kolem určité hodnoty, což je způsobeno působením gravitace na senzor. Tato hodnota je pro dané aktivity téměř vždy specifická. Při aktivitě stoj se hodnoty os x a z pohybují okolo nuly, hodnota osy y přibližně odpovídá tíhovému zrychlení. To odpovídá svislému uložení telefonu v kapse kalhot (viz zobrazení orientace os na telefonu na obrázku 1.3). Podobně je tomu u sedu, kde je ale tíhové zrychlení, s mírnou odchylkou, naměřeno v ose z – telefon v kapse leží na stehně, mírným náklonem odkloněn od vodorovné polohy, hodnoty os x a y se zde nepřekrývají. Při položení na stole je telefon ve vodorovné poloze – x a y se překrývají na 0 (šipky na obrázku 3.2), v ose z je naměřeno tíhové zrychlení. Také při telefonování je poloha smartphonu specifická (mírné naklonění telefonu od ucha k ústům) a projeví se rozkladem naměřeného zrychlení do osy x a y , výkyvy hodnot jsou zde spojeny s pohyby hlavy, trupu a možnou mírnou chůzí. Při psaní zpráv je telefon v téměř vodorovné poloze s mírným náklonem dozadu, drobné zákmity v grafu odpovídají úderům prstů na display.



Obrázek 3.1: Surová data akcelerometru (1/2)



Obrázek 3.2: Surová data akcelerometru (2/2)

4 Realizace algoritmu klasifikace v programovém prostředí MATLAB

Realizovaný algoritmus určení denní aktivity se skládá ze tří hlavních částí: úpravy dat, výpočtu příznaků a samotné klasifikace pomocí neuronové sítě. Každé části bude v následujícím textu věnována podkapitola.

4.1 Úprava dat

Jednotlivá měření bylo nutné ořezat od neužitečného signálu na začátku a na konci záznamu, který byl způsoben například vkládáním telefonu do kapsy. Dále byla měření zkompileována do přehledné matice, kde řádky (1-8) představovaly aktivity, sloupce jednotlivé hodnoty naměřené akcelerometrem, a dimenze osy snímání (x , y , z). Záznamy jednotlivých měřených osob byly vkládány za sebou na příslušné řádky. Tato data byla mírně zašuměná pohyby telefonu v kapse. Byla na nich vyzkoušena mediánová a průměrovací filtrace, ale docházelo k velkému zkreslení signálu. V zájmu zachování co největšího množství informace nebyla data nijak filtrována (ani filtry potlačujícími určité frekvence, pro zachování celého rozsahu). Na vypočítané příznaky mírný šum neměl větší vliv.


4.2 Výpočet příznaků

Pro výpočet příznaků bylo použito posuvné okno o délce 5 sekund, což je již dostatečná délka pro zachycení period signálu (viz obrázek 3.1, pomalejší periodická aktivita chůze do schodů, s periodou přibližně 1,5 sekundy) a zároveň je toto okno dostatečně krátké pro reagování na případnou změnu aktivity. Při použité vzorkovací frekvenci 20 Hz odpovídá 5- ti sekundové okno 100 vzorkům. Délka okna je v programu nastavitelná, čehož by mohlo být využito při optimalizaci. Okna mezi sebou mají překryv 50 %, aby nedocházelo ke ztrátě informace na okrajích oken. Překryv je také nastavitelný.

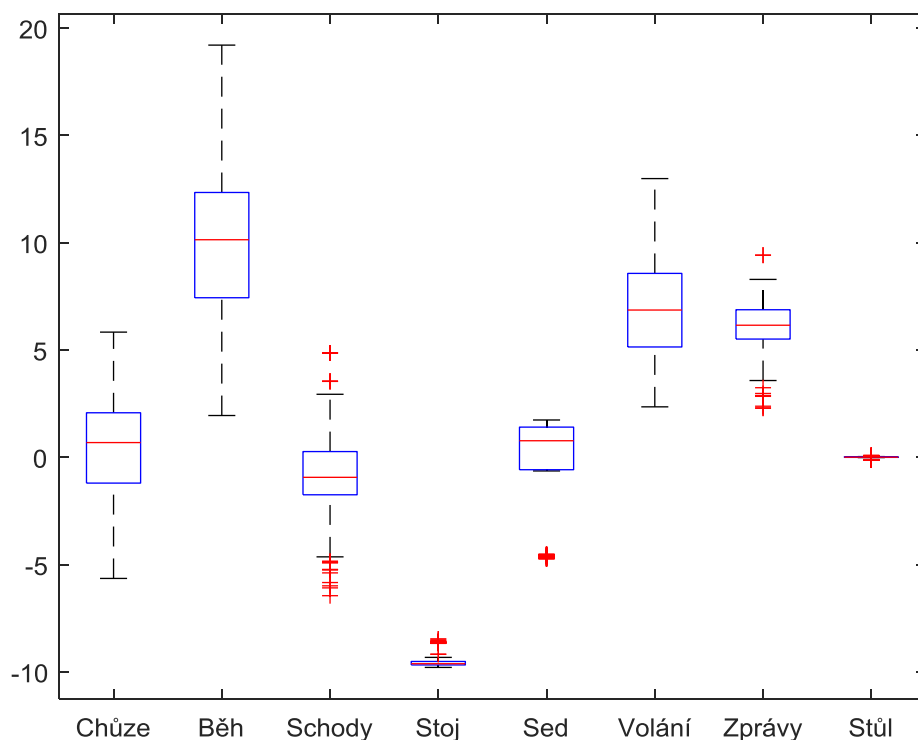
Bylo počítáno celkem 13 příznaků, pro každou ze tří os akcelerometrického signálu (x , y , z) samostatně. Celkem tedy takto bylo získáno 39 příznaků pro každou aktivitu. Mezi 13 z oken počítaných příznaků patří: aritmetický průměr; směrodatná odchylka; maximální a minimální hodnota; rozdíl maxima a minima; mediánová absolutní odchylka; efektivní hodnota (RMS); perioda získaná z autokorelace okna jako diference pozic 3 nejvyšších korelačních „peaků“; krátká perioda získaná jako průměrná vzdálenost všech „peaků“ autokorelace okna; střední perioda získaná jako průměrná vzdálenost „peaků“, které jsou minimálně vzdáleny o nahoru zaokrouhlenou krátkou periodu; dlouhá perioda získaná

podobně jako druhá, ale „peaky“ byly vzdáleny o zaokrouhlenou střední periodu; hlavní frekvence signálu v okně získaná z Rychlé Fourierovy Transformace (FFT) a příznak amplituda hlavní frekvence. Vzorce pro výpočet většiny příznaků jsou uvedeny v tabulce 2.1.

