

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2022

Bc. Jakub Vraný



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

IDENTIFIKACE PROJEVŮ RESPONZIVNÍ SLOŽKY ELEKTRODERMÁLNÍ AKTIVITY

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE Bc. Jakub Vraný
AUTHOR

VEDOUCÍ PRÁCE doc. Ing. Jana Kolářová, Ph.D.
SUPERVISOR

BRNO 2022



Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

Student: Bc. Jakub Vraný

ID: 192484

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Identifikace projevů responzivní složky elektrodermální aktivity

POKYNY PRO VYPRACOVÁNÍ:

- 1) Proveďte literární rešerši metod pro identifikaci projevů responzivní složky v záznamech elektrodermální aktivity.
- 2) Anotujte přítomnost projevů responzivní složky v záznamech elektrodermální aktivity z databáze UBMI.
- 3) Navrhněte a realizujte metodu pro identifikaci těchto projevů, využívající hlubokého učení.
- 4) Navrženou metodou identifikujte projevy responzivní složky v záznamech elektrodermální aktivity získaných během klidového stavu i během stavu mentální zátěže.
- 5) Statisticky zpracujte výsledky a interpretujte jejich význam.
- 6) Vyhodnoťte limity navržené metody a diskutujte je. Pro splnění semestrálního projektu je nutné vypracování alespoň bodů 1) až 3).

DOPORUČENÁ LITERATURA:

- [1] BOUCSEIN, Wolfram. Electrodermal activity. 2nd ed. New York: Springer, 2012. ISBN 978-146-1411-260.
- [2] KIM, Phil. MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence. Berkeley, CA: Apress, 2017. ISBN 978-1-4842-2844-9.

Termín zadání: 7.2.2022

Termín odevzdání: 25.5.2022

Vedoucí práce: doc. Ing. Jana Kolářová, Ph.D.

doc. Ing. Radim Kolář, Ph.D.

předseda rady studijního programu

UPOZORNĚNÍ:

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

Abstrakt

Elektrodermální aktivita je druh elektrochemického signálu generovaným v návaznosti na aktivitu autonomního nervového systému, který stimuluje potní žlázy. Tímto způsobem lze měřit aktivitu sympatické části nervstva a vyhodnotit kognitivní zátěž vyšetřované osoby, která se projevuje responzivními signály v záznamu EDA, resp. jejich vyšší četnosti. Cílem této práce je navrhnout algoritmus hlubokého učení pro identifikaci této složky v záznamu dat vypůjčených z databáze UBMI. Záznamy obsahují sekvenci měření konduktance na pokožce vyšetřovaného v čase, které byl podroben střídavě klidovému stavu a následně stavu mentální zátěže. Data byla anotována dle přítomnosti responzivní složky. Následně byl navržen a implementován vhodný algoritmus hlubokého učení určeného ke klasifikaci responzivních složek v měřeném signálu EDA. Model neuronové sítě byl následně setem anotovaných předzpracovaných dat naučen, optimalizován a implementován na vzorcích měření. Získaná data byla statisticky vyhodnocena z pohledu úspěšnosti klasifikace responzivních složek a rozdílů v záznamech mentálního klidu a zátěže. Výsledky klasifikace a porovnání záznamů EDA měřených při různých stavech dotyčného byly následně diskutovány.

Klíčová slova

Autonomní nervový systém, elektrodermální aktivita, hluboké učení, responzivní složka, spektrální analýza, konvoluční neuronové sítě, klasifikace časové sekvence, učení se supervisorem.

Abstract

Electrodermal activity is a kind of electrochemical signal generated with relation to activity of the autonomic nervous system that stimulates the sweat glands. In this way, is it possible to measure the activity of the sympathetic part of the nerve system and evaluate the cognitive stress of the treated person, which is manifested by responsive signals in EDA record, respectively to increased occurrence of responses. The aim of this work is to design a deep learning algorithm for the identification of this component in the record of data taken from UBMI database. The recordings contain a sequence of measurements the conductance of the skin of patient, who was subjected alternately to the states of rest and subsequently a state of mental stress. The data were annotated according to presence of the responsive components occurring in the records of EDA. Subsequently, a suitable deep learning algorithm was implemented in order to classify the responsive components in the measured EDA signal. The neural network model has been taught, optimized and implemented on the measurement samples using annotated data. The obtained results data were statistically evaluated to qualify the success of the classification of responsive components and differences in the records of mental calm and stress. The results of the classification and comparison of EDA records measured at different conditions of the patient were discussed subsequently.

Keywords

Autonomic nervous system, electrodermal activity, deep learning algorithm, responsive component, spectral analysis, convolution neural networks, time sequence classification, learning with supervisor.

Bibliografická citace

VRANÝ, J. *Identifikace projevů responzivní složky elektrodermální aktivity.* Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2022. 108 s. **Diplomová práce.** Vedoucí práce: doc. Ing. Jan Kolářová, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta:	<i>Bc. Jakub Vraný</i>
VUT ID studenta:	<i>192484</i>
Typ práce:	<i>Diplomová práce</i>
Akademický rok:	<i>2021/22</i>
Téma závěrečné práce:	<i>Identifikace projevů responzivní složky elektrodermální aktivity</i>

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné 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 závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: 6. června 2022

podpis autora

Poděkování

Upřímně chci poděkovat všem blízkým za jejich neúnavnou podporu, zejména své přítelkyni MVDr. Radce Zemánekové, že mi byla při psaní této práce oporou a pomohla mi mj. s korekturou psaného textu. Rovněž chci v rámci pomoci v odborné praktické části věnovat poděkování Dr. Kumaranu Ponnambalamovi, odborníkovi v oblasti datového inženýrství, za jeho pomoc v rámci konzultace výběru a návrhu vhodného typu algoritmu pro daný typ problému. Zároveň bych rád rovněž vyjádřil poděkování Adamovi Geitgeyovi, vývojáři a konzultantovi v oblasti strojového učení, za jeho přínosný příspěvek v rámci konzultace optimalizace navrženého algoritmu. V neposlední řadě bych rád poděkoval své pracovní kolegyni Ing. Kateřině Červinkové za významnou pomoc při praktické části.

V Brně dne: 6. června 2022

podpis autora

Obsah

SEZNAM OBRÁZKŮ	8
ÚVOD	10
1. TEORETICKÁ ČÁST	11
1.1 ELEKTRODERMÁLNÍ AKTIVITA	11
1.2 KOMPONENTY EDA	13
1.2.1 <i>Tonické složky</i>	14
1.2.2 <i>Fázické složky</i>	14
1.3 REŠERŠE – METODY IDENTIFIKACE RESPONZÍ A JEJICH APLIKACE.....	16
1.3.1 <i>SW metody identifikace a jejich aplikace</i>	16
1.3.2 <i>HW metody identifikace a jejich aplikace</i>	28
1.4 ZÁVĚR ANALÝZY.....	29
2. PRAKTICKÁ ČÁST	31
2.1 ZPRACOVÁNÍ DAT A ANOTACE.....	31
2.2 NÁVRH A IMPLEMENTACE ALGORITMU	39
2.2.1 <i>Výběr typu neuronové sítě pro klasifikaci</i>	39
2.3 NÁVRH A REALIZACE NEURONOVÉ SÍTĚ	46
2.3.1 <i>Sestavení sítě</i>	47
2.3.2 <i>Nastavení parametrů a hyperparametrů</i>	48
2.4 NÁVRH PROCESU UČENÍ A OPTIMALIZACE SÍTĚ.....	51
2.4.1 <i>Optimalizace struktury sítě</i>	52
2.4.2 <i>Optimalizace trénovací fáze</i>	56
2.4.3 <i>Evaluace optimalizovaného modelu</i>	58
2.5 VÝSLEDKY A STATISTICKÉ VYHODNOCENÍ	59
2.5.1 <i>Výsledky optimalizace struktury sítě</i>	59
2.5.2 <i>Optimalizace učení sítě</i>	77
2.5.3 <i>Učení a vyhodnocení optimalizovaného modelu</i>	84
2.5.4 <i>Vyhodnocení modelu klasifikace měřených záznamů</i>	89
2.6 DISKUZE.....	90
ZÁVĚR	95
LITERATURA.....	96
SEZNAM SYMBOLŮ A ZKRATEK	100
SEZNAM PŘÍLOH.....	103

SEZNAM OBRÁZKŮ

1.1 Vzorový záznam EDA [1]	12
1.2 Schéma základního rozdělení EDA komponent [2]	14
1.3 Ilustrace fázické složky EDA [3]	15
1.4 Rozbor signálu SCR [4]	15
1.5 Výkonové spektrum EDA s popisem zastoupení aktivity větví ANS [5]	17
1.6 Schéma zpracování EDA [6]	19
1.7 Měřené signály EDA (modré křivky) při různých stimulech [7]	20
1.8 Grafické znázornění tonické a fázické EDA [8]	22
1.9 Ilustrace extrakce fázické složky metodou dekonvoluce [6]	26
2.1 Vzorový naměřený signál EDA [10]	32
2.2 Vzorový průběh SCR v záznamu EDA [11]	33
2.3 Naměřený záznam EDA bez mentální aktivity	34
2.4 Naměřený záznam – mentální aktivita	35
2.5 Frekvenční spektrum – záznam s aktivitou	36
2.6 Frekvenční spektrum – záznam bez aktivity	36
2.7 Náhled datasetu pro neuronovou síť	37
2.8 Rozsegmentovaný záznam s anotovanými SCR – bez aktivity	37
2.9 Rozsegmentovaný záznam s anotovanými SCR – aktivita	38
2.10 Schéma zpracování 1-D signálu algoritmem hlubokého učení [33]	40
2.11 Schéma architektury sítě CNN [34]	41
2.12 Schematické znázornění architektury INN [34]	43
2.13 Schematické znázornění funkce Incepčního bloku [35]	44
2.14 Struktura návrhu výchozího modelu	47
2.15 Graf vývoje Accuracy při nastavení epoch – fáze tréninku	60
2.16 Graf vývoje Accuracy při nastavení epoch – fáze validace	60
2.17 Graf vývoje Accuracy – nastavení batch	62
2.18 Graf vývoje Accuracy – pořadí MaxPool a Dropout	63
2.19 Graf vývoje Accuracy – nastavení počtu konv. vrstev	65
2.20 Graf vývoje Accuracy – nastavení počtu konv. filtrů	66
2.21 Graf vývoje Accuracy – nastavení šířky konv. filtrů	67
2.22 Graf vývoje Accuracy – nastavení inicializace vah konv. filtrů	69
2.23 Graf vývoje Accuracy – nastavení MaxPool a Dropout	71
2.24 Graf vývoje Accuracy – nastavení počtu vrstev ANN	72
2.25 Graf vývoje Accuracy – nastavení počtu perceptronů v ANN	73
2.26 Graf vývoje Accuracy – nastavení aktivační funkce ANN sítě	75
2.27 Vývoj Accuracy – nastavení inicializace vah perceptronů	76
2.28 Graf vývoje Accuracy – Bach Normalizace	78
2.29 Graf vývoje Accuracy – optimalizační algoritmy učení	79
2.30 Graf vývoje Accuracy – nastavení kroku učení	80
2.31 Graf vývoje Accuracy – regularizace – trénování	82
2.32 Graf vývoje Accuracy – regularizace – validace	82
2.33 Graf vývoje Accuracy – Dropout ANN	83
2.34 Graf vývoje Accuracy – Dropout ANN	84
2.35 Struktura optimalizovaného modelu	85
2.36 Graf vývoje Accuracy – optimalizovaný model – učení	86
2.37 Graf vývoje Accuracy – optimalizovaný model – validace	87

2.38 Boxplot analýza úspěšnosti identifikace modelu na testovacích datech	88
2.39 Konfuzní matice – SCR v záznamech s a bez mentální aktivity	89

ÚVOD

Účelem a cílem této práce je navrhnut a využít metodu pro identifikaci projevů responzivní složky ze záznamu měření elektrodermální aktivity. Konkrétněji je pro tento účel navržen algoritmus tzv. hlubokého učení (pozn. z angl. deep learning). Jedná se v současnosti o jeden z nejmodernějších a hojně využívaných softwarových technických prostředků na poli informačních technologií, jenž lze použít ke zpracování signálu mnoha druhů. Kromě zmíněného využití algoritmů daného typu, pokrývá široké pole mnoha dalších odvětví, atď už se jedná o komerční, průmyslové, zábavní, medicínské nebo jiné, v nichž se uplatňuje zejména jejich rychlosť, efektivita a možnost automatizace s využitím schopnosti vlastního učení algoritmu a vlastní optimalizace k dosažení adekvátních výsledků. Algoritmy typu hlubokého učení jsou postaveny na odvozené struktuře, tzv. neuronových sítí (pozn. z angl. *artificial neural networks*), jenž mají inspiraci ve fungování nervového systému s architekturou vzájemně propojených neuronů, jejichž vazby jsou váhovány. Tuto strukturu si lze zjednodušeně představit jako systém vzájemně propojených malých procesních jednotek (perceptronů). V rámci této práce je navržen model pro klasifikaci signálu typu hlubokého učení pro analýzu sekvenčního jednorozměrného signálu, získaného ze záznamu elektrodermální aktivity. Algoritmus je navržen tak, aby byl schopen klasifikovat určené projevy činnosti nervového systému, které v rámci hodnocených dat odpovídají tzv. kožním responzivním složkám. V rámci trénovacího procesu byla experimentálně provedena optimalizace navrženého modelu. V další fázi praktické části je již optimalizovaný model aplikován na jednotlivé záznamy měřené elektrodermální aktivity pro rozpoznání responzivní složky, jenž je elektrochemickým kožním projevem mentální aktivity jedince. Následně je provedena závěrečná statistická analýza a vyhodnocení včetně diskuze k získaným výsledkům.

1. TEORETICKÁ ČÁST

1.1 Elektrodermální aktivita

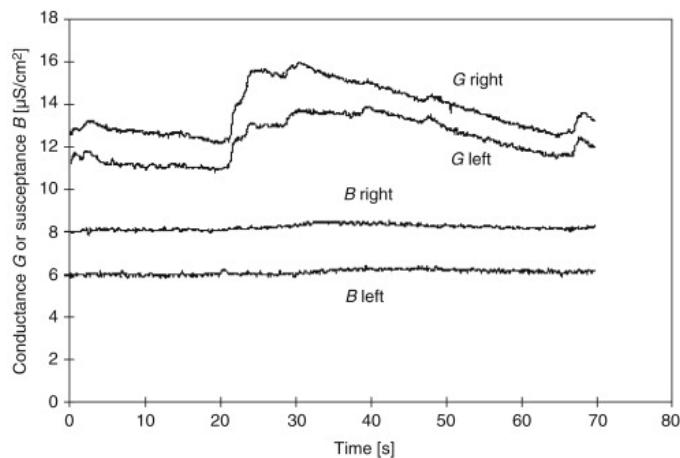
Elektrodermální aktivita je měřitelný projev elektrochemických změn na pokožce člověka. Záznam tohoto signálu lze získat měřením několika elektrických fyzikálních projevů, např. konduktance, elektrochemický potenciál, proudové změny (vhodnější je však měřit konduktanci), elektrická impedance atd.

Jedná se o projevy, které lze nepřímo využít k hodnocení činnosti sympatického nervového systému (součást ANS). Tento fyziologický projev je měřitelný pomocí senzorů s přichycenými elektrodami rozmístěnými v rozličné prostorové konfiguraci na kůži dotyčného. Měření elektrodermální aktivity reflektuje aktivitu nervového systému, který svou činností ovlivňuje v kůži přítomné potní žlázy. Tento projev následně zapříčinuje změny elektrochemické aktivity, kterou lze pomocí zmíněných veličin měřit a následně záznam vyhodnotit [21].

Principem vzniku signálu EDA je, jak již bylo zmíněno, nervovým systémem ovlivňována funkce potních žláz, čímž dochází ke změnám elektrochemického potenciálu na pokožce anatomicky překrývajících se vrstev skupin žláz. Signál z nervového systému je přenášen v ose dráhy jeho supraspinální částí, která zahrnuje orbitofrontální kortex, hypothalamus posterior, thalamus dorsalis a ventrolaterální ventrikulární formaci [4]. Tento jev se v záznamu EDA objevuje jednak spontánně (nespecifické responzivní složky) nebo může být vyvolán jako odpověď na určité podněty, jako např. dýchání, kašel, uleknutí, mentální zátež nebo elektrickou stimulaci. Jedná se o projev reakce sympatiku vedené přes pokožku nebo periferní autonomní povrchový systém. Odezva sympatiku na kůži může být změřena povrchovými elektrodami, které jsou dodatečně používány během vyšetření v rámci přídavného měření při pořizování záznamu jiných biosignálů, např. EMG nebo EKG. Jedním ze zavedených způsobů měření EDA, resp. povrchového kožního potenciálu, je umístění elektrod na plantární nebo palmární část končetiny, zatímco neutrální (referenční elektroda) je umístěna na vzdálený a pevný povrch příslušné oblasti, většinou se jedná o pevnou oblast končetiny, např. kloubní výběžek [14]. Záznam signálu EDA při zpracování obvykle využívá aplikaci filtrů typu dolní propust' s mezní frekvencí 1,2 – 2 Hz a horní propust' s mezní frekvencí 1–5 kHz [13]. Při tomto nastavení úrovně filtrace dosahuje latence projevů responzivních komponent signálu mezních hodnot v rozsahu 1,5 – 2,1 sekund. Pokud dochází k opakovániemu stimulu, je následován evokovanou odpovědí nervového systému projektovanou v záznamu EDA. Díky tomuto měřitelnému projevu lze hodnotit i variabilitu responzivních složek. Pokud dochází k aplikování stimulů v nepravidelných intervalech, může dojít ke snížení návyku generování odezvy systému, resp. k utlumení míry responzivity systému, kdy se SCR složky objevují s větší latencí, menší amplitudou, sníženou četností anebo jsou v signálu zcela infiltrovány.

Vzhledem k tomu, že nejčastější metodou měření je pořizování záznamu konduktance, je signál elektrodermální aktivity kvantifikován měřením záznamu elektrického potenciálu mezi dvěma body v místě kontaktu elektrod s kůží. Následně je mezi těmito body změren protékající elektrický proud, jenž je následně elektronickým obvodem překalkulován na elektrickou konduktanci.

Měření a pořizování záznamu EDA se v běžné praxi provádí na končetinách, nejčastěji v oblastech prstů a dlaní, a to z důvodu velké hustoty potních žláz (cca $240/\text{cm}^2$). Pokud vytyčené oblasti nejsou při měření zcela dosažitelné, resp. nejsou pro daný typ vyšetření vhodné, lze elektrodermální aktivitu měřit ze spodu na chodidle (hustota žláz cca $180/\text{cm}^2$) nebo na čele (cca $240/\text{cm}^2$). Měření elektrodermální aktivity u některých jedinců prokázalo, že dochází permanentně ke generování optimální úrovně odezvy EDA měřením na lokalitách v oblasti paže a předloktí ($\sim 180/\text{cm}^2$), nohou ($\sim 100/\text{cm}^2$). Velikost odezvy EDA je ovlivněna faktorem, kdy její detekovatelnost je v přímém úměře počtu ekrinních potních žláz nacházejících se mezi přiloženými senzory, nikoli pod nimi [19]. Umístění senzoru by tedy mělo být pro optimální měřitelnou úroveň signálu voleno tak, aby elektrody byly v co největší vzájemné vzdálenosti při zachování pokrytí měřené oblasti. V místech s nižší koncentrací potních žláz, kde výše zmíněný postup nelze uplatnit, je třeba zesílit signál pro odlišení odezvy elektrodermální aktivity. Rozhodující je rovněž výběr senzorů z vhodného materiálu s dostatečnou přilnavostí.



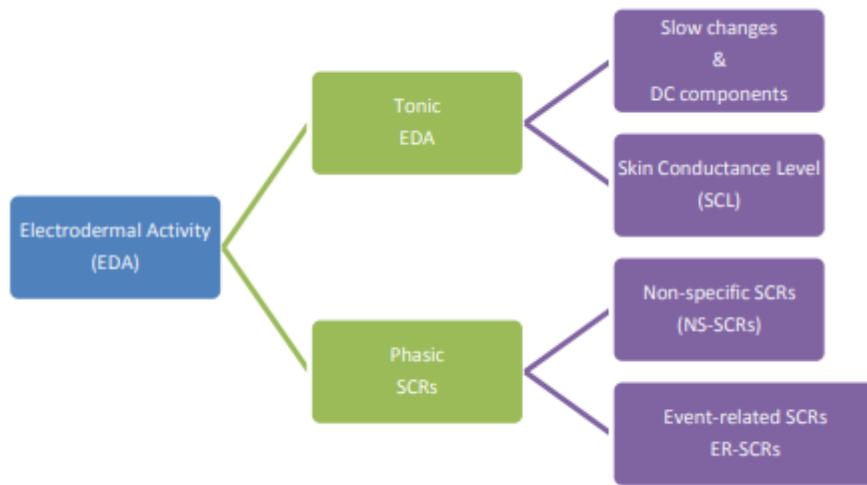
Obrázek 1.1 Vzorový záznam EDA [1]

Metody měření záznamu EDA, s aplikací nových instrumentů detekce responzivních složek a prostředků pro pokročilé zpracování signálu, se staly v posledních letech oblíbeným prostředkem k vyhodnocení dynamiky autonomního nervového systému. Vzhledem k tomu, že EDA je založena na měření konduktance (vodivosti) pokožky, je po elektrochemické stránce v silné korelací s produkcí potu.

Elektrodermální aktivita reflektuje pouze aktivitu sympatické části autonomního nervového systému, protože potní žlázy nejsou parasympatickou částí inervovány. Z toho důvodu je EDA patrně jedním z nejužitečnějších indikátorů změn vzrušivosti sympatického systému. Elektrochemické projevy EDA mají vazbu k emocionálním a kognitivním stavům dotyčného jedince. Měřený záznam tak může být využit k vyhodnocení skrytých emocionálních pocitů, které se mohou objevit bez vědomého úsilí nebo bez kognitivního obsahu [1]. Nedávné studie prokázaly, že EDA je vhodným indikátorem pozornostního zpracování podnětů, kdy hlavní podněty a úkony vyžadující větší míru soustředění, evokují příslušnou odezvu i v záznamu aktivity. Vyšetřování a analýzy EDA jsou využívány při výzkumech a studiích v rámci širokého spektra jiných odvětví, jako je například psychopatologie, fyziologie a neuropsychologie. V důsledku modernizace technologie, metodologie a záznamu signálu, se měření EDA stává významnější součástí výzkumu v psychologických vědách. Získané poznatky vedly k dalším pokrokům zahrnujícím techniky a metody analýzy naměřených dat a jejich následné interpretaci. Je důležité mít na paměti, že měření je výrazně ovlivněno okolním prostředím a podmínkami, během kterých je záznam pořizován. Změny v měření se mohou projevit při jakémkoliv formě stresu, kterému je subjekt vystaven, proto je při vyšetření nezbytné, aby byly eliminovány a následná analýza tak o odpovídala očekávání.

1.2 Komponenty EDA

V časové oblasti signálu je patrná přítomnost několika signifikantních složek v zaznamenaném signálu EDA. První je tzv. tonická složka (komponenta s nízkou frekvencí), druhou složkou je složka fázická (signál s vyšší frekvencí) [23]. Tyto dvě složky vykazují vysokou míru variability mezi jedinci. Tonická složka je označována jako **SCL**, fázická jako **SCR**. SCL je obvykle měřena v jednotkách μS a má charakter pomalého driftu signálu a zvláště má vazbu na úroveň vodivosti kůže. SCL je obvykle kalkulována jako průměr několika měření zaznamenaných v průběhu specifické nestimulační klidové periody [23]. SCR je naproti tomu charakteristická projevem rychlých obvykle polyfázických změn hodnot konduktivity přítomných v signálu EDA v návaznosti na příslušné stimuly. SCR komponenty se však mohou vyskytovat i autonomně bez předešlého stimulu systému.



Obrázek 1.2 Schéma základního rozdělení EDA komponent [2]

1.2.1 Tonické složky

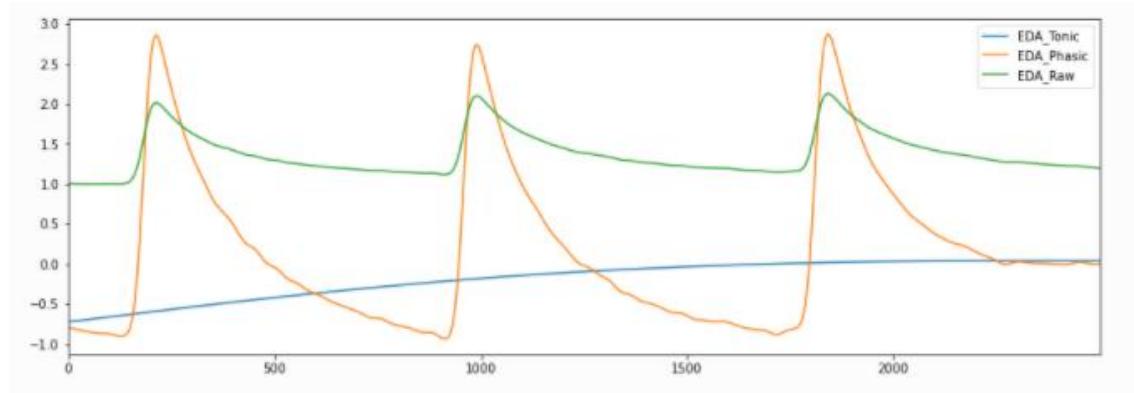
Tonické složky jsou v záznamu EDA charakteristické jako signály s nízkou frekvencí. Prakticky se projevují velmi pomalým posunem signálu v průběhu určitého časového intervalu směrem k nižším nebo vyšším hodnotám konduktance. Určují konstantní úroveň měřené hodnoty signálu v rámci pořízeného záznamu. Změny v signálu SCL reflektují celkové změny v autonomním systému, na které má vliv zejména dlouhodobější vystavení určité stresové situaci, čímž se organismus dostává do stavu vyšší excitace nervové soustavy.

V rámci šetření EDA je vhodné SCL rozpoznat, jelikož díky přítomnosti této složky v signálu je ovlivněna jeho základní úroveň vlivem malé frekvence posuvu. Jinými slovy, tonická složka se vlivem SCL konstantně mění mezi jednotlivými intervaly pořizované sekvence EDA (lze spatřit rozdíl mezi periodami záznamu signálu). Tento fakt vedl k závěrům, bez dlouhodobějšího záznamu nemá hodnota SCL sama o sobě velký informativní význam pro vyšetřování [4]. Prosté průměrování přes celý signál jako vyhodnocení parametru SCL je nedostatečné, protože tato metoda je z podstaty náchylná k nadhodnocení oproti skutečné hodnotě. Jednotlivé části průměrování totiž obsahují též SCR složky, které výpočet zkreslují. Není tedy zcela zřejmé, zdali lze tuto metodu vyhodnocení SCL použít u některých jedinců k určení stavu nervové excitace organismu.

1.2.2 Fázické složky

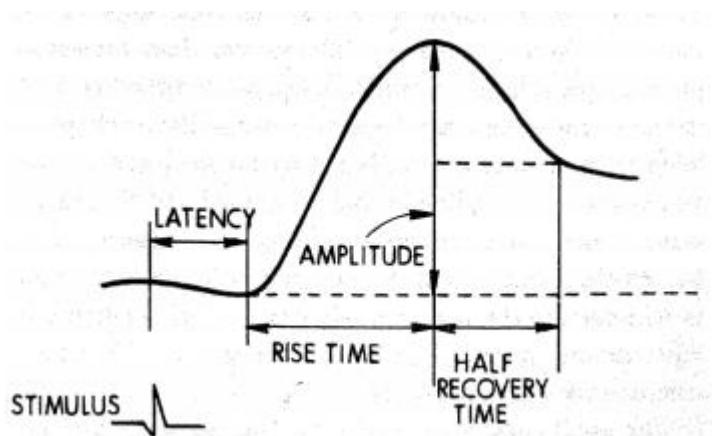
Fázické složky jsou, jak již sám jejich název napovídá, složeny z několika fází, které se projevují v signálu EDA rychlými změnami hodnot konduktance. Většinou se tyto složky projevují monofázickým nebo bifázickým průběhem. Projev fázických složek má za následek výskyt tzv. SCR signálů (viz kapitola 1.1), které jsou charakteristické

svým tvarem strmého náběhu do maxima, zatímco přechod na původní hodnotu v klidové fázi je výrazně pomalejší.



Obrázek 1.3 Ilustrace fázické složky EDA [3]

Formy SCR jsou dvojího typu. Objevují se buď jako komplex evokujícího podnětu a následné odpovědi, kdy před samotným strmým píkem předchází stimul, který je o amplitudě výrazně nižší. Přítomnost stimulu následně generuje po určité době latence zpožděnou odpověď ve formě amplitudy SCR. Tento signál je bifázického charakteru, kdy strmému navýšení vodivosti předchází po stimulu mírný přechod do hodnot nižších (resp. pod hodnotu SCL). V rámci činnosti autonomního nervstva se však někdy vyskytuje SCR bez předcházejícího stimulu. Tento druh fázické složky se označuje jako nespecifické SCR (nS.SCR). Signál má zde tvar monofázický, protože odpověď zde přichází bez příslušného stimulu. SCR i nS.SCR se zpravidla vyzdvihují jako počet píků v záznamu EDA za jednotku času a jsou obecně projevem tonického stresu produkovaného během stimulů určitého druhu.



Obrázek 1.4 Rozbor signálu SCR [4]

Obrázek 1.4 ilustruje schematicky důležité parametry, které jsou v rámci EDA při analýze signálu SCR vyhodnocovány, včetně již zmíněné četnosti výskytu responzivních komponent. Pro kvantitativní analýzu je důležitá kalkulace doby latences (času náběhu), hodnoty amplitudy a doba poklesu SCR na polovinu hodnoty maxima [13]. Vyhodnocení SCR je narozdíl od SCL potenciálně nezávislé na druhé jmenované složce, jelikož jak ukázala studie, navýšení počtu aktivních potních žláz, které se podílejí na generování EDA, má za následek produkci ekvivalentního inkrementu konduktance bez ohledu na úroveň bazální aktivity, resp. SCL [16]. Komponenty SCR lze vyhodnotit pomocí přímého výpočtu bez nutnosti dalšího zpracovávání nebo úprav signálu, které již neprobíhají v reálném čase záznamu. Proto při pořizování měření úseku signálu je důležité dbát na nastavení pevného časového úseku měření, kdy je frekvence píků (hrotů signálu) hodnocena přes celý záznam s odlišnými podmínkami.

1.3 Rešerše – metody identifikace responzí a jejich aplikace

Pro rekapitulaci předchozí kapitoly, z hlediska obsahu signifikantních informací pro analýzu aktivity autonomního nervového systému, je EDA složena ze dvou důležitých komponent:

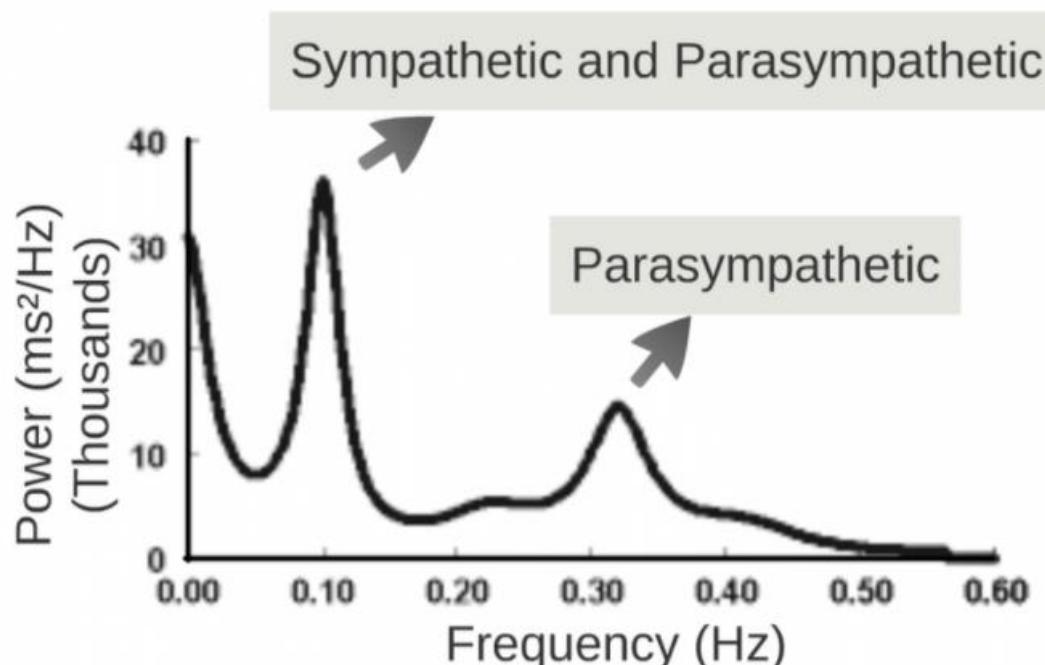
- **SCL** – definuje úroveň signálu
- **SCR** – určuje rychlé změny v EDA

Zatímco SCL z principu nemůže být hodnoceno přímo v aktuálním okamžiku měření, kdy je nutné pořídit celý záznam EDA s následným odečtením komponenty SCR, SCR lze kvantifikovat v reálném čase během měření, a to v pevně stanoveném časovém úseku, kdy frekvence anebo z ní odvozená četnost píků je zaznamenána a následně vyhodnocena [25].

1.3.1 SW metody identifikace a jejich aplikace

Posada-Quintero et. al (2016) publikoval studii, která se zabývá vyšetřením autonomního nervového systému pomocí definovaných komponent v záznamu měření EDA, pro které byl stanoven způsob identifikace specifických složek elektrodermální aktivity [23]. Studie byla provedena za účelem neinvazivního vyšetření dysfunkcí srdečního rytmu pomocí záznamu HRV v kombinaci se simultánním měřením EDA. Důvodem využití záznamu EDA byla přítomnost nízkých frekvencí (0,04 – 0,15 Hz) v datech HRV, které jsou výrazně ovlivněny dvěma komplementárními větvemi ANS (sympatikus a parasympatikus), které není možno oddělit od původního signálu spektrální analýzou, což zůstává pro vědce velkou výzvou do dalších let. V rámci studie byl pořízen záznam EDA v časové oblasti s vyhodnocením parametrů SCL a SCR, které jsou v korelacích s řízením

sympatického nervového systému. Jak bylo zjištěno, tyto složky signálu postrádají konzistenci, protože se zde projevuje vliv jak rozličných podmínek nastávajících během měření, tak vliv individuálního psychického nastavení mezi samotnými subjekty. Spektrální analýza v této studii byla vykonána za účelem stanovení frekvenčních pásem složek, které jsou výsledkem činnosti ANS. Bylo prokázáno, že aktivita sympatiku se v záznamu EDA projevuje nejintenzivněji, resp. složky frekvenčního spektra mají největší amplitudu v rozmezí 0,045 – 0,25 Hz (v rámci studie označeno jako ***EDASymp***). Dodatečně byla provedena časově proměnná analýza založená na výpočtem stanovených spektrogramech s dostatečně širokým časovým okénkem a překryvem k zajištění vysokého frekvenčního rozlišení. Touto analýzou bylo zjištěno, že v rozmezí 0,08 – 0,24 Hz frekvenčního pásma se nachází nejvíce responzivních komponent aktivity sympatického nervstva (zde označeno jako ***TVSymp***). Vyhodnocené rysy signálu EDASymp, TVSymp jsou, jak bylo výsledky studie interpretováno, více senzitivními a konzistentními ukazateli ortostatického, fyzického a kognitivního stresu, než je tomu v případě analýzy v časové doméně EDA a lze také těmito parametry mnohem lépe kvantifikovat samotnou funkci sympatické větvě nervového systému.



Obrázek 1.5 Výkonové spektrum EDA s popisem zastoupení aktivity větví ANS [5]

Kromě výše zmíněných doložených skutečností bylo také prokázáno, že projev sympatiku v EDA se dynamicky mění posuvem složek k vyšším frekvencím, kdy je dotyčný pacient vystaven fyzické námaze. Výsledky byly následně využity pro úpravu pásem pro HR, kdy dochází ke zvyšování frekvence srdečního tepu. Stejné pásmo

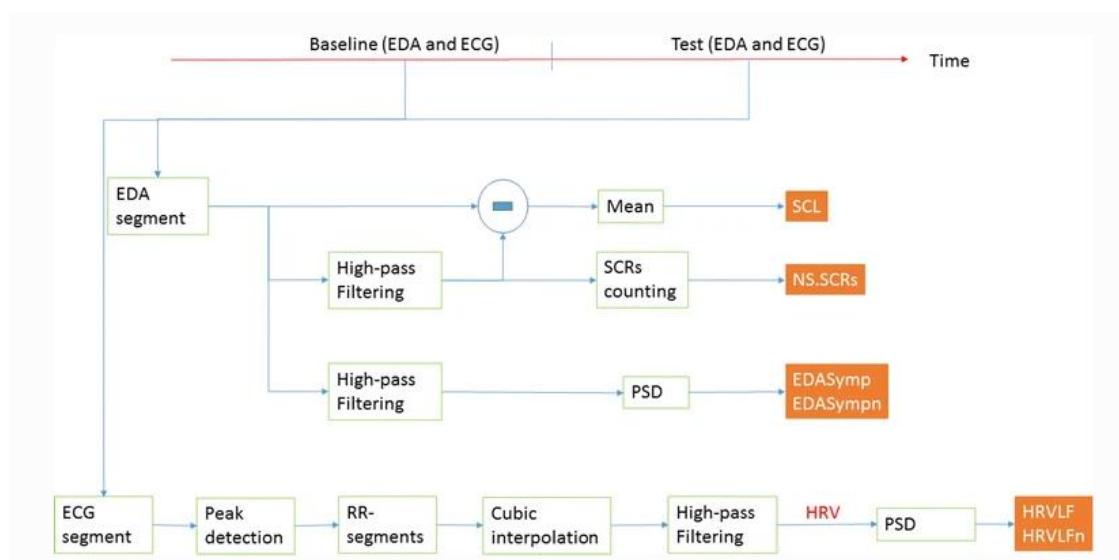
frekvencí bylo využito pro analýzu stavů při odpočinku a fyzické aktivitě. Dalšími aplikacemi bylo hodnocení EDA v rámci spánkové deprivace. Během tohoto experimentu proběhlo 24hodinové sledování pacientů ve stavu bdělosti. V záznamech byly detekovány složky o vysokých frekvencích odpovídající SCR, jejichž přítomnost je spjata s dlouhou dobou bez odpočinku, zatímco nízké frekvence (odpovídající SCL) mají vztah k reaktivitě organismu.

