



Zadání bakalářské práce

Název:	Aplikace pro real time analýzu EKG signálu pomocí umělé inteligence
Student:	Tadeáš Pála
Vedoucí:	Ing. Jan Hejda, Ph.D.
Studijní program:	Informatika
Obor / specializace:	Webové a softwarové inženýrství, zaměření Softwarové inženýrství
Katedra:	Katedra softwarového inženýrství
Platnost zadání:	do konce letního semestru 2022/2023

Pokyny pro vypracování

Cílem práce je návrh a implementace aplikace pro zpracování EKG signálu a identifikaci kognitivní zátěže pomocí metod umělé inteligence (AI). Navrhněte postup předzpracování EKG signálu do formy vhodné pro další zpracování metodami AI. Otestujte možnost detekce QRS komplexu na předzpracovaném signálu. Metody zpracování dat zvolte na základě analýzy současného stavu a upřednostňujte metody, které jsou zavedeny v klinické praxi. V rámci práce navrhněte a implementujte alespoň jednu metodu využívající neuronové sítě v algoritmech hodnocení EKG a detekce vybraných charakteristických projevů kognitivní zátěže v reálném čase. Součástí aplikace bude prezentace měřených dat, vypočtených parametrů a jejich přehledná grafická vizualizace. Aplikaci implementujte v prostředí Python. Navržené metody otestujte a statisticky vyhodnoťte oproti jiným standardně používaným postupům.



**FAKULTA
INFORMAČNÍCH
TECHNOLGIÍ
ČVUT V PRAZE**

Bakalářská práce

Aplikace pro real time analýzu EKG signálu pomocí umělé inteligence

Tadeáš Pála

Katedra softwarového inženýrství
Vedoucí práce: Ing. Jan Hejda, Ph.D.

13. května 2021

Poděkování

Chtěl bych poděkovat především vedoucímu této práce Ing. Janu Hejdovi, Ph.D. za veškeré rady, bez kterých by tato práce nemohla vzniknout. Dále bych chtěl poděkovat celé své rodině a všem přátelům za jejich pomoc a podporu.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona, ve znění pozdějších předpisů, zejména skutečnost, že České vysoké učení technické v Praze má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 citovaného zákona.

V Praze dne 13. května 2021

.....

České vysoké učení technické v Praze
Fakulta informačních technologií

© 2021 Tadeáš Pála. Všechna práva vyhrazena.

Tato práce vznikla jako školní dílo na Českém vysokém učení technickém v Praze, Fakultě informačních technologií. Práce je chráněna právními předpisy a mezinárodními úmluvami o právu autorském a právech souvisejících s právem autorským. K jejímu užití, s výjimkou bezúplatných zákonných licencí a nad rámec oprávnění uvedených v Prohlášení na předchozí straně, je nezbytný souhlas autora.

Odkaz na tuto práci

Pála, Tadeáš. *Aplikace pro real time analýzu EKG signálu pomocí umělé inteligence*. Bakalářská práce. Praha: České vysoké učení technické v Praze, Fakulta informačních technologií, 2021.

Abstrakt

Tato bakalářská práce se zabývá analýzou a zpracováním elektrokardiografického signálu v reálném čase pomocí konvolučních neuronových sítí. V práci jsou prezentovány navržené metody předzpracování signálu do podoby vhodné pro další zpracování pomocí metod umělé inteligence. Dále jsou popsány použité architektury konvolučních neuronových sítí a statistické vyhodnocení jejich výsledků. V rámci práce vznikla aplikace umožňující analýzu elektrokardiografického signálu v reálném čase za účelem identifikace kognitivní zátěže.

Klíčová slova Neuronové sítě, elektrokardiografie, strojové učení, umělá inteligence

Abstract

This bachelor thesis focuses on analysis and processing of ECG signals in real-time using convolutional neural networks. Presented are methods used for preprocessing of ECG signal, models used for its' subsequent analysis and methods used for statistical evaluation of said models. An application for real-time ECG analysis was developed. Said application allows for real-time identification of cognitive load from ECG signal.

Keywords Neural networks, electrocardiography, machine learning, artificial intelligence

Obsah

Úvod	1
1 Elektrokardiografie	3
1.1 Elektrokardiogram	3
1.2 Provedení EKG	5
1.2.1 Dvanáctisvodové EKG	5
2 Strojové učení	7
2.1 Klasifikace	7
2.2 Učení	7
2.3 Umělé neuronové sítě	8
2.3.1 Model neuronu	8
2.3.2 Přenosová funkce	9
2.4 Konvoluční neuronové sítě	9
2.4.1 Vrstvy konvolučních neuronových sítí	9
2.4.1.1 Konvoluční vrstva	10
2.4.1.2 Pooling vrstva	10
2.4.1.3 Plně propojená vrstva	10
2.5 Užití strojového učení pro analýzu EKG	11
2.6 Analýza EKG v reálném čase	11
3 Metody užité pro statistické zhodnocení	13
3.1 Přesnost	13
3.2 Matice záměn	13
4 Použitá data	17
4.1 Multi-modal Dataset for Wearable Stress and Affect Detection	17
4.2 Database for Cognitive Load, Affect and Stress Recognition	18
4.3 Předzpracování	18
4.3.1 Butterworthův filtr	19

4.3.2	Standardizace směrodatnou odchylkou	19
4.3.3	Klouzavý průměr	19
5	Použité modely	21
5.1	Model 1	21
5.2	Model 2	21
5.3	Model 3	22
6	Implementace	23
6.1	Programovací jazyk	23
6.2	Použité knihovny	23
6.2.1	Keras a Tensorflow	23
6.2.2	NeuroKit2	24
6.2.3	Scikit-learn	24
6.3	Členění kódu	24
6.3.1	Předzpracování dat	24
6.3.2	Učení a evaluace neuronových sítí	24
6.3.3	Analýza EKG v reálném čase	24
6.3.4	Utilitární funkce	24
6.4	Učení neuronových sítí	25
6.5	Analýza EKG v reálném čase	25
6.5.1	Producent a spotřebitel	26
6.5.2	Implementace návrhového vzoru	26
6.5.3	HRV parametry	27
6.6	Detekce QRS komplexu	28
7	Výsledky	29
7.1	Předzpracování	29
7.2	Detekce QRS komplexu	30
7.3	Výsledky modelů	32
7.4	Analýza EKG v reálném čase	33
8	Diskuze	35
	Závěr	37
	Literatura	39
	A Seznam použitých zkratk	43
	B Architektury neuronových sítí	45
	C Výsledky modelů	47
	D Spuštění aplikace, Obsah příloženého média	51

Seznam obrázků

1.1	Průběh jedné srdeční periody, zdroj: [1]	4
2.1	Matematický model neuronu	8
2.2	Max-pooling	10
2.3	Average pooling	10
6.1	Učení neuronových sítí	25
6.2	Simulace analýzy v reálném čase	27
7.1	EKG s kolísající izoliní	30
7.2	EKG po aplikaci Butterworthova filtru	30
7.3	Výsledek detekce QRS komplexu na nepředzpracovaném signálu	31
7.4	Výsledek detekce QRS komplexu, Butterworthův filtr	31
7.5	Výsledek detekce QRS komplexu, Butterworthův filtr, klouzavý průměr	32
7.6	Vytvořená aplikace	33

Úvod

Systémy umělé inteligence se stávají čím dál větší součástí každodenního života. Objevují se v aplikacích běžně užívaných na našich mobilních telefonech, či na stránkách, které denně navštívujeme. Jejich hlavním cílem není nahradit člověka, ale umožnit mu rychle a efektivně vyřešit určité problémy. Příkladem problematiky, s jejímž řešením nám může pomoci umělá inteligence, je porozumění velkému množství dat.

Jedním z výpočetních modelů užívaných v oboru umělé inteligence jsou umělé neuronové sítě. Neuronové sítě umožňují zpracování komplexních dat, jako je například obraz, video nebo biologické signály.

Tato práce je zaměřena na předzpracování elektrokardiografického signálu a jeho následnou analýzu pomocí metod umělé inteligence v reálném čase. Účelem analýzy signálu je identifikace kognitivní zátěže. Kognitivní zátěž je celkové množství mentální aktivity, kterému je v daný okamžik vystavena pracovní paměť člověka.

V práci jsou popsány metody užití pro předzpracování biologického signálu, jeho následnou klasifikaci a metody užití pro statistickou analýzu úspěšnosti použitých přístupů.

Elektrokardiografie

Elektrokardiografie je základní neinvazivní metoda vyšetření elektrické aktivity srdečního svalu. Slouží k diagnostice mnoha srdečních onemocnění, jako je infarkt myokardu, poruchy rytmu, srdeční nedostatečnost apod.

Kolem srdce se vytváří elektrické pole, které se šíří vodivým prostředím těla. Lze jej změřit i na povrchu těla, jako rozdíl elektrického napětí mezi dvěma elektrodami. Potenciály jsou vektorové, mají velikost i směr.


Elektrokardiograf vynalezl v roce 1887 britský fyziolog Augustus Desiré Waller. Přístroj byl schopný snímat pomocí Lippmannova kapilárního elektrometru elektrickou aktivitu srdce a promítat ji na fotografickou desku. Historicky byla elektrokardiografie zavedena jako klinická metoda holandským lékařem Willemem Einthovenem v roce 1906. Willem Einthoven aplikací matematických rovnic upravil křivku snímanou kapilárním elektrometrem a přiřadil výchylkám křivky písmena P, Q, R, S a T.

1.1 Elektrokardiogram

Elektrokardiogram je grafický záznam cyklicky se opakující srdeční činnosti, získaný elektrokardiografií. Jeden cyklus se skládá z depolarizace a repolarizace síní a z depolarizace a repolarizace komor.

