

Bakalářská práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra řídicí techniky

Zpracování signálů z inerciálních sensorů za účelem stanovení míry tremoru

Adam Jiráček

Vedoucí: Ing. Jan Havlík, Ph.D.
Obor: Kybernetika a robotika
Květen 2023

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Jirák** Jméno: **Adam** Osobní číslo: **498853**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra řídicí techniky**
Studijní program: **Kybernetika a robotika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Zpracování signálů z inerciálních sensorů za účelem stanovení míry tremoru

Název bakalářské práce anglicky:

Analysis of signals from accelerometers/gyroscopes and objective examination of the tremor

Pokyny pro vypracování:

- 1) Seznamte se s problematikou klasifikace třesu (tremoru), možnostmi vyšetření tremoru u pacientů s roztroušenou sklerózou nebo u pacientů po mozkové mrtvici a možnostmi využití inerciálních (akcelerometrických a gyroskopických) sensorů pro stanovení míry tremoru u těchto pacientů.
- 2) Navrhněte a implementujte algoritmy signálového zpracování umožňující stanovení míry tremoru ze signálů pořízených inerciálním senzorem.
- 3) Ověřte použitelnost navržených algoritmů na reálných datech.

Seznam doporučené literatury:

- [1] Marcus Koch, Jop Mostert, Dorothea Heersema, and Jacques De Keyser: Tremor in multiple sclerosis. Journal of Neurology, vol. 254, no. 2, pp. 133 - 145, 2007.
- [2] S. H. Alusi, S. Glickman, T. Z. Aziz, and P. G. Bain: Tremor in multiple sclerosis. Journal of neurology, neurosurgery, and psychiatry, vol. 66, no. 2, pp. 131 - 134, February 1999.
- [3] Paula Pascoal-Faria, Miguel Patrcio, Adriana Leal, Francisco Caramelo, Antnio Freire, Cristina Janurio, and Miguel Castelo-Branco: Understanding tremor in rapid upper limb movements using 3D accelerometers data. Neuroscience and Medicine, vol. 5, no. 5, pp. 205-213, 2014.
- [4] Brain Barkley Graham: Using an accelerometer sensor to measure human hand motion. Master Theses, Massachusetts Institute of Technology, May 11 2000.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

Ing. Jan Havlík, Ph.D. katedra teorie obvodů FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **17.01.2023**

Termín odevzdání bakalářské práce: **26.05.2023**

Platnost zadání bakalářské práce: **22.09.2024**

Ing. Jan Havlík, Ph.D.
podpis vedoucí(ho) práce

prof. Ing. Michael Šebek, DrSc.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta

Poděkování

Zejména bych chtěl poděkovat vedoucímu práce, panu Ing. Janu Havlíkovi, PhD., za odborné vedení práce, připomínky, vstřícnost a ochotu při konzultacích a v průběhu celého vypracovávání práce.

Dále děkuji doc. Ing. Karlu Zimmermannovi, PhD. spolu s Ing. Patrikem Vackem za doporučení literatury v oblasti neuronových sítí.

V neposlední řadě také děkuji své rodině a blízkým za podporu při psaní práce a celém studiu.

Prohlášení

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

V Praze, 26. května 2023

Abstrakt

Tremor (třes) je mimovolný rytmický oscilační pohyb jedné, či více částí těla, který je častým příznakem pacientů s roztroušenou sklerózou. Často má na jejich běžný život velmi negativní vliv. Tato práce se zaměřuje na využití akcelerometrických a gyroskopických záznamů posturálního tremoru horních končetin z dodané signálové databáze za účelem stanovení míry tremoru pacientů a jejich případnou klasifikací. Databáze obsahovala skupinu 16 pacientů trpících roztroušenou sklerózou a skupinu 18 kontrolních probandů, kteří netrpěli žádnou neurologickou chorobou.

Pro klasifikaci byly využity různé modely neuronových sítí, které analyzovaly výkonovou spektrální hustotu signálů. Byla navržena řada modelů plně propojených, konvolučních a rekurentních neuronových sítí implementovaných s využitím knihovny pytorch v programovacím jazyce Python.