Ikezawa et. al (2012) uvádí výzkum s využitím měření EDA za účelem vyhodnocení míry responzivity v záznamech pacientů se schizofrenií. Výzkum proběhl za účelem vyšetření přítomnosti/absence SCR a utlumení fázické složky projevující se u pacientů se schizofrenií, ale i u některých zdravých jedinců. Pacienti byli stimulováni sledováním emocionálně-evokujícím záznamem videa a nebo snímků s neutrálním „nezatěžujícím“ obsahem. Následně bylo provedeno vyhodnocení neurokognitivní funkce a sociální kognitivity. Zároveň v rámci experimentu byly snímány elektrochemické potenciály s vazbou na stimulující události (z angl. **ERP** – *Event related potentials*), jimž bylo promítání obrázků lidí zažívajících bolest a lidí relaxovaných. Na základě rozdílu v počtu naměřených SCR byla hodnocena patogenita psychického stavu dotyčných. Záznam SCR probíhal na tenárním a hypotenárním povrchu levé ruky při současném zobrazování magnetickou rezonancí v kombinaci s kompatibilními Ag/AgCl elektrodami. Záznam projevu EDA byl kontinuálně monitorován systémem MP-150 Acqknowledge software, kterým byl následně signál analyzován [18]. Klasifikační kritéria pro SCR komponenta byly následující:

- SCR amplituda s prahem hodnoty $0,05 \mu S$
- SCR vlny se vyskytují i po aplikaci filtru typu PP s mezními frekvencemi 2; 0,5 Hz nebo 8-sekundovém vyhlazovacím okénku základní úrovňě
- SCR čas náběhu je v rozmezí 1–13 sekund [16]

Posada-Quintero et. al (2016) publikoval další výzkum ohledně analýzy spektrální hustoty elektrodermální aktivity za účelem vyhodnocení funkce sympatiku. V rámci experimentu bylo měřeno EDA v časové oblasti a byly získány měřitelné změny vodivosti na povrchu kůže pacientů. Pořízený záznam časové domény signálu umožnil kvantifikovat SCL a nS.SCR, u nichž, jak bylo prokázáno, se jejich četnost a intenzita projevu zvyšuje při narůstání aktivity ANS. Součástí analýzy bylo stanovení spektrální hustoty neboli PSD (z angl. zkr. **Power Spectral Density**). PSD bylo použito k vyhodnocení dynamiky sympatického nervstva při aplikovaných stimulech, kde byl zaznamenán projev responsivní složky pomocí vyskytujících se píků v oblasti nižšího frekvenčního pásma. Výsledky byly současně porovnány s měřením variability srdečního rytmu. Bylo zjištěno, že frekvenční složky jsou z hlediska svých amplitud nejvíce zastoupeny v pásmu frekvencí 0,045 - 0,15 Hz (předepsané pásmo pro HRVLF). Jedná

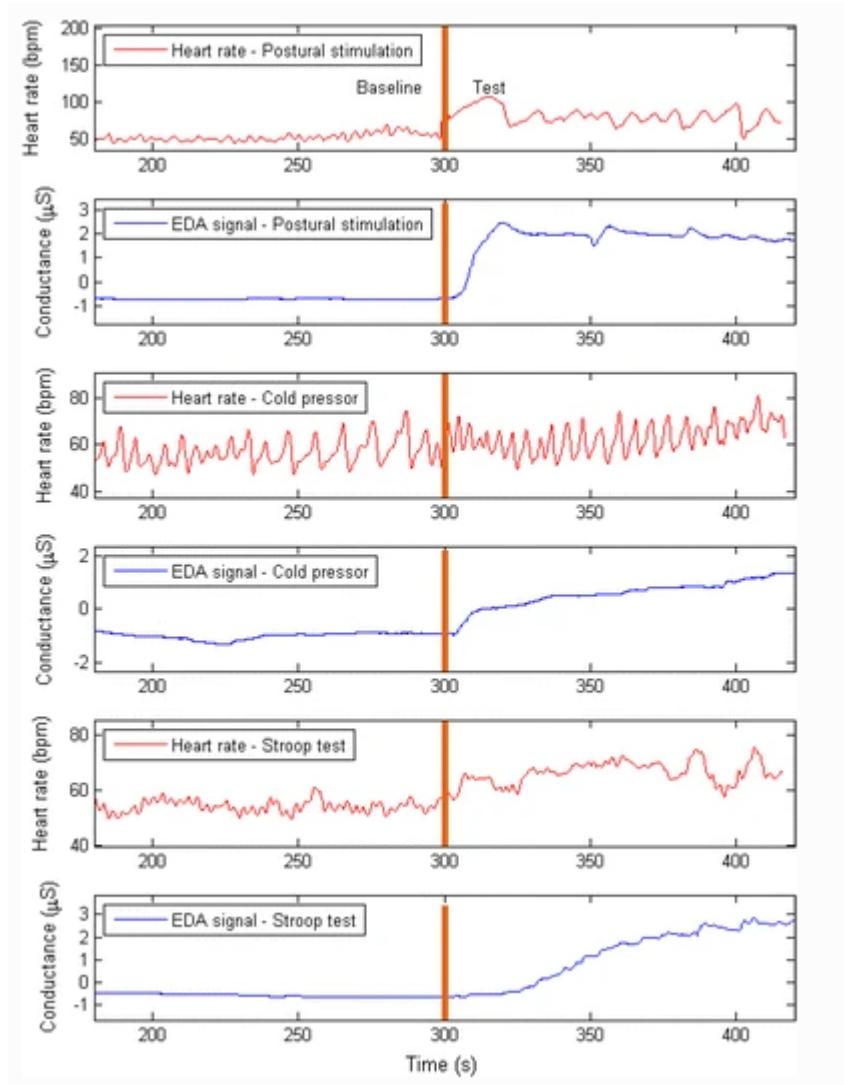
se o frekvence signálu nejvíce ovlivnitelné činností sympatiku. Nicméně byla zjištěna přítomnost dalších složek zahrnující 5 – 10 % spektrální hustoty v pásmu 0,15 – 0,25 Hz, kdy subjekt podstoupil stimuly všech v rámci experimentu předepsaných druhů. Byla stanovena normalizovaná komponenta sympatiku (EDASymp: pásmo 0,045 – 0,25 Hz), zatímco pouze malá část spektrálního výkonu se nacházela v pásmu nad 0,25 Hz. Výsledky ukazují, že charakter EDA v časové doméně u SCL, nS.SCR a EDASymp se významně mění, resp. že tato komponenta dosahuje vyšší intenzity, pokud dochází k větší kognitivní, fyzičké a jiné aktivitě dotyčného. Dále bylo zjištěno, že EDASymp byla více responzivní než poměr SCL a nS.SCR, kdy docházelo ke stimulaci pacienta tím, že byl vyzván k tlačení rukou na chladný předmět, zatímco SCL a nS.SCR byly více senzitivní vůči posturálnímu namáhání a tzv. Stroop testu (slova předkládána v různé barvě, kdy dotyčný má říct barvu daného slova). EDASymp složka v záznamu vykazovala vyšší míru konzistence a nižší stupeň variability ve srovnání s vlastnostmi získanými vyšetřením v časové doméně. Proto PSD analýzu EDA záznamu lze považovat za slibnou techniku vyšetření funkce sympatiku.



Obrázek 1.6 Schéma zpracování EDA [6]

Obrázek 1.6 značí schematicky postup zpracování signálu EDA při studii popsané v publikaci Posada-Quintero et. al (2016). S ohledem na cíl této práce (identifikace responzivních komponent) je pasáž zaměřena na část ve schématu, kde vstupuje časosběrný záznam signálu do bloku „EDA segment“, ve kterém dochází k následnému rozvětvení značící různé postupy dalšího zpracování. Pro ilustraci jsou uvedeny jednotlivé větve procesu zpracování signálu jako větve 1, 2, 3 od shora dolů v rámci uvedeného úseku diagramu v Obrázku 1.6. V prvotní fázi zpracování byl extrahován pevně stanovený úsek signálu fixní časové délky. Úsek sekvence je následně simultánně

zpracováván v rámci jednotlivých větví **1**, **2**, **3** představujících proces zpracování. Ve věti **1** dochází k odečtu časového úseku EDA po extrakci složek s vyšší frekvencí od původního úseku. Tím je získán signál o nízké frekvenci, který je následně zprůměrován, čímž je získána hodnota základní úrovně signálu, tedy SCL (uváděno v angl. jako „*baseline*“). Ve věti **2** je na vstupu signál odfiltrován HP filtrem o mezní frekvenci odpovídající dolní hranici frekvenci vysokofrekvenčních složek (responzivní komponenty). Následně je záznam podroben analýze v časové oblasti (identifikace poloh amplitud rychlých změn signálu odpovídající responzivním složkám a komplexů stimul-amplituda), kdy je získán absolutní počet projevů a následně frekvenci četnosti pro daný časový úsek. Ve věti **3** probíhá filtrace stejné signálu jako v předchozí věti diagramu, nicméně v této fázi je také přidružena analýza ve spektrální oblasti, kdy je získáno rozložení spektrálního výkonu. V rámci analýzy tak bylo stanoveno zastoupení jednotlivých spektrálních složek v signálu z hlediska jejich energie.



Obrázek 1.7 Měřené signály EDA (modré křivky) při různých stimulech [7]

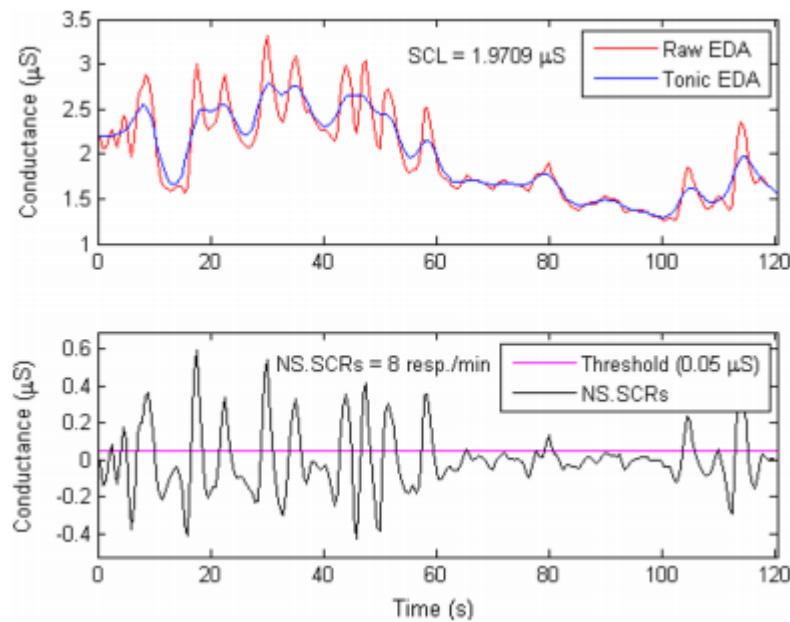
Obrázek 1.7 zobrazuje signály EDA, které byly získány metodikou využitou ve studii publikovanou Quintero et. al (2016). Lze si povšimnout změn tvaru signálu aktivity při aplikacích stimulů rozličného druhu pacientovi. V rámci posturální stimulace je patrné, že v záznamu dochází ke strmému nárůstu měřeného signálu na vyšší hodnoty s následným výskytem responzivních složek o nižší frekvenci. Naproti tomu stimulace vyvolaná tlačením na chladný předmět má za následek velmi pomalý náběh k vyšší hodnotě konduktance. Ta se během měření neprestává kontinuálně zvyšovat, zatímco výskyt responzivních složek je zde nepatrný. Vyšetřování *Stroop* testem vykazuje, že přechod konduktance na novou klidovou hladinu je zde pozvolný s patrným obsahem responzivních složek o vyšší amplitudě a vysokou frekvencí. Dále je zřejmé, že stimulace *Stroop* testem za účelem vyvolání kognitivní a mentální zátěže, má za následek generování vyšší míry výskytu responzivních složek měřených pomocí EDA. V tomto momentě je totiž aktivita autonomního nervového systému sympatiku vysoká.

Výzkum Posada-Quintero et. al (2018) hodnotil kognitivní zátěž ve vodě ponořeného člověka s využitím měření a analýzy EDA. Pokud se člověk potopí do velké hloubky, je jeho organismus vystaven velkému stresu vlivem okolních zátěžových podmínek, které následně vyvolávají odezvu psychického kontrolního systému organismu. Ještě vyšší míry aktivity nervové soustavy je logicky dosaženo při podrobení dodatečné kognitivní zátěži, jak již bylo zmíněno v předchozích popsaných případech. Z tohoto důvodu bylo zvoleno pro analýzu právě měření signálu elektrodermální aktivity, jakožto slibná metoda neinvazivního vyšetření činnosti ANS senzitivní vůči projevům psychické zátěže. Prvně bylo provedeno vyšetření EDA v časovém rozmezí a následně v oblasti frekvenční během ponoření. Vyšetřovaný strávil 4 minuty ponořen ve vodě, kdy tato doba určovala periodu základní hladiny konduktance (SCL). Následně byl dotyčný po vynoření podroben *Stroop* testu k vyvolání kognitivní zátěže. Pro analýzu v časové oblasti bylo stanovenno SCL a nespecifické SCR. Hodnoty těchto parametrů nevykazovaly významné změny ve srovnání s měřením základní úrovně signálu. Výsledkem analýzy ve frekvenční oblasti bylo stanovení EDASym a TVSymp (časově frekvenční analýza signálu s fixním časovým rámcem kratší délky). Naměřené hodnoty se při kognitivní zátěži výrazně změnily vůči původnímu klidovému stavu. Studie potvrdila, že spektrální analýza EDA je vhodným nástrojem pro vyšetření kognitivní zátěže.

V rámci vyšetření záznamu elektrodermální aktivity v časové oblasti byl signál rozložen na tonickou a fázickou složku s využitím metody konvexního optimalizačního přiblížení [15]. Veličina SCL byla spočítána standardní metodou průměrování tonické složky záznamu během dvouminutové délky měření. Index nS.SCR byl kalkulován jako počet komplexů SCR během stanovené časové peridy. Při frekvenční analýze byl záznam nejprve předzpracován podvzorkováním na frekvenci 2 Hz. Tomu předcházela filtrace dat filtrem typu DP s mezní frekvencí 0,8 Hz (Chebyshev, 8. rádu). Podvzorkování bylo provedeno s decimačním poměrem 50, tedy z 100 Hz původní

vzorkovací frekvence na 2 Hz (s posloupností filtrů s decimačním poměrem 1/20 a 1/10 Hz). V konečné fázi předzpracování byly signály odfiltrovány filtrem typu HP (Butterworth, 8. rádu) s mezní frekvencí 0,01 Hz, aby byly odstraněny ze signálu dlouhé drifty. V rámci časově proměnné spektrální analýzy bylo výkonové spektrum kalkulováno pomocí Welchova periodogramu s délkou překryvu výpočetního okénka 50 % [15]. Při nastavení periodogramu bylo využito Blackmanova okénka (o délce 128 vzorkovacích bodů) v každém segmentu záznamu s následnou FFT transformací. Získané výkonové spektrum bylo následně zprůměrováno. Byla prokázána velké dynamika záznamu elektrodermální aktivity vymezená ve frekvenčním pásmu menším než 0,4 Hz [17]. Kalkulací EDASymp parametrů byl získán normalizovaný výkon EDA v rozsahu od 0,045 – 0,25 Hz [24].

Pro účely časově variabilní analýzy a reprezentaci v časově-frekvenční oblasti byl měřený signál EDA zpracován pomocí variabilní komplexní frekvenční demodulace. Technika časově-frekvenční spektrální analýzy poskytla reprezentaci relativně přesných odhadů amplitud responzivních složek s vysokým časově-frekvenčním rozlišením [17].



Obrázek 1.8 Grafické znázornění tonické a fázické EDA [8]

Obrázek 1.8 ukazuje grafický průběh tonické a fázické EDA v čase. Je patrné odlišení původního signálu a jeho tonické složky získané pomocí filtrace HP, kterou byla extrahována složka fázická (horní polovina Obrázku 1.8). V dolní polovině lze vidět průběh responzivní složky získané filtrace signálu HP. Pro detekci responzivních složek byla nastavena příslušná prahová hodnota tak, aby bylo možné zaznamenat co největší procento skutečných responzivních komponent EDA a konečný signál nebyl zkreslen

šumem. V tomto případě se jedná o nespecifické responzivní složky, které jsou charakteristické vyšší mírou nepravidelnosti výskytu, kdy se píky responzivních složek v záznamu EDA objevují nahodileji bez přítomnosti stimulačního pulzu a s kratším časem návratu. Ke stanovení prahu detekce pulzu SCR byla nutná filtrace HP kvůli posunu průměrné hodnoty, která by v jiném případě práh zkreslovala.

Jak již bylo zmíněno dříve, klíčovými technikami pro vyhodnocení responzivity nervového systému, odrážející mentální a kognitivní stav jedince, je kvalitativní a kvantitativní analýza komponent SCR v signálu EDA. Pokud se jedná o SCR vyvolané na základě stimulu, latence počátku signálu může být řádově několik sekund. Proto je nutné při identifikaci responzivní složky optimálně nastavit časové okénko záznamu, nejčastěji to bývá hodnota v rozmezí 1–3 s, jenž je optimálním rozsahem [8]. Doby latence delší než 4 s se mohou objevit, ale latence kratší než 1 s by měly být hodnoceny s větší obezřetností, protože zde již může být vliv systémově-immanentních zpoždění, jako je čas potřebný ke zpracování stimulu, vedení odezvy autonomním nervovým systémem k potním žlázám a průchodu potu skrze kanálky vedoucí povrchem pokožky. Po uplynutí času náběhu z iniciálního stavu, kdy dochází k malému propadu v křivce signálu (v rozmezí 0,5 – 5 s) [11], nastává fáze maxima odpovídající amplitudě responzivní složky. V praxi je pro vyhodnocení hodnota výšky píku vyjadřována v jednotkách μS a je vhodné provést logaritmizaci nebo druhé odmocnění za účelem normalizace rozsahu hodnot. Počátek responzivní složky může být určen zpětně přes signál SCR do bodu maximálního zakřivení signálu. Tato metoda byla popsána ve studii Boucsein et. al (2012), která popisuje program SCRGauge vytvořeného Peter Kohlischem [26].

U některých případů je důležité determinovat, zdali se odezva v signálu objevila, protože za určitých okolností může dojít k její úplné absenci nebo infiltraci v signálu. V praxi je determinace provedena stanovením a kvantifikací minimální hodnoty amplitudy, podle které lze porovnáním posoudit, zda daný artefakt je responzivní složkou. Tento požadavek je důležitý zejména při pořizování záznamu nS.SCR, jelikož není pevně stanovena perioda výskytu odezvy a může dojít ke zkreslení výsledku.

Při některých analýzách stimulačně specifické SCR se objevují složky s nulovou amplitudou, odpovídající složkám neresponzivním, jež jsou průměrovány s hodnotami skutečných responzivních složek v signálu. V takovém případě rozdíl mezi neresponzivní složkou a menšími responzemí nemusí být zřetelný. Za těchto okolností se jeví lepší volbou užití analýzy dat za účelem determinovat aktuální hodnotu responze (stanovení aktuální hodnoty amplitudy nebo absolutní počet píků přesahujících stanovenou mez). V důsledku toho, u stimulačně specifických SCR, musí být také specifikována minimální amplituda k určení výskytu responze. Zpravidla je nastavena hodnota $0,05\mu S$ s manuálním zavedením tzv. *skórování* (zn. četnost píků), při automatizovaném výpočetním skórování se však užívá hodnota nižší ($0,01\mu S$). Je podstatné zohlednit

úroveň šumu měřícího zařízení (mj. senzory s elektrodami, přechodový odpor kůže-elektroda atd.) pro prevenci vzniku artefaktů generovaných činností zesilovače v měřícím obvodu, které by mohly být chybně hodnoceny jako SCR. Obdobně, pokud vyšetřovaný vykazuje příliš velkou aktivitu (mentální i fyzickou), se generují pohybové artefakty, které by také mohly být chybně započítávány jako SCR složky s významně nižší amplitudou responze. Zmíněné aspekty ukazují na fakt, že prakticky nevhodnější empiricky stanovený práh pro vymezení amplitudy responzivní složky se pohybuje v rozmezí hodnot $0,01 - 0,05 \mu\text{S}$. Nastavení se mění buď dle aplikace a podmínek měření anebo dle individuality jedince odrážející jeho osobité fyziologické a psychologické vlastnosti.

Jak již bylo zmíněno, responzivní složky mají dobu návratu výrazně pomalejší než dobu náběhu. Tento parametr lze kvantifikovat jako jeden ze způsobu analýzy responzivní složky. Výhoda jeho použití při analýze spočívá právě v jeho delší době, která je tak snáze měřitelná i s menším časovým rozlišením, pokud dojde k filtraci signálu horní propustí. Jako další vhodný měřitelný parametr pro posouzení responzitivity elektrodermálního záznamu je plocha pod křivkou měření konduktance v čase. Ačkolik je zřejmé, že tato metoda vyhodnocení velmi silně koreluje s amplitudou, nejedná se o redundantní veličinu, jelikož je zde větší vliv doby trvání odpovědi charakterizující složky SCR. Nicméně v rámci analýzy se v praxi užívá mnohem méně, nežli je tomu u měření amplitudy. Jedním z možných řešení, jak plochu pod křivkou měřit, bylo navrženo v publikaci výzkumu Bach, Friston, Dolan et. al (2010), která je založena na konvolučním modelu integrální metody časově korelované s SCL [5]. Někteří autoři preferují více užívat veličinu magnitudy pro SCR než amplitudu, což je ekvivalentní průměrné amplitudě získané ze série vzorků větší časti signálu. Tato hodnota však obsahuje již diskutované složky o nulových hodnotách amplitudy a hodnota prahu je pak uměle snížena. Pokud je vyšetřování ve formě přivádění stimulů o vysoké intenzitě (velmi rychlé stimulace), je patrná přítomnost SCR komponent, které se v záznamu překrývají (čas návratu může zčásti nebo zcela splývat s časem náběhu). Proto je osvědčená metoda použití matematických dekonvolučních modelů [7].

Zpracování EDA pomocí techniky dekompozice a dekonvoluce vychází z charakteru složky SCR, která se v záznamu elektrodermální aktivity objevuje v kombinaci s jinými nefázickými komponenty. Standardní užívané metody jsou limitovány svojí menší citlivostí a rozlišením, pokud se detekované píky SCR vyskytují v signálu v těsné blízkosti, kdy se z části nebo zcela překrývají. Postup dekonvoluce byl navržen tak, aby byla složka SCR účinně oddělena ze signálu s výskytem komponent fázických i tonických. Výsledná aktivita fázické složky vykazuje nulovou základní hladinu hodnoty EDA, kdy SCR komponenty, původně se překrývající v originálním záznamu, jsou následně prezentovány na výstupu algoritmu jako časově odlišené kompaktní impulsy vykazující průměrnou dobu trvání menší než 2 s [27]. Následná časová integrace

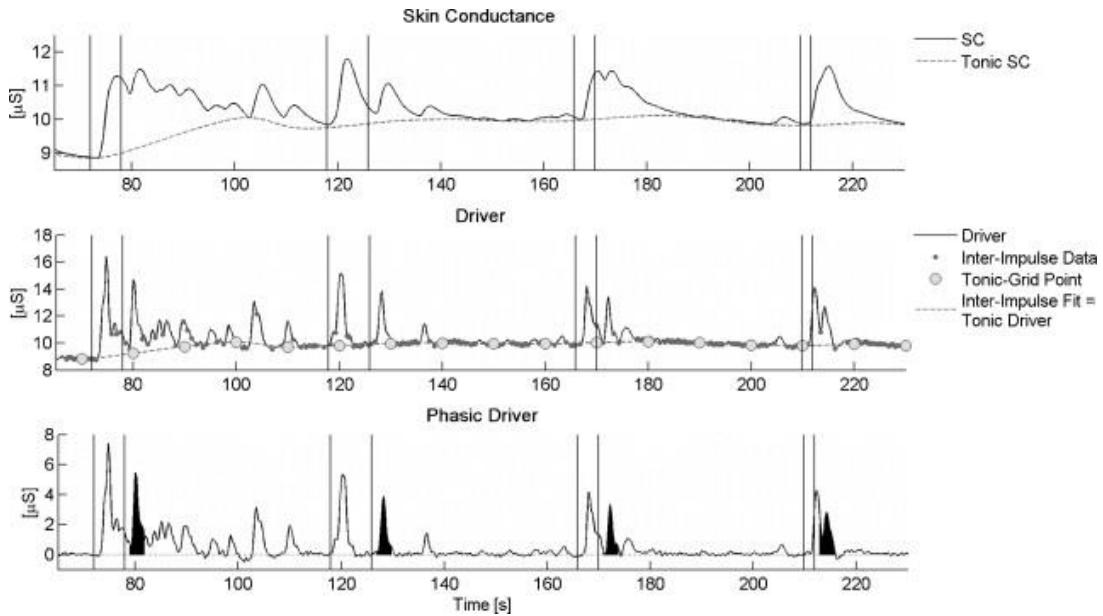
kontinuálního měření fyzické aktivity slouží jako přímočarý indikátor událostně provázané sympathetic aktivity, která se promítá ve výskytu responzivních složek.

Smyslem této metody je co možná nejpreciznější oddělení složky SCR a získání indikátoru fázické aktivity nervové větvě sympatiku, která odráží mentální aktivitu a momentální psychické rozpoložení jedince (z angl. zkr. *SMNA*). Jedná se o kontinuální měření reflektující lokální hustotu (tzv. sudomotorických neuronů), jejichž aktivita vykazuje stabilní hodnotu základní hladiny signálu s kompaktním výskytem aktivity píků SCR složek. Průběžný signál integrované SMNA složky může nést podstatné informace o aktivitě sympatiku v daném časovém okamžiku, u níž se předpokládá, že je přímým projevem složky SCR. V originálním signále se však SMNA složky objevují rozmazeně a časově jsou někdy obtížně odlišitelné, protože nastává vliv pomalých difúzních procesů potních žláz apod. Proto se SCR složky nevyskytují jako samostatné píky fázické aktivity, ale spíše jako výsledky superpozice navazujících procesů, které mohou znehodnotit vyhodnocení míry responzivity. Tato metoda, na rozdíl od standardně užívaných, není založena na dalším zesilováním amplitudy, ale cílí ke kontinuálnímu měření reflektující charakter signálu s obsahem SMNA složek, jež jsou charakteristické stabilní klidovou hodnotou a kompaktními píky o vysoké intenzitě. Tímto postupem lze dosáhnout zobrazení fázických odpovědí v signálu, které jsou jednoznačně časově odlišené a mají dostatečně velkou amplitudu a nejsou významně zkresleny.

Metoda využívání algoritmu standardní dekonvoluce je odkazem na problém, při kterém SCR složky mohou mít variabilní tvary při kontinuálním měření [6]. Procedura extrakce původní fázické komponenty v podstatě zahrnuje tři kroky:

- **Dekonvoluce SCR složek**
- **Vyhodnocení tonické složky**
- **Vyhodnocení fázické aktivity**

Publikace Benedeka et. al (2010) uvádí nastavení základních hodnot předdefinovaných parametrů modelu dekonvoluce $\tau_1 = 0,75\text{ s}$, $\tau_2 = 0,75\text{ s}$ včetně hodnoty tolerance (propustnosti). Hodnota tohoto parametru byla postupně optimalizována, stejně jako výše zmíněné parametry modelu, což zahrnovalo, podobně jako u technik algoritmů strojového učení, opakování běhy všech tří kroků zpracování dat pro každý nový set parametrů.



Obrázek 1.9 Ilustrace extrakce fázické složky metodou dekonvoluce [6]

Obrázek 1.9 demonstруje postup extrakce fázické složky při aplikování párů zkušebních stimulů (vertikální linie v grafech). Horní graf zobrazuje průběh původního EDA signálu. Prostřední graf značí tvar signálu v časové oblasti po dekonvoluci. Spodní graf zobrazuje časový průběh EDA po extrakci tonické složky od fázických.

Podrobněji postup dekonvoluce a následného získání samotné fázické složky zahrnoval níže zmíněné kroky. Jelikož sudomotorické neurony svou činností způsobují zvýšenou aktivitu sekrece potních žláz, spouštějí tím specifické změny v kožní konduktivitě. Z pohledu matematické definice je sudomotorická aktivita aplikátorem sérií po sobě jdoucích impulsů, které spouštějí specifickou distingovanou impulzní odezvu, která se následně projeví jako SCR složka. Tzv. **IRF** faktor popisuje tvar impulzní charakteristiky v čase. Výsledek procesu může být popsán konvolucí aplikátorů pulzů s IRF definované rovnicí:

$$SC_{Phasic} = Driver_{Phasic} * IRF, \quad (1.1)[6]$$

Platí předpoklad, že SCR komponenta v rámci EDA signálu převyšuje pomalu se měnící tonickou složku SCR [7]. Proto lze SC aktivitu pokládat jako kompozici dle následující rovnice:

$$SC = SC_{Tonic} + SC_{Phasic} = SC_{Tonic} + Driver_{Phasic} * IRF, \quad (1.2)[7]$$

Obdobným způsobem lze vyjádřit i aktivitu tonických složek pomocí konvoluce. Ačkoli se již nejedná o fyziologický projev, matematicky ho lze popsat stejným způsobem. V každém případě dekonvoluce, jak je již z názvu patrné, je procesem reverzním ke konvoluci. Dekonvolucí dat EDA je získání funkce aplikátorů stimulujících pulzy, jenž se skládá z tonické i fázické části. Pokud jedna z těchto složek může být měřením odhadnuta, lze vyjádřit výsledný časový průběh SC pulzů rovnicí:

$$\frac{SC}{IRF} = Driver_{SC} = (Driver_{Tonic} + Driver_{Phasic}), \quad (1.3) [6]$$

Vyhodnocení tonické aktivity lze docílit pomocí absence aktivity fázické. SCR složky mají relativně pomalou dobu návratu ke klidové hodnotě, čímž může být zkresleno stanovení tonické aktivity, protože se pulzy mohou vzájemně časově překrývat. Časové intervaly mezi distingovanými fázickými impulzy lze poté využít k odhadu tonické aktivity. Jedná o princip tzv. nonnegativní konvoluce představující proces vyhlažování signálu. Výsledný dekonvoluovaný signál je pokládán za záznam s velkou mírou šumu a zesílených chyb, proto je následně vyhlazen Gaussovským okénkem o $\sigma = 200\ ms$. Následně je použita detekce píku na již vyhlazeném signálu přes hledání nulových bodů první derivace časové domény signálu s nastavením hledaného prahu. Jsou tak nalezeny lokální maxima odpovídající píkům tonické složky. Interpolací je následně kalkulován tonický driver. Jeho konvolucí přes IRF je získána samotná tonická aktivita.

Následný odhad fázické aktivity vyplývá z kroku předchozího zahrnující substrakci získaného tonického driveru od driveru zahrnující obě komponenty. Výsledkem je signál s nulovou základní linií konduktance a pozitivní deflekci, který odpovídá časově omezenému původnímu signálu fázické aktivity, jenž se projevuje jako „převyšující“ frekventovaná složka v EDA záznamu. Narozdíl od procesu nonnegativní konvoluce, může fázický driver zahrnovat i hodnoty negativní (neoptimální IRF nebo vzniklé artefakty v datech elektrodermální aktivity). Ty jsou výrazem kvality extrakčního algoritmu, ale i kvality původních SC dat. Následně je možné stejným způsobem, jako v předchozím případě, získat konvolucí fázickým driverem původní fázická SC data a součtem s tonickými dospět k původnímu složenému signálu.

Publikace Benedek et. al (2010) prokázala úspěšnost separace složek tonických a fázických tvořících signál EDA. Bylo docíleno extrakce nezkreslené fázické složky s nulovou základní linií a kompaktními, časově odlišenými pulzy, jenž lze snadno detektovat a následně vyhodnotit [7].

Martinsson, Gustasson et. al (2017) zveřejnili studii o využití měření elektrodermální aktivity za účelem zlepšení identifikace vyššího mentálního rozrušení pacientů s demencí.

Studie byla zaměřena na průzkum, zdali je měření EDA spolehlivým indikátorem záchvatů u lidí s psychickou poruchou. Měřená data byla posílána online skrze IBM SPSS systém (speciální statistický prediktivní analytický software) společně s daty ze strukturovaných pozorování. Zpracovaná data byla rozčleněna do dvou skupin: první s narušenými jedinci s úzkostnými stavy a záchvaty, druhý se zdravými jedinci. Použitím metody měření EDA s identifikací responzivních složek bylo zjištěno, že existuje určitá korelace míry rozrušení pacientu, resp. jejich excitovaným mentálním stavem a záznamem elektrodermální aktivity [20].

Výzkum Sarchiapone, Gramaglia et. al (2018) demonstroval spojitost elektrodermální aktivity s psychopatologickými stavy jako například deprese a sebevražedné sklony. Toto vyšetření bylo realizováno na základě identifikace responzivních složek ve formě SCR a nS.SCR jevů v signálu EDA. Nižší průměrné hodnoty EDA a nižší hodnoty složek SCL/SCR byly zjištěny u jedinců se silnějšími depresními stavy ve srovnání s jedinci s méně emociálně excitačními stavy.

Byla publikována studie, která definovala doporučení ohledně měřících postupů EDA, následné procesy zpracování signálu a postup identifikace jednotlivých složek, které se v signálu vyskytují [25]. Základním problémem při identifikaci responzivních složek je, že fázické komponenty mají relativně malou amplitudu vůči přidružené složce SCL. Bývá tak občas velmi obtížné monitorovat malé změny způsobené kompozicí s SCL. Některé postupy byly již v této práci definovány, avšak jsou k dispozici i další možné přístupy k řešení, jejichž pouhý výčet by však přesahoval rámec této práce.

1.3.2 HW metody identifikace a jejich aplikace

Ačkoli podstatou této práce je využití softwarových prostředků pro identifikaci responsivních složek, okrajově v této kapitole bude zmíněn i přístup k dané problematice pomocí hardwarových nástrojů s vestavěným elektronickým systémem pro oddělení SCL a SCR komponent.

Pokud měřící hardware a software má dostatečný měřící rozsah, senzitivitu a má kapacitu získat samotný signál SCL, SCR může být v režimu offline tzv. přeskórován. Nicméně i při zvolení takového řešení je stále obtížné pozorovat SCR během akvizice dat. Avšak bylo vyvinuto několik záznamových systémů pro účely vyhodnocení EDA (např. systém Biopac) [25]. Tyto systémy poskytují kromě jiného funkci zobrazení automatickým měřítkem, čímž lze v časové oblasti analyzovat SCR v optimálním rozsahu. Pokud však takový systém není k dispozici, separace fázické nebo tonické komponenty je možná skrze aplikaci napěťového supresoru [2], který lze v praxi snadno ovládat. Další alternativou je vedení signálu zvlášť jedním kanálem se záznamem DC

signálu (stejnosměrný proud) s relativně malým zesílením, zatímco druhý kanál využívá k měření vstup spojený s kapacitorem (měření AC složky elektrického signálu), kde je zesílení naopak nastaveno na vyšší hodnotu pro účel automatického měření SCR bez nutnosti dalšího zpracování signálu [12]. Smyslem tohoto prostředku je zavedení kapacitance na vstupu signálu, kdy je efektivně filtrovaná stejnosměrná složka napětí a velmi nízké frekvence (komponenta SCL), zatímco relativně vyšší frekvence signálů filtrem procházejí a mohou být dále zpracovány měřícím obvodem. Nalezením optimální kombinace rezistence a kapacitance je základem pro filtrování nízkých frekvencí. Při záznamu signálu lze dosáhnout stabilní hodnoty základní úrovně signálu bez vlivu amplitudy SCR. Tato možnost identifikace bude v následujícím textu více rozvinuta.

Oddělené kapacitory jsou spojeny ke každé straně výstupu v sérii zapojeném rezistoru mezi výstupem a vstupem DC zesilovače. Navíc jsou mezi každým kapacitorem a vstupem zesilovače zapojené další rezistory. Klíčovým parametrem RC obvodu je časová konstanta neboli parametr určující, za jakou dobu dojde k poklesu DC napětí na 37% své původní hodnoty. Krátké časy odezvy znamenají filtraci komponent SCR, čímž by bylo znehodnoceno měření. Naopak dlouhé hodnoty časové odezvy znamenají vyšší míru projekce frekventovaněji se měnících složek SCL do záznamu, což se projevuje kolísající základní úrovní signálu, čímž dochází ke komplikaci měření amplitudy SCR složek. V praxi je často používána hodnota 6 s časové odezvy kapacitoru, která umožnuje měřit signál s dostatečně přesnými hodnotami SCR se zachováním stabilní linie základní úrovně signálu.

1.4 Závěr analýzy

Na základě provedené rešerše analyzující metody pro identifikaci responzivních složek, lze shrnout, že v moderních aplikacích je metoda dekompozice signálu v časové oblasti SCR a základové SCL komponenty velmi užívanou a do velké míry spolehlivou metodou k vyhodnocení responzivity v signálech EDA. Na tomto přístupu moderní metody vyhodnocení signálu EDA do velké míry staví a jsou kontinuálně zdokonalovány. Její výhodou je relativně jednoduchá forma implementace, která může být buď na úrovni softwaru při zpracování signálu nebo lze řešit hardwarově při dostatečně kvalitně provedeném měřícím obvodu s vhodně nastavenými filtry na vstupech signálu do vyhodnocovacího systému. Lze tak oddělit responzivní složky již v počátku pozorování signálu a není třeba příliš komplexních algoritmů následného zpracování identifikace amplitudy SCR v získaném záznamu. Navíc tím nedochází ke ztrátě možnosti hodnotit signál v reálném čase. Tato metoda není příliš praktická, protože není možné vždy sledovat signál v reálném čase v adekvátní kvalitě. Vhodnější variantou než hodnocení celého záznamu, je využití časových okének pro větší možnost sledovat změny responzivity signálu v reálném čase během záznamu a hodnotit lokální píky responzivní složky než průměrné hodnoty amplitudy. V jiném případě by tato hodnota byla

degradována vlivem přítomnosti odezv o nulové amplitudě, čímž je stanovený práh k detekci píků výrazně zkreslen. Jak ukázala analýza studií kognitivních zátěží využívající měření signálu elektrodermální aktivity, je více odpovídající analýza ve spektrální oblasti, která významněji reflektuje obsah responzivních složek v signálu a skrze výpočet výkonového spektra je možné tuto složku lépe kvantifikovat. Opět nastává obdobný problém, jako je tomu v případě analýzy v časové doméně, tedy nemožnost provádět analýzu v reálném čase, kdy nejprve celý záznam signálu musí být pořízen a nahrán měřícím systémem a teprve poté je zpracován blokem hodnotícího algoritmu. Nejlépe hodnocenou metodou dle provedené rešerše je v podstatě kombinace obou zmíněných způsobů a sice časově-proměnné frekvenční analýzy, kdy je pomocí spektrogramu vypočteno spektrum signálu v určitém časovém úseku signálu. V tomto případě je klíčovým parametrem nastavení doby trvání okénka, definující segment signálu, který je následně podroben další analýze vyhodnocovacím algoritmem. Tato metoda se velmi osvědčila při analýze mentální a kognitivní zátěže signálu, co se týče identifikace responzivní složky, vymezení spektrální oblasti SCR, stejně tak zastoupení dílčích složek ve spektru a lepšího posouzení dynamiky signálu. Velmi dobrých výsledků dosahuje také metoda dekonvoluce a dekompozice EDA signálu, založena na rozkladu na samostatné fázické a tonické složky v časové oblasti. Metodou lze dosáhnout určení a přesného vymezení žádoucí původních responzivních složek v podobě relativně úzce časově distingovaných pulzů o dostatečně výrazné amplitudě, a to i v případě, že se v signálu promítají i jiné tvarově variabilní responzivní artefakty, jenž neodpovídají vlastní činnosti sympatického nervstva, ale jsou projevem IRF faktoru. Touto implementačně relativně jednoduchou metodou, pracující se signálem v původní časové oblasti s výhodou postupné optimalizace parametrů výpočetního modelu, lze docílit zisku samotné fázické složky EDA v téměř původní podobě odpovídající přímo projektované činnosti sympatického nervstva bez zkreslujících artefaktů.

2. PRAKTICKÁ ČÁST

Cílem praktické části práce je vytvoření metody umožňující identifikovat responzivní složky v signálu EDA v datech záznamů získaných z databáze UBMI. Pro tento účel je využit algoritmus hlubokého učení, který je navržen a ve vhodně zvoleném programovém prostředí implementován a realizován. Ke konkrétnímu výběru typu daného algoritmu bude věnována samostatná kapitola. Složka SCR se projevuje jako výrazný artefakt ovlivňující tvar signálu dle hodnocených dat, které jsou k dispozici. V rámci části návrhu a implementace algoritmu identifikace SCR je posouzen vhodný algoritmus hlubokého učení určený k aplikaci na klasifikaci obsahu v měřeném signálu, resp. úseku signálu, ve kterém je hodnocena přítomnost složek SCR. Z této základní predikce je vycházeno při výběru a návrhu vhodného algoritmu typu hlubokého učení, který je následně aplikován na získaná data měření elektrodermální aktivity. Před samotnou implementací modelu neuronové sítě je provedena úprava a anotace dat určených k vyhodnocení navrženým algoritmem hlubokého učení. Upravená data jsou využita k trénovacím a testovacím procesům neuronové sítě a následně je optimalizovaný implementovaný model aplikován pro určení responzivních složek v jednotlivých nesegmentovaných záznamech. V této „ostré“ fázi testování navrženého algoritmu je sestavený model neuronové sítě aplikován na části záznamu, kdy je dotyčný subjekt v klidové fázi bez mentálního vytížení (prvních cca 20 minut) a následně na část, ve které je podroben úkonům vyžadujících vyšší mentální aktivitu (dalších 20 minut). Výsledky jsou následně statisticky vyhodnoceny a zanalyzovány z pohledu přesnosti identifikace responzivních složek navrženým klasifikačním modelem a rozdílech při aplikaci modelu na záznamech odlišných podmínek měření. V první fázi praktické části této práce je provedeno adekvátní zpracování dat (z angl. „preprocessing“). Veškerá programová implementace praktické části využívá programové prostředí **Jupyter Notebook** od firmy Microsoft instalovanou a spravovanou skrze volně dostupnou aplikaci **Anaconda**. Jako implementační programový jazyk je použit **Python verze 3.9.12**.

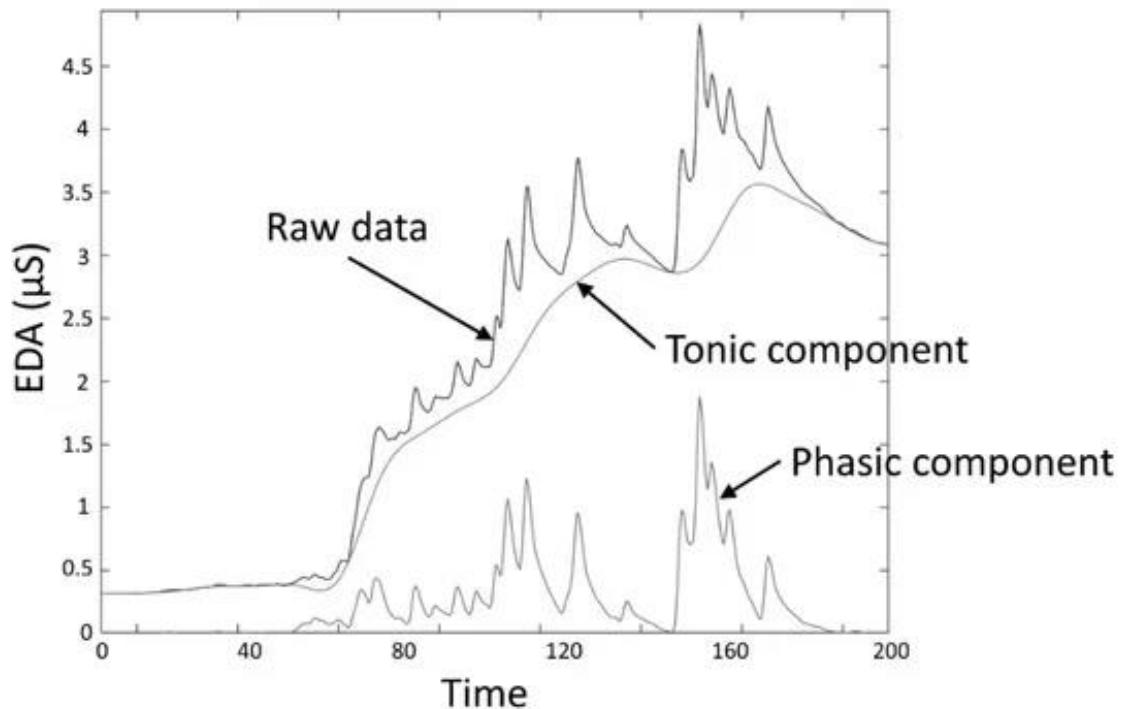
2.1 Zpracování dat a anotace

Data, která byla v rámci experimentální části k dispozici, jsou výsledkem měření elektrodermální aktivity, během které se dotyčná osoba střídavě nacházela v různých fázích mentálního rozpoložení. Konkrétněji prvních 20 minut se jedná o fázi mentálního klidu a dalších 20 minut dotyčný podstupoval úkony zvyšující mentální zátěž. Měřené záznamy byly pořízeny se vzorkovací frekvencí $F_{vz} = 1000 \text{ Hz}$.