Odlišovací schopnost příznaků byla zhodnocena pomocí boxplotů, nevhodné příznaky byly odstraněny. Boxplot (krabicový graf) je graf vizualizující 1. kvartil (spodní hrana boxu), 3. kvartil (horní hrana boxu), medián (červená čára v boxu) a další. Pokud je box pro určitou aktivitu u daného příznaku vzdálený od ostatních (není ve stejné rovině), hodnoty příznaku dané aktivity jsou také odlišné, což umožňuje odlišení aktivity. Některé příznaky dobře odlišují jednu aktivitu od ostatních, například příznak průměr na ose z odlišuje aktivitu sed, viz obrázek 4.1. Jiné příznaky různě odlišují aktivity mezi sebou – boxy neleží v rovině (obrázek 4.2). To je v propojení s ostatními podobně odlišujícími příznaky, ale v jiném uspořádání, vhodné pro klasifikaci pomocí neuronové sítě.




Obrázek 4.1: Boxplot pro příznak průměr na ose z




Obrázek 4.2: Boxplot pro příznak maximum na ose y

Použité příznaky jako rozdíl maximum-minimum, RMS apod. od sebe odlišují vysoce aktivní aktivity (chůze, běh, chůze do schodů) od níže aktivních (telefonování, psaní zpráv), popř. statických (položení na stole). Hodnota daného příznaku odlišuje i jednotlivé příznaky v určité skupině, např. chůzi a běh u vysoce aktivních aktivit (rozdíl maxima a minima je větší u běhu než u chůze, protože při běhu dosahuje zrychlení větších hodnot). Periodické aktivity jsou odlišeny periodami získanými z autokorelace. Autokorelace okna o délce pěti sekund, získaného z osy x u aktivity chůze, je zobrazena na obrázku 4.3. Pokud je aktivita periodická, vznikají při posunu signálu dle autokorelačního vzorce (viz tabulka 2.1 v teoretické části) „peaky“, v místě, kde se periody překrývají (suma součinů je maximální). Vzdálenost nejvyšších „peaků“ odpovídá délce periody. Pouhým okem lze vidět, že na obrázku 4.3 jsou „peaky“ vzdáleny přibližně 20 vzorků, což při vzorkovací frekvenci 20 Hz odpovídá přibližně jedné sekundě. To odpovídá periodě aktivity chůze (viz obrázek 3.1 surových dat). Detekcí těchto „peaků“ a určením jejich vzdálenosti byl získán příznak. Obrázek 4.4 zobrazuje amplitudové (modulové) spektrum signálu-okna z osy x u chůze. Hlavní frekvence tohoto spektra (s největší amplitudou) a její amplituda byly použity jako příznaky. Tyto dva příznaky mají vypovídací hodnotu převážně u periodických, ale i dalších aktivit. Jak příznaky pomáhají odlišit aktivity je také popsáno v kapitole 2.2.



Obrázek 4.3: Autokorelace okna z osy x u aktivity chůze




Obrázek 4.4: Amplitudové spektrum okna z osy x u aktivity chůze

4.3 Neuronová síť

K samotné klasifikaci byla použita dopředná neuronová síť se zpětným šířením chyby (BP – back propagation). Jako výchozí bylo zvoleno nastavení s 1 skrytou vrstvou (hidden) obsahující 10 neuronů. Pro skrytou vrstvu byla použita sigmoidální aktivační funkce, pro výstupní lineární. Na vstup (input) bylo

přivedeno 39 příznaků. Které příznaky budou na vstup přivedeny, je v programu nastavitelné. Výstupní vrstva (output) obsahovala 8 neuronů, pro každou aktivitu jeden. Výstupem (output vpravo) jsou hodnoty udávající příslušnost k dané aktivitě, čím vyšší, tím spíše se jedná o danou aktivitu. Schéma neuronové sítě je zobrazeno na obrázku 4.5.



Obrázek 4.5: Schéma neuronové sítě

Pro trénování sítě byla použita gradientní metoda s výpočtem chyby pomocí MSE (mean squared error- střední kvadratická odchylka). Příznaky pro dataset neuronové sítě byly počítány z 8,77 minut záznamu (již ořezaného) pro každou aktivitu v každé ose. Celkem tak bylo použito přes 210 minut záznamu. Mírně kratší záznam chůze do schodů oproti ostatním aktivitám byl doplněn daty ze začátku záznamu chůze do schodů. Na klasifikaci tato skutečnost neměla viditelný vliv. Dataset byl před trénováním náhodně zamíchán, aby se předešlo nevhodnému přizpůsobení sítě a síť byla lépe natrénována (i otestována). Jako výchozí byl maximální počet epoch učení nastaven na 1000, krok učení na 0,1 a přípustná odchylka (MSE) na 0,01. Tato nastavení byla dále upravena při optimalizaci. Celkový dataset byl rozdělen v poměru 0,50 : 0,25 : 0,25 na trénovací, validační a testovací.

5 Optimalizace algoritmu

Při použití zvolených výchozích nastavení, uvedených ve 4. kapitole, úspěšnost klasifikace kolísala mezi 75–88 %, nejčastěji dosahovala přibližně 82 %. Kolísavost úspěšnosti byla dána závislostí učení na inicializaci sítě (náhodné hodnoty vah a prahů), náhodném zamíchání datasetu, nedostatečném počtu epoch/malém kroku učení apod. Těmto skutečnostem bude věnována pozornost dále v této kapitole.

Úspěšnost klasifikace je hodnocena podle vzorce 5.1 jako:

$$\text{úspěšnost} = 100 - 100 \left(\frac{\text{počet chybných klasifikací}}{\text{celkový počet klasifikací}} \right) \quad (5.1)$$

K hodnocení úspěšnosti klasifikace byla také použita tzv. confusion matrix – matice záměn, která uvádí závislost skutečně klasifikované výstupní třídy na cílové třídě klasifikace (zde jsou třídy aktivity, matice záměn viz obrázek 5.1).