Obecně nejlepších výsledků dosahovaly sítě konvoluční. Naopak plně propojené sítě dopadaly nejhůře, nejspíše z důvodu malého množství trénovacích dat. Nejlepším navrženým modelem byl model pojmenovaný CNN-3, který na validační množině dosáhl hodnot recall 100 % a precision 89 %.

Klíčová slova: Zpracování signálů, neuronové sítě, tremor, roztroušená skleróza, klasifikace, akcelerometr, gyroskop

Vedoucí: Ing. Jan Havlík, Ph.D.
Technická 1902/2 Praha,
C4-462

Abstract

Tremor is an involuntary rhythmic oscillatory movement of one or more parts of the body, which is a common symptom in patients with multiple sclerosis. It can also be one of the most disabling features. This thesis aims to use accelerometer and gyroscopic measurements of postural tremor of the upper limbs from a provided signal database in order to determine the degree of tremor and classify the patient. The used database contained measurements of a group of 16 patients suffering from multiple sclerosis and a group of 18 control probands, that did not suffer from any neurological disease.

For the classification, different neural network model were proposed, all of which used the power spectral density of the provided signals. The proposed models include fully-connected, convolutional and recurrent neural network models, that were implemented using the pytorch library in the Python programming language.

Generally convolutional networks were the best performing. On the other side the fully-connected networks showed the worst results, probably due to the small size of the training dataset. The best proposed model was the one named CNN-3, which managed to reach a recall of 100 % and a precision of 89 % on the validation dataset.

Keywords: Signal processing, neural networks, tremor, multiple sclerosis, classification, accelerometer, gyroscope

Title translation: Analysis of signals from accelerometers/gyroscopes and objective examination of the tremor

Obsah

1 Úvod	1	4.4.4 Kombinovaný model (CNN-4)	33
2 Roztroušená skleróza	3	4.5 Plně propojené neuronové sítě ..	34
2.1 Etiopatogeneze	3	4.5.1 Nejjednodušší model (FNN-1)	34
2.2 Průběh	3	4.5.2 Model s postupnou redukcí kanálů (FNN-2)	35
2.3 Diagnostika	5	4.5.3 Model s identickými vrstvami (FNN-3)	36
2.4 Tremor	5	4.5.4 Semilineární model (FNN-4) .	37
2.4.1 Dělení tremoru	5	4.6 Rekurentní neuronové sítě	38
2.4.2 Charakteristiky tremoru	6	4.6.1 Model s jedním rekurentním uzlem (RNN-1)	38
2.4.3 Tremor u pacientů s RS	6	4.6.2 Model s rekurentními uzly pro akcelerometrická a gyroskopická data (RNN-2)	40
2.4.4 Měření tremoru	7	4.7 Výsledky	41
3 Neuronové sítě	9	5 Diskuse	43
3.1 Plně propojené sítě	10	6 Závěr	45
3.1.1 Lineární vrstva	10	Bibliografie	47
3.2 Aktivační funkce	10	A Souhlas etické komise	51
3.3 Konvoluční sítě	12	B Informovaný souhlas	53
3.3.1 Konvoluční vrstva	13		
3.3.2 Max-pool vrstva	15		
3.3.3 Batch normalizační vrstva ...	15		
3.4 Rekurentní sítě	16		
3.4.1 Rekurentní uzel	17		
3.5 Ztrátové funkce	18		
3.5.1 Cross-entropy	19		
3.5.2 Logistická regrese	19		
3.6 Optimalizační algoritmy	19		
3.6.1 Stochastic Gradient Descend (SGD)	20		
3.6.2 Adam	20		
3.7 Učení neuronových sítí	20		
3.8 Metriky klasifikátorů	21		
4 Klasifikace tremoru	25		
4.1 Použitá data	25		
4.1.1 Klinický souhlas	26		
4.2 Příprava dat	26		
4.2.1 Databáze signálů	26		
4.2.2 Předzpracování signálů	27		
4.2.3 Struktura dat pacientů	27		
4.2.4 Příprava datasetu	27		
4.2.5 Rozdělení datasetu	28		
4.3 Proces učení modelů	28		
4.4 Konvoluční neuronové sítě	29		
4.4.1 Komplexní model (CNN-1) ..	30		
4.4.2 Obecně zjednodušený model (CNN-2)	30		
4.4.3 Model se zjednodušenou plně propojenou částí (CNN-3)	32		