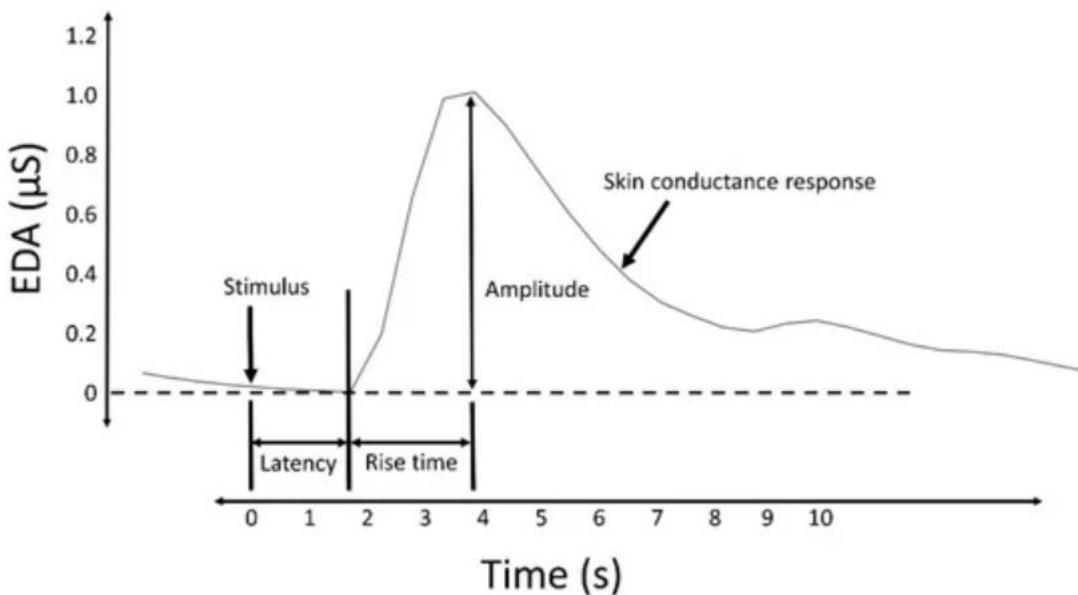
Dostupné záznamy EDA (viz kapitola 1.2) jsou výsledkem kombinace dvou složek, tj. fázické a tonické. Pro rychlé připomenutí, tónická (SCL) složka je výsledkem celkové měrné vodivosti kůže s charakterem pomalých posuvů hodnot signálu bez významnější vazby na sympatickou nebo parasympatickou část nervstva. SCR složka je rychlejším

projevem vyznačující se v signálu hroty znatelně pomalejší nosné vlny složky SCL, monofázického nebo bifázického charakteru. Tyto komponenty jsou jedním z doložených projevů aktuální mentální zátěže jedince, jejichž výskyt promítá činnost nervstva sympatiku a parasympatiku. Větve sympatiku jsou systémově propojeny s potními žlázy, čímž dochází k přímému vlivu na vodivost kůže. Tímto způsobem se činnost nervového systému promítne do signálu EDA a lze ji tak nepřímo změřit. Tato komponenta jsou cílovou složkou, která je navrženým algoritmem rozpoznána a z hlediska aplikace klasifikována.

Responzivní složka, která je v hodnoceném záznamu při preprocessingu dat anotována, má charakteristický tvar s monofázickým nebo bifázickým průběhem, jak bylo výše popsáno v kapitole 1.2.2. Fázická složka se vyskytuje v datech EDA v superpozici se složkou tónickou (délétrvající trendy stoupavosti a klesavosti signálu) a je fiziologickou odezvou činnosti nervových drah sympatiku nebo parasympatiku, čímž do jisté míry odráží momentální psychické rozpoložení pacienta [31].



Obrázek 2.1 Vzorový naměřený signál EDA [10]

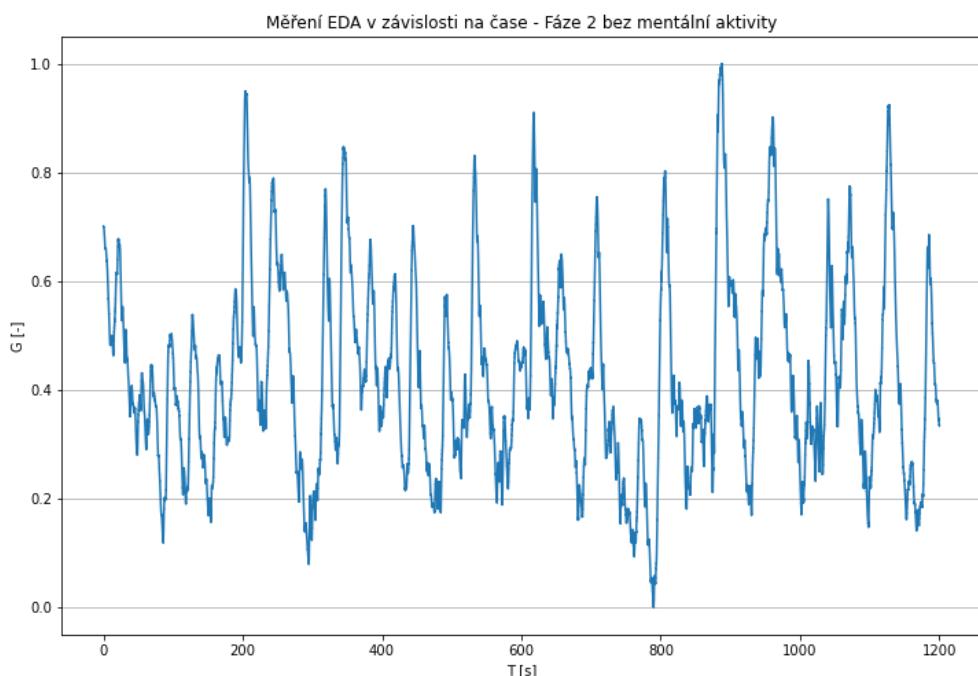


Obrázek 2.2 Vzorový průběh SCR v záznamu EDA [11]

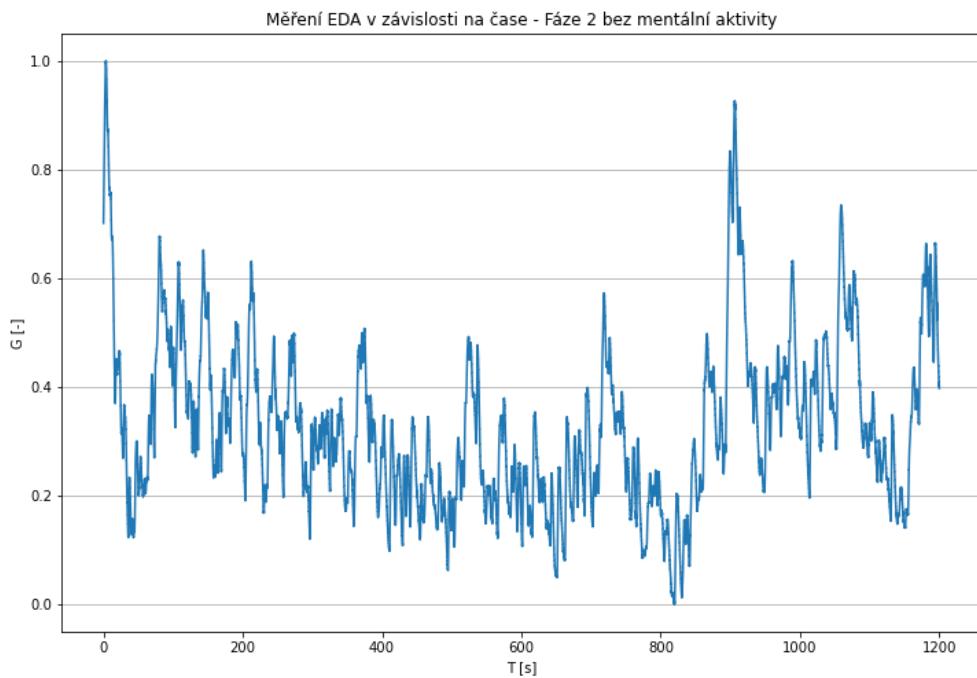
Obrázek 2.1 značí vzorový průběh signálu v záznamu EDA se vztahem tonických a fázických složek. Je zřejmé, že fázická komponenta se v signálu projevuje krátkými „výčnělkami“ vůči složce tónické s podstatně rychlejším průběhem. Anotace dat proběhla formou detekce jednotlivých píků jakožto lokálních maxim vyskytujících se v časovém průběhu záznamu signálu. Za účelem anotace co největšího množství odpovídajících SCR složek, v rámci procesu detekce lokálních maxim, byly experimentálně nastavovány parametry D , W , P v algoritmu detekce lokálních maxim. Původní hodnoty parametrů pro detekci byly nastaveny v souladu s teoretickými předpoklady fyziologických hodnot parametrů SCR (velikost amplitudy, doba náběhu, doba uklidnění), nadcházející úpravy hodnot parametrů byly stanoveny experimentálně, aby bylo detekováno co největší množství SCR složek. Konečné nastavení detekce je $D = 5s$, $W = 1s$, $P = 0,025$ (normalizovaný rozsah signálu). Segment signálu, v němž se responzivní složka vyskytuje, byl rovněž stanoven experimentálně s původní nastavenou hodnotou odpovídající předpokládané fyziologické hodnotě délky výskytu SCR složek 10 s. Nadcházející úpravy šíře intervalu vycházejí z experimentálního nastavení, aby bylo možné odlišit co nejvíce odpovídajících SCR složek v rámci stanoveného segmentu, který bude následně navrženým algoritmem klasifikován. Konečná experimentálně stanovovaná hodnota nastavení šíře segmentů signálu určených k anotaci je 5 s. Jednotlivé segmenty o časové délce 5 sekund byly anotovány podle polohy detekovaných lokálních maxim, jež jsou předpokládanými amplitudami SCR složek.

Obrázek 2.2 znázorňuje detail vzorového průběhu složky SCR včetně zobrazení některých důležitých měřitelných charakteristických parametrů. Díky velmi úzkému pásmu výskytu cílových složek SCR ve frekvenčním spektru kolem 0 Hz nebylo možné

signál upravit v programovém prostředí dostupnými filtry typu PP nebo HP pro odstranění SCL trendů. Míra šumu o vyšší frekvenci však nebyla v žádném vzorku záznamu významná, frekvenční maxima se vyskytovala převážně v rozsahu $< 0,05$; $0,4 > Hz$, což dle teoretických předpokladů odpovídá fyziologickým hodnotám výskytu SCR. S výjimkou dlouhodobých posuvů základní hodnoty měřené elektrodermální aktivity nebylo nezbytné dle frekvenční analýzy signál dále filtrovat. Signál je upraven odstraněním trendů vzniklých posuvy elektrody nebo pohybem měřené osoby. Následně byl rozsah signálu normalizován pro lepší porovnatelnost a pro účely klasifikaci neuronovou sítí, přičemž se jedná o jednu z nutných podmínek, aby zpracování a následná klasifikace modelu neuronové sítě bylo efektivní. Chybějící vzorky signálu v záznamu byly doplněny polynomální interpolací 5. stupně.

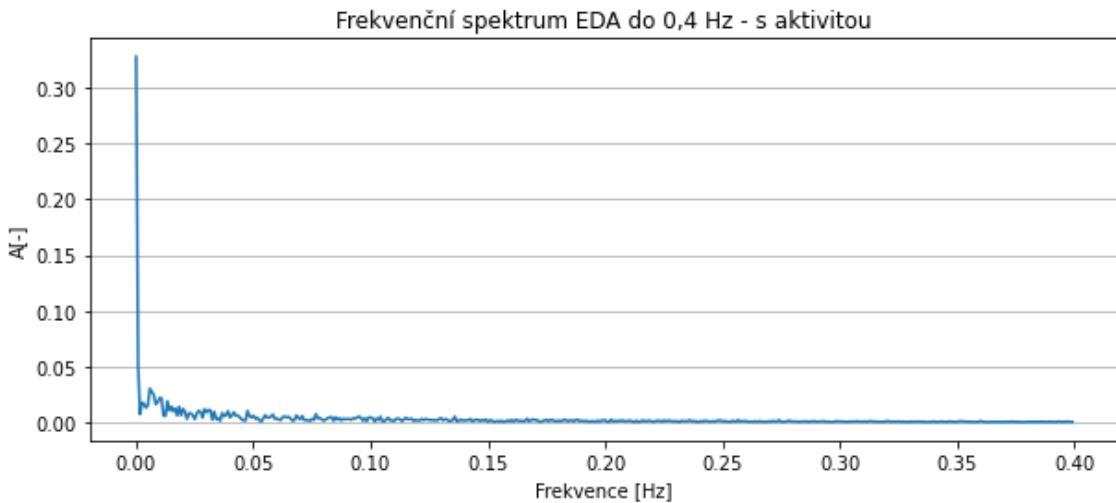


Obrázek 2.3 Naměřený záznam EDA bez mentální aktivity

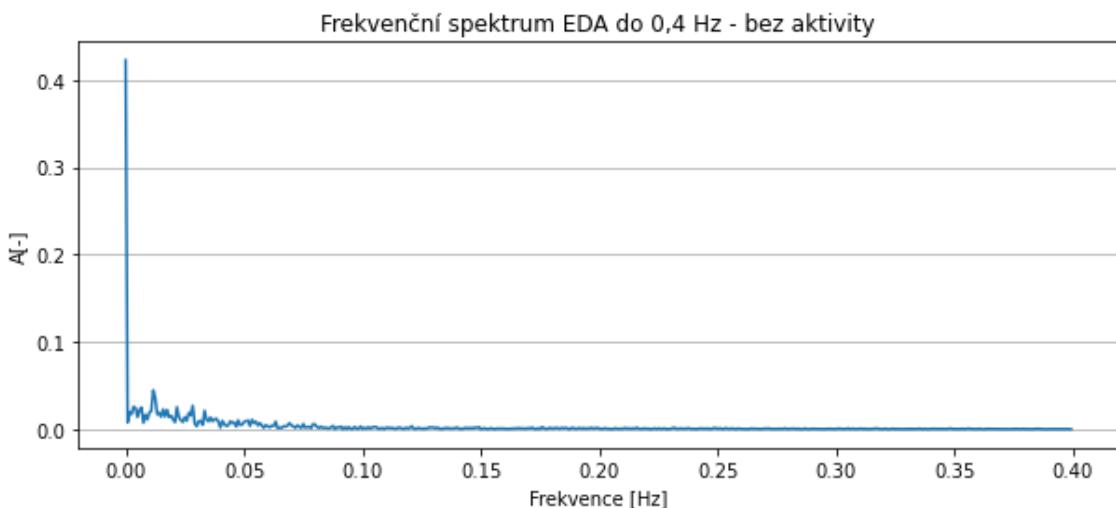


Obrázek 2.4 Naměřený záznam – mentální aktivita

Obrázky 2.3 a 2.4 zobrazují naměřené průběhy EDA se záznamy bez a s probíhající mentální aktivitou. Je zřejmé, že v případě, kdy měřená osoba podstupovala proces vyžadující vyšší míru psychického snažení, byl tento faktor následován vyšším mírou výskytu SCR složek o vyšší frekvenci. Nutno však podotknout, že na základě pozorování, pravděpodobně vzhledem k velkému vlivu individuálního psychického rozpoložení jedince, nebyl tento jev patrný ve všech záznamech. V některých případech byla míra výskytu responzivních složek v obou částech záznamu téměř identická nehledě na fázi experimentu.



Obrázek 2.5 Frekvenční spektrum – záznam s aktivitou



Obrázek 2.6 Frekvenční spektrum – záznam bez aktivity

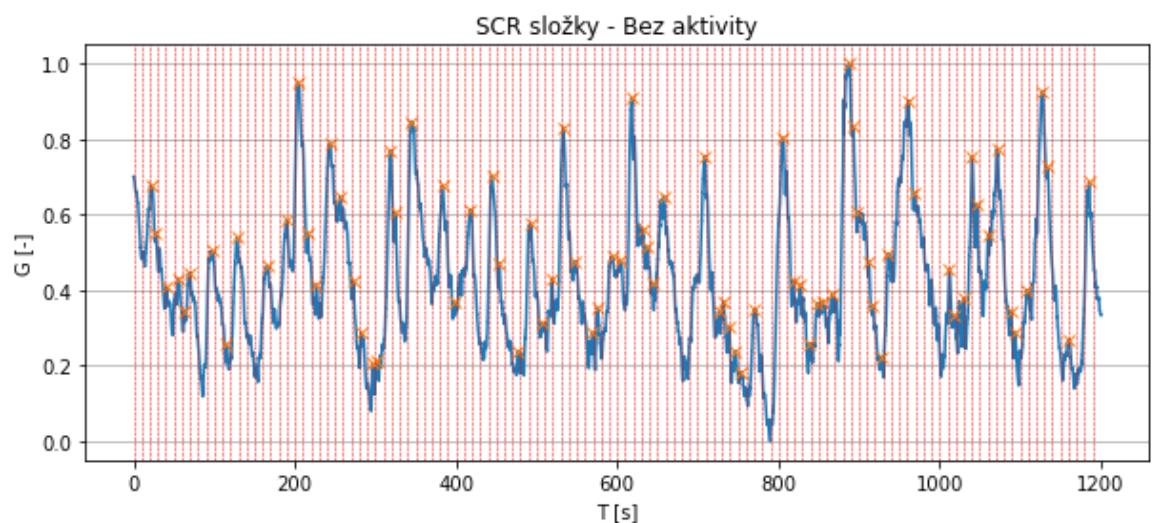
Obrázky 2.5, 2.6 znázorňují frekvenční rozsah signálu. Jak je patrné, není ani v jednom případě frekvenční rozsah z hlediska velikosti amplitud relevantních složek vyšší než 0,4 Hz. Převážný výskyt složek signálu se vyskytuje blízko hodnotě 0 Hz ve velmi úzkém pásmu. SCR složky s amplitudou podstatně nižší se nacházejí v pásmu cca $< 0,02; 0,2 >$ Hz. Z tohoto důvodu nebylo možné využít dostupných číslicových filtrů typu PP nebo HP za účelem extrakce SCR složek bez významné decimace původního záznamu. Z hlediska rozsahu užitečného frekvenčního pásma signálu se však nejednalo o nutný krok. V konečné fázi bylo nutné dodatečně datový set vybalancovat, aby počet segmentů s responzemi a bez nich byl vyrovnaný. Při použití nastavení segmentů a anotovaných složek je dominantní výskyt složek neresponzivních, datový set tak byl upraven tím způsobem, aby množství identifikovaných responzí bylo rovnoměrné se segmenty bez

anotovaných responzí. V opačném případě by navržená síť kvůli většímu množství neresponzivních složek nebyla schopna při daném vzorku dat přesně rozpoznat SCR, jelikož by byla během učící fáze tzv. „přehlcena“ segmenty neresponzivními.

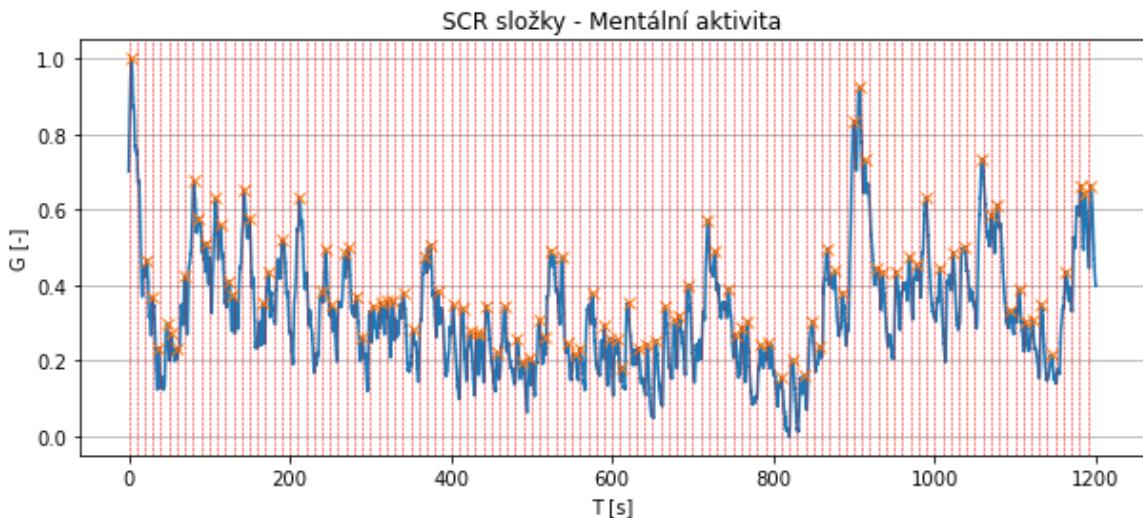
Z tohoto důvodu byl vytvořen vstupní dataset s anotovanými segmenty o časové délce 5 s podle obsahu responzivní složky v daném segmentu (viz. Obrázek 2.7). Kromě tohoto datasetu byly vytvořeny dodatečně datasety s celými záznamy všech měření podle stupně mentální aktivity. Tyto záznamy slouží pro závěrečnou evaluaci modelu pro porovnání rozdílů identifikace navrženým algoritmem hlubokého učení po procesech optimalizace, učení a validace dle úrovně aktivity jedince.

	Segmenty Signálu	Responzitivita
0	[0.8614718941629691, 0.8614718936001526, 0.861...	R
1	[0.3044897260366879, 0.30448933929104344, 0.30...	N
2	[0.23072945763584804, 0.2307291740072274, 0.23...	R
3	[0.7377376106133161, 0.7377690320228083, 0.737...	R
4	[0.3587078874778829, 0.35870778511133306, 0.35...	N

Obrázek 2.7 Náhled datasetu pro neuronovou síť



Obrázek 2.8 Rozsegmentovaný záznam s anotovanými SCR – bez aktivity



Obrázek 2.9 Rozsegmentovaný záznam s anotovanými SCR – aktivita

Obrázky 2.8 a 2.9 znázorňují vzorové provedení anotací SCR složek v rámci měřeného záznamu EDA. Zvolené parametry algoritmu pro detekci lokálních maxim byly nastavovány experimentálně za účelem zachycení co největšího počtu SCR, jak již bylo výše zmíněno. Finální nastavení parametrů vychází z experimentálního detekování ve všech dostupných záznamech měření. Vzhledem k relativně vysoké vzorkovací frekvenci $F_{vz} = 1000 \text{ Hz}$ vůči frekvenčnímu rozsahu měřeného signálu bylo v rámci datasetu provedeno podvzorkování segmentů o decimační faktor $d = 50$, kdy konečná délka hodnoceného segmentu činila 100 vzorků. K tomuto kroku bylo přistoupeno za účelem urychlit výpočetní procesy neuronové sítě, omezit riziko přeúčtení sítě vyplývající z velkého rozsahu vstupní vrstvy a nutnosti příliš navyšovat komplexnost modelu se zaměřením na významné rysy signálu nižší úrovně, které jsou pro klasifikaci 1D signálu nevhodnější. V neposlední řadě také snížit výpočetní náročnost vyplývající z technických prostředků, který byly pro řešení daného problému k dispozici s kláděním důrazu na efektivitu procesu klasifikace. Rozhodujícím faktorem byla velmi malá pásmová šířka složek signálu kolem 0 Hz ve frekvenčním spektru, kdy při dané vzorkovací frekvenci byl signál výrazně převzorkován z hlediska obsahu užitečných frekvenčních složek. V rámci experimentu bylo provedeno zkušební 10násobné navýšení rozsahu klasifikovaného segmentu signálu, což potvrdilo teorii o riziku rychlého přeúčtení. Docházelo tím k rychlému navýšení přesnosti a snížení ztrátovosti do menších limitních hodnot, avšak následně poté docházelo k postupnému poklesu úspěšnosti klasifikace při relativně nízké délce epoch. Algoritmy pro datový preprocessing, jež byly v této kapitole popsány, jsou implementovány v přiloženém souboru se skriptem zdrojového kódu **DataPreprocessing_DataSets.ipynb**

2.2 Návrh a implementace algoritmu

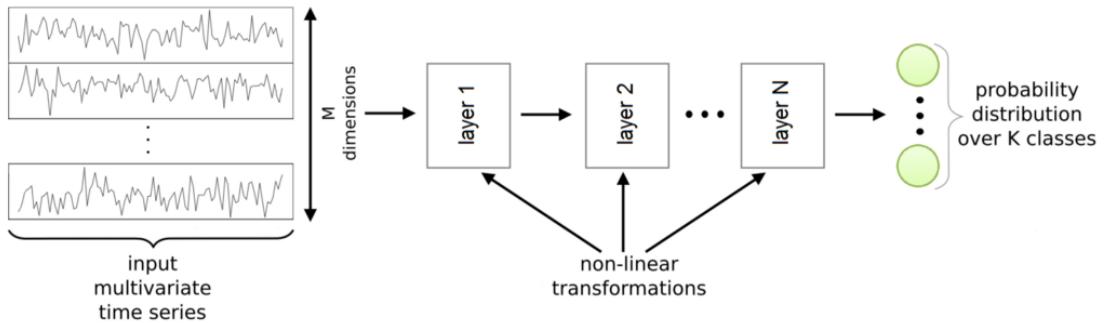
Tato kapitola je věnována popisu a definici implementačních kroků, z nichž závěrem vyplývá stanovení vhodného algoritmu typu hlubokého učení. Vzhledem k podstatě daného problému, jímž se tato práce zabývá (identifikace SCR složek v rámci 1D signálu, tedy specifických projevů vyskytujících se v časové oblasti), bylo usouzeno, že vhodným algoritmem je z hlediska aplikačního typ určený ke klasifikaci signálu, v tomto případě podle obsahu responzivní složky či naopak její absenci (pojednání viz kapitola 2.1). Pro tento účel bylo již vyvinuto a definováno velké množství modelů neuronových sítí, jenž je možné implementovat. V rámci této práce nebyl žádný model převzat z jiných publikací, ale byl odvozen tzv. „from scratch“, tedy od počátku.

Následující kapitola poskytuje krátké informační okénko několika analyzovaných efektivních užívaných algoritmů pro účely klasifikace zpracovávaných 1-D signálů a stručné uvedení principu jejich fungování. Výsledná analýza určuje výběr vhodného typu modelu neuronové sítě pro účel identifikace responzivní složky.

2.2.1 Výběr typu neuronové sítě pro klasifikaci

Aplikace modelu ANN standardní vícevrstvé perceptronové sítě se nejví jako příliš efektivní varianta. Zásadním nedostatkem v případě použití algoritmu tohoto druhu ke daného klasifikaci signálu je velké množství perceptronů ve vstupní vrstvě sítě, z čehož vyplývá velká výpočetní náročnost v rámci trénovacího i implementačního procesu a stejně tak delší výpočetní čas pro řešení daného problému. Dále je nutno podotknout, že kvůli složitosti modelu je zde velká pravděpodobnost dosažení stavu přeúčení sítě v relativně krátkém čase. Jako vhodná varianta se proto jeví využití modelů pracující na principu extrakce relevantních rysů (z angl. „*features*“) daného signálu, což jsou algoritmy hlubokého učení typu konvolučních. Získané charakteristiky následně slouží jako vstupní veličiny bloku klasifikačního algoritmu, který se skládá z vícevrstvé multiperceptronové neuronové sítě napodobující standardní rozhodující neuronovou síť ANN. Lze tak dosáhnout z teoretického hlediska relativně přesných výsledků vzhledem k použití konvolučních filtrů v předních vrstvách sítě za relativně krátký časový úsek.

Největší výhodou algoritmů typu CNN, vůči jiným metodám hlubokého učení určených k řešení obdobného problému, je to, že relevantní „*features*“ je se schopen algoritmus sám naučit a rozpoznat během trénovací fáze, aniž by musely být ručně fixně zadávány. Lze tak dosáhnout výsledků s dostatečnou přesností. Použití algoritmů typu CNN nevyžaduje díky vlastnímu nastavení vhodných rysů signálu pro klasifikaci rozsáhlou přípravu datasetu a tedy menší časovou náročnost tohoto procesu (např. pokročilé metody filtrace), protože tento proces je částečně zahrnut právě v konvolučních vrstvách.



Obrázek 2.10 Schéma zpracování 1-D signálu algoritmem hlubokého učení [33]

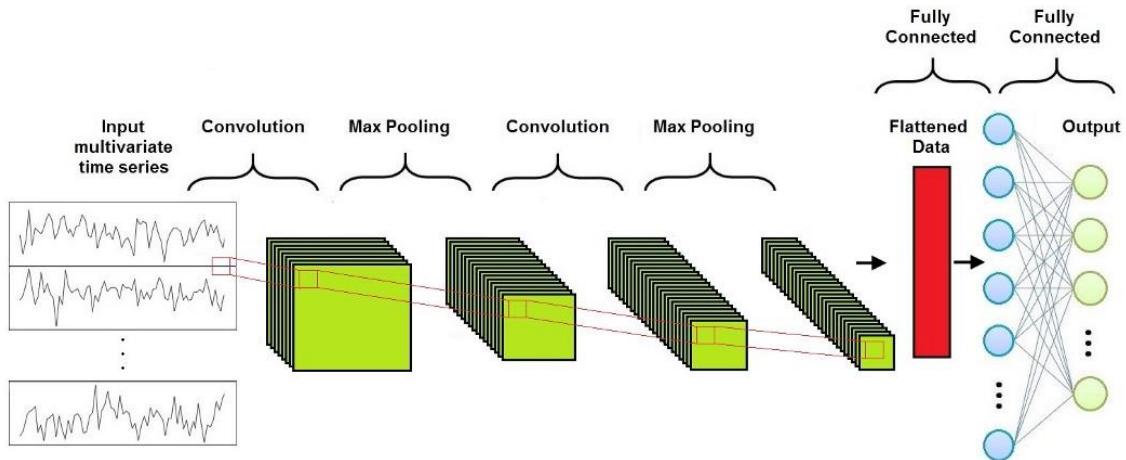
Obrázek 2.10 schematicky znázorňuje obecný proces klasifikace signálu v časové oblasti sítěmi typu CNN. Jedná se o kompozici více vrstev vzájemně propojených perceptronů implementující nelineární funkce. Vstupem může být jedno i vícerozměrný signál časové posloupnosti. Každá vrstva přebírá na svůj výstup výstup předešlé vrstvy a pomocí nelineární transformace přeypočítá nový výstup do podoby tzv. mapy „featurů“. Tento proces se prostupem signálu sítí opakuje, dokud není dosaženo konečného výstupu [32].

Proces nelineární transformace je řízen setem parametrů nastavených v každé vrstvě. Parametry váží vstup sítě, jenž je transformován na výstup. Následně jsou tyto parametry optimalizovány během učící fáze. Z pohledu aplikace pro daný problém byly analyzovány dvě varianty modelů pro identifikaci cílového artefaktu v signálu:

- **Konvoluční neuronová síť**
- **Incepční neuronová síť**

Konvoluční neuronová síť

Z angl. zkratky **CNN** se jedná o algoritmus hlubokého učení, jehož vstupem je buď obraz nebo jedno i vícerozměrný signál v časové oblasti. Základní předností algoritmu je jeho schopnost zachytit prostorové i časové vzorce (z angl. **pattern**) pomocí vrstev obsahujících konvoluční masky a následně na základě vlastní optimalizace přiřadit významnost jednotlivým vzorcům využitím optimalizovatelných vah vstupů perceptronů w . Datový preprocessing je o poznání méně náročný ve srovnání s jinými klasifikačními algoritmy. Žádaná je zejména schopnost CNN vlastního učení filtrů pro odhalení „patternů“ v signálu bez nutnosti jejich explicitní definice [33].



Obrázek 2.11 Schéma architektury sítě CNN [34]

Jak naznačeno na obrázku 2.11, principiálně se CNN skládá ze tří základních vrstev:

- **Konvoluční vrstva**
- „Zádržná“ vrstva (z angl. *MaxPooling Layer*)
- „Plně propojená“ vrstva (z angl. *Fully-Connected Layer*)

Konvoluční vrstva je základním stavebním prvkem CNN, jak sám její název napovídá. Její funkcí je výpočet konvoluce na vstupní časové sérii vzorků dat filtrovací maskou, čímž se získá mapa rysů signálu s cílem extrahat víceroznové vlastnosti signálu, které jsou následně prostupem sítě zpracovávány. Samotná konvoluce je vykonána sadou filtrů fixní velikosti v každé vrstvě. Výstupem filtrace konvoluční vrstvou je vektor „featurů“ série vzorků o délce menší, než je vstupní vektor hodnot odpovídající velikosti konvolučního jádra filtru. Konvoluční vrstva provádí konvoluci mezi všemi filtry a všemi vstupními vzorky mapy „featurů“. Na výstupu vrstvy je získána nová mapa „featurů“ o menších rozměrech vyššího rádu. Váhy filtrů jsou naučitelné a jsou optimalizovány během učícího procesu. Důležitými parametry CNN je délka kroku konvoluce (z angl. *Strides*) a míra výplně výstupní mapy kvůli konvoluci redukovanému počtu vzorků (z angl. *Padding*).

Strides parametr má za účel nastavení délky posunu konvolučního filtru během procesu filtrování, to jest kolik vzorků bude během aplikace masky „přeskočeno“.

Padding parametr indikuje, kolik vzorků bude přidáno do vstupní mapy „featurů“ před aplikací konvolučních filtrů, aby byla snížena redukce rozsahu vstupního signálu nebo zůstala zachována v původní podobě. Tato funkce je významná z pohledu zpracování signálu následujícími vrstvami sítě, protože mapa „featurů“ by v dalších krocích procesu zpracování mohla být příliš redukovaná a mohlo by dojít ke ztrátě relevantních informací. Nežádoucím efektem na druhou stranu může být redukce intenzity rysů v segmentu, které se vyskytuje blízko hranic zkoumaného vzorku.

Zádržná vrstva má za účel tzv. „zastropování“ průchozí mapy featurů pro dosažení redukce dimenzionality při zachování co největšího množství informací z extrahovaných rysů signálu. Vrstva je vhodná pro extrakci dominantních rysů v signálu, které jsou časově invariantní. Vstupem je, stejně jako v předchozích vrstvách, mapa featurů a výstupem je série odlišných map nižšího rozsahu. *Pooling* skrze klouzavé okno pevných rozměrů je aplikován pro každou vstupní mapu. Jsou zde dva různé přístupy operace, tzv. *Max Pooling* (maximální hodnota vybrána v rámci polohy klouzavého okna) a *Average Pooling* (v rámci polohy klouzavého okna je vypočítána průměrná hodnota z překrývajících se hodnot vstupní mapy). Výhodou *Max Pooling* je, že funguje jako filtr k potlačení přítomného šumu. Je vhodnější volbou než *Average pooling* pro signál, kde je míra přítomnosti šumu vyšší a mohlo by dojít k potlačení vysokofrekvenčních složek. Stejně jako v případě konvoluční vrstvy i zde jsou nastavitelné parametry *Stride* a *Padding*. Výhodou zádržné vrstvy je funkce podvzorkování konvolučního výstupního pásma, čímž je redukována variabilita skrytých aktivací.

Plně propojená vrstva má za význam naučení se nelineárních kombinací featurů vysoké úrovňě na výstupu z předchozích vrstev konvolučních. Tuto vrstvu reprezentuje vícevrstevná síť perceptronů. Vstupem je předzpracována mapa featurů, která prostupuje jednotlivými vrstvami ANN s váženými vstupy, jejichž hodnota je optimalizována během trénovacího procesu. Konečnou vrstvou je rozhodovací klasifikační vrstva o počtu perceptronů odpovídající počtu klasifikačních tříd. Zpětná propagace chyby je aplikována pro každou iteraci trénovací části. Během série opakování epoch učení je model v ideálním případě v konečné fázi schopen rozlišit vstupní časovou sérii díky dominantním vysokoúrovňovým featurům a následně je klasifikovat do korektní třídy s určitou přesností a z ní vyplývající mírou nejistoty.

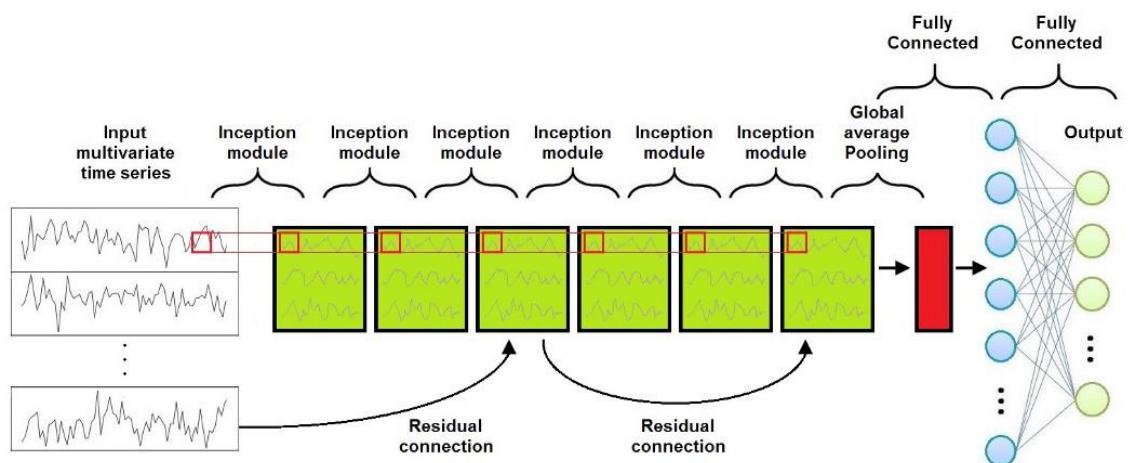
Nejdůležitějšími hyperparametry sítě jsou

- **Počet konvolučních filtrů**
- **Rozměr konvolučního filtru a počáteční hodnoty**
- **Metoda Poolingu a rozměr vrstvy**
- **Inicializační váhy**
- **Aktivační funkce**
- **Počet epoch**

Incepční neuronová síť

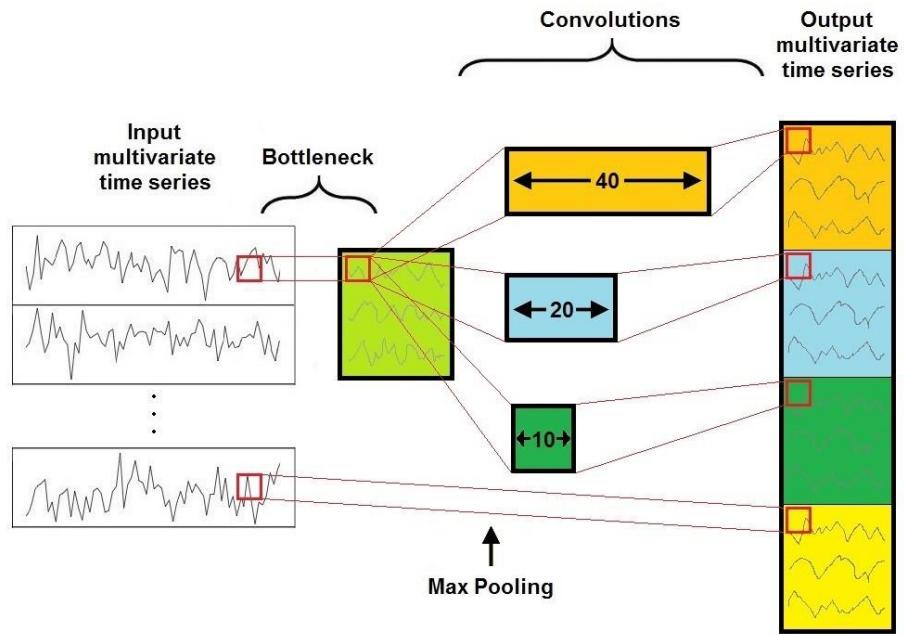
Jedná se o speciální druh aplikace sítě typu CNN. Představuje poměrně novou architekturu a vykazuje vysokou míru přesnosti a schopnost konzistentní klasifikace artefaktů v signálech.

Architektura INN je obdobná architektuře „klasické“ CNN s tím rozdílem, že vrstvy konvoluční a zádržné jsou umístěny v tzv. **incepčních modulech**.



Obrázek 2.12 Schematické znázornění architektury INN [34]

Jak je patrno z obrázku 2.12, INN se skládá ze série za sebou následujících Incepčních modulech na výstupu zakončených globální *Average Pooling* vrstvou a ANN vrstvou. V rámci modelu je přidruženo residuální propojení směřující do každého třetího incepčního modulu. Každý vstup residuálního bloku je transferován přes zkratku lineárním spojením, aby mohl být následně přidán do vstupu dalšího bloku. Tímto dochází k rozmělnění problému mizejícího gradientu díky jeho přímého prostupu skrze vrstvy neuronové sítě [35].