Výstupní aktivita	Chůze	144 8.6%	1 0.1%	10 0.6%	11 0.7%	0 0.0%	39 2.3%	9 0.5%	1 0.1%	67.0% 33.0%
	Běh	11 0.7%	208 12.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	95.0% 5.0%
	Schody	54 3.2%	0 0.0%	199 11.9%	17 1.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	73.7% 26.3%
	Stoj	0 0.0%	0 0.0%	0 0.0%	161 9.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Sed	0 0.0%	0 0.0%	0 0.0%	20 1.2%	209 12.5%	1 0.1%	0 0.0%	0 0.0%	90.9% 9.1%
	Volání	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	161 9.6%	0 0.0%	0 0.0%	100% 0.0%
	Zprávy	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 0.5%	187 11.2%	14 0.8%	89.5% 10.5%
	Stůl	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 0.8%	194 11.6%	93.7% 6.3%
		68.9% 31.1%	99.5% 0.5%	95.2% 4.8%	77.0% 23.0%	100% 0.0%	77.0% 23.0%	89.5% 10.5%	92.8% 7.2%	87.5% 12.5%
	Chůze	Běh	Schody	Stoj	Sed	Volání	Zprávy	Stůl		
	Cílová aktivita									

Obrázek 5.1: Matice záměn neoptimalizovaného algoritmu (celý dataset)
Na obrázku 5.1 Matice záměn neoptimalizovaného algoritmu lze pozorovat, že nejčastěji špatně klasifikovaná aktivita byla aktivita chůze, která byla nejčastěji zaměňována za aktivitu schody (v 54 případech z 209), což lze vysvětlit

podobností pohybů. Další zaměňovanou aktivitou bylo volání, které bylo nejčastěji zaměněno za chůzi, a to v 39 případech z 209. Tyto záměny lze vysvětlit tím, že volání bylo prováděno i za chůze. Zaměňování aktivity stoj za aktivity sed, schody a chůze lze vysvětlit možným nedostatečným naučením sítě. K testování neoptimalizované sítě zde byl použit celý dataset (učební, validační a testovací data). Následující obrázek 5.2 uvádí pro porovnání matici záměn pro testování sítě na testovacím datasetu (25 % z celého datasetu).

Výstupní aktivita	Chůze	28 6.7%	0 0.0%	0 0.0%	2 0.5%	0 0.0%	5 1.2%	2 0.5%	0 0.0%	75.7% 24.3%
	Běh	2 0.5%	65 15.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.0% 3.0%
	Schody	16 3.8%	0 0.0%	43 10.3%	4 1.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	68.3% 31.7%
	Stoj	0 0.0%	0 0.0%	0 0.0%	29 6.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Sed	0 0.0%	0 0.0%	0 0.0%	7 1.7%	56 13.4%	1 0.2%	0 0.0%	0 0.0%	87.5% 12.5%
	Volání	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	43 10.3%	0 0.0%	0 0.0%	100% 0.0%
	Zprávy	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 0.7%	50 12.0%	4 1.0%	87.7% 12.3%
	Stůl	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 1.0%	54 12.9%	93.1% 6.9%
		60.9% 39.1%	100% 0.0%	100% 0.0%	69.0% 31.0%	100% 0.0%	82.7% 17.3%	89.3% 10.7%	93.1% 6.9%	88.0% 12.0%
	Chůze	Běh	Schody	Stoj	Sed	Volání	Zprávy	Stůl		
	Cílová aktivita									

Obrázek 5.2: Matice záměn neoptimalizovaného algoritmu (testovací dataset)

Jak již bylo uvedeno, úspěšnost klasifikace byla při výchozím zvoleném nastavení kolísavá. Při nedostatečně velkém počtu epoch a malém kroku učení (1000 a 0,1) se síť nestačila dostatečně naučit. Proto byl dále zvětšen maximální počet epoch a zvýšen krok učení. Empiricky byl maximální počet epoch stanoven na 4000, s krokem učení 0,4. Síť se tak stihla naučit a inicializace neměla velký vliv. Maximální počet epoch byl nastaven proto, aby se předešlo příliš dlouhému učení sítě v krajním případě. S takto upraveným nastavením síť dosáhla přípustné odchylky 0,01 průměrně během 3300 epoch. Snížení přípustné odchylky pod 0,01 již nemělo pozitivní vliv na úspěšnost. Tímto způsobem naučená síť měla průměrně 94% úspěšnost klasifikace na celém datasetu, viz obrázek 5.3.

Výstupní aktivita	Chůze	191 11.4%	0 0.0%	7 0.4%	11 0.7%	0 0.0%	36 2.2%	9 0.5%	1 0.1%	74.9% 25.1%
	Běh	1 0.1%	209 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.5% 0.5%
	Schody	17 1.0%	0 0.0%	201 12.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	92.2% 7.8%
	Stoj	0 0.0%	0 0.0%	1 0.1%	198 11.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.5% 0.5%
	Sed	0 0.0%	0 0.0%	0 0.0%	0 0.0%	209 12.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Volání	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	173 10.3%	0 0.0%	0 0.0%	100% 0.0%
	Zprávy	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	190 11.4%	2 0.1%	99.0% 1.0%
	Stůl	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 0.6%	206 12.3%	95.4% 4.6%
		91.4% 8.6%	100% 0.0%	96.2% 3.8%	94.7% 5.3%	100% 0.0%	82.8% 17.2%	90.9% 9.1%	98.6% 1.4%	94.3% 5.7%
	Chůze	Běh	Schody	Stoj	Sed	Volání	Zprávy	Stůl		
	Cílová aktivita									

Obrázek 5.3: Matice záměn po zvýšení max. počtu epoch a kroku učení (celý dataset)

Čas spotřebovaný na naučení takovéto sítě se pohyboval okolo 14 sekund (měřeno v Matlabu pomocí funkce tic a toc), z čehož určitou část mohlo spotřebovat grafické zobrazení průběhu učení. Rychlost učení sítě byla testována na dvou počítačích:

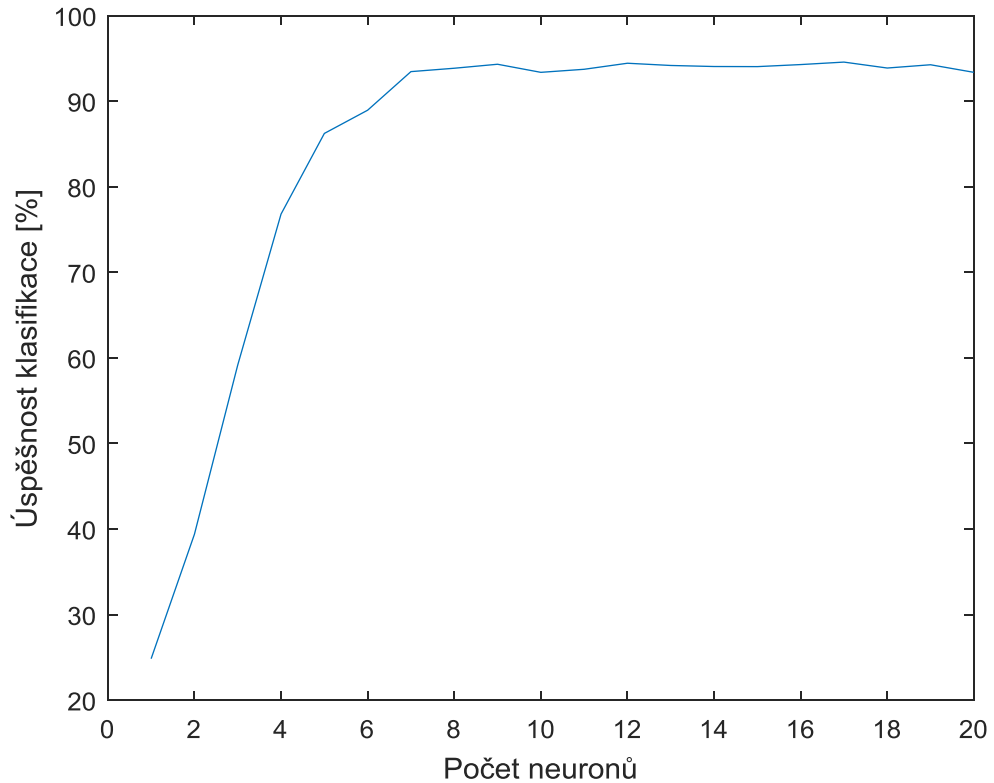
1) Procesor: Intel® Core™ i3-380M, 3M Cache, 2.53 GHz, dual core; RAM: 3 GB; HDD: 320 GB; Grafická karta: ATI Radeon™ HD 6370M

2) Procesor: Intel® Core™ i7-4510U, 4M Cache, 3.10 GHz, dual core; RAM: 8 GB; SSHD: 1000+8 GB; Grafická karta NVIDIA GeForce GT 840M.

S ohledem na spotřebovaný čas a na běžnou výkonnost použitého hardware je učení neuronové sítě výpočetně nenáročné a rychlé.

Při optimalizaci algoritmu bylo také vyzkoušeno použití více skrytých vrstev sítě. S použitím více než jedné skryté vrstvy se ale úspěšnost často naopak snižovala. S využitím více vrstev také stoupala složitost struktury sítě. Z těchto důvodů byla ponechána naprosto dostatečná jedna skrytá vrstva sítě. Obrázek 5.4 znázorňuje závislost úspěšnosti klasifikace na počtu neuronů v skryté vrstvě (průměrnou hodnotu úspěšnosti z pěti učení pro daný počet neuronů). Do sedmi neuronů úspěšnost s počtem neuronů stoupala. S více neurony již úspěšnost kolísala okolo hodnoty 94 %. To může být dáno například náhodným zamícháním

učebních dat. Změna délky okna v rozmezí 1-5 sekund se nezdá mít vliv na úspěšnost naučení a následné klasifikace seřazených dat. Až při klasifikaci kontinuálního záznamu různých aktivit za sebou může mít tento parametr vliv na rychlost zareagování na změnu aktivity.



Obrázek 5.4: Závislost úspěšnosti klasifikace na počtu neuronů v skryté vrstvě (průměr z pěti učení pro daný počet neuronů)


Se snížením velikosti okna roste doba výpočtu příznaků. Počet počítaných oken v závislosti na použitém překryvu a délce okna přibližně odpovídá vztahu 5.2, odvozeného ze vztahu 5.1. Vztah 5.1 je vyvozen z algoritmu výpočtu příznaků, kde jmenovatel zlomku představuje posunovací krok okna po signálu.

$$\text{počet oken} \cong \frac{\text{celková délka signálu}}{\text{délka okna} - \text{překryv} \cdot \text{délka okna}} \quad (5.1)$$

$$\text{počet oken} \cong \frac{\text{celková délka signálu}}{\text{délka okna} \cdot (1 - \text{překryv})} \quad (5.2)$$

Čím menší je délka okna, tím větší je počet oken, čím menší je překryv, tím menší je počet oken (překryv je uveden v části celého okna, např. 0,25). Rychlost výpočtu příznaků nezáleží pouze na počtu oken, jelikož změnou počtu hodnot v okně se upravuje i rychlost výpočtů samotných příznaků. Použití velikosti překryvu

v rozmezí 20-80 % nemělo větší vliv na úspěšnost klasifikace. Pod 20 % úspěšnost klesala, nad 80 % docházelo již k značně velkému prodloužení výpočtu příznaků. Bylo ponecháno nastavení s 50 % překryvem. Nejvyšší úspěšnosti bylo dosaženo s použitím všech 39, již protříděných příznaků (hodnocených pomocí boxplotů). Průběh učení sítě zobrazuje obrázek 5.5.



Obrázek 5.5: Průběh učení optimalizované sítě

Optimalizovaná naučená síť byla uložena pro další použití a klasifikaci.

6 Výsledky a diskuze

V této kapitole byl oproti výše použitým datasetům (celý, testovací) použit také kontinuální dataset, vzniklý z měření jednotlivých aktivit za sebou. Mezi některými aktivitami tohoto datasetu se vyskytuje aktivita chůze (viz kapitola 3- Snímání dat). Pro vyhodnocení správnosti klasifikace je mimo úspěšnost a matici záměn (viz předchozí kapitola) použito také běžně používané F-skóre. Hodnoty skóre jednotlivých aktivit jsou označovány malým f_n . Pro výpočet f_n je používána přesnost p , definovaná jako počet správných pozitivních výsledků dělený celkovým počtem pozitivních výsledků vrácených klasifikátorem, a senzitivita s_e , definovaná jako počet správných pozitivních výsledků dělený počtem všech vzorků, které měli být identifikovány jako pozitivní. f_n je pak počítána jako harmonický průměr p a s_e , viz vztah 6.1 (v upravené formě vztah převzat z [9]).

$$f_n = \left(\frac{s_e^{-1} + p^{-1}}{2} \right)^{-1} = \frac{2 \cdot p \cdot s_e}{p + s_e} \quad (6.1)$$