1. ELEKTROKARDIOGRAFIE

Jednotlivé části EKG křivky během jedné srdeční periody popisuje následující obrázek:



Obrázek 1.1: Průběh jedné srdeční periody, zdroj: [1]

- **Vlna P** – šíření vzruchu (depolarizace) síní
- **Komplex QRS** – šíření vzruchu (depolarizace) po komorách
- **Vlna T** – ústup podráždění (repolarizace) na komorách
- **Bez zobrazení (schované v komplexu QRS)** – ústup podráždění (repolarizace) na síních.

Změny ve tvaru křivky, jejích jednotlivých vln, hrotů či komplexu, změny ve frekvenci a nepravidelnosti rytmu informují o kondici srdečního svalu a jeho případném onemocnění. Analýza elektrokardiogramu může kromě informací o onemocnění srdečního svalu poskytnout i informace o emočním rozpoložení člověka[2] nebo kognitivní zátěži[3, 4, 5].

1.2 Provedení EKG

Elektrokardiografie je prováděna kardiografem. Kardiograf je elektrický přístroj snímající a zaznamenávající elektrickou aktivitu srdce. Měří rozdíl napětí, jako projev šíření akčního potenciálu myokardem. Napětí snímá pomocí elektrod umístěných na kůži. Elektrody jsou umístěny na hrudníku a končetinách. Dnešním standardem jsou dvanáctisvodové EKG přístroje.

1.2.1 Dvanáctisvodové EKG

K tomuto typu záznamu se používá 6 základních unipolárních hrudních svodů, 3 Einthovenovy bipolární končetinové svody a 3 Goldbergovy unipolární svody. Snímá potenciál z povrchu těla. Metoda je neinvazivní.

Strojové učení

Při tradičním přístupu k řešení problémů pomocí výpočetních technologií je zapotřebí naprogramovat algoritmy s přesně danými instrukcemi a pravidly. Tento způsob vyžaduje velmi schopného programátora, často s expertní znalostí oboru dané problematiky. S komplexnějšími daty a rostoucím počtem faktorů, které je potřeba při vývoji brát v potaz, však vyvstává problém s hledáním pravidel, která by umožnila správnou evaluaci problému.

Strojové učení nabízí alternativní přístup k řešení komplexních problémů s velkým množstvím dostupných dat. Na rozdíl od explicitní definice algoritmů a pravidel bývají modely strojového učení na datech natrénovány, čímž získávají své schopnosti. Strojové učení nedokáže úplně eliminovat potřebu lidského vstupu, ale umožňuje řešit problémy jiným způsobem. Rozvoj této podoblasti informatiky způsobil obrovský nárůst množství dostupných dat, jejichž zpracování a analýza nabývá stále většího významu a zvýšení výpočetního výkonu.

2.1 Klasifikace

Jednou z tříd problémů, kterými se strojové učení zabývá, je klasifikace. Klasifikační problémy spočívají v roztrídění dat do několika kategorií. Příkladem klasifikačního problému může být rozdělení emailů do tříd „spam“ a „ne-spam“ nebo přiřazení záznamu elektrokardiografického signálu do tříd „zvýšená kognitivní zátěž“ a „klid“. Algoritmus implementující klasifikaci se nazývá klasifikátor.

2.2 Učení

Před tím, než mohou být modely strojového učení použity k predikci, je potřeba je natrénovat. Natrénování modelu znamená, že model vystavíme předem nasbíraným datům, strukturně se shodujícími s těmi, která bude algoritmus

zpracovávat při samotné predikci. Na základě dat, která jsou poskytnuta při učení, můžeme algoritmy učení rozdělit do kategorií:

- **Učení s učitelem** – Pro vstupní data je určen správný výstup
- **Učení bez učitele** – Pro vstupní data není určen správný výstup

V této práci bylo užito učení s učitelem. Záznamy elektrokardiografického signálu byly označeny jako „zvýšená kognitivní zátěž“ a „klid“.

2.3 Umělé neuronové sítě


Jedním z modelů používaných v oblasti strojového učení jsou umělé neuronové sítě. Vzorem umělých neuronových sítí jsou biologické neuronové sítě. Existuje mnoho typů umělých neuronových sítí, základní principy a uspořádání však zůstávají pro všechny stejné. Skládají se ze sítě umělých neuronů, jejichž předobrazem je biologický neuron. Neurony jsou vzájemně propojeny a předávají si a transformují signály.

2.3.1 Model neuronu

Je popsána řada různých matematických modelů umělých neuronů. Jedním z nejpoužívanějších je model popsáný McCullochem a Pittsem v práci *A logical calculus of the ideas immanent in nervous activity*[6]. Model popisuje následující rovnice:

$$y = f\left(\sum_{i=1}^n (x_i \cdot \omega_i) + b\right) \quad (2.1)$$

x je vstupním vektorem, ω je vektorem vah, y je výstupem neuronu, $f(\xi)$ je přenosovou funkcí a b je prahem. Model neuronu je graficky znázorněn následujícím diagramem:



Obrázek 2.1: Matematický model neuronu

2.3.2 Přenosová funkce

Důležitou částí umělého neuronu je přenosová funkce. Přenosová funkce definuje, jakým způsobem je skalární součin vektorů vstupu a vah převeden na výstup neuronu. Provádí obecnou nelineární transformaci. Jako přenosovou funkci lze použít celou řadu funkcí. Mezi nejpoužívanější patří:

- Skoková funkce

$$f(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2.2)$$

- Sigmoidální funkce

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

- Hyperbolický tangens

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

- ReLU (Rectified Linear Unit)

$$f(x) = \max(0, x) \quad (2.5)$$

2.4 Konvoluční neuronové sítě

Konvoluční neuronové sítě jsou jedním z typů neuronových sítí. Nejčastějším užitím konvolučních neuronových sítí je analýza obrazových dat. Základ pro výzkum těchto sítí položili Hubel a Wiesel[7], kteří zkoumali, jakým způsobem kočičí mozek zpracovává obraz. Jejich prací byl inspirován Kunihiko Fukushima, který navrhl neuronovou síť „Neocognitron“ [8] schopnou rozpoznávat ručně psané znaky a číslice. První moderní konvoluční neuronovou sítí je model nazvaný „LeNet-5“, který představil Yann LeCun[9]. Tato síť byla určena k rozpoznávání ručně psaných číslic a využívala se zejména pro automatizaci zpracování ručně psaných dokumentů v bankách.

Typická konvoluční neuronová síť určená pro klasifikaci dat má dvě části. První část pomocí konvolučních vrstev extrahuje důležité příznaky a předává je ve formě vektoru klasifikátoru, který bývá zpravidla tvořen plně propojenými vrstvami. Konvoluční část je důležitá, protože redukuje množství parametrů předávaných do sítě pouze na ty nejpodstatnější. Tato redukce umožní učení robustnějšího klasifikátoru a výrazně snižuje výpočetní náročnost.

2.4.1 Vrstvy konvolučních neuronových sítí

V následující části budou popsány vrstvy, které jsou v konvolučních neuronových sítích používány. Všechny operace, které jednotlivé vrstvy provádějí, budou popisovány pro konvoluční síť zpracovávající jednorozměrná data. Operace lze aplikovat i na vícerozměrná data, např. obrázky. Tato práce je zaměřena na zpracování signálu, který je reprezentován jednorozměrně.

2.4.1.1 Konvoluční vrstva

Konvoluční vrstva provádí na vstupním signálu filtrování za pomoci operace konvoluce vstupního vektoru s menším vektorem zvaným jádro. Nechť je f vstupním vektorem délky n a g je vektorem jádra délky m . Diskrétní konvoluce $f * g$ vstupního vektoru f a jádra g je definována následovně:


$$(f * g)_i = \sum_{j=1}^m g_j \cdot f_{i-j} \quad (2.6)$$

Operaci konvoluce lze obecně popsat tak, že vektor jádra je postupně přikládán na vstupní vektor. Překrývající se prvky jsou vynásobeny a součet násobků je zapsán do výstupního vektoru. Poté je vektor jádra posunut a operace násobení a sčítání jsou opakovány.


Cílem této operace je získání příznakové mapy. Příznaková mapa v sobě nese informace o význačných částech vstupního signálu a je předávána vrstvám, které ji dále zpracovávají.

2.4.1.2 Pooling vrstva

Úlohou pooling vrstvy je snížit množství reprezentovaných dat a tím redukovat množství parametrů předávaných do sítě. Pooling vrstva má definovanou velikost jádra a kroku. Velikost jádra značí velikost podoblasti vstupního vektoru, na kterou je operace aplikována a krok značí, o kolik se podoblast posouvá vůči vstupnímu vektoru. Nejpoužívanějšími typy pooling vrstev jsou max-pooling a average pooling. Max-pooling z každé podoblasti vektoru vybere maximální hodnotu a average pooling z podoblasti vypočítá aritmetický průměr. Operace max-pooling a average pooling znázorňují následující obrázky:



Obrázek 2.2: Max-pooling



Obrázek 2.3: Average pooling

2.4.1.3 Plně propojená vrstva

Plně propojená vrstva vytváří spojení mezi každým vstupním a výstupním prvkem. V konvolučních neuronových sítích plně propojené vrstvy většinou následují po extrakci důležitých příznaků pomocí kombinace konvolučních a pooling vrstev. Jejich úkolem je samotná klasifikace extrahovaných příznaků.

2.5 Užití strojového učení pro analýzu EKG

Pro analýzu elektrokardiografického signálu již bylo navrženo mnoho modelů využívajících strojového učení. Modely byly navrhovány za účelem dosažení různých cílů, např. detekce srdeční arytmie[10] nebo klasifikace emočního rozpoložení člověka[11]. Sahají od jednoduchých klasifikátorů, jako jsou rozhodovací stromy[12] nebo lineární klasifikátory[13], až po složitější, jako jsou konvoluční neuronové sítě[14, 15]. Kromě samotných modelů bylo experimentováno i s daty, která jim byla poskytnuta a různými metodami jejich předzpracování[16].