Obrázek 2.13 Schematické znázornění funkce Incepčního bloku [35]

Obrázkem 2.13 je znázorněna struktura incepčního modulu, jenž se skládá že čtyř vrstev:

- „**Bottleneck**“ vrstva – dochází zde k redukci dimenziality vstupů, pokud je k dispozici takový signál z více kanálů. Je tím redukován počet parametrů k naučení a také výpočetní zátěž a vyšší míra generalizace komplexních vzorců.
- **Paralelní konvoluční vrstvy** – konvoluční masky rozdílných rozměrů aplikované na stejné vstupní mapy featurů.
- **MaxPooling** – slouží k odstranění vlivu menších pertuberací na celkový výsledek.
- **Hluboká zřetězená vrstva** – dochází ke zřetězení výstupu každého nezávislého paralelního konvolučního filtru a MaxPooling vrstvy, čímž je zformován výstup multivariantní časové série daného incepčního modulu.

Zavedením více incepčních modulů a optimalizováním hodnot konvolučních filtrov skrze zpětnou propagaci, je síť schopna extrahovat latentní hierarchické featury s různým rozlišením s využitím filtrov rozdílných rozměrů. Jedná se o esenciální přednost incepčního modulu, jelikož je umožněno vrstvám uvnitř modulu vybrat si relevantní šířku filtru pro zisk rozhodujícího rysu signálu. Díky tomu lze identifikovat rozdílné vysokoúrovňové rysy, které mohou mít rozdílné rozměry na rozdílných vstupních mapách featurů.

Receptivní pole je klíčovým parametrem k porozumění INN. Na rozdíl od sítí ANN, v tomto případě neuron přijímá informace mapy featury pouze z dané oblasti. Tato oblast se nazývá **receptivním polem**. Je zřejmé, že neurony hlubších vrstev registrují užší pole featurů než neurony vrstev vyšších. Neurony hlubších vrstev tak zachycují lokální struktury časové série, zatímco neurony z vrstev vyšších identifikují komplexnější vzorce obsažených v signálu. Hodnota receptivního pole je závislá na počtu incepčních modulů (hloubce vrstvy) a šířce filtru v dané vrstvě určitého neuronu. Za pozornost stojí sledování přesnosti klasifikace podle hodnoty receptivního pole. Obecně je platné pravidlo, pokud je filtr delší, tím je dosaženo přesnějších výsledků, protože v případě delšího konvolučního filtru je vyšší pravděpodobnost zachycení žádoucího rysu patterny [37]. Naopak zvýšení receptivního pole pomocí zvýšení hloubky vrstev neznamená nutně zlepšení výkonu sítě, což lze pozorovat v případě, pokud je datový set příliš malý, protože síť se tak není schopna adekvátně naučit vrstvy hlubší. Proto při optimalizaci klasifikace sítě INN je vhodnější měnit nastavení délky filtrů nežli jeho hloubku.

Na základě pozorování mnoha provedených experimentů byla zjištěno, že INN s jedním incepčním modulem produkuje výsledky s vysokým rozptylem. Nekonzistentnost však může být způsobena variabilitou nastavení náhodných inicializačních hodnot vah, což se více projeví u sítě menší hloubky. Tomuto jevu lze předejít zavedením více incepčních modulů, kdy každá predikce má následně svou vlastní váhu. Tímto lze dosáhnout stability hodnocení algoritmu, stejně tak přesnosti a schopnosti klasifikace. Různými experimenty bylo dokázáno, že časová komplexnost roste lineárně s rozměrem trénovacího setu a délky vstupní časové série, na rozdíl od jiných algoritmů strojového učení, kde tato komplexnost roste kvadraticky při stejných změnách.

Závěr analýzy

V rámci analýzy algoritmů hlubokého učení byla pozornost zaměřena na algoritmy využívající konvolučních vrstev díky jejich schopnosti vyjmout ze signálu důležité rysy za nižší výpočetní náročnost. Tyto algoritmy jsou následně použity pro výslednou klasifikaci a identifikaci responzivní složky v záznamech EDA dle účelu této práce. Algoritmy jsou schopny zachytit prostorové i časové vzorce v signálech, kdy jednotlivé použité filtry jsou nastavitelné pomocí vah transformace vstupů. Tato esenciální přednost metody byla rozhodujícím faktorem pro využití algoritmu tohoto typu.

U klasických CNN může být problematická jejich vyšší závislost na rozsahu a kvalitě trénovacích dat. Zvláště v případě, kdy je vstupní záznam příliš dlouhý, může být proces trénování výrazně zpomalen zejména u multivariantních signálů. Stejně tak nemusí být dosaženo výsledků s očekávanou přesností, pokud jsou data nekonzistentní, kdy stejný relevantní rys může mít rozdílnou šířku apod. Incepční neuronová síť se jeví jako vhodná varianta rezistentní vůči těmto nedostatkům, pokud je signál více variantní s nejasnou

patternou artefaktu, který je určen k identifikaci. Velkou výhodou je urychlení procesu trénování redukcí dimenzionality signálu a možnost zpracování vstupní časové série, kdy hledaný rys může mít rozdílnou velikost sledovaného parametru.

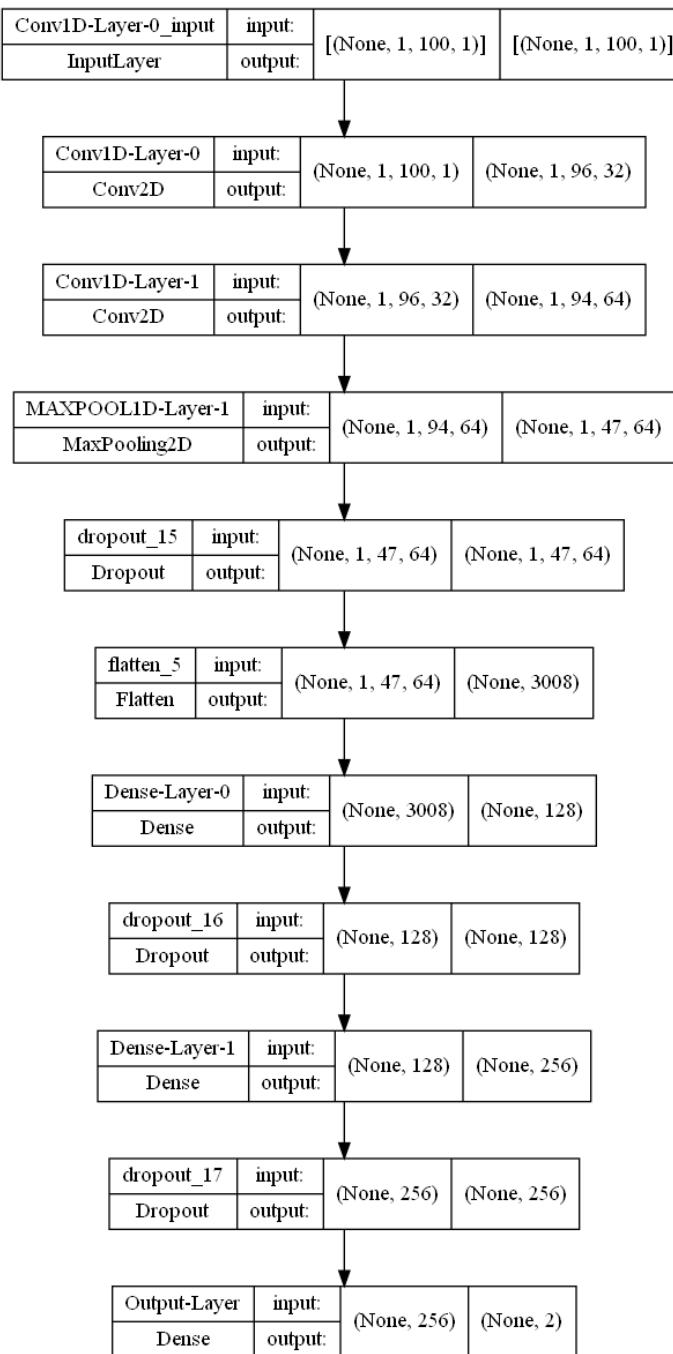
V tomto případě však není uvažován 1-D signál o vysoké dimenzionalitě, kterou by bylo potřeba redukovat. Datový set určený pro trénování je poměrně obsáhlý, kdy jsou k dispozici data záznamu EDA měřených za různých podmínek, jež jsou v rozsegmentované podobě vpouštěny do sítě. Nedostatek chybné klasifikace při výskytu feature o jiném rozměru lze kompenzovat zčásti dostatečně velkým datovým setem a vhodnou technikou optimalizace pro zabránění přeúčení sítě na vstupních datech (např. využitím **Dropout** vrstvy v konvoluční části sítě). Dalším vhodným prostředkem, jak docílit minimalizace nedostatku chybné klasifikace u nekonzistentních dat, je vhodné nastavení šířky konvoluční masky a **MaxPool** vrstvy pro relevantní rys různé šířky byl zachycen, konvoluční sítí zpracován a následně odfiltrován **MaxPool** vrstvou. Standardní síť CNN poskytuje dostatečně vysokou míru efektivity a přesnosti, co se týče klasifikace signálu nižší dimenzionality, bez nutnosti příliš zvyšovat komplexnost modelu, proto pro návrh algoritmu pro identifikaci responzivní složky je uvažována síť typu CNN.

2.3 Návrh a realizace neuronové sítě

Na základě získaných teoretických poznatků uvedených v kapitole 2.2.1 je pro daný účel uvažován návrh neuronové sítě typu CNN. Jednotlivé segmenty získané během datového preprocessingu jsou podrobeny klasifikaci algoritmem hlubokého učení určující obsah responzivní složky nebo její absenci v binární podobě. Vstupními daty pro neuronovou síť jsou segmenty záznamu EDA vytvořené dle postupů uvedených v kapitole 2.1, vyhodnocovanou výstupní cílovou proměnnou je klasifikační třída určující, zdali je SCR složka v segmentu přítomna.

Síť je navržena na základě doporučení z dostupné literatury pro potřebu zpracování signálů klasifikací sítěmi typu CNN, z volně dostupných zdrojových kódů s algoritmy využitých pro obdobný účel a na základě doporučení *Dr. Kumarana Ponnambalamy*, s nímž proběhla konzultace řešení daného problému.

Výchozí struktura modelu, který je pro daný problém navržen, je v sumarizované podobě s popisem jednotlivých vrstev ilustrován Obrázkem **Chyba! Nenalezen zdroj odkazu..**. Daný model byl sestaven experimentálně, na základě osvojených teoretických znalostí a získaných doporučení pro klasifikaci signálu se složitěji odhadovatelnými patternami pro jedno i vícerozměrné signály. Pro identifikaci SCR složky vyskytující se v časové posloupnosti signálu je, vzhledem k vícefázickému projevu složky, původně navržen model s dvěma konvolučními úrovněmi pro zachycení méně patrných rysů linií vyšší úrovně.



Obrázek 2.14 Struktura návrhu výchozího modelu

2.3.1 Sestavení sítě

Následující popis jednotlivých elementů sítě vychází z přiloženého Obrázku **Chyba! Nenalezen zdroj odkazů.** a názvu jednotlivých bloků, které jsou zde uvedeny. Základními bloky přední části sítě jsou dvě za sebou jdoucí konvoluční vrstvy.

Vstupní vrstva (**Conv1D-Layer-0**) je implementována za účelem zachycení tvaru linií signálu a rysů nižší úrovně vstupního vzorku. Druhá konvoluční vrstva (**Conv1D-Layer-1**) je zakomponována k extrakci rysů vyšší úrovně z předchozí vrstvy.

Následuje vrstva „zádržného“ filtru (**MAXPOOL1D-Layer-1**) určeného k odstínování pertuberací a menších šumů v analyzovaném segmentu. Vrstva navíc umožňuje, aby získané rysy z předchozích konvolučních vrstev nebyly váženy podle polohy SCR v klasifikovaném segmentu signálu a získaná “feature” sadou konvolučních filtrů byla invariantní vůči poloze v rámci segmentu.

Pod touto vrstvou se nachází vrstva “výpustě” náhodně zvolených spojení vedoucích k následujícím vrstvám (**dropout_15**). Tato vrstva slouží k zabránění přeúčení elementů vrstev pod ní se nacházející zablokováním náhodně zvolených drah k nim vedoucích. Míra blokace náhodně zvolených spojení mezi perceptry je určena parametrem **Dropout**, jenž odpovídá procentuálnímu množství náhodně zvolených odpojených drah signálu.

Poslední vrstvou v konvoluční části sítě je zplošťující vrstva (**flatten_5**) sloužící k linearizaci vstupního signálu, jelikož konvoluční sítě jsou primárně nastaveny pro zpracování vícedimenzionálních signálů. Linearizací je získán tvar signálu vhodný pro zpracování následující multiperceptronovou částí modelu sítě.

V návaznosti na konvoluční část následuje vrstva multiperceptronová densní vrstva (**Dense-Layer-0**). Jedná se o první vrstvu v části ANN určené k vážení mapy featurů získaných zpracováním vstupního vzorku konvoluční části a transformaci na vstup do další vrstvy. Následuje *Dropout* (**dropout_16**) vrstva, jejíž smysl byl již popsán, následuje druhá densní vrstva (**Dense-Layer-1**), jenž provádí vážení druhého stupně transformovaného signálu a následně je doplněna další *Dropout* vrstvou (**dropout_17**).

Koncovým prvkem je výstupní vrstva (**Output-Layer**) určená ke klasifikaci do rozhodujících tříd, v tomto případě dvou (**Responsitivita / Bez responzitivity**) odpovídající počtu výstupních perceptronů nastavených ve vrstvě. Algoritmus implementující navržený a následně optimalizovaný model se nachází ve skriptu souboru **DefaultModelCreate.ipynb**.

2.3.2 Nastavení parametrů a hyperparametrů

Nastavené parametry a hyperparametry výchozího modelu definuje Tabulka 2.1 Uvedená konfigurace nastavení vychází z empirických zkušeností aplikace CNN při řešení klasifikačních problémů, z volně dostupných algoritmů a na základě doporučení expertů v oblasti využívání algoritmů hlubokého učení pro datové analýzy. Stanovené parametry a hyperparametry byly použity pro výchozí nastavení modelu, v průběhu optimalizace experimentální části byly jejich hodnoty dále upravovány s cílem dosáhnout nejlepších výsledků klasifikace.

Parametry modelu určují základní nastavení a konfiguraci navržené sítě, jejichž hodnota je v průběhu trénovací fáze dále optimalizována (váhy, aditivní složky perceptronů, váhy konvolučních masek v případě CNN apod.).

Hyperparametry sítě určují základní strukturu sítě a nastavení trénovacího procesu (počet epoch, velikost batch, aktivační funkce, krok učení, počet vrstev, počet perceptronů atd.)

Šířky konvolučních filtrů jsou pro výchozí model nastaveny o řád menší, než je vstupní rozsah signálu pro zachycení rysů lokálního charakteru, který se v segmentu může vyskytovat při výskytu SCR. Šířka filtrů následující vrstvy je nastavena na nižší hodnotu pro zesílení váhy lokálních rysů v liniích signálu a pro menší redukci vstupní mapy feature, což by mohlo negativně ovlivnit následné zpracování signálu v dalších vrstvách. Hodnoty počtu konvolučních filtrů ve vrstvách jsou nastaveny dle doporučení z jiných příkladů aplikace CNN, vícenásobný počet v druhé konvoluční vrstvě je nastaven z toho důvodu, aby mohlo být maskou zachyceno větší množství rysů vyšší úrovně v lokálním měřítku, které mohou být charakteristické pro SCR složky. Velikost zádržné vrstvy byla nastavena na hodnotu nižší než šíře konvolučních masek, aby nedocházelo k významné redukci procházejícího signálu, jehož rozsah by poté nemusel být dostatečný pro následující vrstvy, čímž by mohlo docházet k negativnímu vlivu na výsledné vážení získaných feature. Dropout vrstva je vložena, aby nedocházelo k rychlému přeúčení navazujících ANN vrstev, mezi něž je tato vrstva umístěna ze stejného důvodu. Nastavení parametrů denších vrstev ANN časti vychází ze standardního nastavení pro klasifikaci signálu menších rozměrů. Počet perceptronů v každé vrstvě je dvojnásobný oproti vrstvě předchozí, aby rysy signálu vyššího řádu byly pro klasifikační vrstvu váhově silnější, čímž by teoreticky měla být přesnější klasifikace. Nastavení aktivační funkce v poslední rozhodovací vrstvě odpovídá standardně užívanému nastavení pro algoritmy klasifikačního typu s binárním výstupem.

Tabulka 2.1 Nastavené parametry a hyperparametry výchozího modelu

Název vrstvy	Parametr	Hodnota
Conv1D-Layer-0	Počet konv. filtrů	32
	Šířka konv. filtrů	5
	Iniciace aditivní složky	Zeros
	Iniciace vah konvoluce	Glorot Uniform
	Aktivační funkce	ReLU
	Regularizace	None
Conv1D-Layer-1	Počet konv. filtrů	64
	Šířka konv. filtrů	3
	Iniciace aditivní složky	Zeros

	Iniciace vah konvoluce	Glorot Uniform
	Aktivační funkce	ReLU
	Regularizace	None
MAXPOOL1D-Layer-1	Šířka filtru	2
dropout_12	Pravděpodobnost blokace	0,2
flatten_4	-	-
Dense-Layer-0	Počet perceptronů	128
	Iniciace vah	Random Normal
	Iniciace aditivní složky	Zeros
	Aktivační funkce	ReLU
	Regularizace	None
dropout_13	Pravděpodobnost blokace	0,25
Dense-Layer-1	Počet perceptronů	256
	Iniciace vah	Random Normal
	Iniciace aditivní složky	Zeros
	Aktivační funkce	ReLU
	Regularizace	None
dropout_14	Pravděpodobnost blokace	0,25
Output-Layer	Počet perceptronů	2
	Aktivační funkce	Softmax

Tabulka 2.2 Hyperparametry pro učící a validační proces

Název	Popis	Hodnota
Optimalizační algoritmus	Algoritmus minimalizace ztrátové funkce	RSMprop
Učící krok	Míra redukce ztrátové funkce	0,001
Ztrátová funkce	Metoda výpočtu chyby výstupu	Binary Cross Entropy
Počet epoch	Počet časových intervalů vyhodnocení přesnosti učení	10
Velikost Batch	Počet vzorků vpuštěných do sítě během epochy	16
Validační poměr	Poměr rozdělení trénovacích, validačních a testovacích dat	0,2
Batch normalizace	Vrstva normalizace vstupních hodnot z předchozí densní vrstvy	None

Metriky	Metody výpočtu úspěšnosti klasifikace	Přesnost, ztrátovost, preciznost, senzitivita
----------------	---------------------------------------	---

Tabulka 2.2 definuje základní nastavení hyperparametrů trénovacího a validačního procesu. Validační poměr byl nastaven na základě standardně užívaného poměru pro většinu algoritmů strojového učení z dostupné literatury. Optimalizační algoritmus byl zvolen experimentálně. Délka učícího kroku vychází z explicitně doloženého vhodného rozsahu pro efektivní učící proces u sítí menší hloubky. Pro účely této aplikace byla zvolena hodnota hraničního minima vhodného prakticky užívaného rozsahu. Výběr výpočtu ztrátové funkce definující chybu výpočtu v rámci cyklu běhu algoritmu je zvolen z pohledu problému binární klasifikace, v tomto případě identifikace segmentu podle obsahu responze nebo její absence. Základní délka epochy je nastavena na nejmenší prakticky užívanou hodnotu pro cykly základní optimalizace, velikost **Batch** je taktéž nastavena pro počáteční fázi na nejmenší vhodnou hodnotu dle doporučení z dostupných zdrojů. Normalizační vrstva **Batch** je v rámci výchozího nastavení vyjmuta. Zvolené metriky použité pro hodnocení úspěšnosti identifikace, trénovací a validační fáze definuje Tabulka 2.3. Definované metriky byly zvoleny na základě standardně užívaných metod hodnocení skórovacího systému pro hodnocení klasifikace. Z praktických důvodů budou metriky nadále v práci uváděny svými anglickými názvy.

Tabulka 2.3 Definice zvolených metrik

Metrika	Angl. užívaný název	Definice
Přesnost	<i>Accuracy</i>	$\frac{(TP + TN)}{(TP + TN + FP + FN)}$
Ztrátovost	<i>Loss</i>	Výpočet podle ztrátové funkce
Precize	<i>Precision</i>	$\frac{(TP)}{(TP + FP)}$
Senzitivita	<i>Recall</i>	$\frac{(TP)}{(TP + FN)}$

2.4 Návrh procesu učení a optimalizace sítě

V rámci návrhu vhodného algoritmu hlubokého učení je stanoven optimalizační proces struktury sítě a trénovací fáze za účelem dosažení efektivního algoritmu neuronové sítě identifikující SCR složky pomocí klasifikace. Optimalizace je měřena pomocí zvolených výše zmíněných metrik a učící a validační proces je řízen chybou funkcí vypočítávající Loss.

2.4.1 Optimalizace struktury sítě

Optimalizace hyperparametrů definující strukturu sítě a parametrů určující hodnotu jednotlivých výpočetních elementů v rámci vrstev se skládá z několika kroků, které jsou uvedeny v následujících sekcích s příslušnými tabulkami hodnot. Uvedené postupy optimalizace byly provedeny při základním nastavení hyperparametrů učení sítě **10 epoch** a velikosti **batch 16**.

Konvoluční část – nastavení pořadí MaxPool a Dropout vrstev

Prvním krokem optimalizace struktury sítě bylo spouštění učící a validační fáze při základní konfiguraci modelu se sekvencí vrstev **MaxPool-Dropout** a následně stejný proces je proveden jejich prohozením v rámci sítě. **Dropout** s nastavenou mírou odpojení náhodně zvolených vazeb mezi perceptrony vrstev má za úkol zabránit rychlému přeúčtení. Cílem je sledovat vliv na úspěšnost klasifikace, pokud se vloží před **MaxPool** vrstva, což může omezit vstupní vzorek pro zastropování mapy featurů, ale lze také teoreticky dosáhnout optimálnějšího nastavení vah předchozích konvolučních vrstev. V rámci postupu byla měřena Accuracy a Loss během trénovací fáze při základním nastavení.

Konvoluční část – nastavení počtu vrstev

Dalším krokem optimalizace konfigurace struktury modelu bylo nastavení počtu konvolučních vrstev při základním nastavení počtu konvolučních filtrů použitých v každé vrstvě. Tabulka 2.4 zobrazuje navržené experimentální konfigurace pro ladění a optimalizace modelu, resp. jeho konvoluční části.

Tabulka 2.4 Konfigurace nastavení počtu konv. vrstev

Konfigurace	Počet filtrů	Počet vrstev
1	32	1
2	32	2
3	32	3

Konvoluční část – nastavení počtu vrstev

V rámci další fáze optimalizace konvoluční části sítě je stanovena konfigurace počtu vrstev s různým počtem konvolučních filtrů. Konfigurace navrženého nastavení uvádí tabulka 2.5.

Tabulka 2.5 Konfigurace nastavení konv. vrstev – filtrů

Konfigurace	Počet filtrů	Počet vrstev
1	32	1
2	32	2
3	64	1
4	64	2
5	96	1
6	96	2

Konvoluční část – nastavení šířky konvolučních filtrů

Dalším navrženým krokem optimalizace struktury konvoluční části sítě je běh trénovací a validační fáze implementovaného modelu při nastavení různých šírek konvolučních filtrů v rámci jednotlivých konvolučních vrstev. Zvolené experimentální nastavení definuje Tabulka 2.6.

Tabulka 2.6 Konfigurace nastavení šířky filtrů

Konfigurace	Počet filtrů	Počet vrstev	Šířka filtrů
1	32	1	5
2	32	2	5
3	32	1	7
4	32	2	7
5	32	1	9
6	32	2	9
7	32	1	11
8	32	2	11
9	32	1	13
10	32	2	13
11	32	1	15
12	32	2	15

Konvoluční část – nastavení iniciace vah

Optimalizovány jsou i matematické postupy iniciace původních hodnot vah konvolučních filtrů v jednotlivých vrstvách konvoluční části sítě. Tabulka 2.7 stanovuje použité metody nastavení inicializace vah. Zvolené metody byly čerpány z webové stránky knihoven **Keras**.

Tabulka 2.7 Nastavení inicializace vah konvoluce

Konfigurace	Inicializace
1	Random Normal
2	Random Uniform
3	Ones
4	Zeros
5	Truncated Normal
6	Variance Scaling
7	Glorot Normal
8	Glorot Uniform
9	HeNormal
10	HeUniform

Konvoluční část – šířka MaxPool a míry Dropout

V rámci poslední fáze optimalizace konvoluční části byly použity konfigurace nastavení šířky **MaxPool** a míry **Dropout**. Tabulka 2.8 definuje zvolené experimentální nastavení hyperparametrů.

Tabulka 2.8 Konfigurace šířka MaxPool – Dropout

Konfigurace	Šířka MaxPool	Dropout
1	2	0,0
2	2	0,1
3	2	0,2
4	2	0,5
5	3	0,0
6	3	0,1
7	3	0,2
8	3	0,5
9	5	0,0
10	5	0,1

11	5	0,2
12	5	0,5
13	9	0,0
14	9	0,1
15	9	0,2
16	9	0,5

Densní část – nastavení počtu vrstev

Následovala optimalizace multiperceptronové části sítě analogickým způsobem jako při předechozí popsané optimalizaci v konvoluční části. Prvním krokem určení optimálního nastavení bylo stanovit vhodný počet vrstev o počtu perceptronů odpovídající základnímu nastavení modelu. Tabulka 2.9 určuje konfigurace nastavení struktury modelu s různým počtem vrstev ANN.

Tabulka 2.9 Konfigurace nastavení počtu vrstev ANN

Konfigurace	Počet perceptronů	Počet vrstev
1	128	1
2	128	2
3	128	3

Densní část – nastavení počtu perceptronů ve vrstvách

Další fází optimalizace struktury ANN bylo stanovení vhodného počtu perceptronů v jednotlivých vrstvách. Tyto hodnoty byly voleny na základě doporučení a standardně užívaných nastavení pro obdobné aplikace. Tabulka 2.10 stanovuje použité navržené konfigurace.

Tabulka 2.10 Konfigurace nastavení počtu perceptronů ve vrstvách

Konfigurace	Počet perceptronů	Počet vrstev
1	64	64
2	128	128
3	192	192
4	256	256

Densní část – nastavení aktivační funkce perceptronů

Dalším krokem byla optimalizace použité aktivační funkce perceptronů densních vrstev. Experimentální optimalizační nastavení se netýká vrstvy výstupní pro konečnou klasifikaci, kde byla fixně stanovena aktivační funkce *Softmax*, jenž je prokazatelně nejvhodnějším typem pro rozhodující algoritmy s výstupem binárního typu.

Tabulka 2.11 Konfigurace aktivační funkce perceptronů

Konfigurace	Aktivační funkce
1	ReLU
2	Sigmoid
3	Tanh
4	Softmax
5	SoftPlus
6	SoftSign
7	SeLU
8	ELU

Densní část – inicializace vah perceptronů

Poslední krokem optimalizace struktury a hyperparametrů definující model neuronové sítě bylo obdobně jako při optimalizaci konvolučních částí stanovení vhodných typů inicializátorů vah perceptronů. Byly využity stejné konfigurace jako v případě inicializace vah konvolučních jader.

2.4.2 Optimalizace trénovací fáze

Po optimalizaci strukturních parametrů sítě následoval proces ladění hodnot parametrů definující trénovací a validační procesy. Postupy jsou jmenovány v následujících oddílech a byly provedeny při základní konfiguraci modelu. Hodnotícími parametry byly zvolené metriky definované Tabulkou 2.3.

Délka epoch

Prvním krokem bylo stanovení optimální délky epoch pro učící a validační cyklus, tedy intervalů hodnocení úspěšnosti klasifikace navrženou neuronovou sítí. Zvolené délky

epoch byly pro experimentální část v rámci optimalizace nastaveny na **10, 20, 30** při velikosti **Batch 16**.

Batch rozsah

Dalším postupem při nastavení základní délky epoch **10** bylo nastavení vhodné velikosti **Batch**, neboli počtu cyklů v rámci jedné epochy. Na základě dobré zkušenosti a standardního nastavení u aplikací podobného typu byly zvoleny rozsahy **16, 32, 48, 64, 80, 96**. Bylo usouzeno, že vyšší hodnoty nastavení nemají smysl kvůli velikostně omezenému datasetu.

Batch normalizace

Normalizace **Batch**, neboli normalizace vážených vstupů do vrstvy, má za cíl zabránit rozmělnění gradientu během optimalizace v učící fázi. Normalizaci vstupů do vrstvy lze dosáhnout větší přesnosti výsledků při vyšší variantnosti dat. Základní model je implementován bez **Batch** normalizační vrstvy mezi vstupy ANN vrstev, druhá konfigurace **Batch** vrstvu mezi densní části modelu zavádí.

Optimalizační algoritmy

Dále bylo provedeno optimální nastavení algoritmů zavádějící různé metody redukce ztrátové funkce. Výběr metody pro experimentální část optimalizace nastavení učící fáze byl stanoven z dostupných algoritmů knihoven **Keras**.

Tabulka 2.12 Konfigurace optimalizačních algoritmů

Konfigurace	Algoritmus optimalizace
1	SGD
2	RMSProp
3	Adam
4	AdaGrad
5	AdaDelta
6	AdaMax
7	NAdam
8	FTRL

Délka optimalizačního kroku

Poslední relevantním zkoumaným hyperparametrem učící fáze neuronové sítě určeným k optimalizaci bylo učící měřítko (krok). Stanovuje úroveň redukce vypočítané chyby identifikace neuronovou sítí. Stanovení rozsahu nastavení vychází z dostupných zdrojů užívaných při trénovacím procesu. Rozsah použitých hodnot: **0,001; 0,005; 0,01; 0,1;**

0,5.

Optimalizace řízení proti přeúčení sítě

V prvotní fázi je pro sestavený model pro identifikaci SCR složek stanoven vzorek validačních dat o délce odpovídající poměru **1:4**, tedy **20 %** využívaného datasetu. Úspěšnost validační fáze je měřena v každém běhu klasifikace neuronovou sítí během optimalizačních procesů.

Dalším přístupem snížení rizika přeúčení modelu, který je zkoušen v rámci optimalizace, bylo nastavení algoritmů regularizace pro jednotlivé vrstvy s váženými vstupy v konvoluční i densní části navrženého modelu. Regularizace působí proti přeúčení během trénovací fáze tím, že trénovatelné parametry jsou v každém cyklu průchodu dat modelem přenastaveny za účelem eliminace variancí v modelu. Pokud dojde ke zvýšení míry přeúčení, parametr je tzv. „penalizován“, resp. hodnota parametru je usměrněna postupem dle použité metody. Zvolené metody byly definované pomocí dostupných algoritmů knihoven **Keras**: **L1**, **L2**, **L1_L2**. Měření konfigurací změn nastavení regularizace proběhlo při nastavení **20** epoch pro učící a validační část klasifikace.

Poslední krokem úpravy nastavení učícího procesu za účelem omezení přeúčení, ke kterému bylo přistoupeno, bylo zavedení **Dropout** vrstev před vstupem každé ANN vrstvy. Funkce vrstvy již byla popsána dříve. Hodnoty Dropout vstupů byly stanoveny podle doporučení z volně dostupných zdrojů explicitně odvozených při použití neuronových sítí pro obdobné aplikace: **0,0; 0,1; 0,2; 0,5**. Funkce procesů optimalizace sítě jsou k dispozici ve zdrojových kódech souborů **ModelOptimization.ipynb** a **ModelTraining_MandOverfitting.ipynb**, v nichž jsou přiloženy i výsledky jednotlivých měření.

2.4.3 Evaluace optimalizovaného modelu

Po provedení popsaných postupů optimalizace struktury modelu a procesu učení včetně nastavení managementu proti přeúčení sítě bylo přikročeno k aplikaci vhodně nastaveného základního modelu na měřená testovací data a stanovena výsledná evaluace identifikace SCR složek navrženým modelem.

V první fázi byl klasifikační model aplikován na vzorek testovacích dat z vytvořeného datasetu pro učení a validaci sítě. Fáze učení byla nastavena na délku epoch **100**, aby bylo možné sledovat chování modelu z pohledu zavedených metrik úspěšnosti klasifikace v delším časovém měřítku. Následně byl model aplikován na náhodně generovaný vzorek dat ve 30 cyklech. Byly stanoveny následné statistické parametry zvolených metrik: **Maximum**, **Minimum**, **Medián**, **Střední hodnota**, **Směrodatná odchylka**. Současně k doplnění jmenovaných statistik byla přidružena grafická analýza ve formě **Boxplot** grafů.

V konečné fázi byl finálně nastavený model aplikován na jednotlivé celé záznamy elektrodermální aktivity u subjektů, kdy měření probíhalo nejdříve v klidové fázi a poté ve stavu vyššího mentálního vytížení. Pomocí stanovených metrik byly vyhodnoceny rozdíly efektivity identifikace na záznamech získaných za různých podmínek měření. Zvolenými statistikami určené k porovnání výsledků identifikace SCR složek pomocí zavedených metrik byly pro vyhodnocení stanoveny konfuzní matice. Funkční zdrojový kód včetně výsledků evaluace modelu a porovnávacích statistik aplikace na záznamy měření se nachází v souboru *ClassificationRecords_StatisticEvaluation.ipynb*.

2.5 Výsledky a statistické vyhodnocení

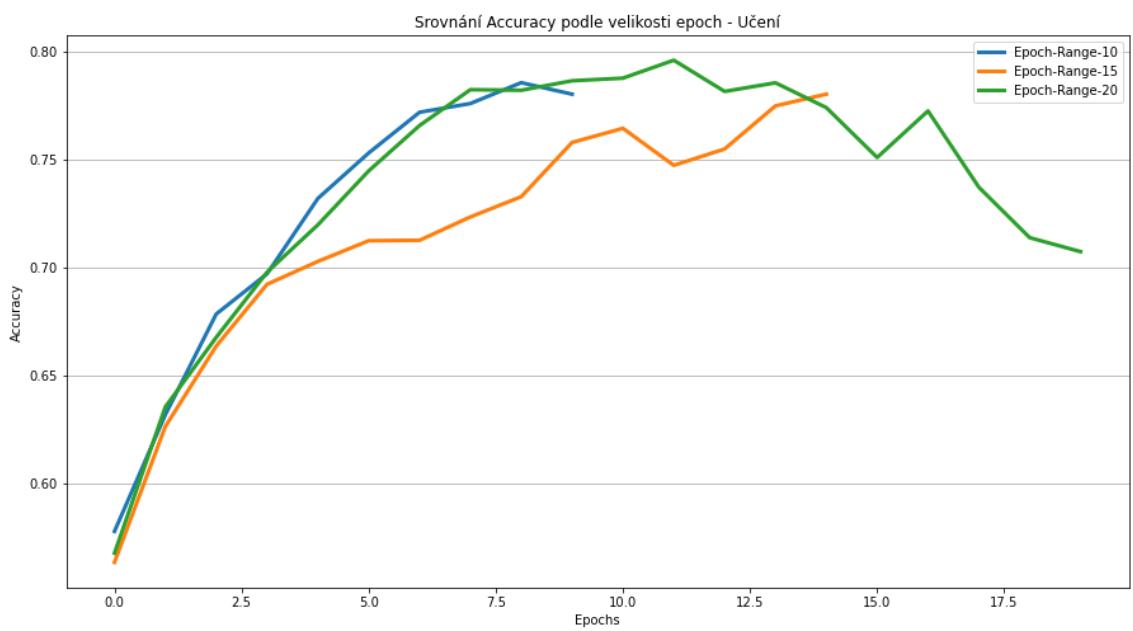
Tato kapitola je věnována uvedením dosažených výsledků, včetně grafického znázornění průběhu úspěšnosti klasifikace navrženým modelem dle zavedených metrik. V rámci optimalizačních procesů uvedených v kapitole 2.4.1 jsou uvedené tabulky a grafy vývoje metrik Accuracy a Loss během trénovací a validační fáze. Po uvedení výsledků optimalizační procesů je model s optimálním nastavení spouštěn přes trénovací a validační fázi, následně je evaluován pomocí zavedených metrik po identifikaci SCR ve 30 cyklech náhodně generovaných datech z datasetu podle nastaveného validačního poměru **0,2**. Naučený optimalizovaný model je následně aplikován pro identifikaci SCR složek v rámci celých záznamů měřených za klidového mentální stavu a následně za stavu vyšší mentální zátěže.

2.5.1 Výsledky optimalizace struktury sítě

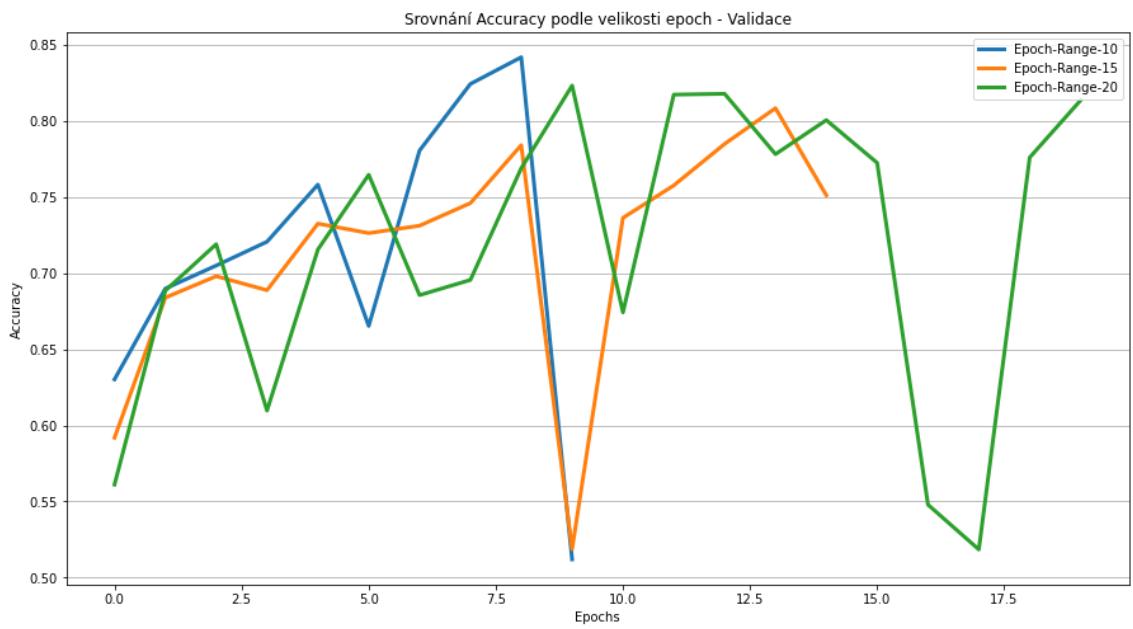
Ke statistickému vyhodnocení klasifikace jsou určeny zavedené metriky Accuracy, Loss, Precision a Recall, jejichž hodnoty jsou uvedeny v tabulkách pro trénovací i validační část měření. Ke každé sekci měření jsou přiložena grafická znázornění vývoje Accuracy v čase, na grafické znázornění vývoje parametru Loss je odkazováno do části **Přílohy**. Měření probíhala během trénovací a validační fáze, přičemž grafický vývoj validační fáze byl z kapacitních důvodů vynechán (pouze v určitých signifikantních případech byl zaveden) a jsou uvedeny pouze hodnoty výsledných metrik v přiložených tabulkách.