Obrázky

2.1 Vedení vzruchu neuronem, převzato z [3]	4
2.2 Dělení tremoru podle podmínek vzniku	6
3.1 Synaptické propojení mezi neurony	9
3.2 Příklad jednoduché architektury plně propojené neuronové sítě, převzato z [23] (přeloženo)	10
3.3 Grafy zmíněných aktivačních funkcí	12
3.4 Příklad výpočtu konvoluce, zvýraznění jsou pouze pro informaci, z jakých hodnot je daná hodnota výstupu odvozena	14
3.5 Příklad výpočtu konvoluce s parametry: kernel_size = 3 × 3, bias = 1, stride = 2, padding = 1, dilation = 2. Samotná operace konvoluce je provedena u šipky znázorňující stride	15
3.6 Příklad výpočtu max-pool vrstvy ve 2D případě. Velikost využitého filtru je 2 (znázorněno jako maxpool2) s nastavením stride 2. .	16
3.7 Rozvinutí rekurentního uzlu do čtyř vrstev, převzato z [23] (přeloženo, upraveno)	18
3.8 Různé varianty rekurentních sítí s chybějícími vstupy či výstupy, převzato z [23] (přeloženo)	18
3.9 Precision a recall, převzato z [33]	22
4.1 Struktura komplexního modelu konvoluční sítě	30
4.2 Průběh učení komplexního modelu konvoluční sítě	31
4.3 Struktura obecně zjednodušeného modelu konvoluční sítě	31
4.4 Průběh učení obecně zjednodušeného modelu konvoluční sítě	31
4.5 Struktura modelu sítě se zjednodušenou plně propojenou částí	32
4.6 Průběh učení modelu sítě se zjednodušenou plně propojenou částí	32
4.7 Struktura kombinovaného modelu konvoluční sítě	33
4.8 Průběh učení kombinovaného modelu konvoluční sítě	33
4.9 Struktura nejjednoduššího modelu plně propojené sítě	34
4.10 Průběh učení nejjednoduššího modelu plně propojené sítě	35
4.11 Struktura modelu s postupnou redukcí kanálů	35
4.12 Průběh učení modelu s postupnou redukcí kanálů	36
4.13 Struktura modelu s identickými vrstvami	36
4.14 Průběh učení modelu s identickými vrstvami	37
4.15 Struktura semilineárního modelu	37
4.16 Průběh učení semilineárního modelu	38
4.17 Struktura modelu s jedním rekurentním uzlem	39
4.18 Průběh učení modelu s jedním rekurentním uzlem	39
4.19 Struktura modelu s rekurentními uzly pro akcelerometrická a gyroskopická data	40
4.20 Průběh učení modelu s rekurentními uzly pro akcelerometrická a gyroskopická data	41

Tabulky

2.1 Přibližné frekvenční rozsahy tremoru horních končetin, převzato z [15]	7
4.1 Ukázka části dodaného CSV souboru (soubory nemají hlavičku)	26
4.2 Metriky komplexního modelu konvoluční síť	30
4.3 Metriky obecně zjednodušeného modelu konvoluční síť	32
4.4 Metriky modelu sítě se zjednodušenou plně propojenou částí	33
4.5 Metriky kombinovaného modelu konvoluční síť	34
4.6 Metriky nejjednoduššího modelu plně propojené sítě	34
4.7 Metriky modelu s postupnou redukcí kanálů	35
4.8 Metriky modelu s identickými vrstvami	36
4.9 Metriky semilineárního modelu .	37
4.10 Metriky modelu s jedním rekurentním uzlem	39
4.11 Metriky modelu s rekurentními uzly pro akcelerometrická a gyroskopická data	40
4.12 Metriky jednotlivých natrénovaných modelů na validační množině	41
5.1 Metriky nejlepších natrénovaných modelů z každé kategorie	43

Kapitola 1

Úvod

Roztroušená skleróza je chronické zánětlivé autoimunitní onemocnění centrální nervové soustavy. Nemoc se projevuje postupnou destrukcí obalů nervových vláken a poté i samotných vláken. Důsledkem toho je celá řada příznaků, které však obecně vedou k invaliditě pacienta. Choroba je v současnosti nevy léčitelná, ovšem včasná diagnóza společně se správnou medikací mohou vést ke značnému oddálení projevů této nemoci. V České republice se prevalence této nemoci odhaduje na 170–200 nemocných na 100 000 obyvatel.