Pro účely identifikace kognitivní zátěže byly v této práci zvoleny konvoluční neuronové sítě. Konvoluční neuronové sítě umožňují analýzu signálu, bez potřeby manuální extrakce parametrů. Dokáží pomocí konvolučních vrstev důležité příznaky extrahovat bez lidské pomoci. Díky této vlastnosti jsou vhodné pro analýzu v reálném čase, neboť vyžadují oproti jiným metodám minimální předzpracování signálu.

2.6 Analýza EKG v reálném čase

Analýza EKG v reálném čase je možná díky rychlosti, s jakou jsou konvoluční neuronové sítě schopny zpracovat signál. V rámci práce bylo navrženo a simulováno řešení, které umožňuje v reálném čase předzpracovat signál a pomocí neuronových sítí detekovat zvýšenou kognitivní zátěž.

Metody užité pro statistické zhodnocení

Během vývoje modelů strojového učení je důležité monitorovat jejich úspěšnost. Vývoj zahrnuje otestování mnoha přístupů a různých modelů, proto je nutné každý přístup statisticky vyhodnotit a porovnat s ostatními.

Běžným postupem při využití strojového učení je stanovení cílů, kterých by mělo být dosaženo a volba numerických metrik, které je reprezentují. Po volbě metrik je vytvořen jednoduchý model, který slouží pro získání prvních výsledků a se kterým jsou následně porovnávány další složitější modely a přístupy.

V následující části budou popsány metody, kterých bylo při hodnocení úspěšnosti jednotlivých modelů použito.

3.1 Přesnost

Přesnost je nejjednodušší metrikou, která může být použita k vyhodnocení úspěšnosti modelu. Její výpočet je popsán následující rovnicí:

$$\text{Přesnost} = \frac{\text{Počet správných predikcí}}{\text{Celkový počet predikcí}} \quad (3.1)$$

Nevýhodou této metriky je, že nesprávně reprezentuje úspěšnost modelu, pokud v sadě dat nejsou jednotlivé třídy zastoupeny rovnoměrně. Modely mohou dosahovat vysoké přesnosti pouze tím, že všechna data klasifikují jako třídu, která se vyskytuje nejčastěji.

3.2 Matice záměn

Běžně užívanou metodou vizualizace úspěšnosti modelů strojového učení při klasifikačních úlohách je matice záměn. Jedná se o matici obsahující ve sloupcích skutečnou hodnotu předpovídaného znaku a v řádcích předpověď klasifikátoru. Buňky matice obsahují četnost, kolikrát došlo na zkoumané datové

3. METODY UŽITÉ PRO STATISTICKÉ ZHODNOCENÍ

množině k dané kombinaci skutečné a predikované hodnoty. Případy na diagonále matice jsou klasifikovány správně a mimo diagonálu chybně.

V případě binární klasifikace kognitivní zátěže se jedná o matici obsahující 4 hodnoty:

- True positives (TP) – Počet správně klasifikovaných záznamů, pořízených při vysoké kognitivní zátěži
- False positives (FP) – Počet chybně klasifikovaných záznamů, pořízených při vysoké kognitivní zátěži
- True negatives (TN) – Počet správně klasifikovaných záznamů, pořízených v klidovém stavu
- False negatives (FN) – Počet chybně klasifikovaných záznamů, pořízených v klidovém stavu

Podoba matice záměn pro klasifikaci kognitivní zátěže je popsána v následující tabulce:

Predikované hodnoty \ Skutečné hodnoty	Kognitivní zátěž	Klid
	Kognitivní zátěž	TP
Klid	FN	TN

Tabulka 3.1: Matice záměn

Počty správně a špatně klasifikovaných pozitivních/negativních hodnot umožňují výpočet dalších metrik, pomocí kterých může být hodnocena úspěšnost modelů. Metriky, které byly v této práci při evaluaci modelů v kombinaci s přesností použity jsou specificita, senzitivita a preciznost. Všechny nabývají hodnot v intervalu $[0; 1]$ a bývají obvykle vyjadřovány v procentech. Jejich výpočet popisují následující rovnice:

$$\text{Specificita} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (3.2)$$

$$\text{Senzitivita} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3.3)$$

$$\text{Preciznost} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3.4)$$

V kontextu detekce kognitivní zátěže podává specificita informaci o tom, s jakou přesností je model schopen klasifikovat záznamy, které byly pořízeny v klidovém stavu. Senzitivita je číselné vyjádření schopnosti modelu správně

identifikovat záznamy naměřené při vysoké kognitivní zátěži. Preciznost podává informaci o tom, jaká část záznamů klasifikovaných jako zvýšená kognitivní zátěž byla relevantní.

Poslední metrikou, která byla při vyhodnocování úspěšnosti modelů použita je skóre F1. Výpočet je proveden pomocí následující rovnice:

$$F_1 = 2 \cdot \frac{\text{preciznost} \cdot \text{senzitivita}}{\text{preciznost} + \text{senzitivita}} \quad (3.5)$$

Použitá data

Základem úspěšného strojového učení je správný výběr dat, na kterých mohou být jednotlivé modely natrénovány. V následující kapitole budou popsána použitá data a způsob jejich předzpracování.

4.1 Multi-modal Dataset for Wearable Stress and Affect Detection

Sada dat *Multi-modal Dataset for Wearable Stress and Affect Detection*[17] obsahuje záznamy biologických signálů patnácti účastníků experimentu ve stavu pobavení, stresu a kontrolním stavu. Pro navození pocitu pobavení byla účastníkům puštěna série videí, určených pro navození tohoto pocitu. Pro navození pocitu stresu byl každý účastník pověřen plněním několika úkolů. Mezi úkoly zadané účastníkům patřily pětiminutový přednes před publikem a početní úloha. V kontrolním stavu nebyli cíleně vystavováni žádným podnětům, které by mohli probudit pocit pobavení či stresu.

Data byla snímána zařízením RespiBAN[18] připevněným k účastníkově hrudi a zařízením Empatica E4[19] připevněným na zápěstí. RespiBAN poskytuje data elektrokardiogramu, elektrodermální aktivity, elektromyogramu, dechové aktivity, tělesné teploty a tříosé akcelerace. Všechny senzory používaly vzorkovací frekvenci 700 Hz. Empatica E4 poskytuje data ze senzorů měřících krevní tlak, elektrodermální aktivitu, tělesnou teplotu a tříosou akceleraci. Senzory používaly vzorkovací frekvence 64 Hz (krevní tlak), 4 Hz (elektrodermální aktivita), 4 Hz (tělesná teplota), 32 Hz (tříosá akcelerace).

Ze sady dat WESAD byly použity pouze záznamy elektrokardiografických signálů naměřených pomocí zařízení RespiBAN, pořízených při provádění početní úlohy a při kontrolním stavu. Data naměřená při početní úloze byla pro potřeby učení neuronové sítě označena jako vysoká kognitivní zátěž. Data naměřená v kontrolním stavu byla označena jako klidová.

4.2 Database for Cognitive Load, Affect and Stress Recognition

Database for Cognitive Load, Affect and Stress Recognition[20] je sadou záznamů biologických signálů 62 účastníků experimentu. Experiment se skládal z několika částí. V první části byli účastníci pověřeni plněním úkolů, které měly za cíl navodit vysokou kognitivní zátěž. Těmito úkoly byly početní úlohy, Stroopův test a logické úlohy. Stroopův test je psychologický test, ve kterém jsou účastníkům předloženy názvy barev napsané barevným písmem (např. slovo „červená“ napsané modrým písmem) a jejich úkolem je jmenovat barvu písma[21]. V druhé části experimentu byla účastníkům pouštěna videa a ukazovány obrazy, které měly vzbudit určité emoce. Kromě záznamů biologických signálů při plnění úkolů a sledování videí a obrazů obsahuje sada dat i záznamy pořízené v kontrolním stavu, tedy když účastníci nebyli cíleně vystavováni žádným podnětům, které by mohly vyvolat vysokou kognitivní zátěž či výraznou emoční změnu.

Data byla snímána zařízeními Shimmer3 GSR+ Unit[22] a Shimmer3 ECG Unit[22], se vzorkovací frekvencí 256 Hz. V sadě dat jsou záznamy elektrokardiografického signálu, fotopletysmografického signálu a elektrodermální aktivity.

Z této sady dat byly použity záznamy elektrokardiografického signálu, pořízené při početních úlohách, Stroopově testu, logických úlohách a kontrolním stavu. Záznamy z části experimentu, kdy účastníci plnili úkoly, byly označeny pro potřeby učení neuronové sítě jako záznamy pořízené při vysoké kognitivní zátěži a záznamy pořízené při kontrolním stavu byly označeny jako klidové.

4.3 Předzpracování

Všechna data byla převzorkována na vzorkovací frekvenci 500 Hz. Korekce izoliny byla provedena pomocí Butterworthova filtru pátého řádu s horní propustí 1 Hz. Filtrace pomocí Butterworthova filtru je standardně používaným postupem v klinické praxi[23]. Po převzorkování a korekci izoliny byla pro každý záznam zvlášť provedena standardizace směrodatnou odchylkou.

Předzpracované záznamy byly rozděleny na stejně dlouhé segmenty. V rámci práce bylo experimentováno s různou délkou segmentů. Každému segmentu byla přiřazena hodnota označující, zda byl naměřen při vysoké kognitivní zátěži.

Okna elektrokardiografického signálu byla náhodně zamíchána a rozdělena na trénovací a testovací části v poměru 7:3. Z trénovací části bylo náhodně vybráno 10 % dat, která byla použita jako validační.