Délka epoch

V první fázi optimalizace bylo nutné stanovit minimální délku epoch, jenž určuje minimální rozsah učící fáze, než začne docházet k přeучení modelu neuronové sítě. Hodnota minimální délky epoch byla následně využita v dalších krocích optimalizace jako výchozí hodnota nastavení hyperparametru. Graf vývoje Accuracy během trénovací a validační fáze reprezentují Obrázky **2.15** a **2.16**, výsledky definovaných metrik uvádí Tabulka **2.13**. Grafy vývoje Loss jsou uvedeny v přílohách A.1 (fáze tréninku) a A.2 (fáze validace)



Obrázek 2.15 Graf vývoje Accuracy při nastavení epoch – fáze tréninku



Obrázek 2.16 Graf vývoje Accuracy při nastavení epoch – fáze validace

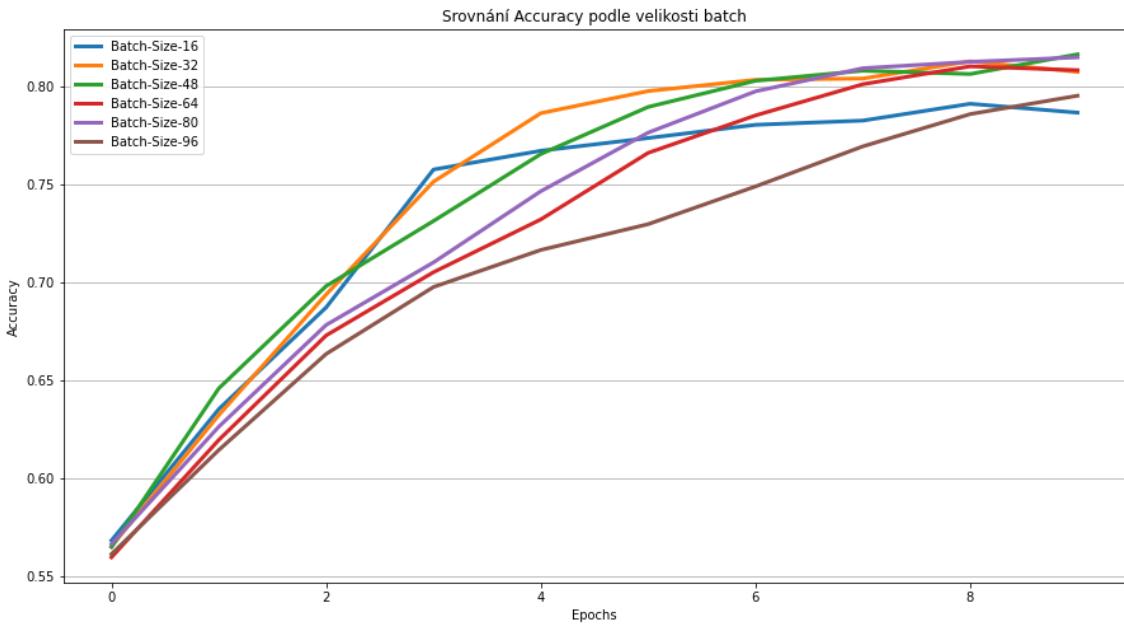
Tabulka 2.13 Nastavení epoch – naměřené hodnoty

Nastavení Epoch	Loss	Accuracy	Precision	Recall
Trénik				
10	0,4969	0,7801	0,7801	0,7801
15	0,4975	0,7801	0,7801	0,7801
20	0,5695	0,7073	0,7073	0,7073
Validace				
10	0,6898	0,5120	0,5120	0,5120
15	0,5145	0,7511	0,7511	0,7511
20	0,4551	0,8135	0,8135	0,8135

Z grafů vývoje Accuracy lze vidět, že hodnota konvergovala k maximu již při výchozím nastavení **10** epoch jak v učící fázi, tak při validaci. Lze vidět, že při překročení této periody během učící fáze docházelo ve všech případech k poklesu Accuracy, nebo její stagnaci v průměru kolem hodnoty **0,8**. V rámci validační fáze byla hodnota po překročení **10**. epochy téměř ustálena. Dle měření Loss docházelo rovněž k ustálení (cca **0,5**) po překročení **10**. epochy, a to na hodnotě cca **0,5**. Jako výchozí nastavení epochy pro další části optimalizace byla uvažována jako dostačující délka epochy **10**.

Velikost Batch

V souladu s předchozím krokem určení optimální délky epoch pro optimalizaci základní konfigurace modelu bylo následně nutné stanovit vhodnou velikost **Batch**, která bude rovněž využita pro následující fáze ladění modelu navržené sítě. Výsledky jsou uvedeny níže.



Obrázek 2.17 Graf vývoje Accuracy – nastavení batch

Tabulka 2.14 Nastavení Batch – naměřené hodnoty

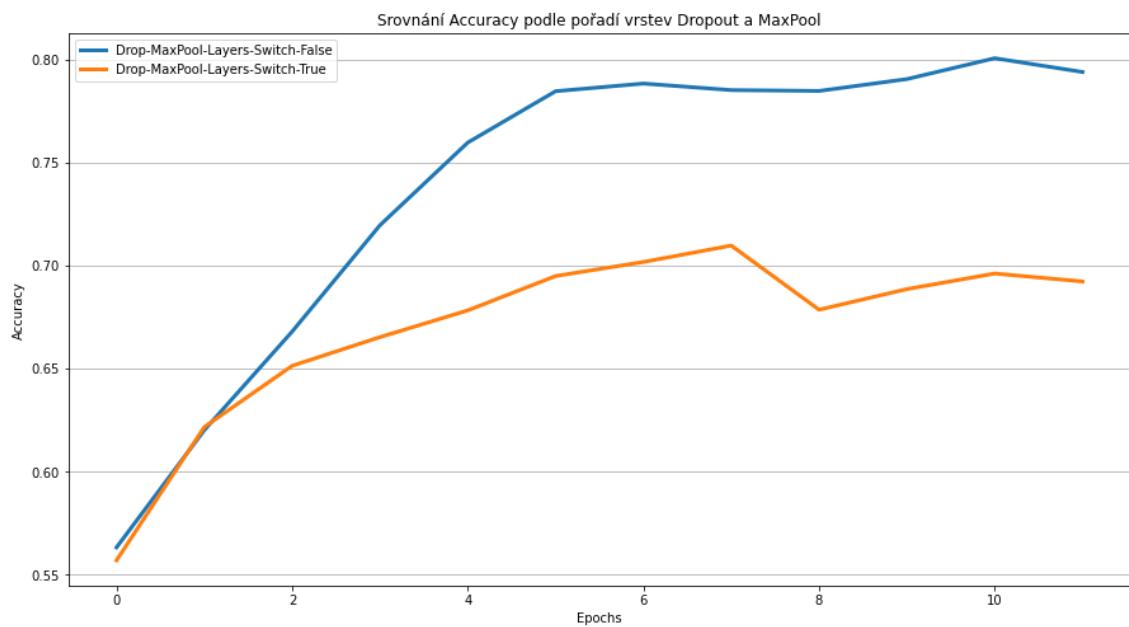
Nastavení Batch	Loss	Accuracy	Precision	Recall
Trénink				
16	0,4906	0,7864	0,7864	0,7864
32	0,4524	0,8072	0,8072	0,8072
48	0,4366	0,8162	0,8162	0,8162
64	0,4457	0,8081	0,8081	0,8081
80	0,4366	0,8146	0,8146	0,8146
96	0,4680	0,7951	0,7951	0,7951
Validace				
16	0,6247	0,6642	0,6642	0,6642
32	0,6622	0,6861	0,6861	0,6861
48	0,4200	0,8281	0,8281	0,8281
64	0,4581	0,8092	0,8092	0,8092
80	0,4220	0,8238	0,8238	0,8238
96	0,5067	0,7582	0,7582	0,7582

Graf 2.17 naznačuje, že nejrychleji dosahuje maxima Accuracy (cca **0,8**) nastavení velikosti Batch **32** a **48**. Graf A.3 ukazuje, že při stejných hodnotách nastavení nejrychleji konverguje Loss. Nastavení Batch na **48** má pomalejší náběh, nicméně obě použité konfigurace se ustalují ve stejném časovém okamžiku a pak následně oscilují kolem konvergenční hodnoty. Z pohledu měření nejlepších výsledků dosahuje nastavení pro **48** s hodnotami Accuracy vyhodnocenou pro trénovací a validační fázi **0,81662** a **0,8281**.

zatímco Loss dosahovala hodnot **0,4366** a **0,4200**, nicméně vzhledem k menší délce epoch se nejedná o zcela ustálený stav a hodnoty metrik se mohly v konečném výsledku lišit. Z hlediska trendů vzestupu Accuracy a poklesu Loss se lepší variantou pro optimální model jeví **Batch** o hodnotě **32**.

Pořadí MaxPool-Dropout v konvoluční vrstvě

Bylo provedeno měření úspěšnosti klasifikace SCR během optimalizace při různých konfiguracích pořadí vrstev **MaxPool-Dropout**, kdy výchozí nastavení počítá se zařazením **MaxPool** před **Dropout** vrstvou,



Obrázek 2.18 Graf vývoje Accuracy – pořadí MaxPool a Dropout

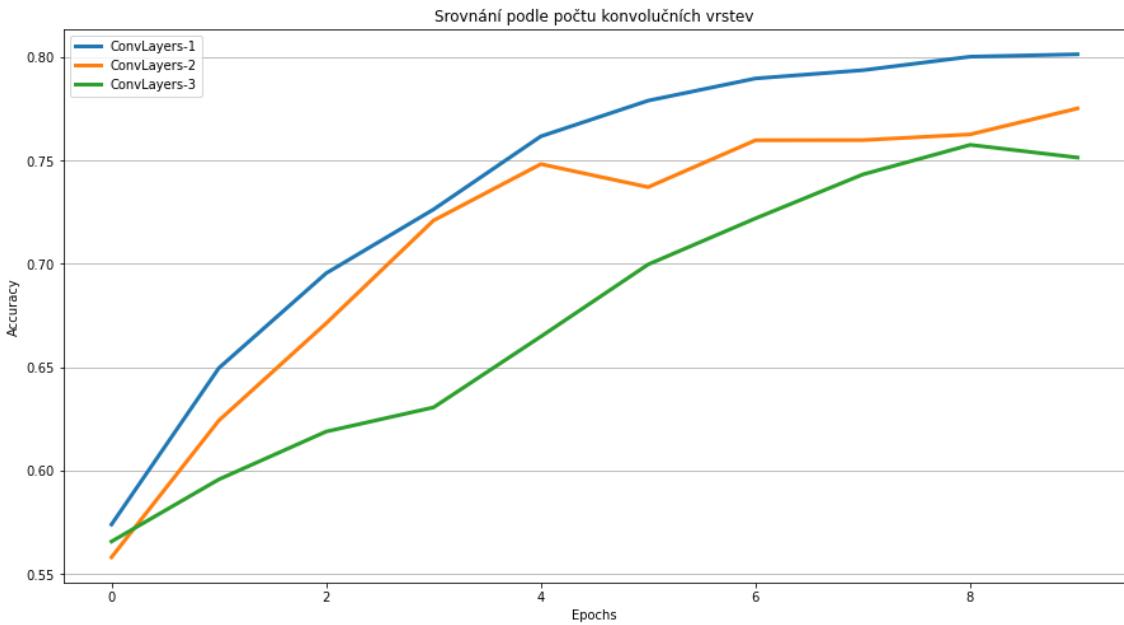
Tabulka 2.15 Konfigurace MaxPool/Dropout - naměřené hodnoty

MaxPool-Dropout konf.	Loss	Accuracy	Precision	Recall
Trénink				
MaxPool-Dropout	0,4870	0,7938	0,7938	0,7938
Dropout- MaxPool	0,5971	0,6961	0,6961	0,6961
Validace				
MaxPool-Dropout	0,5739	0,7158	0,7158	0,7158
Dropout- MaxPool	0,5683	0,6891	0,6891	0,6891

Graf 2.18 demonstruje, že lepšího vývoje Accuracy i vzhledem k dosažené maximální hodnotě je v případě zachování výchozího pořadí, tedy vrstvy **MaxPool** – Dropout. Stejný výsledek značí graf A.4, kdy dochází k podstatně rychlejšímu poklesu Loss a rychlejší konvergenci k minimu. Tabulka 2.15 ukazuje, že lepších výsledků bylo dosaženo při nastavení s výchozím pořadí vrstev při trénovací fázi, při validaci jsou však hodnoty metriky úspěšnosti lepší při obrácenou konfiguraci. Opět lze vidět, že ke konvergenci Accuracy dochází při hodnotách nad **0,8**, zatímco hodnota Loss se pohybuje kolem **0,5** a níže.

Nastavení počtu konvolučních vrstev

Proběhlé měření detekce SCR navrženým modelem ukazuje úspěšnost klasifikace během trénovací a validační fáze při změnách nastavení hloubky konvoluční části pro účely optimalizace struktury modelu.



Obrázek 2.19 Graf vývoje Accuracy – nastavení počtu konv. vrstev

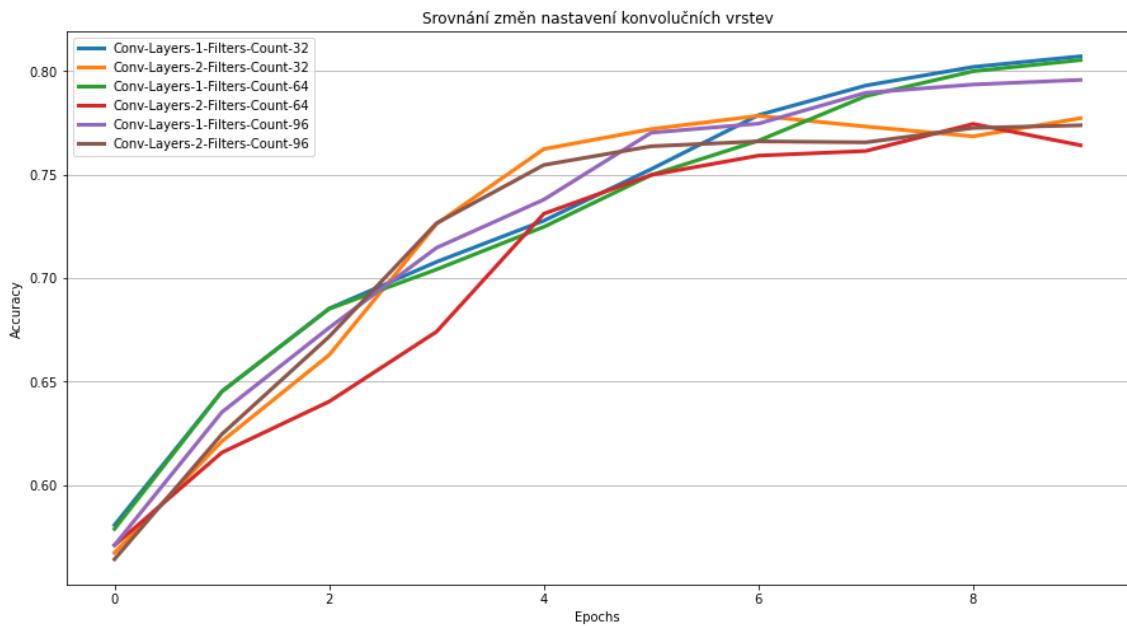
Tabulka 2.16 Hloubka konv. části – naměřené hodnoty

Počet konv. vrstev	Loss	Accuracy	Precision	Recall
Trénink				
1	0,4764	0,8014	0,8014	0,8014
2	0,5206	0,7752	0,7752	0,7752
3	0,5371	0,7515	0,7515	0,7515
Validace				
1	0,3921	0,8505	0,8505	0,8505
2	0,4549	0,8235	0,8235	0,8235
3	0,5330	0,7377	0,7377	0,7377

Graf 2.19 znázorňuje, že při nastavení modelu o jedné konvoluční vrstvě dosahuje Accuracy vyšší hodnoty svého maxima nad **0,8**, ke kterému rovněž rychleji konverguje. Stejný výsledek poskytuje grafická interpretace vývoje Loss A.5, kdy křivka klesá podstatně rychleji než při ostatních použitých konfiguracích, kdy dochází k ustálení na hodnotách pod **0,5**. Tabulka 2.16 ukazuje dle naměřených hodnot, že v rámci fáze tréninku a validace metriky dosahují neoptimálnějších hodnot při konfiguraci s jednou konvoluční vrstvou.

Nastavení počtu konvolučních filtrů

Následovalo měření pro optimalizaci nastaveného počtu konvolučních filtrů během trénovací a validační fáze.



Obrázek 2.20 Graf vývoje Accuracy – nastavení počtu konv. filtrů

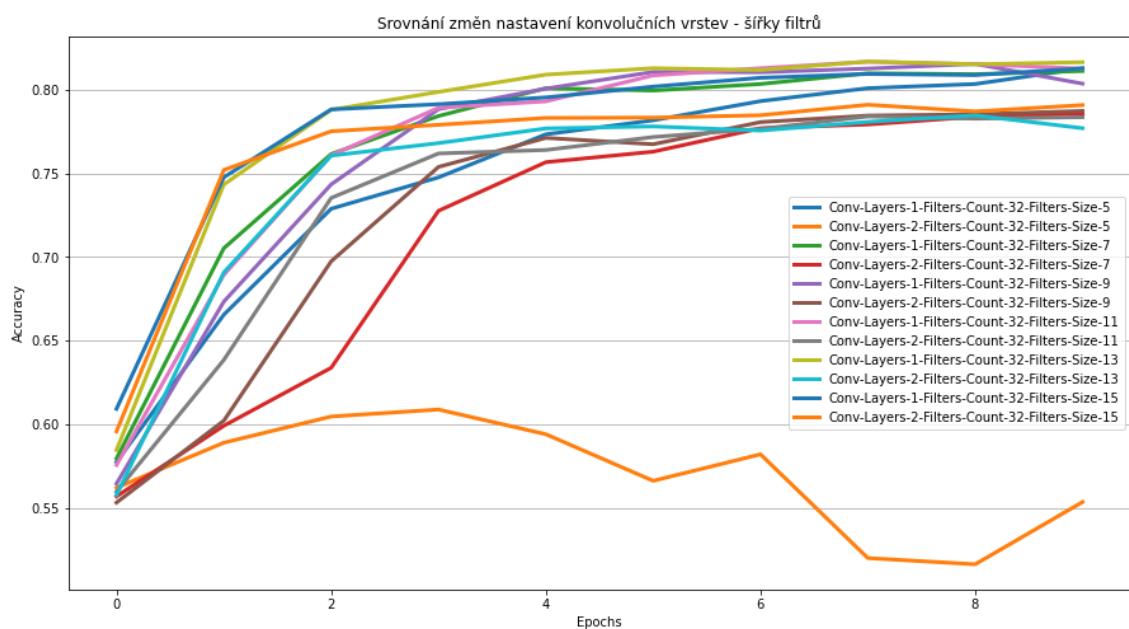
Tabulka 2.17 Nastavení počtu konv. filtrů – naměřené hodnoty

Počet konv. filtrů- Počet vrstev	Loss	Accuracy	Precision	Recall
Trénink				
32-1	0,4636	0,8072	0,8072	0,8072
32-2	0,5130	0,7773	0,7773	0,7773
64-1	0,4692	0,8054	0,8054	0,8054
64-2	0,5213	0,7642	0,7642	0,7642
96-1	0,4881	0,7958	0,7958	0,7958
96-2	0,5232	0,7739	0,7739	0,7739
Validace				
32-1	0,4430	0,8289	0,8289	0,8289
32-2	0,4254	0,8335	0,8335	0,8335
64-1	0,5497	0,7476	0,7476	0,7476
64-2	0,5830	0,6116	0,6116	0,6116
96-1	0,4699	0,8084	0,8084	0,8084
96-2	0,4487	0,8159	0,8159	0,8159

Graf 2.20 zobrazující vývoj Accuracy naznačuje, že hodnota dosahuje svého maxima při nastavení pro **32** a **64** konv. filtrů v jedné vrstvě, kdy průběh daných konfigurací je podle grafického znázornění prakticky totožný, jen s menšími odchylkami se jeví lepším nastavení se **32** filtry v konvoluční vrstvě. Obě nastavené konfigurace však konvergují k maximu nad **0,8**. Stejný závěr lze usoudit z grafického průběhu Loss, kdy dochází ke konvergenci k hodnotám kolem **0,45**. Tabulka 2.17 stanovuje, že k přesnejší klasifikaci dochází při nastavení **32** konvolučních filtrů v jedné vrstvě, kdy hodnoty Accuracy, Loss v trénovací a validační fázi dosahovaly cca **0,8** a **0,45**.

Nastavení šířky konvolučních filtrů

Dále bylo provedeno měření úspěšnosti identifikaci SCR složek při optimalizaci šířky konvolučních filtrů.



Obrázek 2.21 Graf vývoje Accuracy – nastavení šířky konv. filtrů

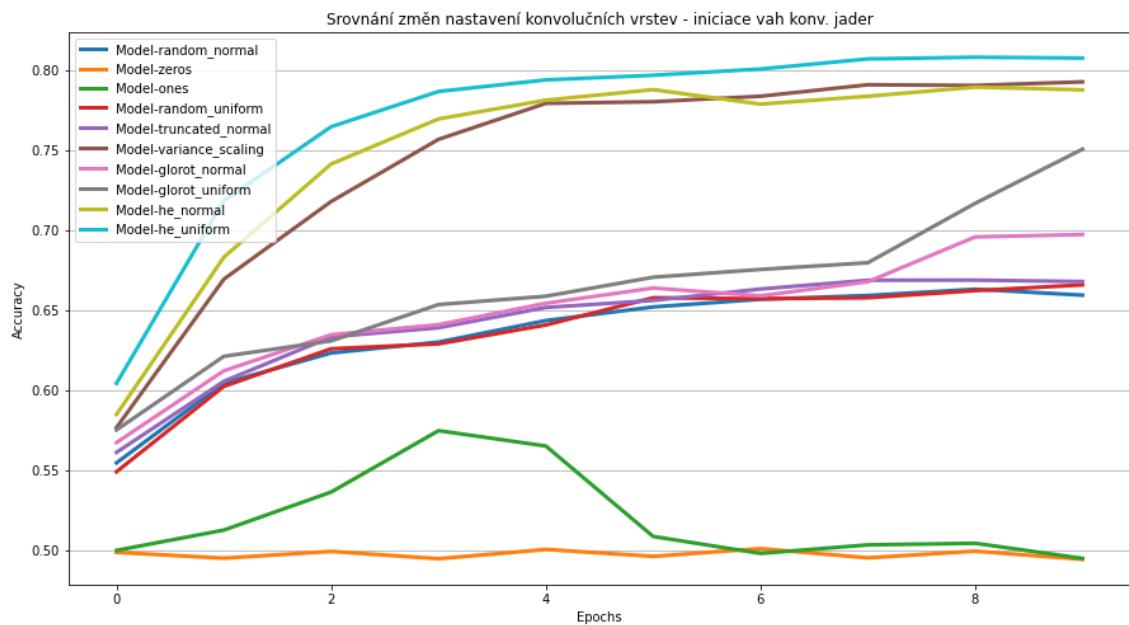
Tabulka 2.18 Nastavení šířky konv. filtrů – naměřené hodnoty

Šířka konv. filtrů-počet filtrů-počet vrstev	Loss	Accuracy	Precision	Recall
Trénink				
5-32-1	0,4659	0,8128	0,8128	0,8128
5-32-2	0,6846	0,5534	0,5534	0,5534
7-32-1	0,4710	0,8113	0,8113	0,8113
7-32-2	0,5010	0,7858	0,7858	0,7858
9-32-1	0,4664	0,8037	0,8037	0,8037
9-32-2	0,4949	0,7874	0,7874	0,7874
11-32-1	0,4592	0,8127	0,8127	0,8127
11-32-2	0,4948	0,7837	0,7837	0,7837
13-32-1	0,4508	0,8165	0,8165	0,8165
13-32-2	0,5064	0,7770	0,7770	0,7770
15-32-1	0,4539	0,8129	0,8129	0,8129
15-32-2	0,4911	0,7909	0,7909	0,7909
Validace				
5-32-1	0,4611	0,8202	0,8202	0,8202
5-32-2	0,6793	0,5360	0,5360	0,5360
7-32-1	0,4108	0,8367	0,8367	0,8367
7-32-2	0,5005	0,7833	0,7833	0,7833
9-32-1	0,4315	0,8265	0,8265	0,8265
9-32-2	0,4581	0,8119	0,8119	0,8119
11-32-1	0,4216	0,8251	0,8251	0,8251
11-32-2	0,5220	0,7571	0,7571	0,7571
13-32-1	0,4665	0,8127	0,8127	0,8127
13-32-2	0,5382	0,7590	0,7590	0,7590
15-32-1	0,4180	0,8129	0,8129	0,8129
15-32-2	0,4469	0,8078	0,8078	0,8078

Dle grafické znázornění 2.21 docházelo k relativně rychlé konvergenci k hodnotám maxima Accuracy u vícero konfigurací (cca **0,82**), kdy stálý zůstal počet konvolučních filtrů. Nejlepších výsledků dosahovaly konfigurace se **32** filtry o jedné konvoluční vrstvě. Totéž lze usoudit posouzením vývoje Loss znázorněným grafem A.7, kdy hodnota konvergovala při zmíněných konfiguracích k **0,45**. Tabulka 2.18 dle naměřených hodnot potvrzuje závěr, že nevhodnější je konfigurace o jedné konvoluční vrstvě o **32** filtroch. Na základě naměřených výsledků a dle grafických průběhu vývoje Accuracy a Loss byla stanovena jako vhodná konfigurace pro optimalizovaný model **jedna konv. vrstva – 32 filtrů – šířka filtru 13**.

Inicializace vah konvolučních filtrů

V další kroku optimalizace modelu bylo provedeno měření klasifikace při nastavení různých definovaných matematických metod stanovení inicializačních hodnot vah konvolučních filtrů.



Obrázek 2.22 Graf vývoje Accuracy – nastavení inicializace vah konv. filtrů

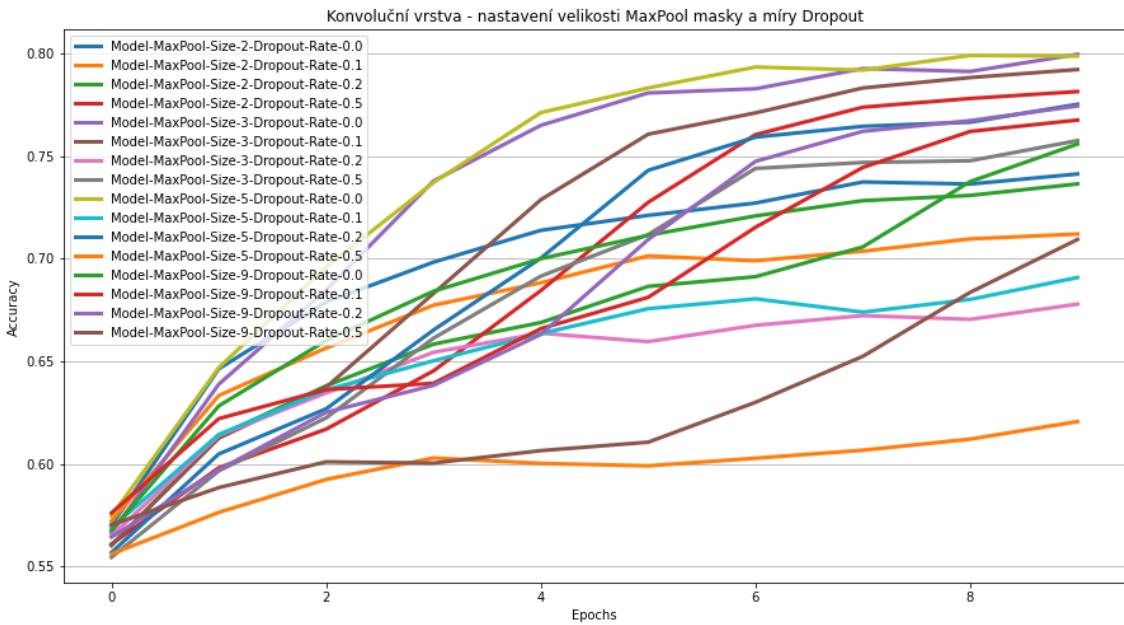
Tabulka 2.19 Nastavení inicializace konv. filtrů – naměřené hodnoty

Inicializace vah konv. filtrů	Loss	Accuracy	Precision	Recall
Trénink				
Random Normal	0,6322	0,6595	0,6595	0,6595
Zeros	0,6932	0,4945	0,4945	0,4945
Ones	0,6935	0,4951	0,4951	0,4951
Random Uniform	0,6266	0,6659	0,6659	0,6659
Truncated normal	0,6208	0,6680	0,6680	0,6680
Variance scaling	0,4893	0,7927	0,7927	0,7927
Glorot normal	0,5937	0,6973	0,6973	0,6973
Glorot uniform	0,5430	0,7507	0,7507	0,7507
He Normal	0,4912	0,7877	0,7877	0,7877
He Uniform	0,4684	0,8075	0,8075	0,8075
Validace				
Random Normal	0,6045	0,7304	0,7304	0,7304
Zeros	0,6931	0,4999	0,4999	0,4999
Ones	0,6932	0,4999	0,4999	0,4999
Random Uniform	0,6016	0,6688	0,6688	0,6688
Truncated normal	0,5949	0,6996	0,6996	0,6996
Variance scaling	0,4363	0,8402	0,8402	0,8402
Glorot normal	0,7549	0,6923	0,6923	0,6923
Glorot uniform	0,4462	0,8157	0,8157	0,8157
He Normal	0,4322	0,8216	0,8216	0,8216
He Uniform	0,4633	0,8078	0,8078	0,8078

Graf vývoje Accuracy 2.22 ukazuje nejlepší průběh u metody **He Uniform**, kdy je dosaženo při 10 epochách nejvyšší maximální hodnoty nad **0,8**. Graf A.8 naznačuje stejný výsledek při sledování vývoje Loss. Zhodnocením tabulky naměřených výsledků 2.19 lze vidět, že nejnižších hodnot Loss bylo dosaženo metodami **Variance Scaling**, **He Normal** a **He Uniform** změřených při cca **0,45**. Hodnota maximální dosažené Accuracy zůstala při pozorovaném maximu **0,8**.

Nastavení šířky MaxPool a míry Dropout

V další fázi optimalizačního procesu byla experimentálně nastavována šířka **MaxPool** vrstvy a intenzity **Dropout**. Pro různá nastavení byly pořízeny měřené hodnoty zavedených metrik.



Obrázek 2.23 Graf vývoje Accuracy – nastavení MaxPool a Dropout

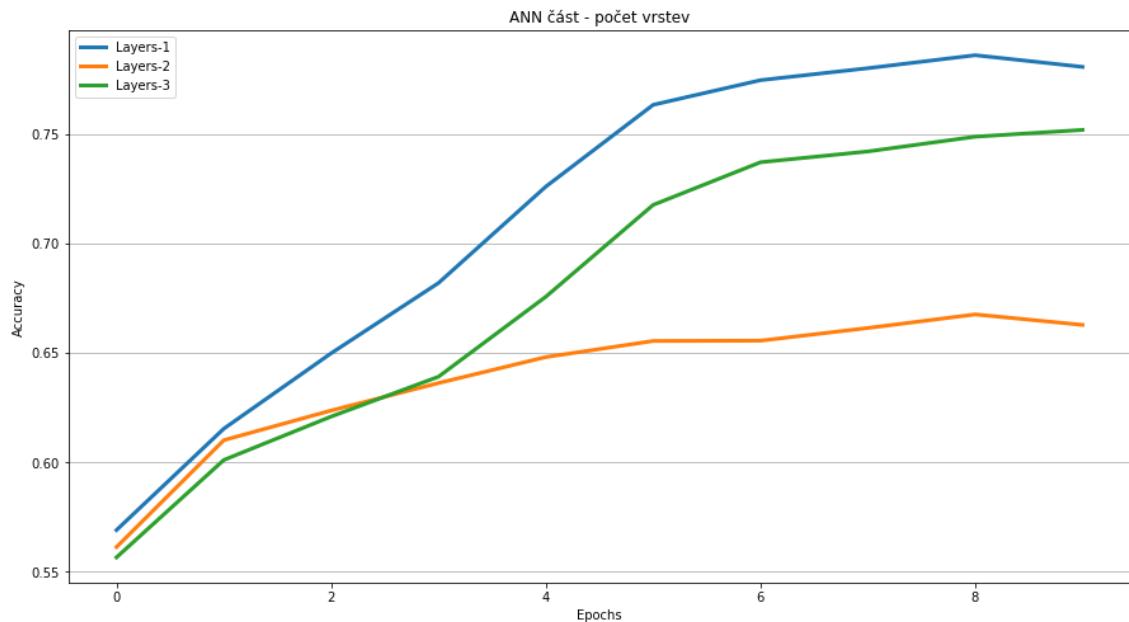
Tabulka 2.20 Nastavení MaxPool a Dropout – naměřené hodnoty

Nastavení MaxPool a Dropout	Loss	Accuracy	Precision	Recall
Trénink				
3-0.0	0,4847	0,7995	0,7995	0,7995
5-0.0	0,4812	0,7986	0,7986	0,7986
Validace				
3-0.0	0,7128	0,6316	0,6316	0,6316
5-0.0	0,4368	0,8246	0,8246	0,8246

Vzhledem k množství měření za různých konfigurací, kdy pouze některé vykazovaly relevantní uspokojivé výsledky, jsou pouze tyto nastavení uvedené v Tabulce naměřených hodnot 2.20 komentovány. Při stanovených konfiguracích byla nejvyšší hodnota Accuracy, pouze však konfigurace s **nulovou** intenzitou **Dropout** a šírkou **MaxPool 5** vykazují nejnižší hodnoty Loss v trénovací a validační fázi. Z grafů vývoje Accuracy 2.23 a Loss A.9 je patrné dle průběhu, že nejlepších výsledků klasifikace dosahuje nastavení při zmíněné šířce **MaxPool** vrstvy a bez **Dropout**.

Nastavení počtu vrstev v ANN síti

Po optimalizaci konvoluční části bylo přistoupeno k nastavení vhodné konfigurace ANN klasifikační části neuronové sítě. Prvním krokem bylo nalezení vhodného počtu vrstev ANN při výchozím počtu **128** perceptronů ve vrstvách.



Obrázek 2.24 Graf vývoje Accuracy – nastavení počtu vrstev ANN

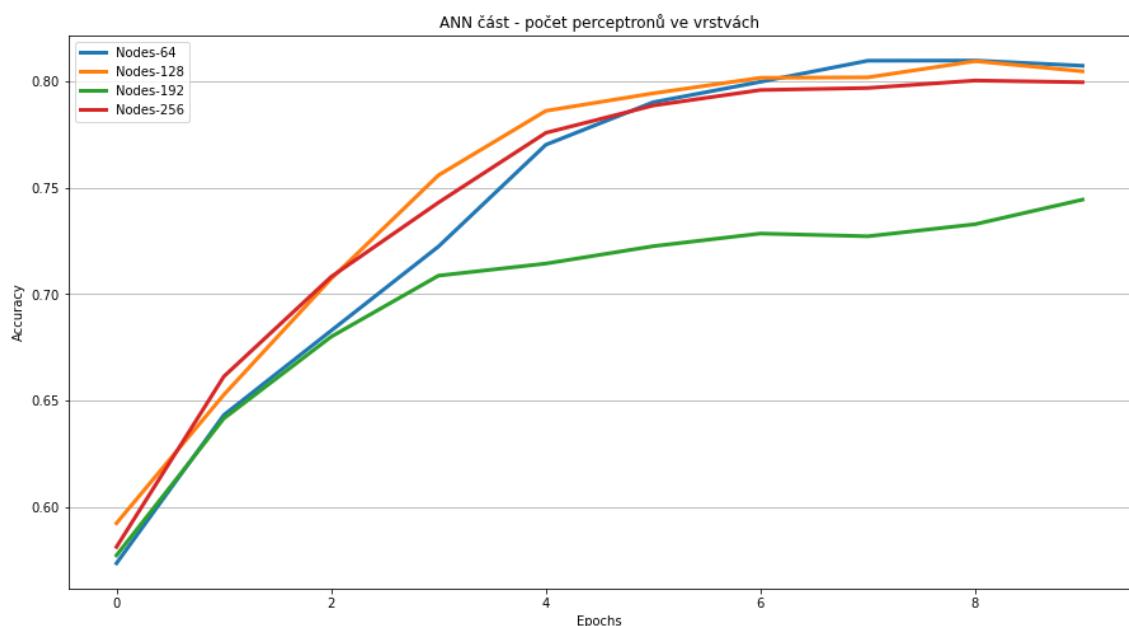
Tabulka 2.21 Nastavení počtu vrstev ANN – naměřené hodnoty

Počet vrstev ANN	Loss	Accuracy	Precision	Recall
Trénink				
1	0,4804	0,7993	0,7993	0,7993
2	0,5352	0,7490	0,7490	0,7490
3	0,5587	0,7349	0,7349	0,7349
Validace				
1	0,4814	0,8016	0,8016	0,8016
2	0,5265	0,7722	0,7722	0,7722
3	0,5395	0,7298	0,7298	0,7298

Z výsledných naměřených hodnot vyplývá jako nejvhodnější nastavení při **jedné** zavedené densní vrstvě. Při této konfiguraci bylo dosaženo Accuracy kolem **0,8** a Loss **0,48**, kdy tyto hodnoty byly konstantní při trénovací i validační fázi. Dle grafických průběhu Accuracy a Loss lze zhodnotit, že co se týče průběhu učení, je nastavení modelu s jednou ANN vrstvou nejoptimálnější.

Nastavení počtu perceptronů v ANN síti

V návaznosti na experimentální určení optimálního počtu ANN vrstev proběhlo měření klasifikace implementovaným modelem pro různé nastavení množství perceptronů v ANN vrstvách.



Obrázek 2.25 Graf vývoje Accuracy – nastavení počtu perceptronů v ANN

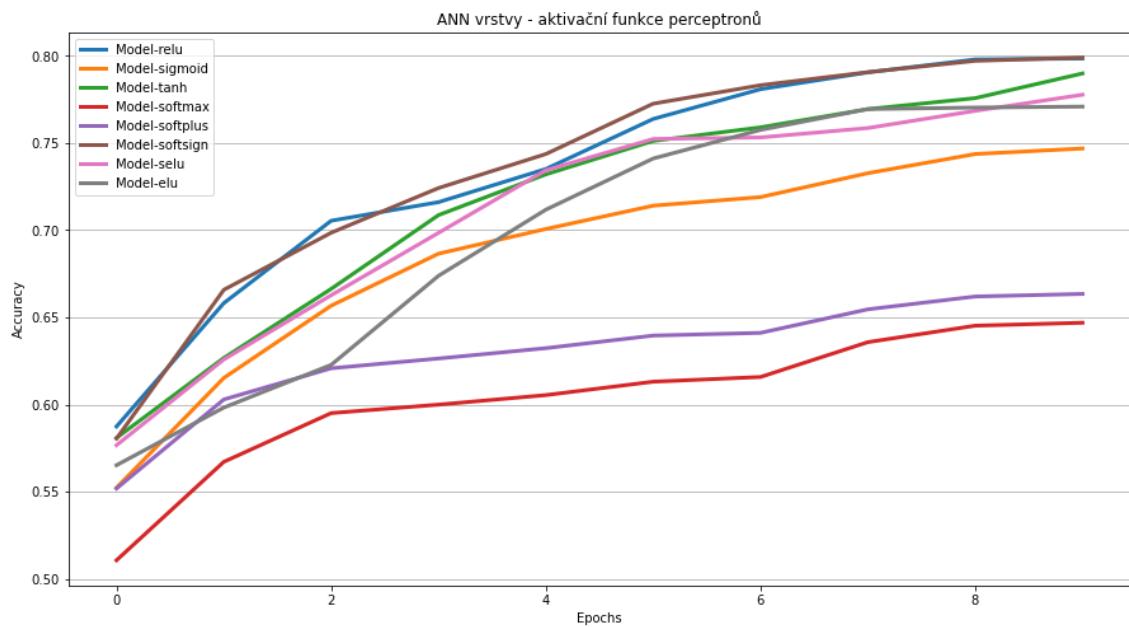
Tabulka 2.22 Nastavení počtu perceptronů ANN – naměřené hodnoty

Počet perceptronů ve vrstvách ANN	Loss	Accuracy	Precision	Recall
Trénink				
64	0,4514	0,8072	0,8072	0,8072
128	0,4575	0,8046	0,8046	0,8046
192	0,5445	0,7443	0,7443	0,7443
256	0,4618	0,7994	0,7994	0,7994
Validace				
64	0,4101	0,8375	0,8375	0,8375
128	0,4416	0,8116	0,8116	0,8116
192	0,5475	0,7914	0,7914	0,7914
256	0,4648	0,7949	0,7949	0,7949

Naměřené průběhy Accuracy (2.25) a Loss (A.11) vykazují rychlý náběh (Accuracy) a pokles (Loss) k limitním hodnotám při nastavení o **128** perceptronech ve vrstvách výchozí modelu. Hodnoty pro danou konfiguraci modelu byly naměřeny pro Accuracy cca **0,8** a Loss při hodnotě kolem **0,45**.

Nastavení aktivační funkce perceptronů v ANN síti

Následovalo podobně jako při ladění konvoluční části modelu měření a nalezení vhodné konfigurace modelu při změnách nastavení aktivační funkce perceptronů pomocí různých matematických modelů.