Jedním z častých projevů roztroušené sklerózy je tremor (třes) postihující libovolnou část těla. Ten se vyskytuje u 25–58 % pacientů a má často velmi negativní dopad na jejich běžný život. Třes se v klinické praxi v současnosti vyšetřuje primárně řadou testů, které jsou subjektivně vyhodnocovány vyšetřující osobou. Míra třesu je však určována jen na velmi hrubé stupnici.

Jednou z objektivních metod, jež se dají využít k diagnóze a měření míry tremoru, je analýza akcelerometrických dat pořízených z vyšetřované části těla pacienta. Tato metoda se prokázala jako spolehlivá při stanovení míry třesu u nemocí jako je Parkinsonova choroba.

Cílem této práce je zpracovat dodanou signálovou databázi obsahující akcelerometrické a gyroskopické záznamy tremoru u dvou skupin probandů. První skupinou jsou pacienti trpící roztroušenou sklerózou, druhá skupina je využita jako kontrolní a obsahuje probandy netrpící žádnou neurologickou poruchou. Cílem tohoto zpracování je určení míry tremoru u pacientů a jejich případná klasifikace.

Kapitola 2

Roztroušená skleróza

Roztroušená skleróza (RS) je chronické zánětlivé autoimunitní onemocnění centrální nervové soustavy (CNS). [1] Dochází při ní k destrukci myelinu (obalu nervových vláken) a následně i axonů (vláken) u neuronů v mozku a míše. To poté vede často až k trvalé invaliditě pacienta. [2, 3]

Onemocnění se obecně vyskytuje 2–3× častěji u žen a obvykle se manifestuje u mladých lidí ve věku 20–40 let. V současnosti se prevalence RS v České republice odhaduje na 170–200 nemocných na 100 000 obyvatel. [1, 4] Avšak v situacích, kdy je výskyt RS v příbuzenstvu, se prevalence zvyšuje až na 3–4 %. RS je tedy značně závislá na genetických vlivech. [3]

2.1 Etiopatogeneze

Ačkoli zásadní příčina zůstává u RS nejistá, mezi známé rizikové faktory se řadí nedostatek vitamínu D, infekce virem Epstein-Barr (EBV), kouření, obezita (obzvláště v období puberty) či vystavování ultrafialovému B světlu. První z faktorů vysvětluje, proč prevalence RS roste směrem od rovníku k pólům. [3, 5]

U EBV konkrétně může dojít k prolomení imunitní tolerance, jelikož mohou určité jeho komponenty připomínat složení myelinu, který obaluje nervové dráhy v CNS. EBV však poté zůstává v paměťových B-lymfocytech. [3]

2.2 Průběh

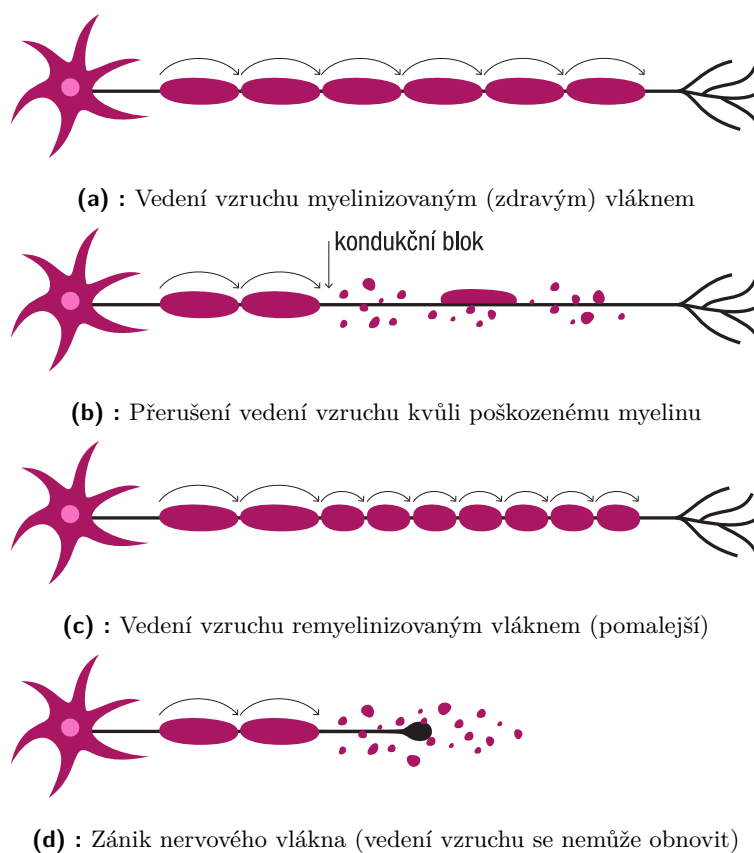
RS je nemoc s velmi individuálním průběhem. U většiny pacientů však probíhá střídáním relapsů a remisí. Zbylí pacienti se neprojevují relapsemi, ale stále mají většinu příznaků identických s běžnou RS. Tato forma se projevuje nejčastěji až ve vyšším věku a to se stejným zastoupením u obou pohlaví. [2, 3, 4]