Po rozdělení dat v trénovací části výrazně převažovaly záznamy pořízené při kognitivní zátěži. Tato nevyváženost byla způsobena vysokým počtem

úkolů vyvolávajících kognitivní zátěž, kterými byli pověřeni účastníci experimentu provedeného při sběru dat pro sadu CLAS[20]. Nevyváženost rozdělení záznamů snižovala úspěšnost trénovaných modelů. Způsobila, že modely klasifikovaly všechny záznamy jako vysokou kognitivní zátěž. Z důvodu předejití zaujatosti modelů byla z trénovacích dat náhodně vyřazena část záznamů označených jako kognitivní zátěž.

Trénovací data sloužila k učení jednotlivých modelů, validační data sloužila k ověření jejich úspěšnosti v průběhu učení. Testovací data nebyla při tréninku vůbec použita. Sloužila k ověření přesnosti již natrénovaných modelů.

4.3.1 Butterworthův filtr

Butterworthův filtr je druh zpracování signálu poprvé popsán inženýrem Stephenem Butterworthem[24]. Filtr je navržený tak, aby měl co nejvíce plochou frekvenční odezvu v propustném pásmu.

4.3.2 Standardizace směrodatnou odchylkou

Standardizace EKG signálu směrodatnou odchylkou není v klinické praxi běžně používána, neboť může výrazně ovlivnit amplitudu signálu. Pro potřeby analýzy pomocí neuronových sítí je však vhodná. Pro vektor x velikosti n , reprezentující vzorek EKG signálu je směrodatná odchylka σ definována následovně:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (4.1)$$

x_i značí i -tý prvek vektoru a \bar{x} aritmetický průměr hodnot vzorku. Standardizaci pomocí směrodatné odchylky definuje následující rovnice:

$$x'_i = \frac{x_i - \bar{x}}{\sigma} \quad (4.2)$$

4.3.3 Klouzavý průměr

Klouzavý průměr může být použit k odstranění vysokofrekvenčního ruchu z EKG signálu[25]. V této práci byl použit při testování detekce QRS komplexu. Při trénování a evaluaci konvolučních neuronových sítí použit nebyl.

Použité modely

Pro účely klasifikace elektrokardiografických signálů byly zvoleny konvoluční neuronové sítě. Konvoluční neuronové sítě jsou pro analýzu biologických signálů vhodné, protože oproti jiným metodám strojového učení dokáží bez lidské pomoci extrahovat ze signálu důležité parametry a následně je vyhodnotit.

V rámci práce bylo navrženo a otestováno několik architektur konvolučních neuronových sítí. Vstupem všech neuronových sítí jsou úseky předzpracovaného elektrokardiografického signálu. Všechny neuronové sítě byly učeny na trénovací části dat a následně byla vyhodnocena jejich úspěšnost na testovací části dat. Během učení byla monitorována jejich přesnost na validační části dat. Pro každý model proběhlo 500 iterací.

5.1 Model 1

První navrženou architekturou, která byla pro identifikaci kognitivní zátěže otestována je jednoduchá neuronová síť skládající se ze 2 konvolučních vrstev a 2 plně propojených vrstev. Výstup konvolučních vrstev je přeskládán do vektoru a předán plně propojeným vrstvám. Struktura neuronové sítě je plně popsána v tabulce B.1.

Tento model nebyl při klasifikaci příliš úspěšný, poskytl však výsledky, se kterými mohly být srovnávány další složitější architektury.

5.2 Model 2

Druhou architekturou použitou pro analýzu elektrokardiografických signálů je architektura inspirovaná článkem *Stress detection using deep neural networks* [15]. Model představený v článku byl použit na detekci stresu a přijímal několik biologických signálů současně. Bylo ho tedy nutné upravit tak, aby přijímal pouze jeden. Kromě snížení počtu přijímaných signálů byl zvýšen počet

neuronů v plně propojených vrstvách. Původní model přijímal kratší úseky signálu. Zvýšením počtu neuronů byl tento fakt kompenzován.

Architektura obsahuje 3 dvojice konvolučních a max-pooling vrstev. Konvoluční vrstvy jsou poskládány za sebou s rostoucím počtem filtrů a snižující se velikostí jádra. Oproti dalším dvěma použitým modelům využívá různou velikost kroku, tzn. okénko filtru konvoluční vrstvy se posouvá po více než jedné hodnotě. Data z konvolučních vrstev jsou přeskládána do vektoru a předána plně propojeným vrstvám. Struktura celé neuronové sítě je popsána v tabulce B.2.

5.3 Model 3

Třetí architektura byla inspirována modelem použitým k detekci srdeční arytmie[10]. Skládá se ze 7 konvolučních vrstev se 128 filtry a velikostí filtru 5. Každá konvoluční vrstva je následována max-pooling vrstvou. Po konvoluční části následují 4 plně propojené vrstvy, jejichž úkolem je klasifikace příznaků, které jim předala konvoluční část sítě. Architektura třetí použité neuronové sítě je popsána v tabulce B.3.

Tato architektura je ze všech nejsložitější, což má za následek její nejvyšší výpočetní náročnost. Byla pro identifikaci kognitivní zátěže nejuspěšnější.

Implementace

Tato kapitola je věnována implementaci aplikace pro real-time analýzu EKG signálů pomocí umělé inteligence. Popsány jsou použité technologie, rozdělení kódu do funkčních celků a prostředí použité k učení a evaluaci neuronových sítí.

6.1 Programovací jazyk

Programovacím jazykem, ve kterém byla aplikace implementována je Python. Python je vysokoúrovňový skriptovací jazyk. Vyznačuje se jednoduchostí syntaxe a podporou různých programovacích paradigmat, včetně objektově orientovaného, procedurálního a v omezené míře funkcionálního. Je interpretovaným programovacím jazykem, což má za následek jeho nižší výkonnost oproti jiným kompilovaným jazykům.

Python je vhodný pro strojové učení, neboť pro tento účel poskytuje mnoho knihoven. Kromě knihoven pro samotné strojové učení poskytuje i nástroje pro analýzu, vizualizaci a práci s daty, které jsou nedílnou součástí strojového učení.

6.2 Použité knihovny

6.2.1 Keras a Tensorflow

Keras[26] je open-source knihovnou poskytující rozhraní pro tvorbu umělých neuronových sítí. Umožňuje navrhnout a natrénovat neuronovou síť, bez potřeby explicitního naprogramování jejich částí. Knihovna poskytuje stavební bloky modelu, které lze snadno aplikovat. Keras funguje jako vysokoúrovňové rozhraní pro práci s knihovnou TensorFlow[27].

6.2.2 NeuroKit2

NeuroKit2[28] je knihovnou, umožňující zpracování biologických signálů. Poskytuje rozhraní pro jejich analýzu a předzpracování. Obsahuje i algoritmy sloužící k detekci QRS komplexu. V této práci byla použita k filtraci EKG signálu a otestování detekce QRS komplexu.

6.2.3 Scikit-learn

Scikit-learn[29] je knihovnou implementující mnoho algoritmů strojového učení. Kromě samotných algoritmů také poskytuje funkcionalitu pro statistické vyhodnocení úspěšnosti modelů a předzpracování dat. V této práci byla použita na předzpracování dat a evaluaci trénovaných modelů.

6.3 Členění kódu

Kód je členěn do několika logických celků. Každý logický celek tvoří jeden balíček.

6.3.1 Předzpracování dat

Balíček `data_prep` je zodpovědný za načítání a předzpracování dat. Obsahuje moduly `wesad_data_prep` a `clas_data_prep`, které se starají o načítání a předzpracování jednotlivých sad dat. Součástí balíčku je modul nazvaný `ecg_preprocessing`, jehož úkolem je převzorkování, filtrace a další předzpracování EKG signálu.

6.3.2 Učení a evaluace neuronových sítí

Balíček `neural_network` obsahuje definice jednotlivých modelů a slouží k jejich natrénování. Součástí balíčku je modul `evaluation`, který poskytuje rozhraní pro výpočet metrik popsaných v části 3.

6.3.3 Analýza EKG v reálném čase

Balíček `real_time_analysis` slouží k samotné analýze elektrokardiografického signálu v reálném čase. Zprostředkovává simulaci analýzy načtením signálu ze souboru. Umožňuje vizualizaci signálu, ze kterého neuronová síť predikuje.

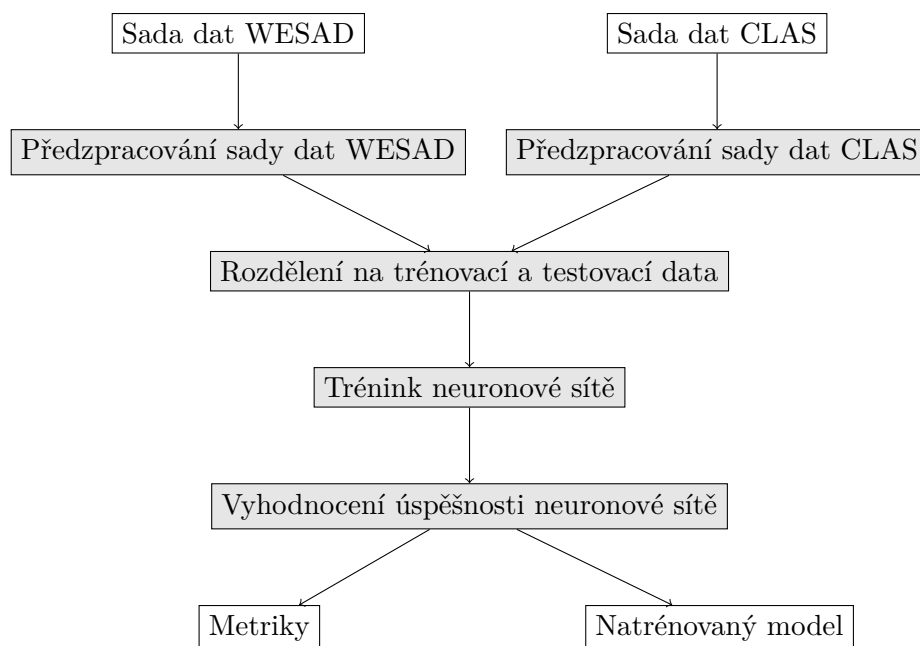
6.3.4 Utilitární funkce

Balíček `util` poskytuje utilitární funkce. Poskytuje funkcionalitu nutnou pro vytváření složek a souborů a manipulaci s datovými strukturami.