Obrázek 2.26 Graf vývoje Accuracy – nastavení aktivační funkce ANN sítě

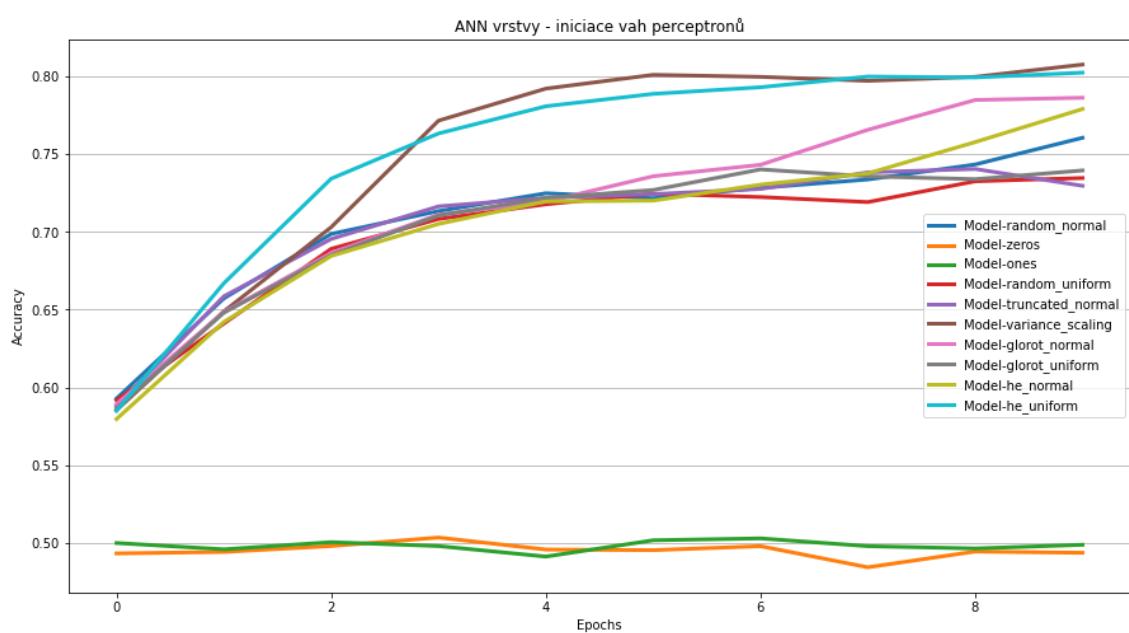
Tabulka 2.23 Nastavení aktivační funkce ANN sítě – naměřené hodnoty

Aktivační funkce ANN sítě	Loss	Accuracy	Precision	Recall
Trénink				
ReLU	0,4691	0,7985	0,7985	0,7985
Sigmoid	0,5288	0,7469	0,7469	0,7469
Tanh	0,4841	0,7899	0,7899	0,7899
Softmax	0,6206	0,6469	0,6469	0,6469
Softplus	0,6384	0,6635	0,6635	0,6635
SoftSign	0,4700	0,7990	0,7990	0,7990
SeLU	0,5083	0,7777	0,7777	0,7777
ELU	0,5316	0,7704	0,7704	0,7704
Validace				
ReLU	0,4248	0,8246	0,8246	0,8246
Sigmoid	0,5007	0,7544	0,7544	0,7544
Tanh	0,5175	0,7730	0,7730	0,7730
Softmax	0,5712	0,7320	0,7320	0,7320
Softplus	0,6268	0,6947	0,6947	0,6947
SoftSign	0,4736	0,7978	0,7978	0,7978
SeLU	0,6156	0,7196	0,7196	0,7196
ELU	0,5207	0,7711	0,7711	0,7711

Z grafů průběhu Accuracy 2.26 a Loss A.12 lze spatřit téměř identický průběh aktivačních funkcí u metodách **ELU** a **ReLU**. Pro tyto aktivační funkce byla rychlosť náběhu k limitním hodnotám nejrychlejší, stejně byla vykázána nejlepší dosažená hodnota daných metrik. Dle tabulky hodnot 2.23 byly nejoptimálnější hodnoty během trénovací a validační fáze naměřeny při nastavení aktivační funkce **ReLU**.

Nastavení inicializace vah perceptronů v ANN síti

Poslední část stanovení vhodné konfigurace modelu sítě bylo měření při nastavení vybraných nastavení způsobů inicializace hodnot parametrů vah perceptronů.



Obrázek 2.27 Vývoj Accuracy – nastavení inicializace vah perceptronů

Tabulka 2.24 Nastavení inicializace vah perceptronů – naměřené hodnoty

Inicializace vah perceptronů ANN sítě	Loss	Accuracy	Precision	Recall
Trénink				
Random Normal	0,5218	0,7604	0,7604	0,7604
Zeros	0,6932	0,4939	0,4939	0,4939
Ones	0,6932	0,4990	0,4990	0,4990
Random Uniform	0,5537	0,7346	0,7346	0,7346
Truncated normal	0,5565	0,7296	0,7296	0,7296
Variance scaling	0,4505	0,8075	0,8075	0,8075
Glorot normal	0,4812	0,7862	0,7862	0,7862
Glorot uniform	0,5433	0,7395	0,7395	0,7395
He Normal	0,4967	0,7789	0,7789	0,7789
He Uniform	0,4665	0,8023	0,8023	0,8023
Validace				
Random Normal	0,4962	0,7676	0,7676	0,7676
Zeros	0,6931	0,5001	0,5001	0,5001
Ones	0,6932	0,5001	0,5001	0,5001
Random Uniform	0,4998	0,7700	0,7700	0,7700
Truncated normal	0,5259	0,7430	0,7430	0,7430
Variance scaling	0,5074	0,7646	0,7646	0,7646
Glorot normal	0,4627	0,8062	0,8062	0,8062
Glorot uniform	0,5890	0,7077	0,7077	0,7077
He Normal	0,4411	0,8076	0,8076	0,8076
He Uniform	0,4220	0,8273	0,8273	0,8273

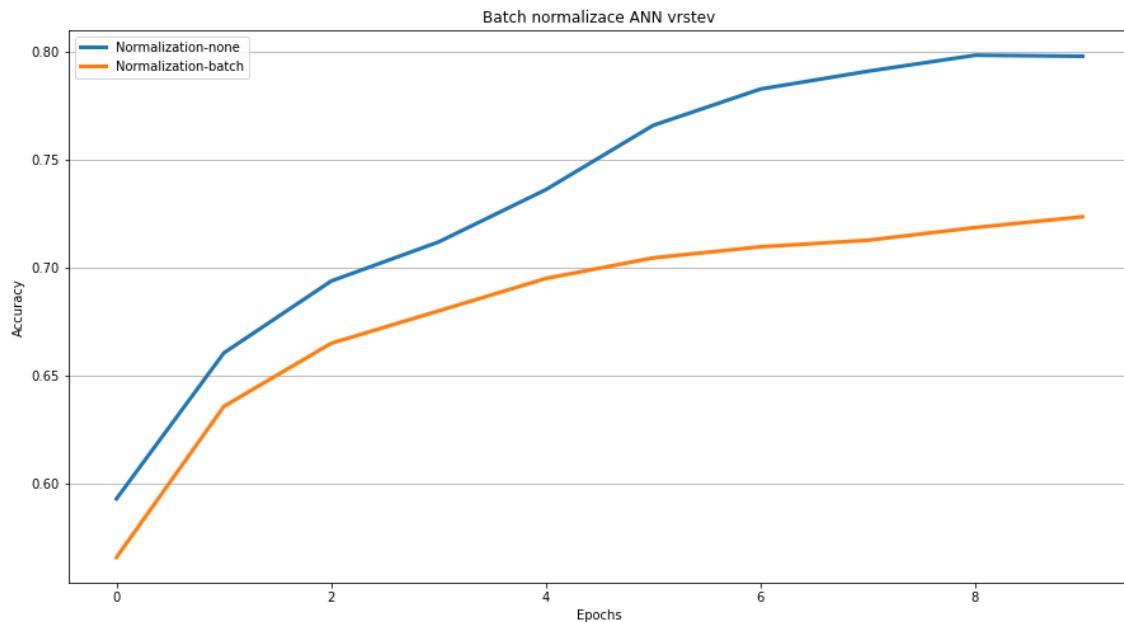
Dle grafu vývoje Accuracy 2.27 si lze povšimnout nejrychlejší konvergence k limitním hodnotám kolem **0,8** zavedením metod inicializace **He Uniform** a **Variance Scaling**. Tomu odpovídají i naměřené hodnoty metrik v tabulce 2.24, kdy naměřená Accuracy je hodnotově u obou metod téměř identická, avšak Loss je významně nižší pro **He Uniform** metodu ve validační fázi optimalizace.

2.5.2 Optimalizace učení sítě

Po naměření cyklů optimalizace struktury a nastavení sítě byla stejným způsobem provedena optimalizace hyperparametrů trénovací fáze dle konfigurací a postupů uvedených v kapitole 2.4.2 pomocí měření efektivity detekce SCR složek dle zavedených metrik.

Optimalizace pomocí Batch Normalizační vrstvy

Prvním zahájeným procesem za účelem optimalizace trénovací fáze sestaveného modelu sítě bylo měření vlivu zavedení **Batch** normalizační vrstvy mezi sítěmi ANN pro normalizaci vstupů.



Obrázek 2.28 Graf vývoje Accuracy – Bach Normalizace

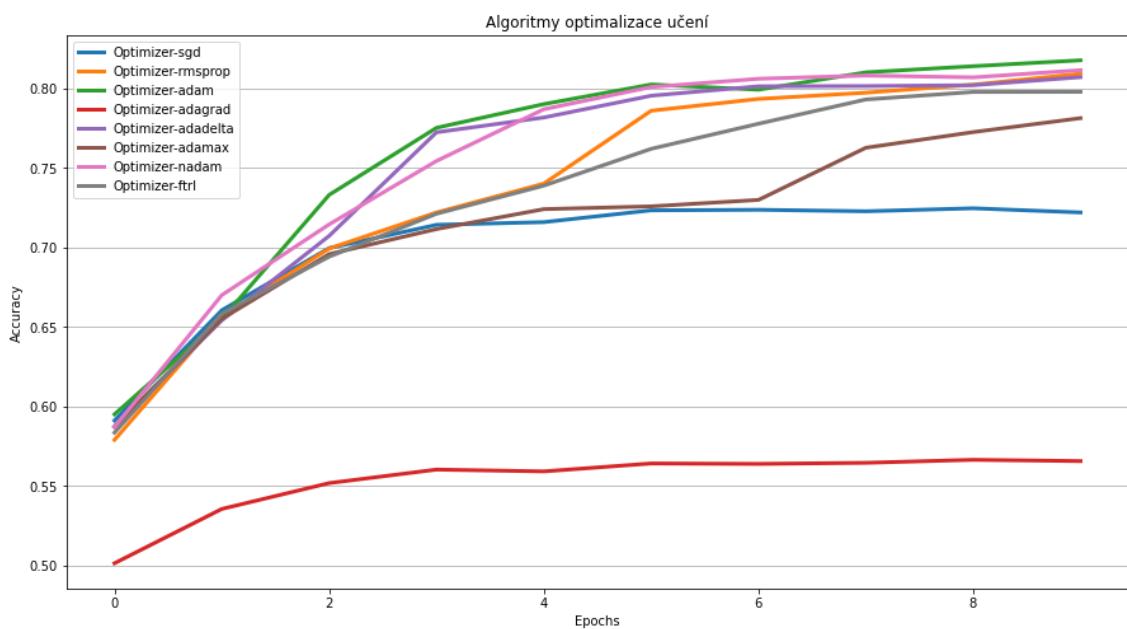
Tabulka 2.25 Batch normalizace – naměřené hodnoty

Batch Normalizační vrstva	Loss	Accuracy	Precision	Recall
Trénink				
Ano	0,5536	0,7235	0,7235	0,7235
Ne	0,4658	0,7978	0,7978	0,7978
Validace				
Ano	0,5201	0,7568	0,7568	0,7568
Ne	0,4558	0,8073	0,8073	0,8073

Jak naznačují grafické interpretace vývoje Accuracy 2.28 a Loss A.14, zavedením Batch Normalizace mělo za následek zhoršení průběhu učení identifikace SCR složek. Náběh Accuracy a Loss je výrazně zpomalen a rovněž finální konvergenční hodnoty jsou nižší. To dokládají naměřené hodnoty Accuracy a Loss během trénovací i validační fáze, měření při nastavení bez zařazení Batch normalizační vrstvy vykazuje hodnoty Accuracy kolem **0,8** při Loss **0,45**.

Nastavení optimalizačního algoritmu učení

Dalším krokem optimalizace učící fáze bylo experimentální zvolení optimalizačního učícího algoritmu nastavením dostupných algoritmů v rámci knihoven **Keras** a **Tensorflow**.



Obrázek 2.29 Graf vývoje Accuracy – optimalizační algoritmy učení

Tabulka 2.26 Algoritmy optimalizace učení – naměřené hodnoty

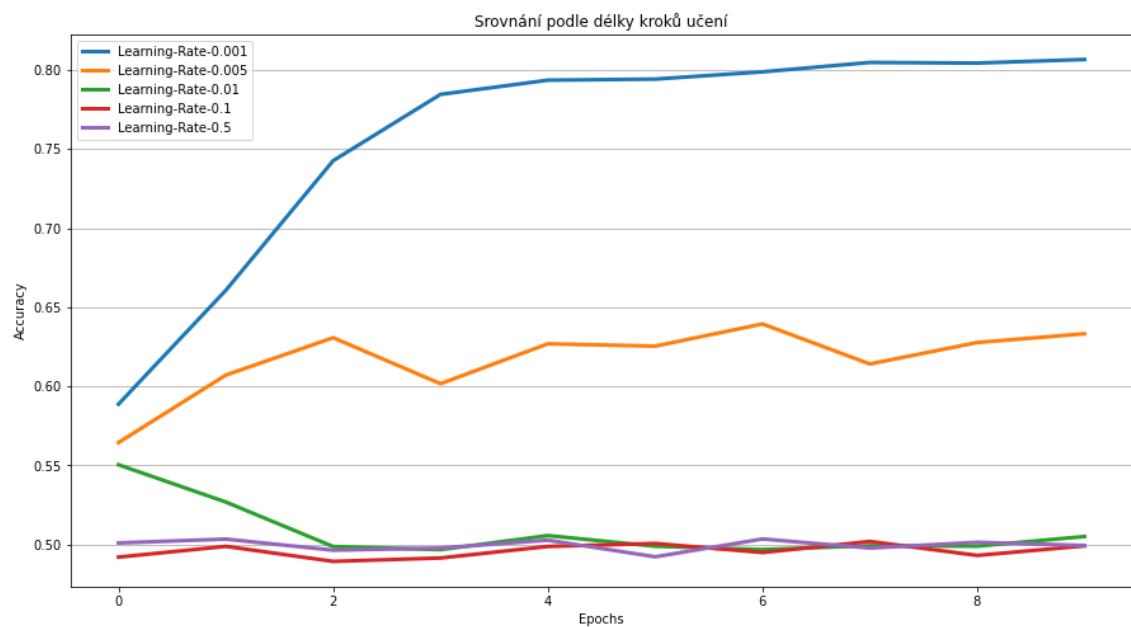
Algoritmy optimalizace učení	Loss	Accuracy	Precision	Recall
Trénink				
SGD	0,5641	0,7220	0,7220	0,7220
RMSProp	0,4460	0,8093	0,8093	0,8093
Adam	0,4379	0,8177	0,8177	0,8177
AdaGrad	0,6858	0,5657	0,5657	0,5657
AdaDelta	0,4617	0,8071	0,8071	0,8071
AdaMax	0,4888	0,7814	0,7814	0,7814
Nadam	0,4475	0,8115	0,8115	0,8115
FTRL	0,4622	0,7979	0,7979	0,7979
Validace				
SGD	0,5242	0,7514	0,7514	0,7514
RMSProp	0,4822	0,7719	0,7719	0,7719

Adam	0,5213	0,7860	0,7860	0,7860
AdaGrad	0,6854	0,5619	0,5619	0,5619
AdaDelta	0,4635	0,8213	0,8213	0,8213
AdaMax	0,4394	0,8073	0,8073	0,8073
Nadam	0,4475	0,8115	0,8115	0,8115
FTRL	0,4600	0,8084	0,8084	0,8084

Z grafů průběhu Accuracy (2.29) a Loss (A.15) lze vidět, že vhodné je nastavení pro více variant optimalizačních algoritmů. Nejlepších výsledků dle zavedených metrik vykazuje algoritmus **Adam**, kde docházelo k relativně rychlému náběhu naměřených hodnot, výsledné naměřené hodnoty během učící fáze pro Accuracy a Loss jsou dle Tabulky 2.26 **0,4379** a **0,8093**, avšak již z hlediska výsledků jako nedostatečná se ukázala být metoda během validační fáze, kdy se naměřené hodnoty metrik zhorsily, avšak Accuracy zůstala na vysokých hodnotách.

Nastavení délky učícího kroku

Následovalo měření pro nalezení vhodné délky učícího kroku. Měření proběhlo pro stanovený rozsah učících kroků.



Obrázek 2.30 Graf vývoje Accuracy – nastavení kroku učení

Tabulka 2.27 Nastavení kroku učení – naměřené hodnoty

Algoritmy optimalizace učení	Loss	Accuracy	Precision	Recall
Trénink				
0,001	0,4801	0,7890	0,7890	0,7890
0,005	0,6160	0,6730	0,6730	0,6730
0,01	0,6968	0,5225	0,5225	0,5225
0,1	0,6963	0,5008	0,5008	0,5008
0,5	0,7127	0,4992	0,4992	0,4992
Validace				
0,001	0,5138	0,7493	0,7493	0,7493
0,005	0,6340	0,6335	0,6335	0,6335
0,01	0,6842	0,5225	0,5225	0,5225
0,1	0,6942	0,5001	0,5001	0,5001
0,5	0,9014	0,5001	0,5001	0,5001

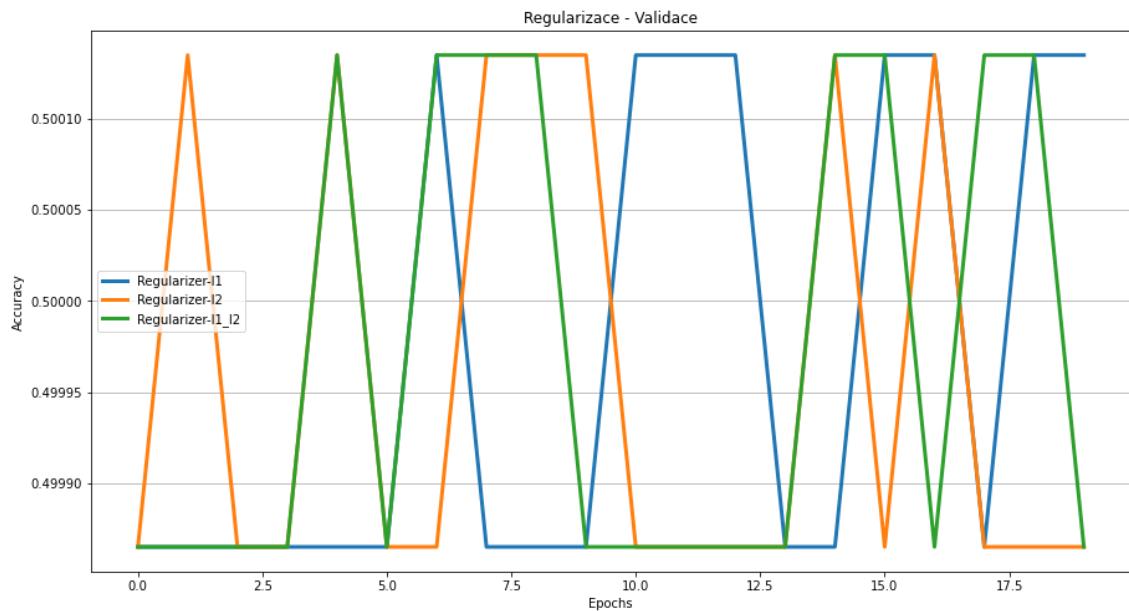
Jak dokládají grafy vývoje Accuracy (2.30) a Loss (A.16), nejoptimálnější je nastavení s učícím krokem **0,001**, kde pouze v tomto případě úspěšnost klasifikace konvergovala k nejvyšším hodnotám Accuracy (cca **0,8**) při Loss kolem **0,5**.

Nastavení regularizace

V rámci optimalizace hyperparametrů s cílem redukovat míru přeúčení sítě bylo vykonáno měření se zavedením regularizace v rámci vrstev modelu a sledován vliv této metody na úspěšnost klasifikace zejména při validaci, která by tímto krokem měla být teoreticky zlepšena.



Obrázek 2.31 Graf vývoje Accuracy - regularizace - trénování



2.32 Graf vývoje Accuracy – regularizace – validace

Tabulka 2.28 Regularizace – naměřené hodnoty

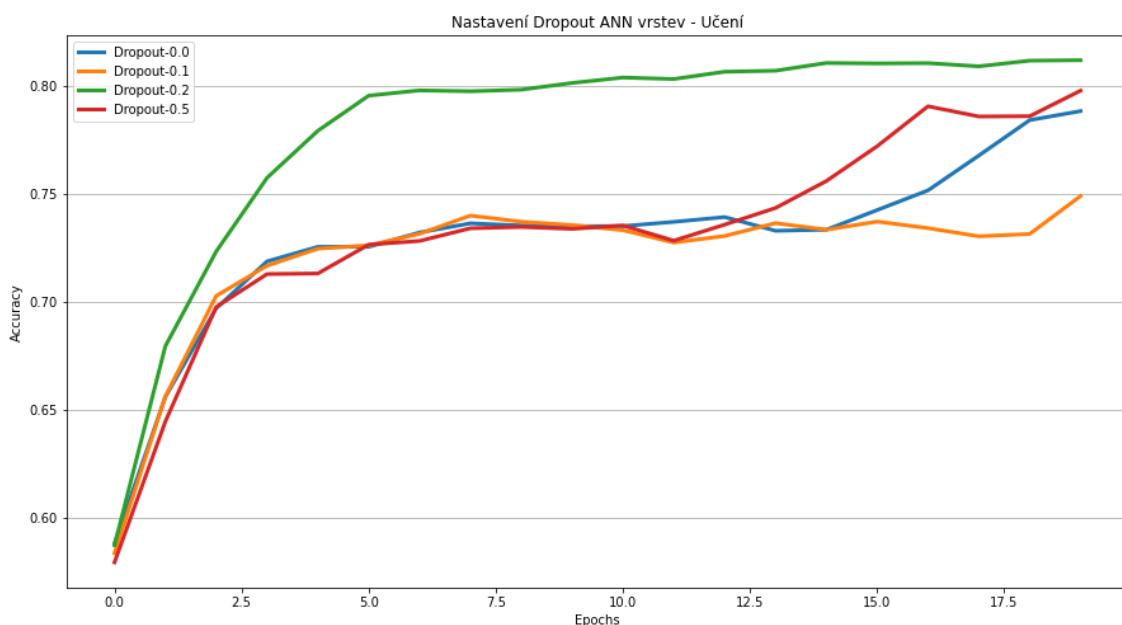
Regularizace	Loss	Accuracy	Precision	Recall
Trénink				
L1	0,6943	0,4983	0,4983	0,4983
L2	2,6676	0,4988	0,4988	0,4988
L1_L2	2,8147	0,4971	0,4971	0,4971

Validace				
L1	0,6942	0,4999	0,4999	0,4999
L2	2,6584	0,5001	0,5001	0,5001
L1_L2	2,8147	0,4999	0,4999	0,4999

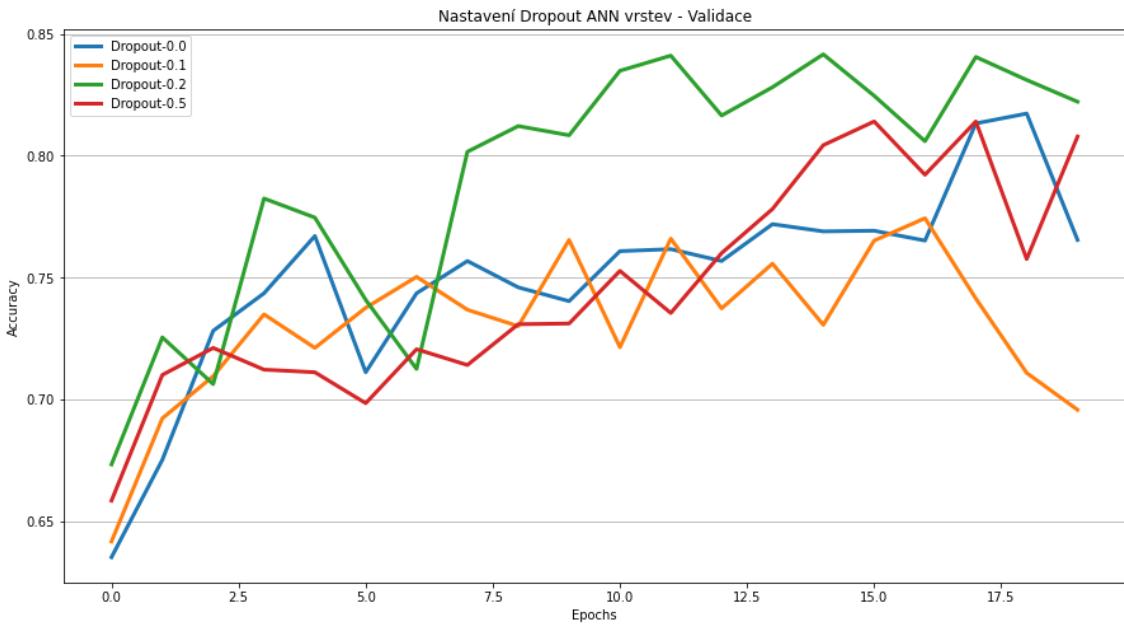
Měřením bylo zjištěno, že zavedením kteréhokoli zvolené algoritmu regularizace není docíleno optimální úspěšnosti klasifikaci SCR. Jak vypovídá tabulka naměřených hodnot 2.28, nejnižší hodnota Loss je **0,69** a Accuracy **0,49** pro regularizace **L1**. Ostatní metody regularizace vykazují již násobně horší výsledky Loss a úroveň Accuracy pod **0,5**. Jak je vidět z grafických průběhu vývoje Accuracy 2.31 a 2.32, nedochází vlivem regularizace k rychlejšímu náběhu metrik jako v předchozích případech v naměřené limitní hodnotě **0,8** a s vyšší naměřenou hodnotou Loss **0,5**.

Nastavení Dropout v ANN

Posledním experimentálním měřením optimalizace nastavení modelu v rámci řízení proti riziku přeучení bylo zavedení různých hodnot Dropout vrstev umístěných mezi ANN vrstvami.



Obrázek 2.33 Graf vývoje Accuracy – Dropout ANN



Obrázek 2.34 Graf vývoje Accuracy – Dropout ANN

Tabulka 2.29 Dropout ANN – Naměřené hodnoty

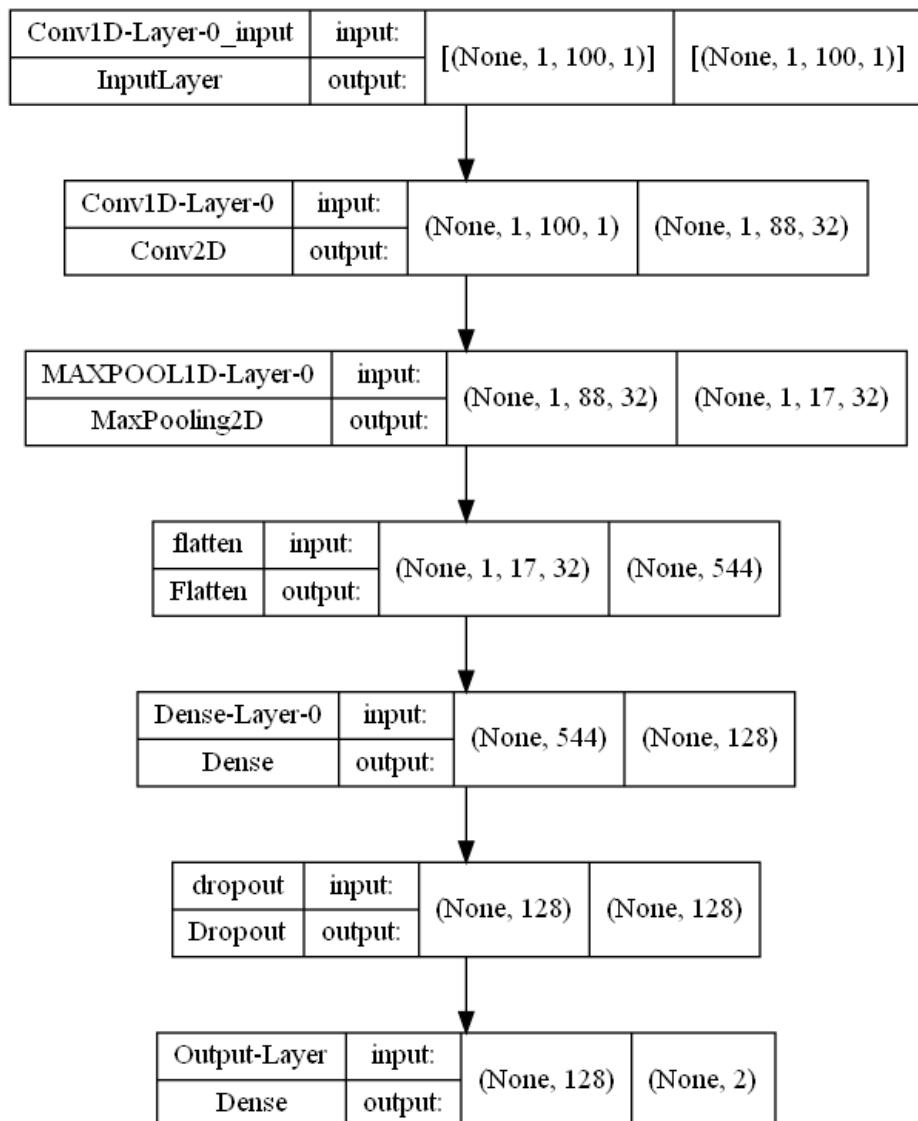
Dropout ANN	Loss	Accuracy	Precision	Recall
Trénink				
0,0	0,4790	0,7882	0,7882	0,7882
0,1	0,5358	0,7489	0,7489	0,7489
0,2	0,4521	0,8118	0,8118	0,8118
0,5	0,4761	0,7977	0,7977	0,7977
Validace				
0,0	0,5251	0,7655	0,7655	0,7655
0,1	0,5925	0,6958	0,6958	0,6958
0,2	0,4264	0,8221	0,8221	0,8221
0,5	0,4481	0,8078	0,8078	0,8078

Měřením byla zjištěna dle průběhu Accuracy (2.33, 2.34) a Loss (A.19, A.20), že nejoptimalnější je nastavení Dropout **0,2**, kdy nastavení parametru s touto hodnotou dosahuje relativně vysoké Accuracy nad úroveň **0,8**, během validace limitně se blížící k **0,85**, zatímco Loss bylo naměřeno pod hodnotami **0,45** a během validační fáze byla naměřena hodnota konvergující k **0,4**.

2.5.3 Učení a vyhodnocení optimalizovaného modelu

Na základě výsledků uvedených v předchozí kapitole optimalizačních procesů byla stanovena optimalizovaná struktura modelu dle experimentálně stanovené konfigurace parametrů a hyperparametrů neuronové sítě. Strukturu optimalizovaného modelu shrnuje

Obrázek ***Chyba! Nenalezen zdroj odkazů.*** s uvedením jednotlivých vrstev a parametrů s ítě. Na základě experimentálního optimalizačního procesu byla v konvoluční části ponechána jedna konvoluční vrstva s nastavenou šírkou masky **13** vzorků o počtu filtrů **32**. Byla upravena šířka MaxPool vrstvy na **5** vzorků, Dropout vrstva byla na základě horších výsledků klasifikace odebrána. Optimalizovaný model implementuje na základě výsledků optimalizace pouze **jednu** densní vrstvu o počtu perceptronů **128** s následující Dropout vrstvou o pravděpodobnosti blokace vstupů signálů **0,2**. V tabulce jsou shrnutý zbylé hyperparametry optimalizovaného modelu, jejichž nové nastavení bylo zjištěno během optimalizační fáze praktické části. Model konfigurace nastavení byl následně použit pro „ostrou“ testovací fázi.

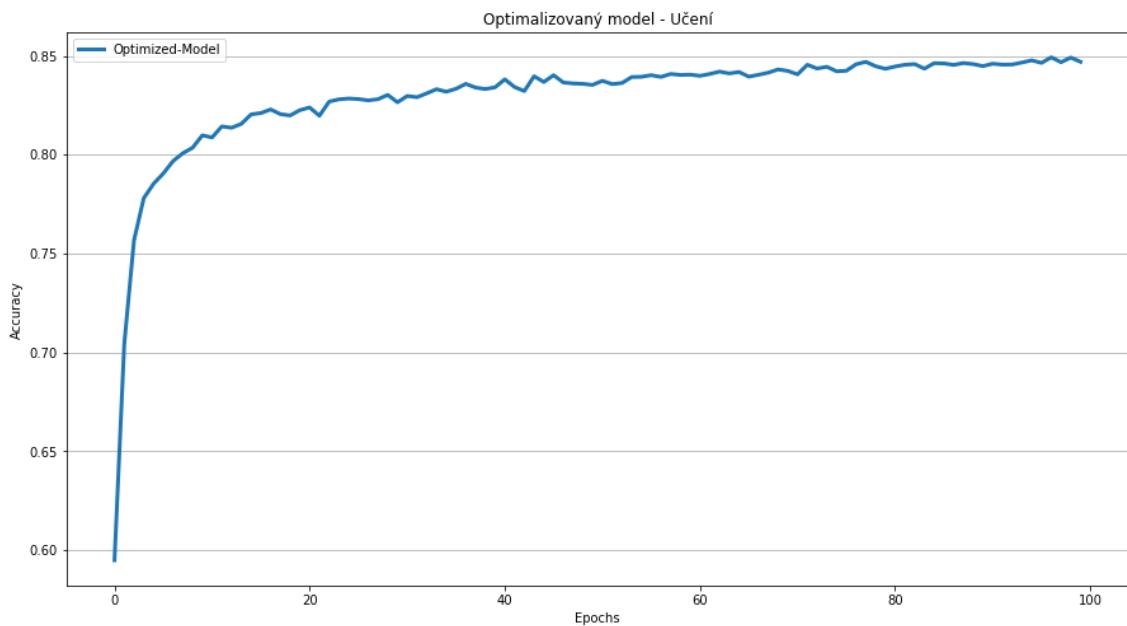


Obrázek 2.35 Struktura optimalizovaného modelu

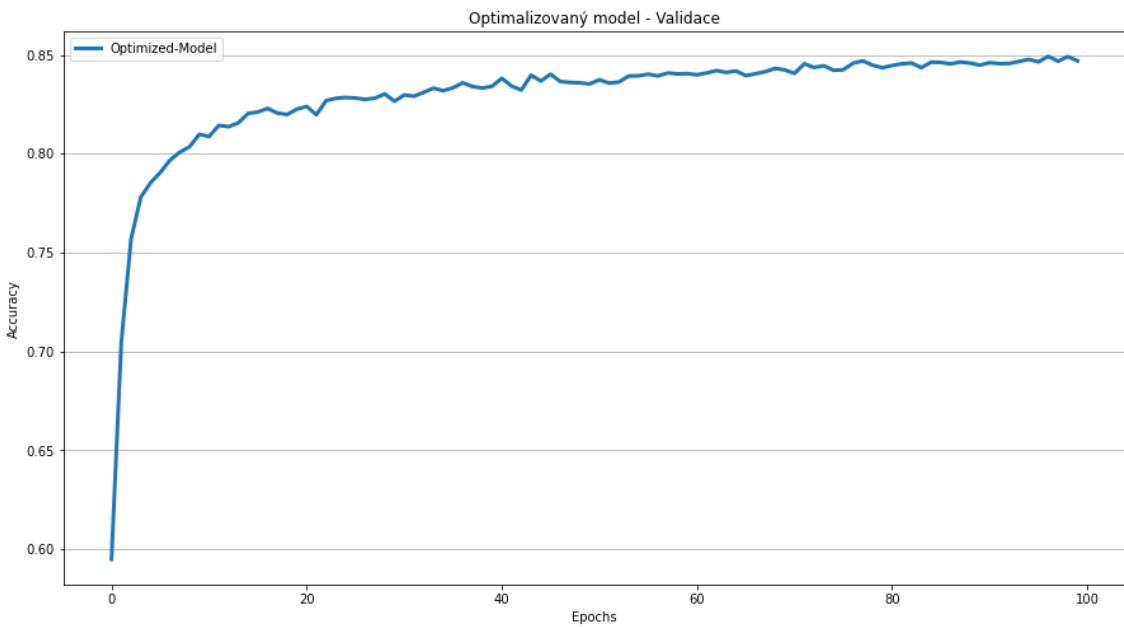
Tabulka 2.30 Optimalizované nastavení hyperparametrů

Optimalizované hyperparametry	Nastavené hodnoty
Inicializace vah konv. filtrů	He Uniform
Inicializace vah perceptronů	He Uniform
Optimalizační algoritmus	Adam
Velikost Batch	32

Před samotnou testovací fází bylo provedeno učení a validace modelu s nově získaným nastavením parametrů a hyperparametrů. Procesy validace a tréninku proběhly při nastavení **100** epoch, aby bylo možné sledovat chování modelu v dlouhodobějším měříku a jeho stabilitu vývoje metrik klasifikace SCR složek v testovaném datasetu.



Obrázek 2.36 Graf vývoje Accuracy – optimalizovaný model – učení



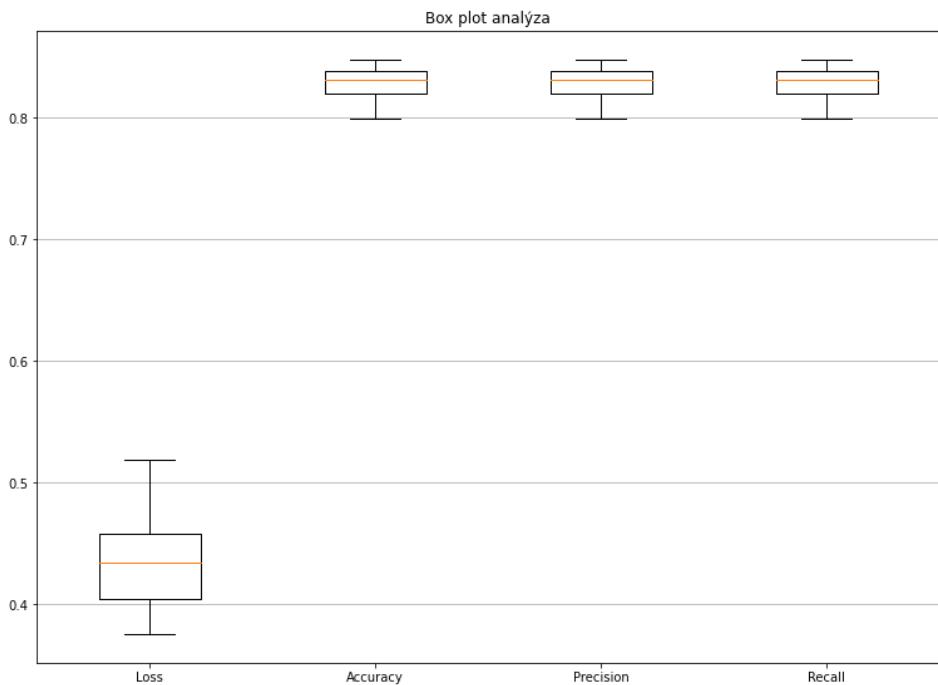
Obrázek 2.37 Graf vývoje Accuracy – optimalizovaný model – validace

Tabulka 2.31 Optimalizovaný model – naměřené hodnoty

Optimalizovaný model, Epoch = 100	Loss	Accuracy	Precision	Recall
Trénink				
	0,3650	0,8470	0,8470	0,8470
Validace				
	0,4054	0,8445	0,8445	0,8445

Průběh naměřených hodnot Accuracy identifikace responzivních složek během trénovací a validační fáze demonstrují grafy 2.36, 2.37 při nastavení 100 epoch učení dochází ke konvergenci k hodnotám **0,85**. V případě měření Loss se hodnota blíží k **0,35**. Je tak patrné zlepšení oproti předcházejícímu modelu, kdy při optimalizaci došlo k jeho zjednodušení.

Po trénování a validaci optimalizovaného modelu s upraveným nastavením byl algoritmus evaluován na vzorku testovacích dat náhodně generovaných ve 30 měřících cyklech. V těchto datech byla ve zkušební fázi hledána responzivní složka adaptovaným algoritmem hlubokého učení.



Obrázek 2.38 Boxplot analýza úspěšnosti identifikace modelu na testovacích datech

2.32 Statistické parametry evaluace modelu

Statistické parametry evaluace opt. modelu	Max	Min	Med	Stř. hodnota	Sm. odchylka
Loss	0,5507	0,3886	0,4685	0,4706	0,0481
Accuracy	0,8539	0,7768	0,8307	0,8259	0,0196
Precision	0,8539	0,7768	0,8307	0,8259	0,0196
Recall	0,8539	0,7768	0,8307	0,8259	0,0196

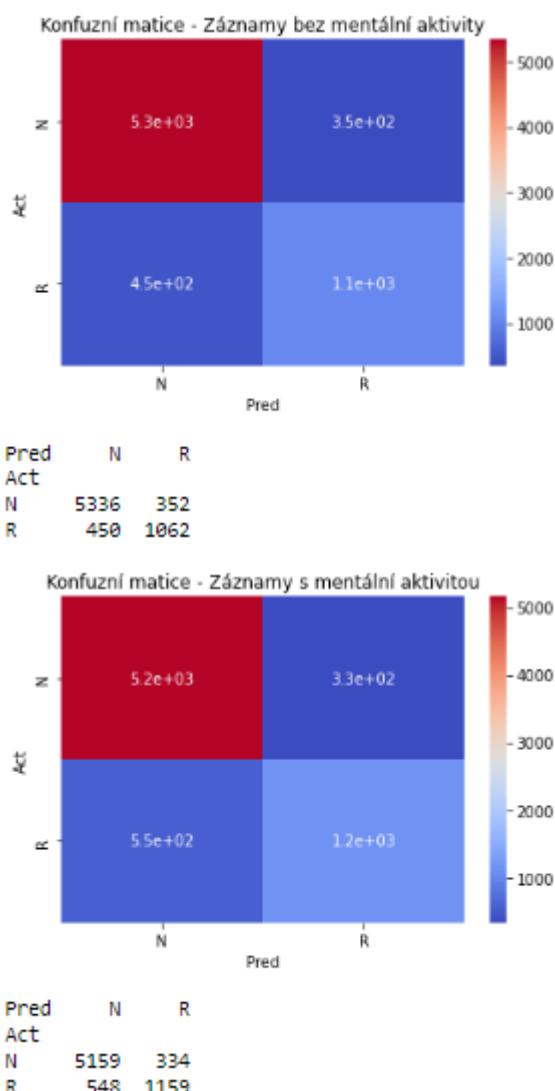
Boxplot analýza 2.38 ukazuje rozložení hodnot použitých metrik identifikace SCR. V případě Accuracy, Precision a Recall je rozložení většiny hodnot v relativně úzkém pásmu s horní mezí definovanou maximem **0,8539** a dolní mezí definovanou minimem **0,7768**. Rozložení kvartilů je u použitých metrik v relativně úzkém rozmezí kolem hodnot **0,82** a **0,83** s mediánem **0,8307**, tedy blíže k horní hranici. Průměrná hodnota metrik byla kalkulována z naměřených vzorků evaluace klasifikačního modelu na **0,8259** se směrodatnou odchylkou **0,0196**.