Charakteristickým projevem RS jsou poté primárně právě ataky při relapsu. Ty v zásadě trvají více než 24 hodin, většinou se ale pohybují v řádu několika dní. Ataky začínají tak, že se T-lymfocyty aktivované myelinem porušením hematolikorové bariéry dostávají do CNS, čímž vytvářejí zánětlivá ložiska.

V nich tyto lymfocyty nejprve ničí právě myelin, následně však dochází vlivem různých mechanismů k poškozování samotných nervových vláken (axonů).

Samotný myelin je schopen částečné regenerace. Axon neuronu je tedy opět alespoň částečně chráněn, nový myelin je však tenčí a vede signály pomaleji. Tento proces ale trvá měsíce, a tak při opakovaných atacích nemusí být dostačující. Poté nastává stále častěji řadou různých mechanismů samotná destrukce axonů, ty už však nejsou schopny žádné regenerace a daný neuron je tedy trvale ztracen.

Další metodou opravy je v CNS jizvení, které zanechává tužší (sklerotickou) strukturu, jež dala nemoci její název. Nevýhodou této metody pro opravu je však její následné zabraňování účinné remyelinizaci. [3]



Obrázek 2.1: Vedení vzruchu neuronem, převzato z [3]

Kvůli těmto obecným projevům zaviňujícím poškozování nervových vedení v CNS jsou typickými příznaky RS:

- Optická neuritida (zánět očního nervu) - Projevuje se různými způsoby zhoršením zraku od zamřzení obrazu po výpadky zorného pole, poruchy barevného vidění či úplnou ztrátu zraku. S poruchou se pacient již probudí nebo se postupně zhoršuje v rámci i několika dní.
- Poruchy cití - Mohou mít charaktery hypestézie, hyperestézie nebo parestézie na určité oblasti či dokonce celé polovině těla. Často jde

o jedny z prvních projevů RS u pacientů.

- Poruchy hybnosti - Obecně může jít o různé typy paréz způsobené poškozením průběhu pyramidové dráhy. Pacienti tak často narážejí na problémy s chůzí, zakopávání nebo neobratnost rukou.
- Mozečkové příznaky - Jde o poruchy koordinace pohybu končetin či trupu. Často jsou spojené i s třesem končetin (tremorem) primárně vázaným na pohyb, může jít však i o poruchy řeči a výslovnosti.
- Poruchy okulomotoriky a nystagmus - Jsou způsobeny parézami okohybných nervů a jejich drah. Z pohledu pacienta jde o dvojité vidění, které je stálé, či jen v určitých směrech.
- Parézy ostatních hlavových nervů - Může jít o poruchy sluchu, bolesti v oblasti patra, poruchy lícního nervu nebo jiné projevy v oblasti hlavy. Obecně však nejsou tak běžné. [1]

2.3 Diagnostika

V současnosti je diagnóza RS primárně založena na tzv. McDonaldových kritériích, která pocházejí z roku 2001, ale byla od té doby několikrát revidována. Ta se kromě samotné přítomnosti atak opírají také o výsledky magnetické rezonance (MR). Je důležité u pacienta na MR snímcích lokalizovat ložiska v CNS podle šedě zobrazených jizev a to ložiska různých stáří v různých lokacích CNS. Zároveň pokud jsou na MR nalezena nová ložiska, je možné jimi při diagnóze nahradit přítomnost klinických atak. [1, 6, 7]