6.4 Učení neuronových sítí

Pro potřeby učení modelů byla zvolena platforma Microsoft Azure. Jedná se o cloudovou platformu společnosti Microsoft, která umožňuje používání virtuálních strojů. Modely byly učeny na virtuálním stroji velikosti Standard B4ms se čtyřmi virtuálními procesory, pamětí 16 GB a operačním systémem Ubuntu 18.04.

Proces učení neuronových sítí zahrnuje předzpracování dat, jejich rozdělení na trénovací a testovací část, samotný trénink neuronové sítě a vyhodnocení její úspěšnosti. Celý tento proces popisuje následující diagram:



Obrázek 6.1: Učení neuronových sítí

Po natréování jsou modely uloženy a mohou být použity k samotné analýze EKG v reálném čase.

6.5 Analýza EKG v reálném čase

V rámci práce bylo navrženo řešení, které umožňuje analyzovat elektrokardiografický signál za účelem detekce zvýšené kognitivní zátěže. Součástí výsledné aplikace je i výpočet několika HRV parametrů a jejich evaluace.

Navržené řešení simulace analýzy v reálném čase a využitý návrhový vzor jsou popsány v následující části.

6.5.1 Producent a spotřebitel

Problém producenta a spotřebitele je jedním z klasických problémů a návrhových vzorů, které se objevují při programování souběžných procesů. Problematika spočívá v nutnosti paralelního běhu produkce dat a jejich zpracování. Producent produkuje data a vkládá je do zásobníku omezené velikosti. Spotřebitel je ze zásobníku odebírá a následně zpracovává.

V případě simulace analýzy elektrokardiografických signálů v reálném čase je možné využít vzor producenta a spotřebitele. Úkolem producenta je simulovat snímání elektrokardiografického signálu. Úkolem spotřebitele je jeho zpracování a následná identifikace kognitivní zátěže.

6.5.2 Implementace návrhového vzoru

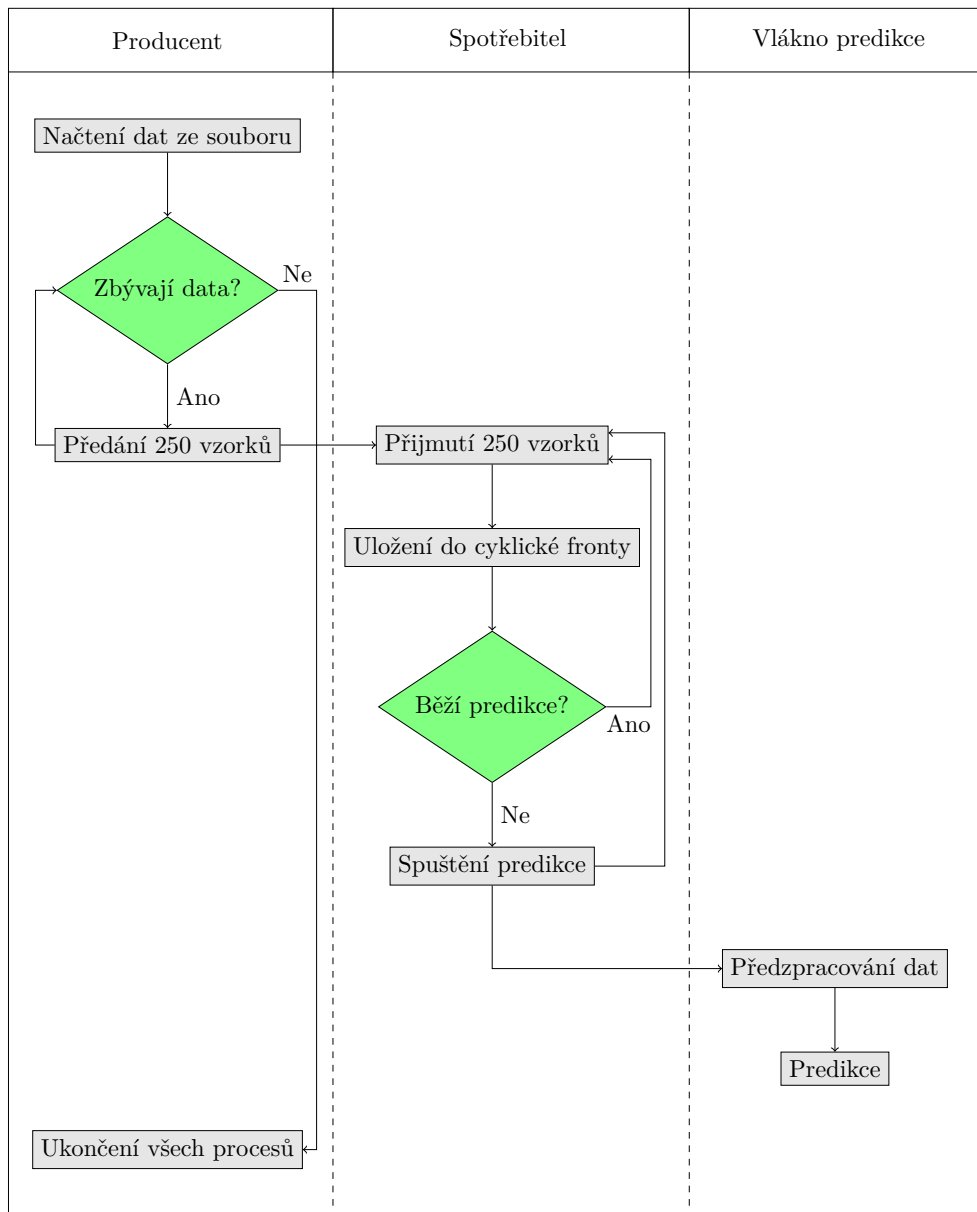
K implementaci návrhového vzoru producent a spotřebitel byla použita knihovna Multiprocessing. Tato knihovna je součástí standardní knihovny[30] programovacího jazyka Python. Multiprocessing umožňuje jednoduchou implementaci návrhového vzoru producent a spotřebitel, neboť poskytuje vysokoúrovňové rozhraní pro práci s paralelně běžícími procesy.

Proces starající se o simulaci senzoru načte záznam EKG signálu ze souboru a v půlvtěřinových intervalech ho po 250 vzorcích předává spotřebitelskému procesu. Tímto je dosaženo simulace senzoru snímajícího signál se vzorkovací frekvencí 500 Hz.

Spotřebitelský proces ukládá posledních 15000 hodnot EKG signálu a spouští vlákno, které se stará o zpracování signálu, výpočet HRV parametrů a samotnou predikci pomocí natrénované neuronové sítě, zda se jedná o zvýšenou kognitivní zátěž, či ne. Predikce spolu se zpracováním signálu a výpočtem HRV parametrů probíhá na jiném vlákne než přijímání, aby nedocházelo k blokadě přijímání dat.

Spotřebitelský proces využívá pro ukládání částí signálu cyklickou frontu. Cyklická fronta je datová struktura omezené velikosti. Její podstatou je zacyklené pole, ve kterém po posledním prvku znovu následuje první. Po zápisu na poslední prvek se zapisuje opět do prvního. Tato datová struktura je pro potřeby spotřebitelského procesu vhodná, neboť je nutné uchovávat pouze poslední nejaktuálnější záznamy, ze kterých může neuronová síť predikovat kognitivní zátěž.

Komunikaci mezi jednotlivými procesy a spouštění vlákna sloužícího pro předzpracování signálu a predikci znázorňuje diagram 6.2.



Obrázek 6.2: Simulace analýzy v reálném čase

6.5.3 HRV parametry

Spotřebitelský proces kromě predikce pomocí neuronové sítě poskytuje i predikce založené na HRV parametrech. Vypočítává několik HRV parametrů z předzpracovaného signálu a každý z nich následně klasifikuje. Těmito parametry jsou tepová frekvence, průměrná délka RR intervalu a RMSSD, což je

druhá odmocnina průměru druhých mocnin průměrných hodnot délek po sobě následujících RR intervalů. RR interval je vzdálenost dvou po sobě jdoucích R kmitů. Výpočet jednotlivých parametrů popisují následující rovnice:

$$HR = \frac{60}{l} \cdot m \quad (6.1)$$

$$\overline{RR} = \frac{1}{n} \sum_{i=1}^n RR_i \quad (6.2)$$

$$RMSSD = \sqrt{\frac{1}{n-1} \sum_{i=1}^{n-1} (RR_{i+1} - RR_i)^2} \quad (6.3)$$

HR je tepová frekvence, \overline{RR} je průměrná délka RR intervalu, l je délka segmentu ve vteřinách, m je celkový počet R kmitů v segmentu, n je počet RR intervalů v segmentu, RR_i je i -tý interval v segmentu. Tepová frekvence je vyjadřována v tepech za minutu. Průměrná délka RR intervalu a RMSSD jsou vyjadřovány ve vteřinách.