Rozložení naměřených hodnot v rámci měření Loss identifikace SCR optimalizovaným modelem je vyšší s minimem o hodnotě **0,3886** a maximem až **0,5507**, avšak s hodnotou mediánu **0,4685** a průměrnou hodnotou **0,4706** s vyšší směrodatnou

odchylkou. Lze tedy konstatovat, že ačkoli přesnost klasifikace je relativně vysoká, optimalizovaný a naučený model stále vykazuje relativně vyšší míru chybovosti výpočtu klasifikační třídy algoritmem.

2.5.4 Vyhodnocení modelu klasifikace měřených záznamů

Po evaluaci modelu bylo zahájeno měření modelu aplikováním celých záznamů získaných při menší a vyšší mentální aktivitě měření podrobených osob. Záznamy byly náhodně zvolené z pořízeného vzorku naměřených dat ve 30 cyklech měření, kdy proběhla identifikace SCR složek v jednotlivých záznamech elektrodermální aktivity optimalizovaným, naučeným a evaluovaným modelem.



Obrázek 2.39 Konfuzní matice – SCR v záznamech s a bez mentální aktivity

Obrázek 2.39 ilustruje statistickou analýzu identifikace SCR ve vzorcích záznamu dle míry mentální aktivity formou konfuzních matic.

V případě identifikace SCR složek v záznamech u jedinců ve fázi bez mentální aktivity jsou dominantní segmenty bez responsitivit stejně jako v případě fáze, kdy je mentální aktivita zvýšená. To je způsobeno charakterem signálu, kdy se responzí v relativně dlouhé časovém záznamu vyskytuje významně méně. Accuracy je v případě měření při fázi bez mentální aktivity cca **0,888**, Precision je po přepočítání na úrovni cca **0,7512** a Recall je kalkulována na hodnotu **0,7023**.

Po aplikaci klasifikačního algoritmu na záznam měření u subjektů s vyšší mentální aktivitou byla naměřena přepočítaná Accuracy **0,8775**, Precision o hodnotě **0,7763** a Recall kalkulována na hodnotu **0,6789**. Je patrné mírné snížení Accuracy, kdy se v záznamu s vyšší mentální aktivitou vyskytovalo více SCR složek, které v některých případech algoritmus nebyl schopen rozpoznat. Vyšší množství identifikovaných SCR složek navrženým a optimalizovaným algoritmem bylo podle předpokladů zaregistrováno v měřených záznamech, avšak oproti skutečným detekovaným složkám s výrazně menší hodnotou Recall, zatímco Precision se pohybuje na zhruba konstantní hodnotě, jak v případě naměřených výsledků u záznamů bez mentální aktivity.

2.6 Diskuze

V úvodu diskuzní části nutno podotknout a upozornit na fakt, že při přepočítávání stanovených metrik vyhodnocení úspěšnosti klasifikace navrženým modelem došlo k nežádoucímu efektu, kdy hodnoty Precision a Recall byly implementovaným algoritmem přepočítány na identickou hodnotu s vyhodnocenými hodnotami metiry Accuracy. K tomu docházelo ve všech případech měření v rámci experimentální části. I přes ověření správnosti implementace algoritmu pomocí programových knihoven **Keras** nebylo možné přes vícenásobné zkoušení jiných variant, například přes knihovny **Scikitlearn**, zvolené metriky získat. Jedná se o pravděpodobně technickou limitaci chybňých dll knihoven pro programové balíčky **Keras** a **Scikitlearn** aplikovaných skrze použité programové prostředí **Jupyter Notebook**, jenž nebylo možné zprovoznit na počítači, na němž veškerá činnost související s touto prací probíhala. Pro ilustraci jsou však hodnoty zmíněných metrik v tabulkách hodnot uvedeny, aby byl evidentní výstup běhu implementovaných algoritmů. Výstupní výsledky včetně konkrétní implementace je možné dohledat v příslušných souborech se zdrojovými kódy v přibaleném zip souboru.

V rámci optimalizačních postupů původně navrženého modelu CNN je patrné, že zlepšení klasifikace SCR složek bylo docíleno zjednodušení navržené architektury odstraněním některých prvků modelu s výchozím nastavením. To odpovídá teoretickému předpokladu fungování CNN, kdy pro zachycení význačný rysů v 1D signálech postačuje

algoritmům daného typu konvoluční vrstvení nižší hloubky, které je schopno zaznamenat cílené artefakty záznamů 1D liniích. Více konvolučních vrstev může mít za následek, jak bylo ověřeno v experimentální části optimalizace, zaměření sítě na některé chybné nebo nepodstatné detaily vyšší úrovně, které nemusí být součástí SCR složek a dochází tak k chybnější identifikaci responzivních složek. Tento jev byl pozorován při aplikaci více konvolučních vrstev o větším počtu filtrů a menší šírkou masky, kdy neuronová síť byla více zaměřena na rysy více lokálního charakteru vyššího stupně, což následně ztěžovalo klasifikaci navazujících vrstev ANN. Relativně vysoké úspěšnosti klasifikace, resp. identifikace responzivních složek bylo docíleno implementací algoritmu hlubokého učení relativně jednodušší architektury, čímž byly i procesy spouštění navržené sítě jako učení, validace a evaluace významně urychleny, stejně jako průběh testování celistvých záznamů podle stupně mentální aktivity. Redukce navržených modulů byla provedena odstraněním, jak se postupně při optimalizačním procesu projevilo, **Dropout** vrstev z původního návrhu modelu v rámci konvoluční části neuronové sítě. Vlivem příslušné vrstvy byla redukována větší míra vstupních vzorků ještě před průchodem do **MaxPool** vrstvy a vzhledem k relativně nízkému vstupnímu vzorku měřeného signálu elektrodermální aktivity byly tak některé relevantní „featury“ ze vstupní mapy odstraněny a vícenásobné stínění navazující **MaxPool** vrstvou mohlo signál významně redukovat, kdy následná klasifikace již byla z omezeného datového toku sítí velmi problematická. Odstranění **Dropoutu** bylo velmi přínosné z hlediska následně měřených hodnot metrik Accuracy, která se během učící a validační fáze zvýšila a stabilizovala nad hodnotami **0,8** a konvergovala limitně k hodnotě **0,85**. Dostatečná byla pro navržený model pro účel identifikace SCR složek jedna vrstva ANN o **128**, kdy hodnota Accuracy byla ustálena nad hodnotami **0,8** a naměřená Loss hodnotově klesala pod **0,5**. Dropout vrstva za ANN vrstvou byla, jak se během optimalizace ukázalo, přínosným prvkem pro zabránění přeúčení densní části vrstvy při hodnotě pravděpodobnosti odpojení signálu **0,2**. Jednalo se o významný element v rámci managementu proti riziku přeúčení, což je velkým nedostatkem zvláště i modelů menší hloubky a ne příliš vysoké komplexnosti i při relativně obsáhlém datasetu. Batch normalizační vrstva pro ANN sítě nebyla potřebná, vzhledem k menšímu vstupnímu datovému setu docházelo ke zhoršení schopnosti klasifikace. Obdobně tomu bylo při zavedení regularizace elementů jednotlivých vrstev, což se neprojevilo žádoucím účinem zvýšení schopnosti identifikace SCR během validace, kdy Accuracy klesla v některých případech podle měření až pod hodnotu **0,5** zatímco hodnota Loss se zvýšila k řádově vyšším hodnotám. Důvodem pravděpodobně byl vyšší negativní vliv změn parametrů sítě při chybné klasifikaci během validace, kdy vzhledem k menšímu počtu elementů byl proces zpracování narušen náhlými změnami hodnot nastavitelných parametrů vlivem regulace. Nejvhodnějším nástrojem v tomto případě se ukázala být zmíněná **Dropout** vrstva v části ANN. V rámci řešení dané problematiky byla možná implementace modele s konvoluční vrstvou o jednotkové hloubce a stejně tak ANN částí o stejně šířce. Optimalizovaný model podle měření Accuracy při trénovací a

validační fázi je výpočetně méně náročný, proces učení je relativně rychlý, stejně jako následně evaluace signálu elektrodermální aktivity. Accuracy konvergovala velmi rychle při optimalizovaných hyperparametrech k hodnotám i nad **0,85**, což je ale ještě považováno za relativně nízkou přenosnost klasifikace v rámci moderních aplikací klasifikačního typu. Problematická byla rovněž ustálená hodnota měřené Loss zaznamenaná ve všech provedených experimentech, což byl hlavní faktor neúspěchu identifikovat některé SCR složky v konečné ostré testovací fázi při aplikaci naučeného optimalizovaného algoritmu na celé záznamy elektrodermální aktivity. Zde byla patrná relativně vysoká úrovně Pression k hodnotě **0,8** avšak nízkou úrovní Recall kolem **0,7**. To lze interpretovat tak, že naučený model je schopen přesně klasifikovat daný typ SCR více se vyskytující v záznamech bez mentální zátěže, avšak je už méně schopen zachytit některé variabilnější artefakty responzivních složek vyskytujících se zejména při mentální aktivitě, tj. že je více specifický.

Jednou z příčin k výše popsaným zjištěným nedostatkům a potenciálním negativním projevem mohl být relativně omezený datový set, kdy v prvopočátku před samotnou přípravou dat bylo nutné některé celé záznamy odstranit ze vzorků kvůli chybnému měření, kdy měřený signál byl buď zcela nepatrny nebo vlivem chybné metodiky měření zcela zdeformovaný a nepoužitelný. V rámci procesu anotace rovněž nebylo možné zcela přesně detektovat veškeré složky SCR, jelikož se projevovaly někdy s velkou variabilitou tvarů a ačkoli navržená metoda anotace byla vyzkoušena na všech vzorcích záznamů, jež byly k dispozici, aby byla schopna pokrýt co největší množství vyskytujících se responzitivit, vlivem lidského faktoru nebylo v některých případech možné některé artefakty přesně rozpoznat, tudíž nastavení detekce lokálních maxim nemuselo být vždy zcela přesné. Nicméně i přesto bylo poskynuto relativně velké množství vzorku SCR proměnných tvarů, což ale na druhou stranu může mít pozitivní vliv, kdy obsah zkoumaných rysů signálů extrahovaných ze signálu konvolučními vrstvami je vyšší a díky proměnlivosti vstupních vzorků s detekovanými SCR je menší riziko přeúčtení. Nežádoucí mohla být relativně obsáhlá délka velmi dlouhých záznamů, kdy dominantní v segmentovaných datech byl projev jiných složek než responzivních, které jsou zpravidla velmi rychlé, jejich výskyt není tak frekventovaný a jejich výskyt je mj. velmi individuální podle mentálního a psychického nastavení jedince, což bylo v některých záznamech velmi patrné, kdy k menšímu výskytu SCR složek docházelo i při fázích vyšší mentální zátěže. Po vybalancování anotovaných segmentů byl datový set výrazně zredukován, nicméně pro účely navržené sítě relativně malé komplexnosti, rychle se učící s nastavením velikosti Batch **32** byl pravděpodobně dostatečný. Limitací metody může být větší citlivost, pokud data nejsou konzistentní, například když se objevují detekované složky SCR s vyšší variabilitou, které konvoluční jádra sítě s pevnou šírkou filtrů nemusí zcela přesně vysegmentovat. Vzhledem k teoreticky stanovenému relativně úzkému frekvenčnímu pásmu výskytu responzivních složek ať už generované přes sympatickou nebo parasympatickou větev nervového systému, by tento jev neměl být příliš významný,

ačkoli se opět jedná o faktor, který je významně ovlivněn individualitou každého subjektu. Relativně úzký vzorek signálu pro vstupní část byl dostatečný vzhledem k velmi nízké frekvenci pásma hledaných responzí, experimentální zvýšení rozsahu vstupního vzorku signálu nevykazovalo zlepšení míry identifikace SCR, kdy docházelo mj. k rychlému přeучení, snížení dynamiky učení a celkově menších dosažených naměřených hodnot Accuracy.

I přes zmíněné nedostatky algoritmus byl schopen zaznamenat responzivní složky s relativně velkou přesností během fáze testování optimalizovaného a validovaného modelu na záznamech s různým stupněm aktivity, kdy vyšší aktivita byla v korelací s vyšším výskytem reálných i detekovaných responzí. Vlivem menší účinnosti modelu vlivem variability hledaných složek během mentální zátěže, kdy se zapojovaly více nervové dráhy sympatiku, byly zaznamenána významně nižší senzitivita, tedy účinnost správného zaznamenání SCR složek, i když její hodnota se konstantně pohybovala kolem hodnot cca 0,8. Variabilita dat by nicméně měla být z části kompenzována například **MaxPool** vrstvou, která nezávisle na pozici nebo výskytu některých rušivých elementů nebo změn parametrů relevantních rysů, je schopna hledanou charakteristiku určenou pro klasifikaci extrahovat a zesílit. To bylo prokázáno během experimentů nastavení vyšší šířky okénka **MaxPool** vrstvy, což mělo přínosný efekt pro přesnost detekce SCR navrženým modelem.

Lze tak shrnout, že i přes v porovnání s jinými algoritmy klasifikačního typu z rodiny hlubokého nebo strojového učení má navržený model pro identifikaci relativně vysokou míru měřené ztrátovosti, kterou se nepodařilo i přes delší nastavení epoch učení snížit pod méně jak **0,35**, model byl i přesto schopen s relativně velkou přesností kolem hodnoty **0,85** identifikovat responzivní složky ve všech záznamech a rozeznat je od složek bez responzitivity. To bylo umožněno nehledě na variabilitu některý poskytnutých dat objevujících se zejména v záznamech s vyšší mentální aktivitou. I přesto byl algoritmus schopen rozpoznat rozdíl v míře v psychického rozpoložení jedinců s očekávaným vyšším množstvím detekovaných SCR, ale s poněkud menší senzitivitou. Je ale nutné vzít do úvahy okolnosti související s efektivitou zpracování algoritmem, který je schopný rychle se naučit i při delším nastavení epoch nebo velikostí batch. Dostatečná však byla velikost **32** nastavení hyperparametru **batch**. Jako vhodný prostředek ke zlepšení navržené metody detekce SCR do budoucna se jeví rozšířené modelu v konvoluční části pomocí incepčních modulů využívaných v současnosti např. sítěmi GoogleNet určených ke klasifikaci obrazů. K této nové architektuře modelu neuronových sítí typu CNN bylo věnováno samostatné pojednání v kapitole 2.2.1. Model incepční neuronové sítě totiž aplikuje v rámci jedné vrstvy paralelně více konvolučních filtrů pro extrakci daného hledaného význačného rysu hledaného artefaktu v signálu s různým nastavení (např. počet filtrů, počet konvolučních masek atd.), které zpracovávají vstupní signál simultánně. Tím lze teoreticky docílit snížení míry citlivosti identifikace navrženým algoritmem k vyšší variabilitě vyhodnocených záznamu elektrodermální aktivity. Tento

přístup však v rámci návrhu a designu algoritmu nebyl uvažován jako vhodný, protože v praxi je jeho smysl největší při zpracování signálu mnohonásobné dimensionality, kdy je záznam signálu pořízen z mnoha jiných zdrojů ve stejném čase, resp. senzorů. Kromě tohoto faktoru, byl v rámci předzpracování signálu pro vytvoření anotovaného datasetu pro navržený algoritmus každý vzorek záznamu podroben frekvenční analýze, kdy pro většinu případů bylo frekvenční pásmo maximálních sledovaných SCR složek $0,02 - 0,2 \text{ Hz}$ a hodnotou amplitudy $0,01 - 0,05$ normalizovaného rozsahu měřené konduktance. Z těchto naměřených údajů bylo tedy usouzeno, že responzivní složky jsou vzhledem k nízkým hodnotám frekvence a amplitudy, jenž se vyskytuje dle frekvenční analýzy v intervalech malého rozsahu, relativně stálého charakteru bez velké míry variantnosti parametrů definující jejich tvar.

ZÁVĚR

Cílem práce byla implementace a realizace vybraného algoritmu typu hlubokého učení a tuto metodu použít k identifikaci responsivních složek v signálech elektrodermální aktivity a ověřit rozdíly v případech, kdy je jedinec ve stavu vyšší bdělosti vlivem zvýšení mentální a psychické aktivity. Toho bylo docíleno navrzením a implementací algoritmu využívající model neuronové sítě typu CNN s méně komplexní navrženou architekturou, která se však během optimalizačního procesu ukázala být pro jednorozměrný signál daného typu jako dostatečná. Algoritmus po procesu učení, validace a evaluace byl schopen rozpoznat SCR složky s relativně velkou úspěšností. Trénovací fáze algoritmu vykazovala relativně vysokou dosaženou přesnost v poměrně krátkém časovém horizontu díky implementovaným konvolučním filtrům, avšak s poměrně vysokou měrenou ztrátovostí. To se projevilo zejména při klasifikaci na záznamech s vyšší mentální aktivitou, kdy byla výrazně menší senzitivita, nicméně stále vyšší vzorek responzivních složek byl algoritmus schopen rozpoznat i přes vyskytující se variabilitu složek v signálu obsáhle časové délky. Vyšší nález responzivních složek byl tedy v korelací s teoretickým předpokladem vzhledem k vyšší mentální aktivitě, což potvrdil i počet responzí detekovaných metodou anotace. Bylo tak možno, na základě vyššího výskytu detekovaných SCR složek, rozpoznat, zda se jedná o fázi mentální aktivity nebo nikoli. I přes zjištěné nedostatky a nepřesnosti detekce některých vyskytujících se responzitivit, lze závěrem zhodnotit, že algoritmus hlubokého učení typu CNN je vhodným nástrojem pro efektivní zpracování 1D signálu s rychlým a efektivním chodem a je schopen responzivní složky klasifikačním přístupem pomocí řetězce konvolučních operací rozpoznat. Jako teoretický předpoklad ke zpřesnění identifikace responzí navrženého algoritmu se jeví do budoucna rozšíření stávajícího modelu pomocí bloku architektury incepčních neuronových sítí.

LITERATURA

- [1] A Guide for Analysing Electrodermal Activity (EDA) & Skin Conductance Responses (SCRs) for Psychological Experiments [online]. 2. University of Birmingham, UK: Behavioural Brain Sciences Centre, University of Birmingham, UK, 2015 [cit. 2021-01-04]. Dostupné z: <https://www.birmingham.ac.uk/Documents/college-les/psych/saal/guide-electrodermal-activity.pdf>
- [2] Alexander, D. M., Trengove, C., Johnston, P., Cooper, T., August, J. P., & Gordon, E. (2005). *Separating individual skin conductance responses in a short interstimulus-interval paradigm*. *Journal of Neuroscience Methods*, 146, 116–123
- [3] AMIEZ, Céline a Emmanuel PROCYK. *Midcingulate somatomotor and autonomic functions. Cingulate Cortex* [online]. Elsevier, 2019, 2019, s. 53-71 [cit. 2021-01-04]. *Handbook of Clinical Neurology*. ISBN 9780444641960. Dostupné z: doi:10.1016/B978-0-444-64196-0.00004-2
- [4] Analyze Electrodermal Activity (EDA). [Www.neurokit2.readthedocs.io](http://www.neurokit2.readthedocs.io) [online]. Dominique Makowski Revision, 2020 [cit. 2021-01-04]. Dostupné z: <https://neurokit2.readthedocs.io/en/latest/examples/eda>.
- [5] Bach, D. R., Friston, K. J., & Dolan, R. J. (2010). *Analytic measures for quantification of arousal from spontaneous skin conductance fluctuations*. *International Journal of Psychophysiology*, 76, 52–55.
- [6] BENEDEK, Mathias a Christian KAERNBACH. A continuous measure of phasic electrodermal activity. *Journal of Neuroscience Methods* [online]. 2010, 190(1), 80-91 [cit. 2022-05-07]. ISSN 01650270. Dostupné z: doi:10.1016/j.jneumeth.2010.04.028
- [7] Benedek, M., & Kaernbach, C. (2010). *Decomposition of skin conductance data by means of nonnegative deconvolution*. *Psychophysiology*, 47, 647–658.
- [8] Ben-Shakhar, G. (1985). *Standardization within individuals: A simple method to neutralize individual differences in psychophysiological responsivity*. *Psychophysiology*, 22, 292–299.
- [9] Blecker, C. R., Kirsch, P., Schaefer, F., & Vaitl, D. (2001). *Skin conductance measurement during fMRI scans: A methodology study*. *Psychophysiology*, 38, S27.
- [10] BOUCSEIN, Wolfram. *Electrodermal Activity* [online]. Boston, MA: Springer US, 2012 [cit. 2022-05-07]. ISBN 978-1-4614-1125-3. Dostupné z: doi:10.1007/978-1-4614-1126-0
- [11] Boucsein, W., Schaefer, F., & Sommer, T. (2001). *Electrodermal long-term monitoring in everyday life*. In J. Fahrenberg & M. Myrtek (Eds.), *Progress in ambulatory assessment* (pp. 549–560). Göttingen: Hogrefe.
- [12] Breska, A., Maoz, K., & Ben-Shakhar, G. (2011). *Inter-stimulus intervals for skin conductance response measurement*. *Psychophysiology*, 48, 437–440.
- [13] Cowley, M. Filetti, K. Lukander, J. Torniainen, A. Henelius, L. Ahonen, O. Barral, I. Kosunen, T. Valtonen, M. Huotilainen, N. Ravaja, G. Jacucci. *The Psychophysiology Primer: a guide to methods and a broad review with a focus on human-computer interaction. Foundations and Trends in Human-Computer Interaction*, vol. 9, no. 3-4, pp. 150–307, 2016. Dostupné z: <https://arxiv.org/pdf/1608.06986.pdf>
- [14] FREEMAN, Roy a Mark W. CHAPLEAU. *Testing the autonomic nervous system. Peripheral Nerve Disorders* [online]. Elsevier, 2013, 2013, s. 115-136 [cit. 2021-01-04]. *Handbook of Clinical Neurology*. ISBN 9780444529022. Dostupné z: doi:10.1016/B978-0-444-52902-2.00007-2
- [15] GRECO, Alberto, Gaetano VALENZA, Antonio LANATA, Enzo SCILINGO a Luca CITI. *CvxEDA: a Convex Optimization Approach to Electrodermal Activity Processing*. *IEEE Transactions on Biomedical Engineering* [online]. , 1-1 [cit. 2021-01-05]. ISSN 0018-9294. Dostupné z: doi:10.1109/TBME.2015.2474131

- [16] *Handbook of physiology* [online]. 2. University of Cambridge, UK: Cambridge university press, 2000, s. 24 [cit. 2021-01-04]. Dostupné z: <http://apsychoserver.psych.arizona.edu/JJBAReprints/PSYC501A/Readings/Chapter%208.pdf>
- [17] CHON, K.H., Shishir DASH a Kihwan JU. *Estimation of Respiratory Rate From Photoplethysmogram Data Using Time–Frequency Spectral Estimation*. IEEE Transactions on Biomedical Engineering [online]. 2009, 56(8), 2054-2063 [cit. 2021-01-05]. ISSN 0018-9294. Dostupné z: doi:10.1109/TBME.2009.2019766
- [18] IKEZAWA, Satoru, Silvia CORBERA, Jiacheng LIU a Bruce E. WEXLER. *Empathy in electrodermal responsive and nonresponsive patients with schizophrenia*. Schizophrenia Research [online]. 2012, 142(1-3), 71-76 [cit. 2021-01-04]. ISSN 09209964. Dostupné z: doi:10.1016/j.schres.2012.09.011
- [19] KRAPOHL, Donald J. a Pamela K. SHAW. *Advanced topics. Fundamentals of Polygraph Practice* [online]. Elsevier, 2015, 2015, s. 231-273 [cit. 2021-01-04]. ISBN 9780128029244. Dostupné z: doi:10.1016/B978-0-12-802924-4.00011-6
- [20] MELANDER, Catharina, Jesper MARTINSSON a Silje GUSTAFSSON. *Measuring Electrodermal Activity to Improve the Identification of Agitation in Individuals with Dementia*. Dementia and Geriatric Cognitive Disorders Extra [online]. 2018, 7(3), 430-439 [cit. 2021-01-05]. ISSN 1664-5464. Dostupné z: doi:10.1159/000484890
- [21] POSADA-QUINTERO, Hugo F., John P. FLORIAN, Alvaro D. ORJUELA-CAÑÓN, Tomas ALJAMA-CORRALES, Sonia CHARLESTON-VILLALOBOS a Ki H. CHON. *Power Spectral Density Analysis of Electrodermal Activity for Sympathetic Function Assessment*. Annals of Biomedical Engineering [online]. 2016, 44(10), 3124-3135 [cit. 2021-01-04]. ISSN 0090-6964. Dostupné z: doi:10.1007/s10439-016-1606-6
- [22] POSADA-QUINTERO, Hugo F., John P. FLORIAN, Alvaro D. ORJUELA-CAÑÓN a Ki H. CHON. *Electrodermal Activity Is Sensitive to Cognitive Stress under Water*. Frontiers in Physiology [online]. 2018, 8 [cit. 2021-01-04]. ISSN 1664-042X. Dostupné z: doi:10.3389/fphys.2017.01128
- [23] POSADA-QUINTERO, Hugo. *Electrodermal Activity: What it can Contribute to the Assessment of the Autonomic Nervous System* [online]. THES, 2016/12/06 [cit. 2021-01-04].
- [24] POSADA-QUINTERO, Hugo F. a Ki H. CHON. *Innovations in Electrodermal Activity Data Collection and Signal Processing: A Systematic Review*. Sensors [online]. 2020, 20(2) [cit. 2022-05-08]. ISSN 1424-8220. Dostupné z: doi:10.3390/s20020479
- [25] *Publication recommendations for electrodermal measurements*. Psychophysiology [online]. 2012, 49(8), 1017-1034 [cit. 2021-01-05]. ISSN 00485772. Dostupné z: doi:10.1111/j.1469-8986.2012.01384.x
- [26] SARCHIAPONE, Marco, Carla GRAMAGLIA, Miriam IOSUE, Vladimir CARLI, Laura MANDELLI, Alessandro SERRETTI, Debora MARANGON a Patrizia ZEPPEGNO. *The association between electrodermal activity (EDA), depression and suicidal behaviour: A systematic review and narrative synthesis*. BMC Psychiatry [online]. 2018, 18(1) [cit. 2021-01-05]. ISSN 1471-244X. Dostupné z: doi:10.1186/s12888-017-1551-4
- [27] SHIELDS, Stephanie A., Kathleen A. MACDOWELL, Sarah B. FAIRCHILD a Mary L. CAMPBELL. *Is Mediation of Sweating Cholinergic, Adrenergic, or Both? A Comment on the Literature*. Psychophysiology [online]. 1987, 24(3), 312-319 [cit. 2022-05-08]. ISSN 0048-5772. Dostupné z: doi:10.1111/j.1469-8986.1987.tb00301.x
- [28] SHIMOMURA, Yoshihiro, Takumi YODA, Koji SUGIURA, Akinori HORIGUCHI, Koichi IWANAGA a Tetsuo KATSUURA. *Use of Frequency Domain Analysis of Skin Conductance for Evaluation of Mental Workload*. Journal of PHYSIOLOGICAL ANTHROPOLOGY [online]. 2008, 27(4), 173-177 [cit. 2021-01-05]. ISSN 1880-6805. Dostupné z: doi:10.2114/jpa2.27.173
- [29] Y. YACOOB ALDOSKY, Haval a Dindar S. BARI. *Electrodermal Activity: Simultaneous Recordings*. EL-AZAZY, Marwa, Mart MIN a Paul ANNUS, ed. *Electrochemical Impedance*

- Spectroscopy* [online]. IntechOpen, 2020, 2020-12-16 [cit. 2021-01-04]. ISBN 978-1-78985-215-8. Dostupné z: doi:10.5772/intechopen.89025
- [30] *Mathworks* [online]. United States: The MathWorks, 1994 [cit. 2021-01-06]. Dostupné z: <https://www.mathworks.com/>
- [31] Publication recommendations for electrodermal measurements. *Psychophysiology* [online]. 2012, **49**(8), 1017-1034 [cit. 2022-05-08]. ISSN 00485772. Dostupné z: doi:10.1111/j.1469-8986.2012.01384.x
- [32] Time Series Classification with Deep Learning. *Towards Data Science* [online]. online: Marco Del Pra, 2020 [cit. 2022-05-08]. Dostupné z: <https://towardsdatascience.com/time-series-classification-with-deep-learning-d238f0147d6f>
- [33] Hands-On Climate Time Series Classification with Deep Learning, using Python. *Towards Data Science* [online]. online: Piero Paialunga, 2021 [cit. 2022-05-08]. Dostupné z: <https://towardsdatascience.com/hands-on-climate-time-series-classification-with-deep-learning-using-python-6d5de81004c9>
- [34] Recurrent Neural Networks by Example in Python. *Towards Data Science* [online]. online: Will Koehrsen, 2018 [cit. 2022-05-08]. Dostupné z: <https://towardsdatascience.com/recurrent-neural-networks-by-example-in-python-ffd204f99470>
- [35] Deep Learning for Time Series Classification (InceptionTime). *Towards Data Science* [online]. online: Vasilis Stylianou, PhD, 2020 [cit. 2022-05-08]. Dostupné z: <https://towardsdatascience.com/deep-learning-for-time-series-classification-inceptiontime-245703f422db>
- [36] Object Localization using Keras. *Medium.com* [online]. online: Analytics Vidhya, 2020 [cit. 2022-05-08]. Dostupné z: <https://medium.com/analytics-vidhya/object-localization-using-keras-d78d6810d0be>
- [37] Python Deep Learning - Implementations. *Tutorialspoint.com* [online]. online: Tutorials Point, 2022 [cit. 2022-05-08]. Dostupné z: https://www.tutorialspoint.com/python_deep_learning/python_deep_learning_implementations.htm
- [38] Playing with time series data in python. *Towardsdatascience.com* [online]. online: Towards Data Science, 2018 [cit. 2022-05-08]. Dostupné z: <https://towardsdatascience.com/playing-with-time-series-data-in-python-959e2485bfff8>
- [39] Working with Time Series. *Jakevdp.github.io* [online]. online: Python Data Science Handbook, 2018 [cit. 2022-05-08]. Dostupné z: <https://jakevdp.github.io/PythonDataScienceHandbook/03.11-working-with-time-series.html>
- [40] Time Series Analysis in Python: Filtering or Smoothing Data (codes included). *Www.earthinversion.com* [online]. online: Earth Inversion, 2020 [cit. 2022-05-08]. Dostupné z: <https://www.earthinversion.com/techniques/Time-Series-Analysis-Filtering-or-smoothing-data/>
- [41] What are Hyperparameters ? and How to tune the Hyperparameters in a Deep Neural Network?. *Medium* [online]. online: Towards Data Science, 2017 [cit. 2022-05-19]. Dostupné z: <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a>
- [42] Optimizers. *Keras* [online]. [cit. 2022-05-19]. Dostupné z: <https://keras.io/api/optimizers/>
- [43] Optimizers in Deep Learning. *Medium* [online]. [cit. 2022-05-19]. Dostupné z: <https://medium.com/mllearning-ai/optimizers-in-deep-learning-7bf81fed78a0>
- [44] Understand the Impact of Learning Rate on Neural Network Performance. *Machine Learning Mastery* [online]. [cit. 2022-05-19]. Dostupné z: <https://machinelearningmastery.com/understanding-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/>

- [45] Loss Functions in Deep Learning: An Overview. *Analytics In Diamag* [online]. <https://analyticsindiamag.com/> [cit. 2022-05-19]. Dostupné z: <https://analyticsindiamag.com/loss-functions-in-deep-learning-an-overview/>
- [46] Layer weight initializers. *Keras* [online]. [cit. 2022-05-19]. Dostupné z: <https://keras.io/api/layers/initializers/>

SEZNAM SYMBOLŮ A ZKRATEK

Zkratky:

ANS	Autonomní nervový systém
EDA	Elektrodermální aktivita
HP	Horní propust'
DP	Dolní propust'
PP	Pásmová propust'
SCL	Skin conductance level
SCR	Skin conductance response
PC	Personal computer
EMG	Electromyograph
nS.SCR	Non-specific skin conductance response
HRV	Heart rate variability
EDASymp	Electrodermal activity sympathetic
TVSymp	Time variability sympathetic
HR	Heart rate
ERP	Event related potentials
Ag	Argentum
Ag/Cl	Argentum/Chloride
PSD	Power spectral density
HRVLF	Heart rate variability low frequencies
FFT	Fast Fourier transform
DC	Direct current
AC	Alternating current
RC	Resistance-capacitance
LSTM	Long short-term memory
RNN	Recurrent neural network
BLSTM	Bilateral recurrent neural network
CNN	Convolutional neural network
INN	Inception neural network
CPU	Computational processing unit
ANN	Artificial neural network
SMNA	Sudomotor nerve activity
IRF	Impulse response factor
1-D	jednodimenzionální
INN	Inception neural network
TP	Skutečně pozitivní
TN	Skutečně negativní
FP	Falešně pozitivní

FN	Falešně negativní
API	Automated programmable interface
EKG	Elektrokardiograf

Symboly:

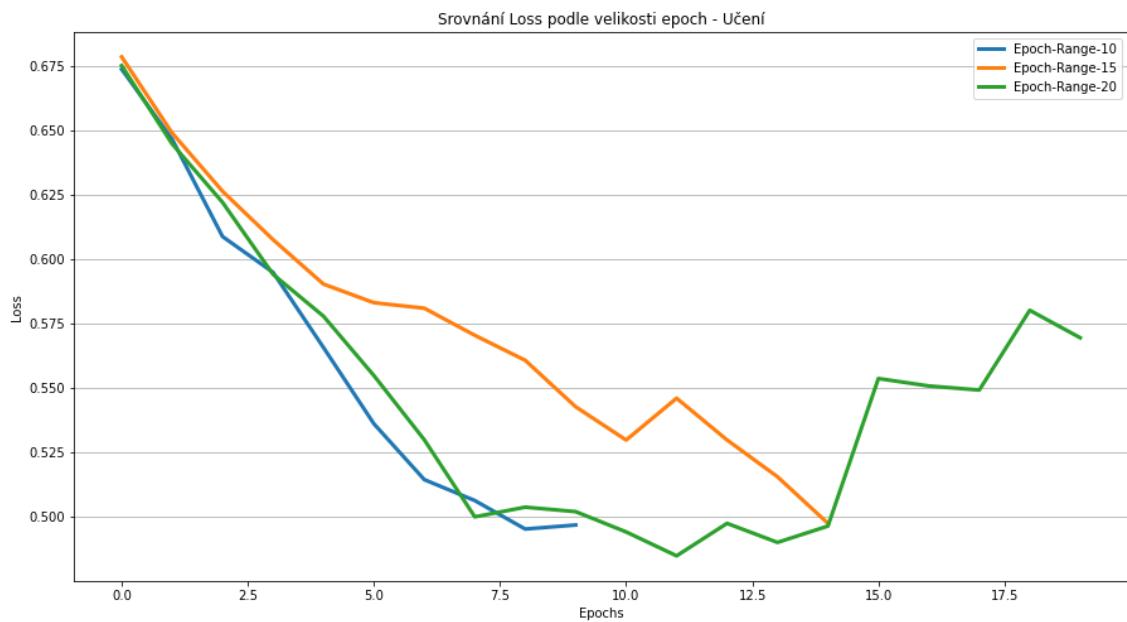
μS	Micro Siemens	(-)
s	Sekunda	(-)
σ	Šířka Gaussova okénka	(ms)
τ	Časová konstanta	(s)
Hz	Hertz	(-)
w	Váha vstupu perceptronu	(-)
f_{vz}	Vzorkovací frekvence	(Hz)
D	Vzdálenost lokálních maxim	(s)
W	Šířka lokálního maxima	(s)
P	Prominence maxima	(-)
D	decimace signálu	(-)

SEZNAM PŘÍLOH

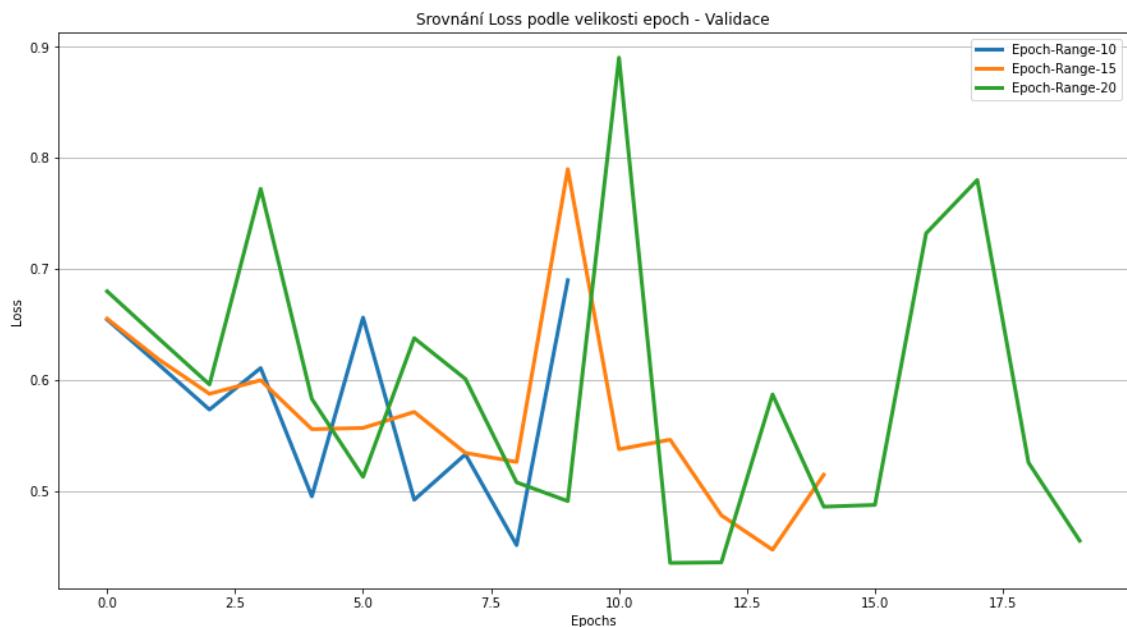
PŘÍLOHA A - NAMĚŘENÉ HODNOTY 104

Příloha A - Naměřené hodnoty

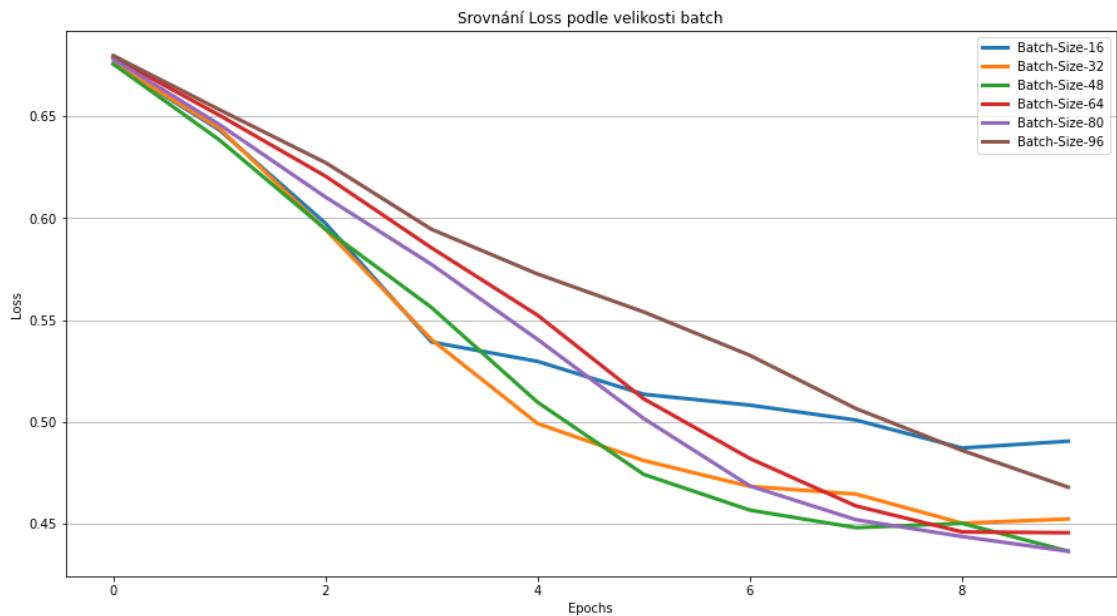
A.1 Graf vývoje Loss – nastavení epoch – trénink