Pro konkrétní výpočet skóre f_n dané aktivity v našem případě, je:

$$p = \frac{SK_n}{\sum r_n} \quad s_e = \frac{SK_n}{\sum s_n}, \quad (6.2)$$

kde SK_n je počet správných klasifikací dané n -té aktivity, $\sum r_n$ je součet všech hodnot n -tého řádku v matici záměn a $\sum s_n$ je součet všech hodnot n -tého sloupce. Po dosazení vztahů 6.2 do rovnice 6.1 a následné úpravě dostáváme zjednodušený tvar:

$$f_n = \frac{2 \cdot \frac{SK_n}{\sum r_n} \cdot \frac{SK_n}{\sum s_n}}{\frac{SK_n}{\sum r_n} + \frac{SK_n}{\sum s_n}} = \frac{2 \cdot SK_n}{\sum s_n + \sum r_n}. \quad (6.3)$$

Celkové F-skóre je počítáno jako aritmetický průměr všech f_n -skóre jednotlivých aktivit (vzorec 6.4).

$$F = \frac{f_{chůze} + f_{běh} + f_{schody} + f_{stoj} + f_{sed} + f_{volání} + f_{zprávy} + f_{stůl}}{8}$$

f_n -skóre nabývá hodnoty od 0 do 1. Čím je hodnota skóre vyšší, tzn. blíže k 1 (popř. rovno jedné), tím byla aktivita lépe klasifikována. To stejné platí pro F-skóre, s tím rozdílem, že se F-skóre vztahuje na celou klasifikaci.

K testování naučené optimalizované sítě byly použity celkem tři datasety: celý (vytvořený z minutových záznamů, obsahující trénovací, validační i testovací data), testovací (část celého datasetu, nebyl použit k samotnému učení) a kontinuální (také nebyl použit k učení).

Na následujícím obrázku 6.1 můžeme vidět matici záměn pro testování na celém datasetu (shodná matice je uvedena také v přechodí kapitole, pro přehlednost a rozebrání výsledků je uvedena znovu). Úspěšnost klasifikace zde dosahovala 94,3 % (zelená hodnota v pravém dolním rohu).

Výstupní aktivita	Chůze	191 11.4%	0 0.0%	7 0.4%	11 0.7%	0 0.0%	36 2.2%	9 0.5%	1 0.1%	74.9% 25.1%
	Běh	1 0.1%	209 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.5% 0.5%
	Schody	17 1.0%	0 0.0%	201 12.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	92.2% 7.8%
	Stoj	0 0.0%	0 0.0%	1 0.1%	198 11.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.5% 0.5%
	Sed	0 0.0%	0 0.0%	0 0.0%	0 0.0%	209 12.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Volání	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	173 10.3%	0 0.0%	0 0.0%	100% 0.0%
	Zprávy	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	190 11.4%	2 0.1%	99.0% 1.0%
	Stůl	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 0.6%	206 12.3%	95.4% 4.6%
		91.4% 8.6%	100% 0.0%	96.2% 3.8%	94.7% 5.3%	100% 0.0%	82.8% 17.2%	90.9% 9.1%	98.6% 1.4%	94.3% 5.7%
	Chůze	Běh	Schody	Stoj	Sed	Volání	Zprávy	Stůl		
	Cílová aktivita									

Obrázek 6.1: Matice záměn optimalizované sítě (celý dataset)

Nejčastěji zaměňovanou aktivitou bylo volání, které bylo zaměňováno za chůzi (36 z 209 případů). To může být způsobeno tím, že aktivita volání (telefonování) byla prováděna za chůze. Další zaměňovanou aktivitou byla chůze, nejčastěji zaměňovaná za chůzi do schodů (17 z 209). Také tato záměna byla pravděpodobně způsobena podobností aktivit. Dále byla častěji zaměňována aktivita zprávy za aktivitu položení na stole (10 z 209) a chůzi (9 z 209).

Níže uvedená tabulka 6.1 zobrazuje vypočítaná f_n -skóre a F -skóre pro všechny datasety. Hodnoty tabulky jsou zaokrouhleny na dvě desetinná místa.

Dataset	$f_{chůze}$	$f_{běh}$	f_{schody}	f_{stoj}	f_{sed}	$f_{volání}$	$f_{zprávy}$	$f_{stůl}$	F -skóre
Celý	0,82	1,00	0,94	0,97	1,00	0,91	0,95	0,97	0,94
Testovací	0,79	0,99	0,94	0,97	1,00	0,89	0,93	0,97	0,94
Kontinuální	0,82	1,00	0,88	0,94	0,98	0,71	0,98	0,97	0,91

Tabulka 6.1: f_n -skóre jednotlivých aktivit a celková F -skóre (všechny datasety)

Nejhůře klasifikovanou aktivitou při testování na celém datasetu byla, dle f -skóre, aktivita chůze, s hodnotou 0,82. Nejlepší f -skóre dosahovala hodnoty 1 (aktivita běh a sed), což je bezchybné určení aktivity. Hodnoty f -skóre ostatních aktivit se pohybovaly v rozmezí 0,91-0,97. Celkové F -skóre zde nabývalo hodnoty 0,94, což poukazuje na dobrou klasifikaci, vzhledem k obtížnosti odlišení některých aktivit (volání-chůze, schody-chůze).

Níže uvedený obrázek 6.2 zobrazuje matici záměn pro testování na testovacím datasetu.

Výstupní aktivita	Chůze	44 10.5%	0 0.0%	0 0.0%	3 0.7%	0 0.0%	11 2.6%	3 0.7%	0 0.0%	72.1% 27.9%
	Běh	1 0.2%	47 11.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.9% 2.1%
	Schody	6 1.4%	0 0.0%	49 11.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	89.1% 10.9%
	Stoj	0 0.0%	0 0.0%	0 0.0%	58 13.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Sed	0 0.0%	0 0.0%	0 0.0%	0 0.0%	56 13.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Volání	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	46 11.0%	0 0.0%	0 0.0%	100% 0.0%
	Zprávy	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	39 9.3%	2 0.5%	95.1% 4.9%
	Stůl	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.2%	52 12.4%	98.1% 1.9%
		86.3% 13.7%	100% 0.0%	100% 0.0%	95.1% 4.9%	100% 0.0%	80.7% 19.3%	90.7% 9.3%	96.3% 3.7%	93.5% 6.5%
	Chůze	Běh	Schody	Stoj	Sed	Volání	Zprávy	Stůl		
	Cílová aktivita									

Obrázek 6.2: Matice záměn optimalizované sítě (testovací dataset)