Klasifikace probíhá pro každý HRV parametr zvlášť, takže celkem poskytuje tři různé predikce. Je založena na jednoduchém algoritmu, který na základě předem nastavených prahových hodnot vyhodnotí úroveň kognitivní zátěže. Jako prahové hodnoty byly použity výsledky měření provedeného při práci *Ultra Short Term Analysis of Heart Rate Variability for Monitoring Mental Stress in Mobile Settings*[31].

6.6 Detekce QRS komplexu

Detekce QRS komplexu byla implementována pomocí knihovny NeuroKit2. Bylo testováno, jaký na ní mají vliv různé metody předzpracování signálu. Vstupními daty algoritmu detekce QRS komplexu byly záznamy EKG ze sady dat WESAD. Bylo experimentováno s několika metodami předzpracování:

- Nepředzpracovaný signál
- Butterworthův filtr pátého řádu s horní propustí 1 Hz
- Butterworthův filtr pátého řádu s horní propustí 1 Hz a klouzavý průměr se šířkou okna 50 Hz


Výsledky detekce byly zhodnoceny vizuální analýzou grafického znázornění detekovaných komplexů a signálu.

Výsledky


Následující část práce je věnována výsledkům předzpracování EKG signálu, úspěšnosti, s jakou byly navržené architektury schopné identifikovat kognitivní zátěž a úspěšnosti detekce QRS komplexu na předzpracovaném signálu. Modely byly evaluovány pomocí metrik popsanych v kapitole 3.

7.1 Předzpracování

Předzpracování elektrokardiografického signálu pro účely učení a evaluace neuronových sítí bylo provedeno Butterworthovým filtrem pátého řádu s horní propustí 1 Hz. Aplikace filtru umožnila odstranění kolísající izoliniie. Obrázek 7.1 zobrazuje nepředzpracovanou část signálu ze sady dat WESAD s kolísající izolinií. Obrázek 7.2 zobrazuje stejnou část signálu po aplikaci filtru. Pomocí filtru bylo kolísání izoliniie minimalizováno, což zvýšilo úspěšnost neuronových sítí.



Obrázek 7.1: EKG s kolísající izolinií




Obrázek 7.2: EKG po aplikaci Butterworthova filtru


7.2 Detekce QRS komplexu

Detekce QRS byla otestována na nepředzpracovaném signálu, signálu po aplikaci Butterworthova filtru a signálu po aplikaci Butterworthova filtru a klouzavého průměru. Obrázky 7.3, 7.4 a 7.5 zobrazují část signálu ze sady dat


WESAD a detekované QRS kmity. Kmit R byl algoritmus schopen detekovat i bez předzpracování signálu, kmity Q a S však detekoval chybně. Nejlepších výsledků dosahoval algoritmus na signálu předzpracovaném pomocí Butterworthova filtru a klouzavého průměru.



Obrázek 7.3: Výsledek detekce QRS komplexu na nepředzpracovaném signálu



Obrázek 7.4: Výsledek detekce QRS komplexu, Butterworthův filtr



Obrázek 7.5: Výsledek detekce QRS komplexu, Butterworthův filtr, klouzavý průměr

7.3 Výsledky modelů

V rámci práce bylo experimentováno s různou délkou okna elektrokardiografického signálu, ze kterého se modely učily a následně predikovaly, zda se jedná o zvýšenou kognitivní zátěž. Dále bylo testováno, zda modely dokáží správně predikovat výsledky ze signálu, bez jeho předzpracování.

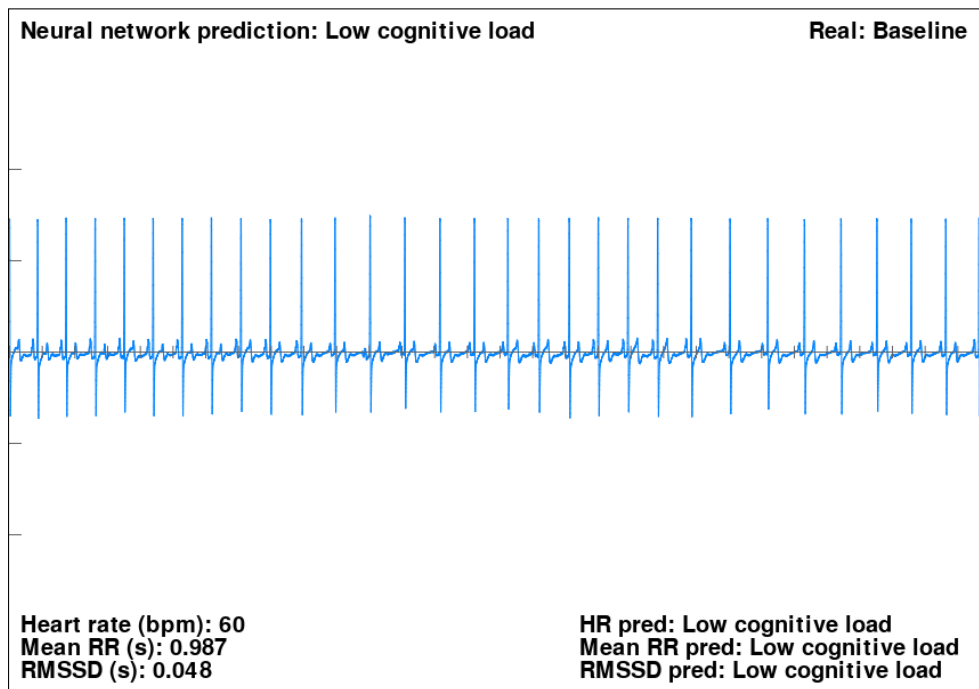
Výsledky jednotlivých modelů pro různé délky oken a metod předzpracování signálu popisují tabulky v příloze C. Třetí navržená architektura pro okna délky 1, 5 a 10 vteřin nemohla být použita. Hloubka konvoluční části způsobila, že se klasifikátoru nedostávalo dost hodnot pro provedení predikce.

Nejlépeších výsledků dosahovaly modely na předzpracovaném signálu s délkou okna 30 vteřin. Třicetivteřinová okna poskytují dostatek informací, ze kterých mohou být extrahovány relevantní příznaky a identifikována zvýšená kognitivní zátěž. Při kratší délce oken dosahovaly modely nižší úspěšnosti. Předzpracování signálu pomocí Butterworthova filtru a jeho následná standardizace směrodatnou odchylku měli na jejich výsledky pozitivní vliv.

Cílem experimentace s různými délkami oken bylo nalezení nejkratšího úseku, ze kterého jsou konvoluční neuronové sítě schopny úspěšně detekovat kognitivní zátěž. Kratší délka okna je vhodná pro analýzu signálu v reálném čase. Modelům stačí kratší úsek měřeného signálu k predikci, tedy mohou začít predikovat dříve, než kdyby bylo okno delší.

7.4 Analýza EKG v reálném čase

Vytvořená aplikace demonstruje analýzu elektrokardiografických signálů v reálném čase za účelem detekce zvýšené kognitivní zátěže. Předučené konvoluční neuronové sítě jsou schopné detekovat zvýšenou kognitivní zátěž s úspěšností popsanou v části 7.3. Rychlost, s jakou je navržené řešení schopné předzpracovat signál a následně detekovat zvýšenou kognitivní zátěž je dostatečná pro jeho použití k analýze v reálném čase.



Obrázek 7.6: Vytvořená aplikace

Aplikace zobrazuje přijímaný signál. Vertikální osa udává hodnotu v mV a horizontální ve vteřinách. Značky na vertikální ose jsou od sebe vzdáleny 1 mV a na horizontální ose 1 s. V levém horním rohu je predikce neuronové sítě pro zobrazovaný úsek. V pravém horním rohu je část experimentu, ve které byl úsek naměřen. V levém dolním rohu jsou hodnoty jednotlivých parametrů a v pravém z nich učiněné predikce na základě stanovených prahových hodnot.

Pro analýzu EKG v reálném čase je používána třetí navržená architektura. Model byl natrénován na předzpracovaném signálu s délkou okna 30 vteřin. Tato kombinace byla zvolena na základě experimentů. V porovnání s ostatními otestovanými možnostmi dosahovala nejlepších výsledků.

Diskuze

V rámci této práce byly otestovány tři různé architektury konvolučních neuronových sítí pro identifikaci kognitivní zátěže ze záznamů elektrokardiografických signálů. Detekce kognitivní zátěže byla dohromady testována na 77 lidech. Byla vytvořena aplikace demonstrující jejich použití při analýze signálu v reálném čase.

Natrénované modely byly schopny identifikovat zvýšenou kognitivní zátěž s přesností až 93 %. Na jejich úspěšnost měla výrazný vliv délka okna signálu, které jim bylo poskytnuto a jeho předzpracování. Na nepředzpracovaném signálu dosahovaly značně nižší úspěšnosti.

Metody použité k předzpracování elektrokardiografického signálu byly zvoleny na základě rešerše. Byly upřednostňovány metody používané v klinické praxi. Aplikace jiných metod předzpracování elektrokardiografického signálu by mohla pozitivně ovlivnit výsledky neuronových sítí.

Užití konvolučních neuronových sítí umožňuje značně snížit předzpracování signálu oproti jiným metodám strojového učení. Zejména extrakci příznaků ze signálu dokáží konvoluční neuronové sítě automatizovat bez potřeby jejího explicitního naprogramování. Nevýhodou užití neuronových sítí je časová a výpočetní náročnost jejich učení.

Jednotlivé architektury byly otestovány na předzpracovaném a nepředzpracovaném signálu. Největší úspěšnosti dosahovaly, když jim bylo poskytnuto 30 vteřin předzpracovaného záznamu elektrokardiografického signálu. V této práci bylo experimentováno s délkami oken 1, 5, 10, 20 a 30 vteřin. Další experimentace s délkou okna by mohla prokázat, že stačí kratší úseky, než 30 vteřin.