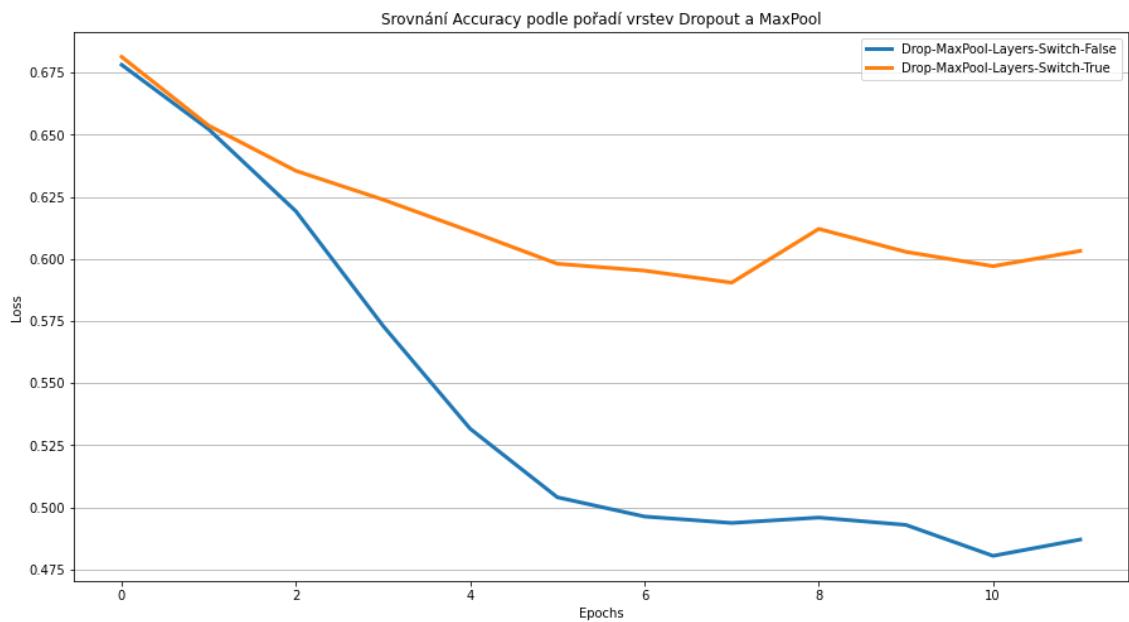
A.2 Graf vývoje Loss – nastavení epoch – validace



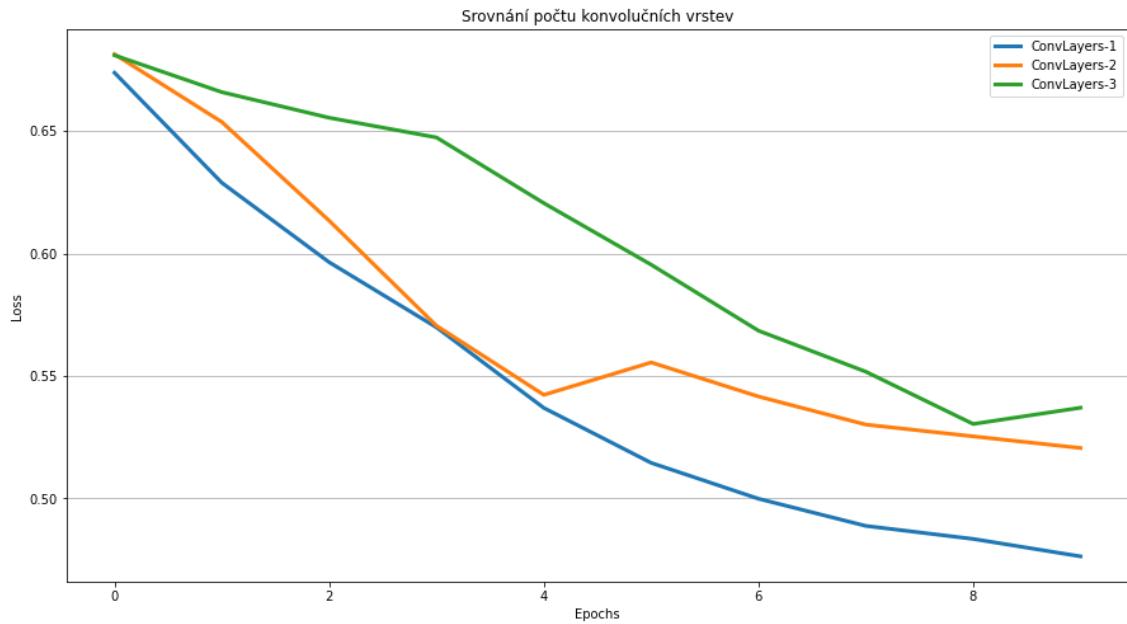
A.3 Graf vývoje Loss – nastavení Batch



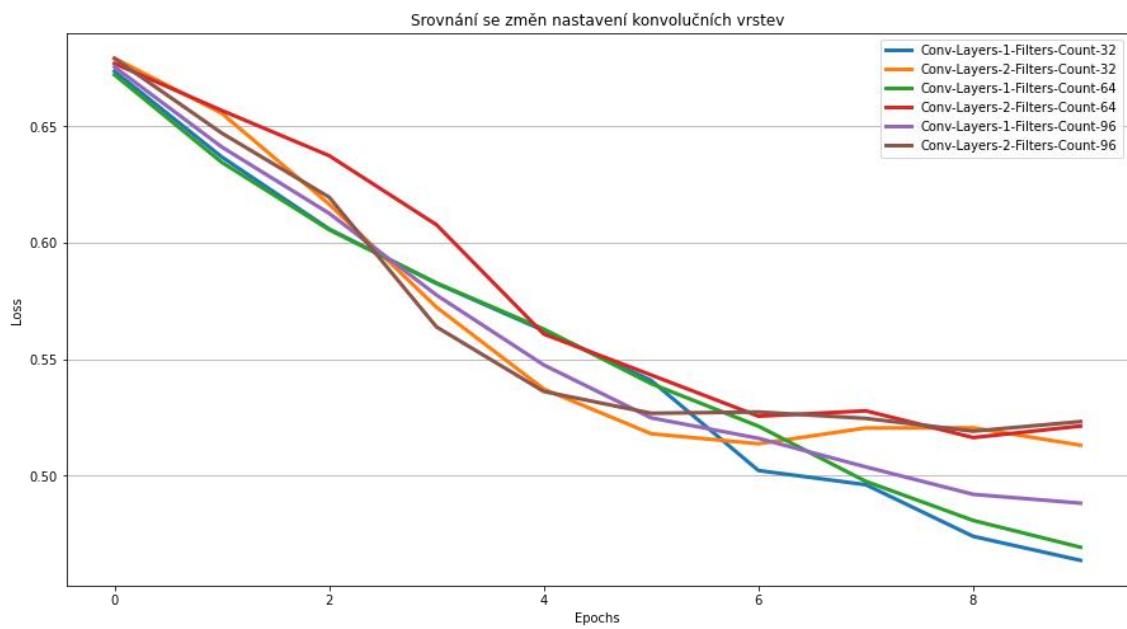
A.4 Graf vývoje Loss – pořadí MaxPool a Dropout



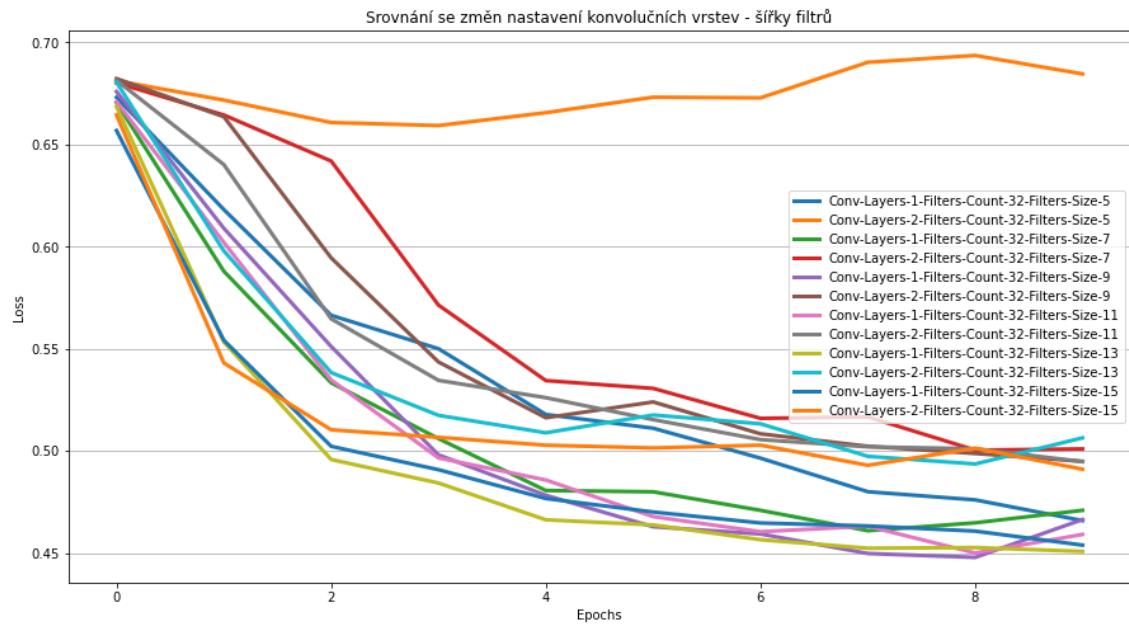
A.5 Graf vývoje Loss – počet konv. vrstev



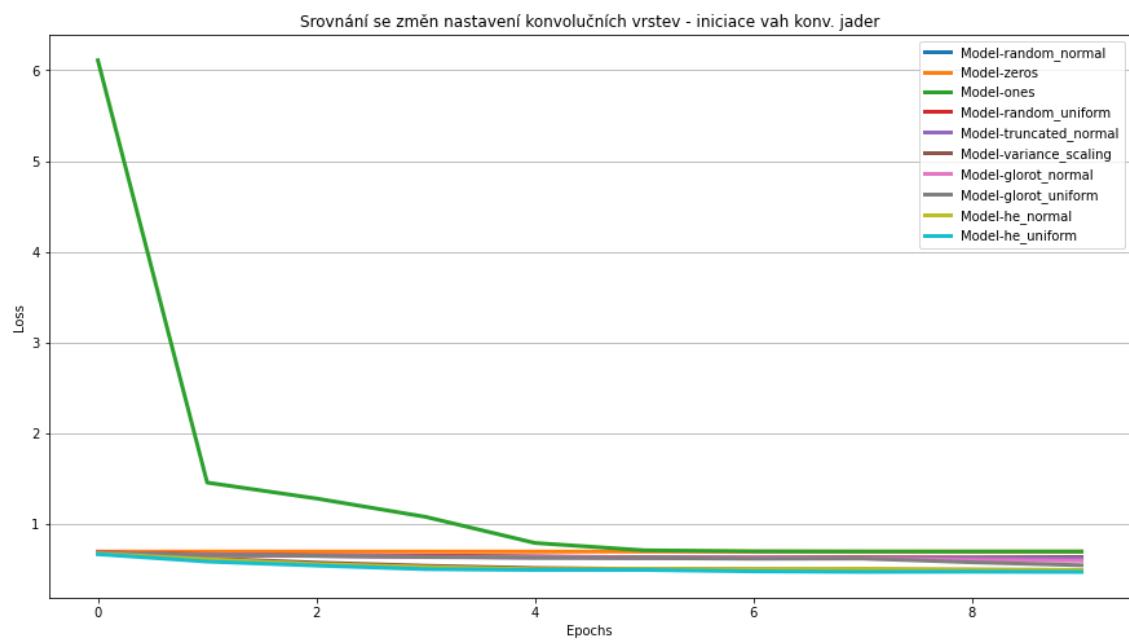
A.6 Graf vývoje Loss – počet konv. filtrů



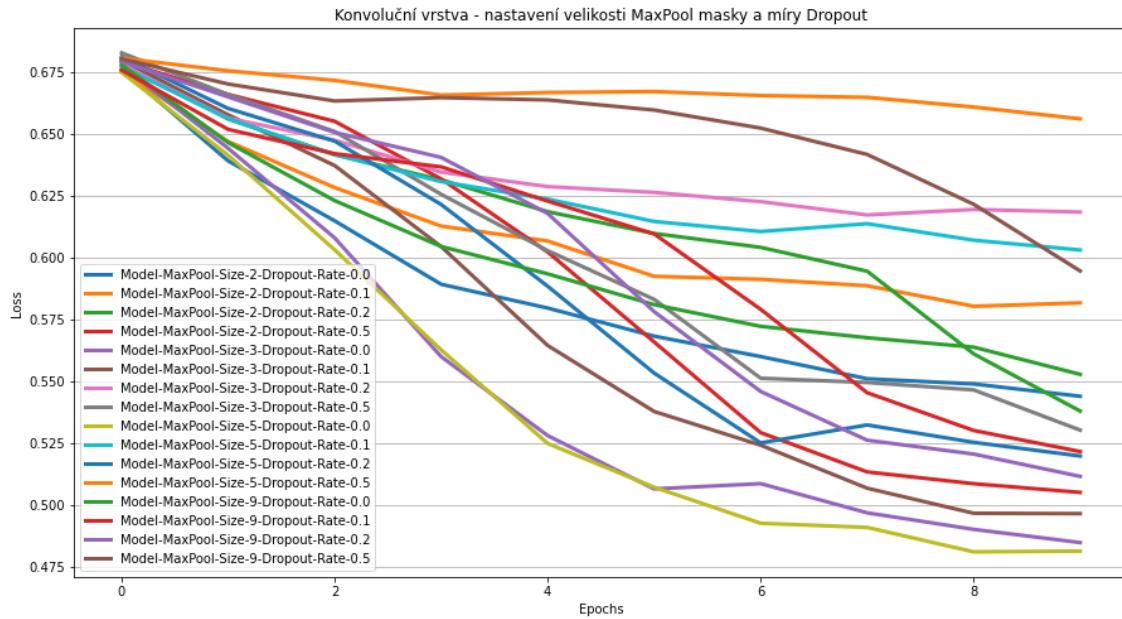
A.7 Graf vývoje Loss – šířka konv. filtrů



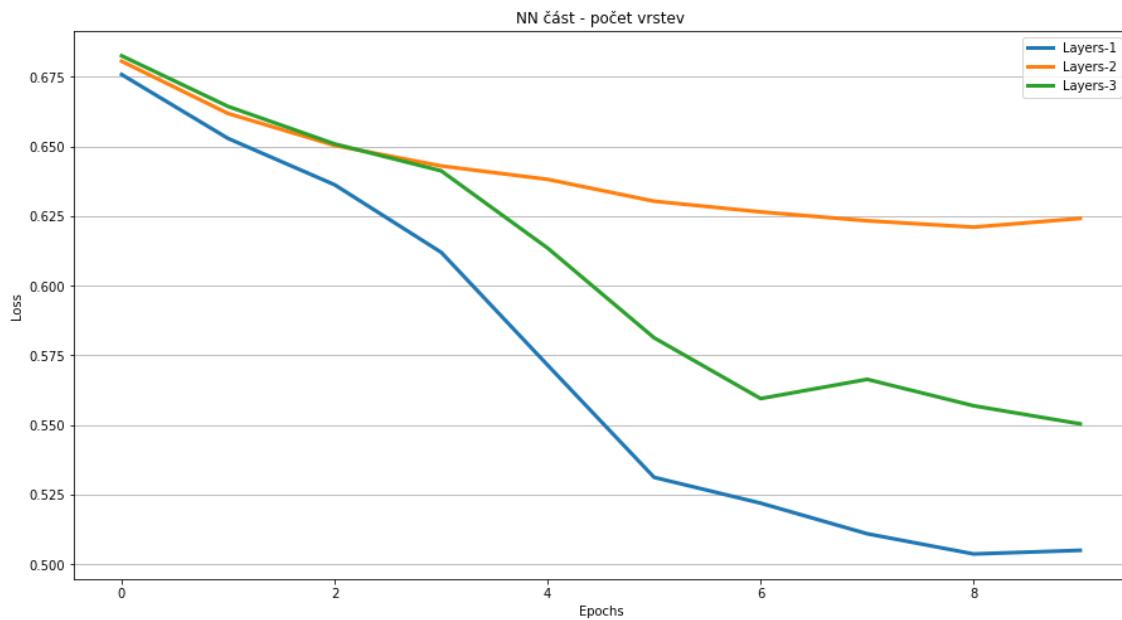
A.8 Graf vývoje Loss – inicializace vah konv. filtrů



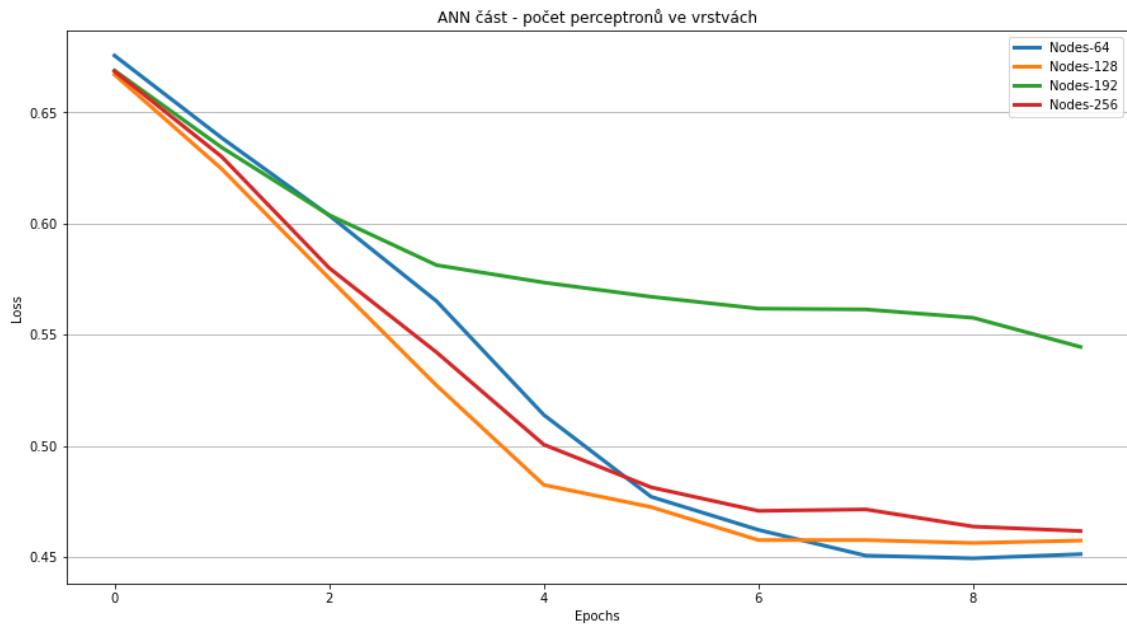
A.9 Graf vývoje Loss – nastavení MaxPool a Dropout



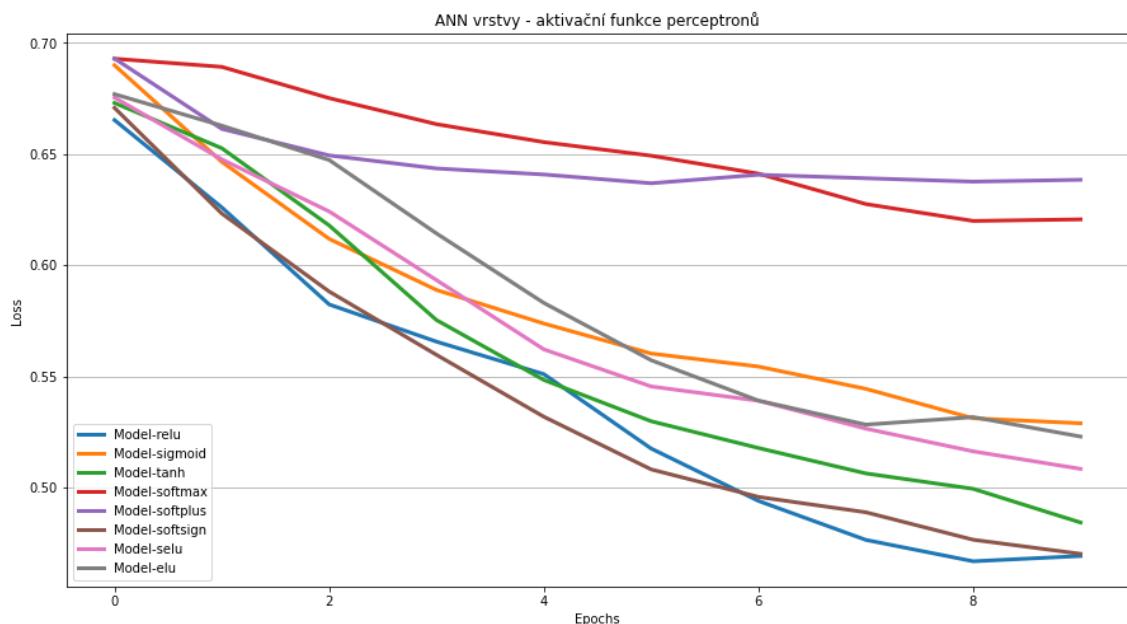
A.10 Graf vývoje Loss – nastavení počtu ANN vrstev



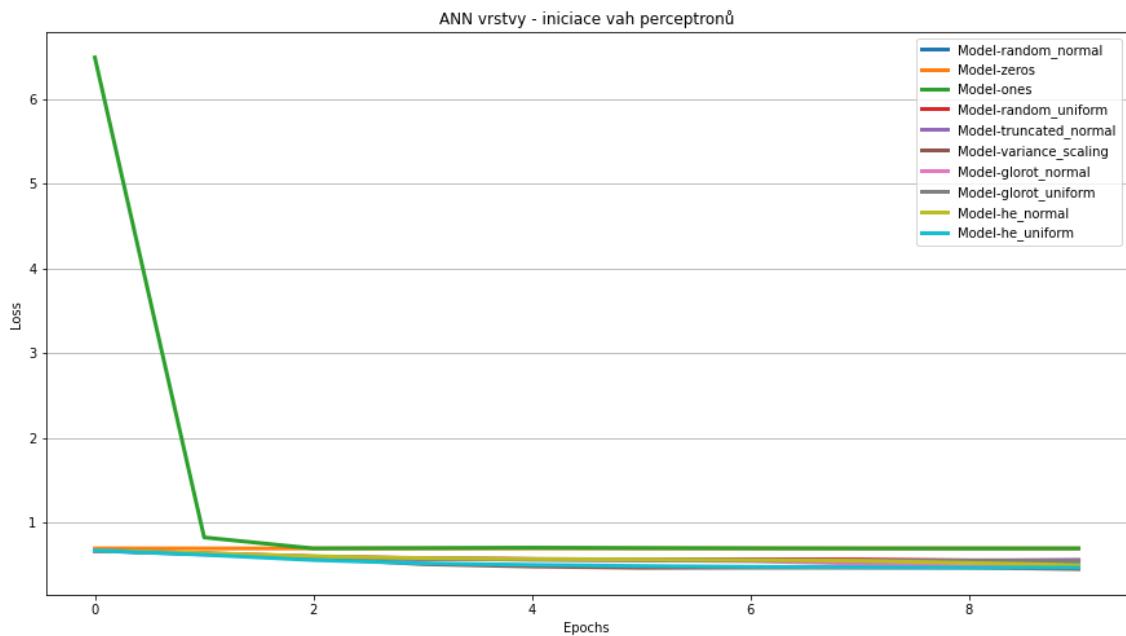
A.11 Graf vývoje Loss – nastavení počtu perceptronů v ANN vrstvách



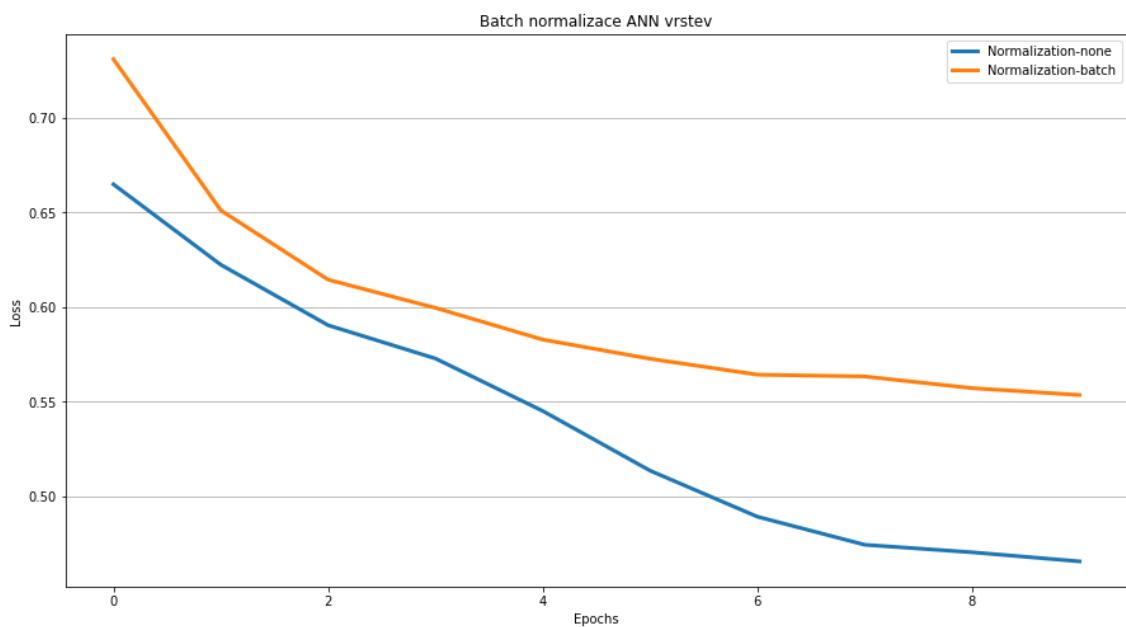
A.12 Graf vývoje Loss – nastavení ak. funkce perceptronů v ANN vrstvách



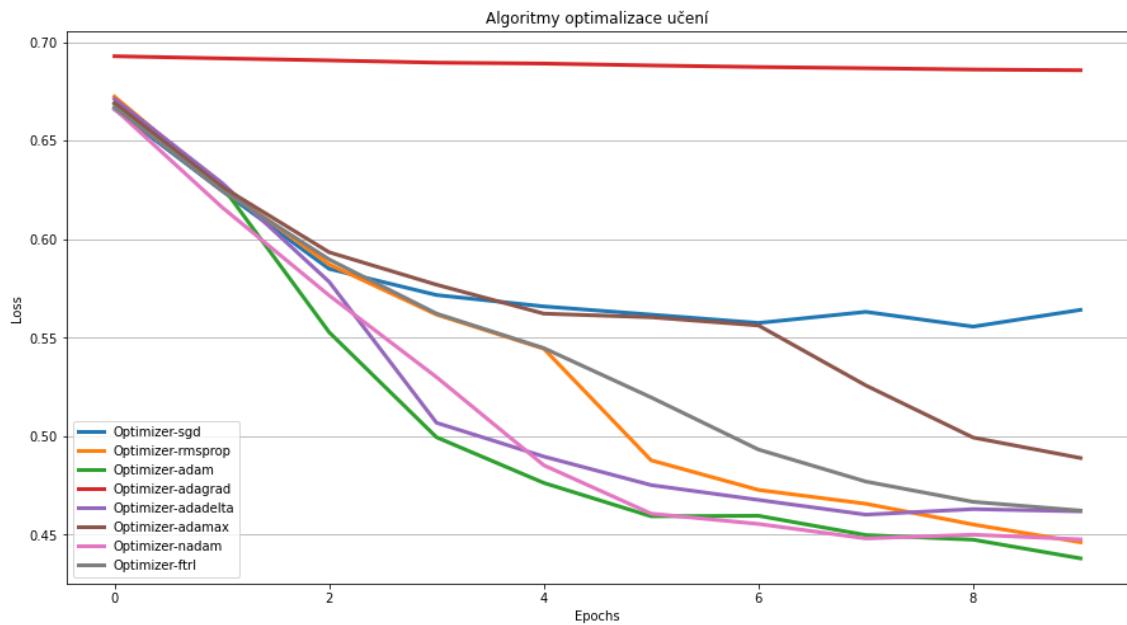
A.13 Graf vývoje Loss – nastavení inicializace vah perceptronů



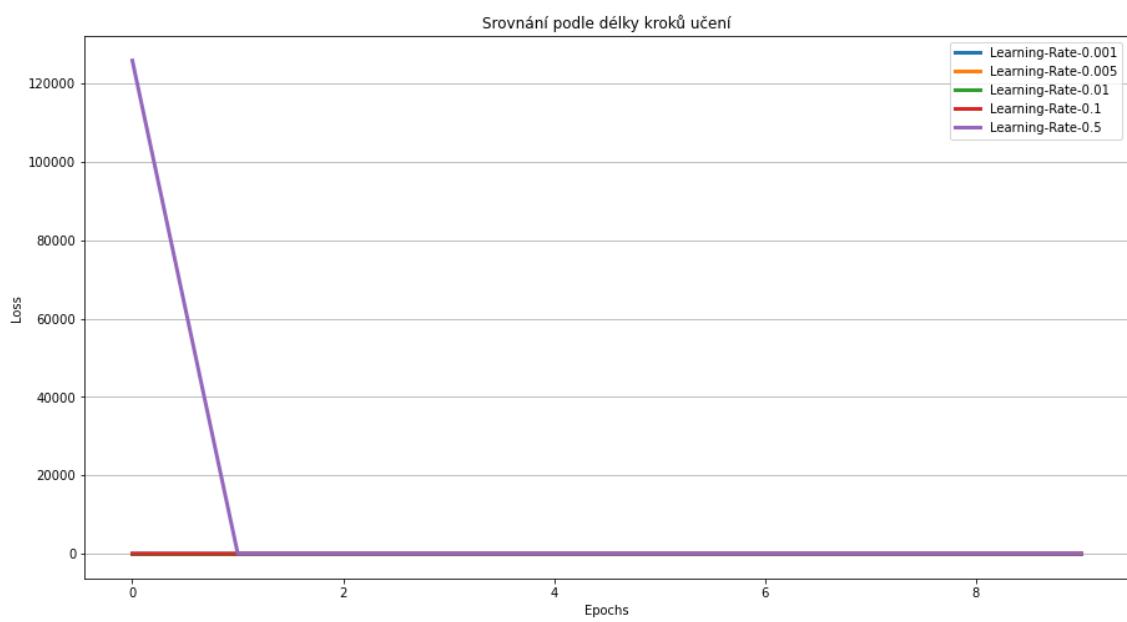
A.14 Graf vývoje Loss – Batch normalizace



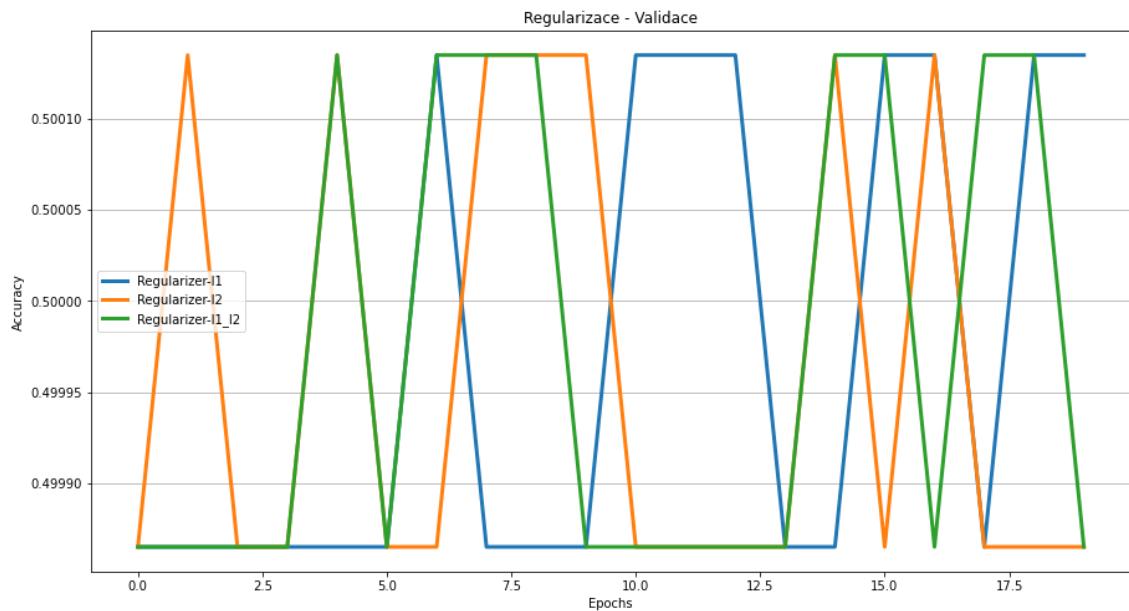
A.15 Graf vývoje Loss – algoritmy optimalizace učení



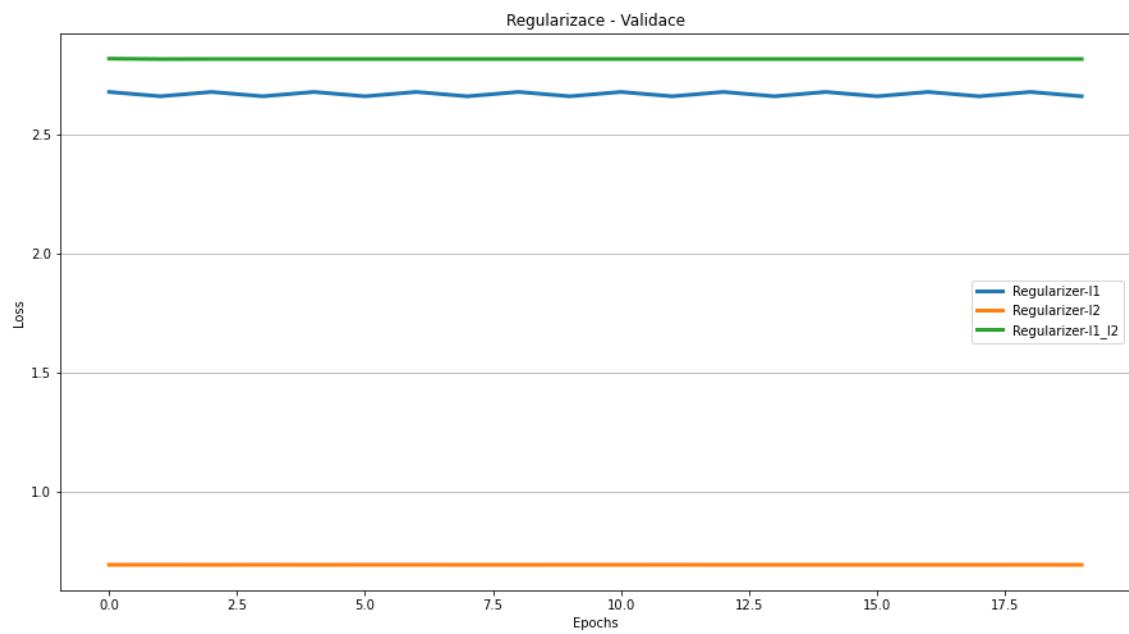
A.16 Graf vývoje Loss – nastavení kroku učení



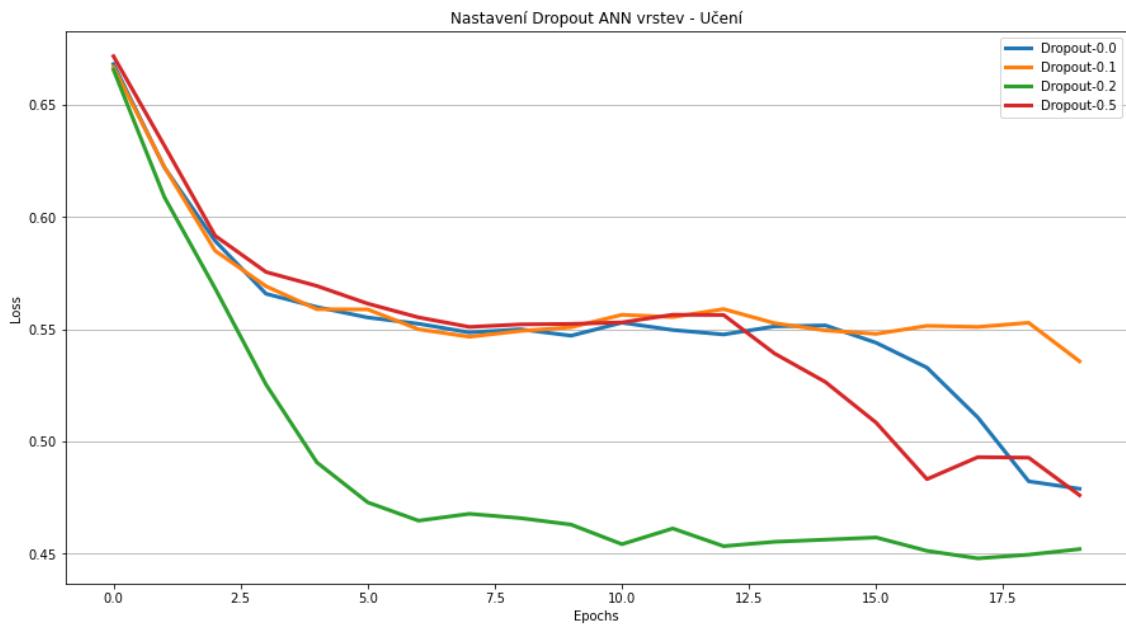
A.17 Graf vývoje Loss – regularizace – trénování



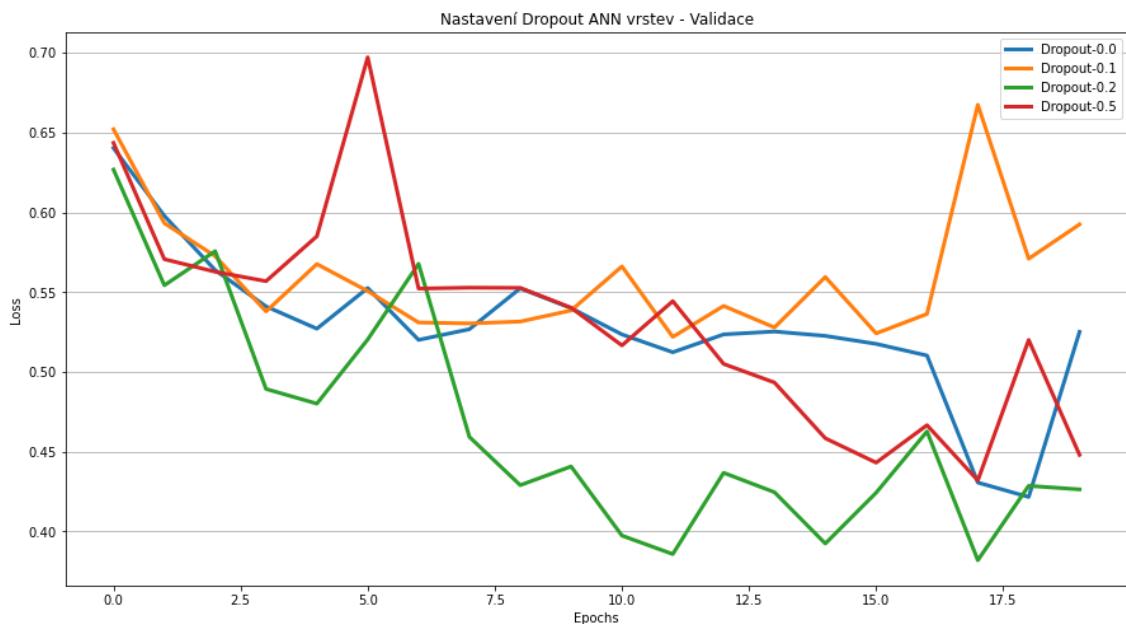
A.18 Graf vývoje Loss – regularizace – validace



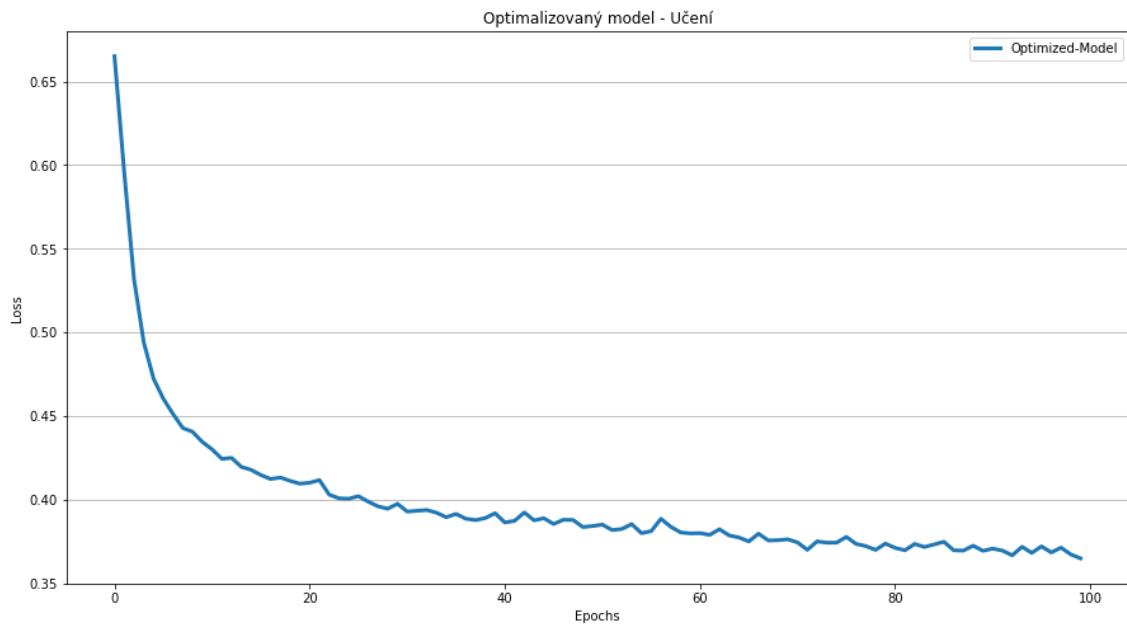
A.19 Graf vývoje Loss – Dropout ANN – trénování



A.20 Graf vývoje Loss – Dropout ANN – validace



A.21 Graf vývoje Loss – optimalizovaný model – učení



A.22 Graf vývoje Loss – optimalizovaný model – trénink