Celková úspěšnost zde dosahuje 93, 5 %, což je pouze o 0,8 % méně než na celém datasetu. Úspěšnost klasifikace obou datasetů je tedy srovnatelná. Na testovacím datasetu byla nejčastěji špatně klasifikovaná aktivita volání, opět zaměňovaná za

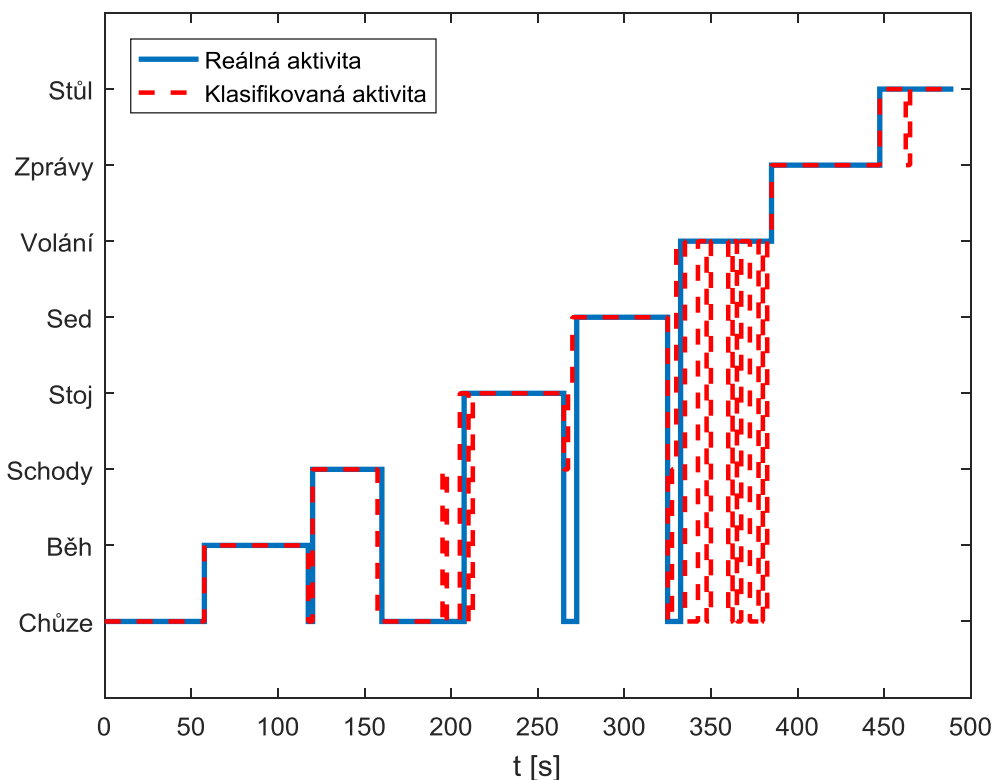
chůzi. Nejhoršího f -skóre dosahovala opět aktivita chůze s hodnotou 0,79 (viz tabulka 6.1). Nejlepší skóre měla aktivita sed, která byla s hodnotou 1 bezchybně určena. Skóre ostatních aktivit nabývalo rozmezí 0,89-0,99. Celkové F -skóre bylo 0,94, tedy shodné (po zaokrouhlení na dvě desetinná místa) s testováním na celém datasetu.

Následuje matice záměn pro testování na kontinuálním datasetu (obrázek 6.3):

Výstupní aktivita	Chůze	42 21.3%	0 0.0%	1 0.5%	1 0.5%	0 0.0%	9 4.6%	0 0.0%	0 0.0%	79.2% 20.8%
	Běh	0 0.0%	24 12.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	Schody	3 1.5%	0 0.0%	15 7.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	83.3% 16.7%
	Stoj	2 1.0%	0 0.0%	0 0.0%	22 11.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	91.7% 8.3%
	Sed	1 0.5%	0 0.0%	0 0.0%	0 0.0%	21 10.7%	0 0.0%	0 0.0%	0 0.0%	95.5% 4.5%
	Volání	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 6.1%	0 0.0%	0 0.0%	92.3% 7.7%
	Zprávy	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	25 12.7%	1 0.5%	96.2% 3.8%
	Stůl	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 8.6%	100% 0.0%
		85.7% 14.3%	100% 0.0%	93.8% 6.3%	95.7% 4.3%	100% 0.0%	57.1% 42.9%	100% 0.0%	94.4% 5.6%	90.4% 9.6%
	Chůze	Běh	Schody	Stoj	Sed	Volání	Zprávy	Stůl		
	Cílová aktivita									

Obrázek 6.3: Matice záměn optimalizované sítě (kontinuální dataset)

Nejhůře zde byla opět klasifikována aktivita volání. Byla zaměňována za chůzi (volání bylo prováděno za chůze), a to v 9 z 21 případů (přibližně 42,9%). Další zaměňovanou aktivitou byla chůze, a to za: chůzi do schodů ve 3 z 49 případů, stoj (2 z 49), sed (1 z 49) a volání (1 z 49). Záměna chůze za jiné aktivity může být způsobena přechody mezi jednotlivými aktivitami kontinuálního datasetu. Tyto přechody jsou definovány jako cílová aktivita chůze. Ne vždy však, zejména při změně pozice telefonu (stoj - sed, sed - volání...), přechod chůzi odpovídá. Tyto přechody by bylo možné vyřešit zavedením další klasifikační třídy „neurčené“. Do této třídy by byla aktivita zařazena, pokud by hodnota na výstupu aktivační funkce výstupní vrstvy nedosáhla určitého prahu. Přechody názorně zobrazuje obrázek 6.4, který znázorňuje porovnání reálné - referenční aktivity a aktivity klasifikované sítě, při testování na kontinuálním datasetu.



Obrázek 6.4: Porovnání reálné - referenční aktivity a aktivity klasifikované sítí (kontinuální dataset)

f_n -skóre testování na kontinuálním datasetu uvádí tabulka 6.1 (viz výše). Nejhorší hodnoty f -skóre dosahuje aktivita volání (0,71). Pod hranicí 0,90 se nachází skóre dalších dvou aktivit: chůze (0,82) a chůze do schodů (0,88). Ostatní aktivity mají skóre nad 0,90. Celkové F -skóre na kontinuálním datasetu bylo 0,91. Úspěšnost klasifikace zde dosahovala 90,4 %, což je úspěšnost nižší než u předchozích dvou datasetů (celý dataset 94,3 %, testovací 93,5 %).