Modely byly učeny na záznamech elektrokardiografického signálu 77 lidí. Trénink a testování na tomto vzorku dokázali, že jsou konvoluční neuronové sítě schopné identifikovat kognitivní zátěž. Robustnost klasifikátoru je možné zvýšit jeho tréninkem na větším vzorku.

Vytvořená aplikace demonstruje analýzu elektrokardiografického signálu v reálném čase. Analýza probíhá na signálu načteném ze souboru. Dalším kro-

8. DISKUZE

kem pro otestování by mohlo být propojení aplikace s opravdovým senzorem snímajícím signál v reálném čase.

Detekce QRS komplexu byla neúspěšnější na signálu, ze kterého bylo odstraněno kolísání izolinie a vysokofrekvenční ruch. Kmity R byl algoritmus s nižší úspěšností schopen predikovat i na nepředzpracovaném signálu. Kmity Q a S byl algoritmus schopný spolehlivě detekovat pouze na předzpracovaném signálu.

Závěr

V rámci této práce byly otestovány tři různé architektury konvolučních neuronových sítí pro identifikaci kognitivní zátěže ze záznamů elektrokardiografických signálů. Detekce kognitivní zátěže byla dohromady testována na 77 lidech. Konvoluční neuronové sítě byly schopné na použitých datech identifikovat zvýšenou kognitivní zátěž s přesností až 93 %.

Vstupem konvolučních neuronových sítí byl předzpracovaný elektrokardiografický signál. Metody předzpracování byly voleny na základě provedené rešerše. Upřednostňovány byly metody používané v klinické praxi.

Na předzpracovaném signálu byla otestována detekce QRS komplexu. Metody navržené pro předzpracování umožnily minimalizovat kolísání izolinie signálu a zvýšily úspěšnost neuronových sítí a detekce QRS komplexu.

Byla vytvořena aplikace demonstrující použití konvolučních neuronových sítí při analýze elektrokardiografického signálu v reálném čase. Aplikace umožňuje simulaci snímání signálu, vizualizaci, výpočet HRV parametrů a detekci kognitivní zátěže v reálném čase.

Literatura

- [1] Wikimedia Commons: Schematic diagram of normal sinus rhythm for a human heart as seen on ECG (with Czech labels). 2009. Dostupné z: <https://commons.wikimedia.org/wiki/File:ECG-P%2BQRSkomplex%2BT.svg>
- [2] Agrafioti, F.; Hatzinakos, D.; Anderson, A. K.: ECG Pattern Analysis for Emotion Detection. *IEEE Transactions on Affective Computing*, ročník 3, č. 1, 2012: s. 102–115, doi:10.1109/T-AFFC.2011.28.
- [3] Caroline Chanel, P. C.; Wilson, M. D.; Scannella, S.: Online ECG-based Features for Cognitive Load Assessment. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 2019, s. 3710–3717, doi:10.1109/SMC.2019.8914002.
- [4] Lampert, R.: ECG signatures of psychological stress. *Journal of Electrocardiology*, ročník 48, č. 6, 2015: s. 1000–1005, ISSN 0022-0736, doi: <https://doi.org/10.1016/j.jelectrocard.2015.08.005>. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0022073615002277>
- [5] Haapalainen, E.; Kim, S.; Forlizzi, J. F.; aj.: Psycho-Physiological Measures for Assessing Cognitive Load. In *Proceedings of the 12th ACM International Conference on Ubiquitous Computing*, UbiComp '10, New York, NY, USA: Association for Computing Machinery, 2010, ISBN 9781605588438, str. 301–310, doi:10.1145/1864349.1864395. Dostupné z: <https://doi.org/10.1145/1864349.1864395>
- [6] McCulloch, W. S.; Pitts, W.: A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, ročník 5, č. 4, Dec 1943: s. 115–133, ISSN 1522-9602, doi:10.1007/BF02478259. Dostupné z: <https://doi.org/10.1007/BF02478259>
- [7] Hubel, D. H.; Wiesel, T. N.: Receptive fields of single neuro-nes in the cat's striate cortex. *The Journal of physiology*, ročník

- 148, č. 3, Oct 1959: s. 574–591, ISSN 0022-3751, doi:10.1113/jphysiol.1959.sp006308, 14403679[pmid]. Dostupné z: <https://doi.org/10.1113/jphysiol.1959.sp006308>
- [8] Fukushima, K.: Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural Networks*, ročník 1, č. 2, 1988: s. 119–130, ISSN 0893-6080, doi:[https://doi.org/10.1016/0893-6080\(88\)90014-7](https://doi.org/10.1016/0893-6080(88)90014-7). Dostupné z: <https://www.sciencedirect.com/science/article/pii/0893608088900147>
- [9] Lecun, Y.; Bottou, L.; Bengio, Y.; aj.: Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, ročník 86, č. 11, 1998: s. 2278–2324, doi:10.1109/5.726791.
- [10] Boris Pyakillya, N. M., Natasha Kazachenko: Deep Learning for ECG Classification. *Journal of Physics: Conference Series*, ročník 913, 2017: s. 1–5, doi:10.1088/1742-6596/913/1/012004. Dostupné z: <http://iopscience.iop.org/article/10.1088/1742-6596/913/1/012004/pdf>
- [11] Hsu, Y.-L.; Wang, J.-S.; Chiang, W.-C.; aj.: Automatic ECG-Based Emotion Recognition in Music Listening. *IEEE Transactions on Affective Computing*, ročník 11, č. 1, 2020: s. 85–99, doi:10.1109/TAFFC.2017.2781732.
- [12] Shao, M.; Bin, G.; Wu, S.; aj.: Detection of atrial fibrillation from ECG recordings using decision tree ensemble with multi-level features. *Physiological Measurement*, ročník 39, č. 9, sep 2018: str. 094008, doi:10.1088/1361-6579/aadf48. Dostupné z: <https://doi.org/10.1088/1361-6579/aadf48>
- [13] Keshan, N.; Parimi, P. V.; Bichindaritz, I.: Machine learning for stress detection from ECG signals in automobile drivers. In *2015 IEEE International Conference on Big Data (Big Data)*, 2015, s. 2661–2669, doi:10.1109/BigData.2015.7364066.
- [14] He, J.; Li, K.; Liao, X.; aj.: Real-Time Detection of Acute Cognitive Stress Using a Convolutional Neural Network From Electrocardiographic Signal. *IEEE Access*, ročník 7, 2019: s. 42710–42717, doi:10.1109/ACCESS.2019.2907076.
- [15] Li, R.; Liu, Z.: Stress detection using deep neural networks. *BMC Medical Informatics and Decision Making*, ročník 20, č. 11, Dec 2020: str. 285, ISSN 1472-6947, doi:10.1186/s12911-020-01299-4. Dostupné z: <https://doi.org/10.1186/s12911-020-01299-4>

-
- [16] Zhang, L.; Peng, H.; Yu, C.: An approach for ECG classification based on wavelet feature extraction and decision tree. In *2010 International Conference on Wireless Communications Signal Processing (WCSP)*, 2010, s. 1–4, doi:10.1109/WCSP.2010.5633782.
- [17] Schmidt, P.; Reiss, A.; Duerichen, R.; aj.: Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection. In *Proceedings of the 20th ACM International Conference on Multimodal Interaction, ICMI '18*, New York, NY, USA: Association for Computing Machinery, 2018, ISBN 9781450356923, str. 400–408, doi:10.1145/3242969.3242985. Dostupné z: <https://doi.org/10.1145/3242969.3242985>
- [18] PLUX wireless biosignals, S.A.: *RespiBAN Professional*. Dostupné z: <https://biosignalsplux.com/products/wearables/respiban-pro.html>
- [19] Empatica Inc.: *E4 wristband*. Dostupné z: <https://www.empatica.com/en-int/research/e4/>
- [20] Markova, V.; Ganchev, T.; Kalinkov, K.: CLAS: A Database for Cognitive Load, Affect and Stress Recognition. In *2019 International Conference on Biomedical Innovations and Applications (BIA)*, 2019, s. 1–4, doi:10.1109/BIA48344.2019.8967457.
- [21] Jensen, A. R.: Scoring the Stroop test. *Acta psychologica*, ročník 24, č. 5, 1965: s. 398–408. Dostupné z: <https://arthurjensen.net/wp-content/uploads/2014/06/Scoring-the-Stroop-Test-1965-by-Arthur-Robert-Jensen.pdf>
- [22] Shimmer: *Shimmer3 GSR+ Unit*. Dostupné z: <https://www.shimmersensing.com/products/shimmer3-wireless-gsr-sensor>
- [23] Nayak, S.; Soni, M.; Bansal, D.; aj.: Filtering techniques for ECG signal processing. *International Journal of Research in Engineering & Applied Sciences*, ročník 2, č. 2, 2012: s. 671–679. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.470.1205&rep=rep1&type=pdf>
- [24] Butterworth, S.; aj.: On the theory of filter amplifiers. *Wireless Engineer*, ročník 7, č. 6, 1930: s. 536–541. Dostupné z: https://www.changpuak.ch/electronics/downloads/On_the_Theory_of_Filter_Amplifiers.pdf
- [25] Pandey, V.; Giri, V. K.: High frequency noise removal from ECG using moving average filters. In *2016 International Conference on Emerging Trends in Electrical Electronics Sustainable Energy Systems (ICETEESES)*, 2016, s. 191–195, doi:10.1109/ICETEESES.2016.7581383.