Dosažené úspěšnosti klasifikace: celý dataset 94,3%, testovací 93,5% a kontinuální 90,4%, lze s přihlédnutím k faktu, že velká část nesprávných klasifikací spadala do určování aktivity volání (velmi podobné s chůzí), považovat za dobré. Také v porovnání s úspěšnostmi různých autorů, lze výsledky považovat za uspokojivé. Přehled úspěšností autorů v použitých člancích (v závorkách jsou uvedeny klasifikované aktivity): 99 % [5] (Chůze, Pomalý běh, Sed, Stoj, Chůze do schodů, Chůze ze schodů), 91,15 % [8] (Tanec, Chůze do schodů, Chůze ze schodů, Pomalá chůze, Rychlá chůze, Běh), 82,8 % až 100 % [1] (autor shrnuje více různých studií). Nutno podotknout, že aktivity uvedených autorů jsou velmi dobře akcelerometricky diferencovatelné.

Naučená neuronová síť je přizpůsobená definovaným pozicím telefonu u daných aktivit, například vložení telefonu do kapsy kalhot vrchní částí dolů a displayem ke stehnu (nejčastější a nejpraktičtější způsob vkládání při běžném držení telefonu v ruce) nebo psaní zpráv s telefonem orientovaným „na výšku“

(také nejčastější způsob). Při velké změně orientace/pozice telefonu, by mohlo docházet k špatným klasifikacím, čemuž by bylo možné předejít definováním většího množství aktivit pro různé pozice/orientace. Také doplnění klasifikace o třídu neurčené by mohlo značně zvýšit úspěšnost klasifikace, zvláště u přechodových signálů mezi různými aktivitami (kontinuální dataset), popř. pokud by byla vykonávána aktivita, která by nebyla definována. Časová náročnost výpočtu příznaků a klasifikace se pohybuje okolo 30 sekund na hodinu záznamu, z čehož časově nejnáročnější je výpočet příznaků (testováno na běžných počítačích, jejichž popis je uveden v kapitole 5 o optimalizaci). Poměrně nízká výpočetní náročnost by umožňovala klasifikaci aktivity přímo v chytrém mobilním telefonu, kde by data mohla být klasifikována kontinuálně po nastřádání určitého množství dat (například několik minut), nebo při použití méně výkonného smartphonu jednou denně v době neaktivity (například v noci).

Závěr

Cílem této bakalářské práce bylo klasifikovat signály denní aktivity, nasnímané pomocí chytrého mobilního telefonu (smartphonu). Požadovaných výsledků bylo dosaženo pomocí několika kroků.

Nejprve proběhlo teoretické seznámení s problematikou snímání biosignálů a jejich klasifikace. Což popisují v kapitoly 1 a 2. Obsahují mimo jiné také popis nositelných zařízení, akcelerometrického senzoru, výpočtu příznaků a neuronových sítí, využitých k samotné klasifikaci. Poskytují tak potřebné základní informace k pochopení principu a průběhu klasifikace.

Druhým krokem bylo nasnímání potřebných signálů aktivit. K snímání dat pro účely této práce byl, pro svou informativní hodnotu a dostupnost v téměř každém chytrém mobilním telefonu, vybrán trojosý akcelerometrický senzor. Pomocí tohoto senzoru uloženého v těle smartphonu bylo nasnímáno celkem osm různých aktivit: Chůze, Běh, Chůze do schodů, Stoj, Sed, Telefonování, Psaní zpráv a Položení telefonu na stole. Celkově bylo snímáno deset různých osob, anotováno přes 75 minut záznamu jednotlivých aktivit a dva krát přibližně 8,5 minuty kontinuálního záznamu všech aktivit za sebou. Podrobněji jsou aktivity, společně s popisem metodiky jejich snímání, popsány v kapitole 3.

Dalším krokem byla realizace algoritmu určujícího denní aktivitu v programovém prostředí MATLAB. K samotné klasifikaci aktivit byla z možných algoritmů strojového učení vybrána neuronová síť, která má oproti některým jiným algoritmům schopnost učit se. V závislosti na povaze aktivit - periodické, statické apod., byly vybrány příznaky, které byly pro neuronovou síť počítány. Celkem bylo z nasnímaných dat počítáno 13 příznaků pro každou osu akcelerometrického signálu (celkem tedy 39). Příznaky byly počítány v posuvných oknech s nastavitelnou délkou a překryvem. Mezi počítané příznaky patří: aritmetický průměr, směrodatná odchylka, maximální a minimální hodnota, rozdíl maxima a minima, mediánová absolutní odchylka, efektivní hodnota (RMS), několik různých period získaných z autokorelace signálu, hlavní frekvence signálu v okně získaná z Rychlé Fourierovy Transformace (FFT) a příznak amplituda hlavní frekvence. To, které příznaky budou počítány a použity, bylo vyhodnoceno pomocí boxplotů, které umožňují vizualizovat jejich odlišovací schopnost. Z boxplotů také vyplynulo, že některé příznaky dovedou odlišit výrazně jednu aktivitu od ostatních, zatímco jiné odlišují různě aktivity mezi sebou. Kombinací příznaků, které odlišují aktivity různým způsobem, lze dospět ke kvalitním výsledkům. Z naměřených dat byly vypočítáním příznaků vytvořeny dva hlavní datasey. Celý dataset, vytvořený ze 75 minut záznamu jednotlivých aktivit, a kontinuální dataset, vytvořený z kontinuálně nahrávaných aktivit. Celkový dataset byl rozdělen v poměru 0,5 : 0,25 : 0,25 na trénovací, validační a testovací dataset.

Síť byla s pomocí validačního datasetu naučena (natrénována) na trénovacím datasetu. Jak způsobem různé příznaky pomáhaly odlišovat jednotlivé aktivity, a celý tento krok popisuje kapitola 4.

Čtvrtým krokem byla optimalizace algoritmu v závislosti na dosažených výsledcích klasifikace. Naučená síť byla v této části testována na celkovém datasetu a také jeho testovací části. V závislosti na úspěšnosti klasifikace byly upravovány parametry učení sítě (počet neuronů, krok učení, maximální přípustná odchylka, ...) a parametry výpočtu příznaků (délka okna, překryv, použití příznaků, ...). Jako nejvhodnější se jevílo použití sítě s jednou skrytou vrstvou, která obsahovala 10 neuronů. Optimalizace algoritmu zvýšila úspěšnost klasifikace přibližně o 6 %. Optimalizaci detailněji popisuje kapitola 5. Kapitola 6 dále obsahuje popis výsledků a diskuzi.

Uvedeným postupem bylo dosaženo úspěšností klasifikace 94,3 % s F -hodnotou 0,94 pro celý dataset, 93,5 % s F -hodnotou 0,94 pro testovací dataset a 90,4 % s F -hodnotou 0,91 pro dataset kontinuální. S přihlédnutím k faktu, že velká část nesprávných klasifikací spadala do určování aktivity označené jako telefonování, která byla velmi podobná aktivitě chůze (telefonování bylo prováděno za chůze), je možné výsledky považovat za dobré. Také s ohledem na výstupy jiných autorů, lze výslednou klasifikaci této práce považovat za uspokojivou.

Seznam použitých zdrojů

- [1] ROSARIO, Michael B., Stephen J. REDMOND a Nigel H. LOVELL. Tracking the Evolution of Smartphone Sensing for Monitoring Human Movement. *Sensors* [online]. 2015, 15(8), 18901-18933 [cit. 2018-10-21]. DOI: 10.3390/s150818901. ISSN 1424-8220. Dostupné z: <https://www.mdpi.com/1424-8220/15/8/18901/htm>
- [2] ALI, Nursabillilah Mohd, GJ TING, LQ SHIUNG, et al. Issues and Challenges of Sensor Technologies in Microelectromechanical System (MEMS) in Smartphones for Motion Tracking Applications. *JOURNAL OF TELECOMMUNICATION, ELECTRONIC and COMPUTER ENGINEERING* [online]. 2018, 10(1-9), 135-140 [cit. 2018-11-15]. ISSN 2180-1843. Dostupné z: <http://journal.utem.edu.my/index.php/jtec/article/view/3890>
- [3] TITTERTON, D. H a J. L WESTON. Strapdown inertial navigation technology. Second edition. Reston, VA: American Institute of Aeronautics and Astronautics, c2004. Progress in astronautics and aeronautics, 207. ISBN 15-634-7693-2.
- [4] KOZUMPLÍK, Jiří a Ivo PROVAZNÍK. Umělá inteligence v medicíně. Brno: VUT, 2007.
- [5] ARIF, Muhammad, Mohsin BILAL, Ahmed KATTAN a S. Iqbal AHAMED. Better Physical Activity Classification using Smartphone Acceleration Sensor. *Journal of Medical Systems* [online]. 2014, 38(9) [cit. 2018-12-9]. DOI: 10.1007/s10916-014-0095-0. ISSN 0148-5598. Dostupné z: <http://link.springer.com/10.1007/s10916-014-0095-0>
- [6] XING SU, HANGHANG TONG a PING JI. Activity recognition with smartphone sensors. *Tsinghua Science and Technology* [online]. 2014, 19(3), 235-249 [cit. 2018-12-27]. DOI: 10.1109/TST.2014.6838194. ISSN 1007-0214. Dostupné z: <http://ieeexplore.ieee.org/document/6838194/>
- [7] REYES-ORTIZ, Jorge-L., Luca ONETO, Albert SAMÀ, Xavier PARRA a Davide ANGUITA. Transition-Aware Human Activity Recognition Using Smartphones. *Neurocomputing* [online]. 2016, 171, 754-767 [cit. 2018-12-27]. DOI: 10.1016/j.neucom.2015.07.085. ISSN 09252312. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0925231215010930>

- [8] BAYAT, Akram, Marc POMPLUN a Duc A. TRAN. A Study on Human Activity Recognition Using Accelerometer Data from Smartphones. *Procedia Computer Science* [online]. 2014, 34, 450-457 [cit. 2018-12-29]. DOI: 10.1016/j.procs.2014.07.009. ISSN 18770509. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1877050914008643>
- [9] The truth of the F-measure. In: Toyota Technological Institute [online]. School of Computer Science, University of Manchester: Yutaka Sasaki, 2007 [cit. 2019-05-10]. Dostupné z: <https://www.toyota-ti.ac.jp/Lab/Denshi/COIN/people/yutaka.sasaki/F-measure-YS-26Oct07.pdf>

Seznam obrázků

Obrázek 2.1: Schéma mechanického akcelerometru	9
Obrázek 1.2: Schéma MEMS akcelerometru	9
Obrázek 1.3: Orientace os akcelerometru	10
Obrázek 2.1: Obecný postup klasifikace	12
Obrázek 2.2: Schéma jednotlivého neuronu	15
Obrázek 2.3: Příklad aktivační funkce	15
Obrázek 2.4: Klasifikace pomocí neuronu	16
Obrázek 3.1: Surová data akcelerometru (1/2)	20
Obrázek 3.2: Surová data akcelerometru (2/2)	21
Obrázek 4.1: Boxplot pro příznak průměr na ose z	23
Obrázek 4.2: Boxplot pro příznak maximum na ose y	24
Obrázek 4.3: Autokorelace okna z osy x u aktivity chůze	25
Obrázek 4.4: Amplitudové spektrum okna z osy x u aktivity chůze	25
Obrázek 4.5: Schéma neuronové sítě	26
Obrázek 5.1: Matice záměn neoptimalizovaného algoritmu (celý dataset)	27
Obrázek 5.2: Matice záměn neoptimalizovaného algoritmu (testovací dataset)	28
Obrázek 5.3: Matice záměn po zvýšení max. počtu epoch a kroku učení (celý dataset)	29
Obrázek 5.4: Závislost úspěšnosti klasifikace na počtu neuronů v skryté vrstvě (průměr z pěti učení pro daný počet neuronů)	30
Obrázek 5.5: Průběh učení optimalizované sítě	31
Obrázek 6.1: Matice záměn optimalizované sítě (celý dataset)	33
Obrázek 6.2: Matice záměn optimalizované sítě (testovací dataset)	34
Obrázek 6.3: Matice záměn optimalizované sítě (kontinuální dataset)	35
Obrázek 6.4: Porovnání reálné - referenční aktivity a aktivity klasifikované sítě (kontinuální dataset)	36

Seznam příloh

Příloha A, obsahující:

- Elektronickou verzi práce ve formátu *.pdf*
- MATLAB toolbox v komprimovaném *.zip* souboru, obsahující:
 - kódy pro výpočet příznaků a tvorbu datasetů
 - kódy pro učení neuronové sítě a optimalizaci
 - kódy pro klasifikaci aktivit pomocí neuronové sítě
 - kódy pro analýzu výsledků
 - vytvořené datasety
 - surová nasnímaná data
 - informace ke spuštění v dokumentu *README.txt*