- [26] Chollet, F.; aj.: Keras. <https://keras.io>, 2015.
- [27] Abadi, M.; Agarwal, A.; Barham, P.; aj.: TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems. 2015, software available from [tensorflow.org](https://www.tensorflow.org). Dostupné z: <https://www.tensorflow.org/>
- [28] Makowski, D.; Pham, T.; Lau, Z. J.; aj.: NeuroKit2: A Python toolbox for neurophysiological signal processing. *Behavior Research Methods*, Feb 2021, ISSN 1554-3528, doi:10.3758/s13428-020-01516-y. Dostupné z: <https://doi.org/10.3758/s13428-020-01516-y>
- [29] Pedregosa, F.; Varoquaux, G.; Gramfort, A.; aj.: Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, ročník 12, 2011: s. 2825–2830.
- [30] Van Rossum, G.: *The Python Library Reference, release 3.8.2*. Python Software Foundation, 2020.
- [31] Salahuddin, L.; Cho, J.; Jeong, M. G.; aj.: Ultra Short Term Analysis of Heart Rate Variability for Monitoring Mental Stress in Mobile Settings. In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2007, s. 4656–4659, doi: 10.1109/IEMBS.2007.4353378.

Seznam použitých zkratk

CLAS A Database for Cognitive Load, Affect and Stress Recognition

CNN Convolutional Neural Network

EKG Elektrokardiografie, Elektrokardiogram

HRV Heart rate variability

WESAD A Multi-modal Dataset for Wearable Stress and Affect Detection

Architektury neuronových sítí

Uvedené rozměry výstupu jsou pro velikost okna 30 vteřin.

Název vrstvy	Počet filtrů	Velikost jádra	Rozměr výstupu	Aktivační funkce
Conv1D	64	3	14998×64	ReLU
Conv1D	64	3	14996×64	ReLU
Dropout			14996×64	
MaxPooling1D		2	7498×64	
Flatten			479872×1	
Dense			100×1	ReLU
Dense			1×1	Sigmoid

Tabulka B.1: Architektura prvního použitého modelu

Název vrstvy	Počet filtrů	Velikost jádra	Krok	Rozměr výstupu	Aktivační funkce
Conv1D	8	32	2	7485×8	ReLU
MaxPooling1D		4	4	1871×8	
Conv1D	16	7	2	933×16	ReLU
MaxPooling1D		4	4	233×16	
Conv1D	32	3	1	231×32	ReLU
MaxPooling1D		2	2	115×32	ReLU
Dropout				115×32	
Flatten				3680×1	
Dense				100×1	ReLU
Dense				1×1	Sigmoid

Tabulka B.2: Architektura druhého použitého modelu

B. ARCHITEKTURY NEURONOVÝCH SÍTÍ

Název vrstvy	Počet filtrů	Velikost jádra	Rozměr výstupu	Aktivační funkce
Conv1D	128	5	14996×128	ReLU
MaxPooling1D		3	4998×128	
Dropout			4998×128	
Conv1D	128	5	4994×128	ReLU
MaxPooling1D		3	1664×128	
Dropout			1664×128	
Conv1D	128	5	1660×128	ReLU
MaxPooling1D		3	553×128	
Dropout			553×128	
Conv1D	128	5	549×128	ReLU
MaxPooling1D		3	183×128	
Dropout			183×128	
Conv1D	128	5	179×128	ReLU
MaxPooling1D		3	59×128	
Dropout			59×128	
Conv1D	128	5	55×128	ReLU
MaxPooling1D		3	18×128	
Dropout			18×128	
Conv1D	128	5	14×128	ReLU
GlobalAveragePooling1D			128×1	
Dense			256×1	ReLU
Dropout			256×1	
Dense			128×1	ReLU
Dropout			128×1	
Dense			64×1	ReLU
Dropout			64×1	
Dense			1×1	Sigmoid

Tabulka B.3: Architektura třetího použitého modelu

Výsledky modelů

Model	Matice záměn	Přesnost (%)	Senzitivita (%)	Specificita (%)	Preciznost (%)	F1 (%)				
1. model	<table border="1"> <tr><td>10365</td><td>2343</td></tr> <tr><td>2723</td><td>9101</td></tr> </table>	10365	2343	2723	9101	79	79	80	82	80
10365	2343									
2723	9101									
2. model	<table border="1"> <tr><td>11132</td><td>2697</td></tr> <tr><td>1956</td><td>8747</td></tr> </table>	11132	2697	1956	8747	81	85	76	80	83
11132	2697									
1956	8747									

Tabulka C.1: Výsledky trénovaných modelů s oknem 1 vteřina a předzpracovaným signálem

Model	Matice záměn	Přesnost (%)	Senzitivita (%)	Specificita (%)	Preciznost (%)	F1 (%)				
1. model	<table border="1"> <tr><td>2093</td><td>556</td></tr> <tr><td>462</td><td>1757</td></tr> </table>	2093	556	462	1757	79	82	76	79	80
2093	556									
462	1757									
2. model	<table border="1"> <tr><td>2080</td><td>621</td></tr> <tr><td>475</td><td>1692</td></tr> </table>	2080	621	475	1692	77	81	73	77	79
2080	621									
475	1692									

Tabulka C.2: Výsledky trénovaných modelů s oknem 5 vteřin a předzpracovaným signálem

C. VÝSLEDKY MODELŮ

Model	Matice záměn	Přesnost (%)	Senzitivita (%)	Specificita (%)	Preciznost (%)	F1 (%)
1. model	$\begin{vmatrix} 1037 & 257 \\ 275 & 839 \end{vmatrix}$	78	79	77	80	80
2. model	$\begin{vmatrix} 1024 & 378 \\ 288 & 718 \end{vmatrix}$	72	78	66	73	75

Tabulka C.3: Výsledky trénovaných modelů s oknem 10 vteřin a předzpracovaným signálem

Model	Matice záměn	Přesnost (%)	Senzitivita (%)	Specificita (%)	Preciznost (%)	F1 (%)
1. model	$\begin{vmatrix} 483 & 165 \\ 179 & 297 \end{vmatrix}$	69	73	64	75	74
2. model	$\begin{vmatrix} 553 & 171 \\ 109 & 291 \end{vmatrix}$	75	84	63	76	80
3. model	$\begin{vmatrix} 642 & 194 \\ 20 & 268 \end{vmatrix}$	81	97	58	77	86

Tabulka C.4: Výsledky trénovaných modelů s oknem 20 vteřin a předzpracovaným signálem

Model	Matice záměn	Přesnost (%)	Senzitivita (%)	Specificita (%)	Preciznost (%)	F1 (%)
1. model	$\begin{vmatrix} 357 & 65 \\ 57 & 150 \end{vmatrix}$	81	86	70	85	85
2. model	$\begin{vmatrix} 378 & 39 \\ 36 & 176 \end{vmatrix}$	88	91	82	91	91
3. model	$\begin{vmatrix} 404 & 34 \\ 10 & 181 \end{vmatrix}$	93	98	84	92	95

Tabulka C.5: Výsledky trénovaných modelů s oknem 30 vteřin a předzpracovaným signálem

Model	Matice záměn	Přesnost (%)	Senzitivita (%)	Specificita (%)	Preciznost (%)	F1 (%)
1. model	$\begin{vmatrix} 370 & 45 \\ 44 & 170 \end{vmatrix}$	86	89	79	89	89
2. model	$\begin{vmatrix} 358 & 40 \\ 56 & 175 \end{vmatrix}$	85	86	81	90	88
3. model	$\begin{vmatrix} 315 & 34 \\ 99 & 181 \end{vmatrix}$	79	76	84	90	83

Tabulka C.6: Výsledky trénovaných modelů s oknem 30 vteřin a nepředzpracovaným signálem

Spuštění aplikace, Obsah přiloženého média

Aplikace je spouštěna pomocí programu `make`. Ke spuštění jednotlivých částí aplikace slouží následující příkazy:

- `make help` – Zobrazení nápovědy
- `make realtime` – Simulace analýzy signálu v reálném čase
- `make realtime` – Simulace analýzy signálu v reálném čase na jiném vzorku
- `make eval` – Evaluace předtrénovaného modelu použitého k real-time analýze
- `make eval MODEL=[cesta_k_modelu] WINDOW_LEN=[délka_okna] PRE-PROCESS=[TRUE/FALSE]` – Evaluace modelu uloženého v `cesta_k_modelu`, natrénovaného s délkou okna `délka_okna`, na předzpracovaném/nepředzpracovaném signálu
- `make qrs` – Vizualizace detekce QRS komplexu
- `make train1` – Trénink a evaluace neuronových sítí s oknem 1 s a předzpracovaným signálem
- `make train5` – Trénink a evaluace neuronových sítí s oknem 5 s a předzpracovaným signálem
- `make train10` – Trénink a evaluace neuronových sítí s oknem 10 s a předzpracovaným signálem
- `make train20` – Trénink a evaluace neuronových sítí s oknem 20 s a předzpracovaným signálem

D. SPUŠTĚNÍ APLIKACE, OBSAH PŘILOŽENÉHO MÉDIA

- `make train30` – Trénink a evaluace neuronových sítí s oknem 30 s a předzpracovaným signálem
- `make train30un` – Trénink a evaluace neuronových sítí s oknem 30 s a nepředzpracovaným signálem
- `make path` – Nastavení adresářů sad dat WESAD a CLAS

Při spouštění příkazů `make train` jsou natrénované modely a evaluační metriky ukládány do adresáře `src/out/train_out/`. Při spuštění příkazu `make eval` jsou metriky uloženy do souboru `src/out/results.csv`. Příkazy pro trénink a evaluaci vyžadují sady dat WESAD a CLAS. Cesty k sadám dat mohou být nastaveny v souboru `config.ini` nebo příkazem:

```
make path WESAD=[adresář_WESAD] CLAS=[adresář_CLAS]
```

Obsah příloženého média je následující:

```
| readme.txt ..... stručný popis obsahu média a spuštění aplikace  
| src ..... zdrojové kódy implementace  
| thesis.pdf ..... text bakalářské práce ve formátu PDF
```