2.4 Tremor

Tremor (třes) je mimovolný rytmický oscilační pohyb jedné, nebo více částí těla pacienta. Je způsoben střídavým stahováním svalů a může se projevovat kdekoli na těle. [8, 9] U pacientů s RS se v současnosti odhaduje prevalence tremoru v rozmezí 25–58 %. Takto velké rozmezí je nejspíše zapříčiněno jistými odchylkami, kdy jsou častěji zkoumáni pacienti s pokročilejšími stádii RS. [10]


2.4.1 Dělení tremoru

Tremor lze dělit hned několika různými způsoby, podle jeho tělesné lokalizace, frekvence, amplitudy či jinak. Základní dělení, je však založeno na podmínkách jeho vzniku. [11]

Klidový tremor je takový typ tremoru, ke kterému dochází i v případě, že daná část těla není nijak aktivovaná. Může tedy být plně podepřena bez jakékoli fyzické aktivity. Od jiných typů tremoru je často oddělován tak, že je zkoumán zároveň cílený pohyb pacienta, při kterém klidový tremor zpravidla mizí. *Akční tremor* je poté jakýkoli typ třesu, který se projevuje při vědomé kontrakci svalů.

Posturální tremor je druhem tremoru akčního a dochází k němu ve chvílích, kdy se pacient snaží držet pozici proti působení gravitace. Dalším typem akčního tremoru je *kinetický tremor*, jenž se projevuje při téměř libovolném dobrovolném pohybu.

Kinetický tremor se dále dělí na čtyři různé typy. Prvním je *jednoduchý kinetický tremor*, který se projevuje při volném bezcílém pohybu. *Intenční tremor* je opačným druhem kinetického tremoru a dochází k němu při cílených pohybech. Dalším typem je *kinetický, vázaný na specifickou činnost*, kdy jde o tremor projevující se pouze při specifických aktivitách (například při psaní). Posledním typem kinetického tremoru je *isometrický tremor*, ke kterému dochází při svalové kontrakci působící proti nějakému objektu (například zatínání pěsti, mačkání objektu). [12]



Obrázek 2.2: Dělení tremoru podle podmínek vzniku

Na tremor jako samostatný příznak, který není součástí komplexnějšího onemocnění je možné narazit ve dvou případech. *Fyziologický tremor* se vyskytuje při jemné činnosti a je možné ho pozorovat u všech zdravých jedinců. V určitých situacích, jako při úzkostech či emočním vypětí, se může jeho projev zvýraznit. *Esenciální tremor* je naopak onemocnění, které se projevuje nejčastěji posturálním, nebo kinetickým tremorem, jenž ve většině případů postihuje symetricky obě horní končetiny. Esenciální tremor je nejčastější centrální poruchou pohybu, jeho etiologie však není v současnosti plně objasněná. [8, 12]

2.4.2 Charakteristiky tremoru

Nejdůležitějšími charakteristickými vlastnostmi tremoru jsou jeho frekvenční pásma a dosahované amplitudy. Třesy různých původů mají často trochu jiné vlastnosti. Obecně je však možné rozdělit frekvence na pomalé (méně než 4 Hz), střední (4 Hz až 7 Hz) a rychlé (více než 7 Hz) [13] a podle výchylky dělit amplitudy třesu na lehké (méně než 0,5 cm), střední (0,5 cm až 1 cm), význačné (1 cm až 2 cm) a závažné (více než 2 cm). [14]

2.4.3 Tremor u pacientů s RS

Jak lze vidět z tab. 2.1, frekvenční pásmo tremoru u pacientů trpících RS je typicky 2–10 Hz, pokud jde o třes horní končetiny. [15] Horní končetiny jsou však částí těla, která je u pacientů s RS postižena tremorem nejčastěji (více než 90 % pacientů s RS trpících tremorem se projevují tremorem alespoň jedné

Typ tremoru	Frekvenční rozsah
Primární ortostatický tremor	13–18 Hz
Fyziologický tremor	7–12 Hz
Esenciální tremor	4–12 Hz
Tremor vázaný na spec. činnost	4–12 Hz
Esenciální tremor	4–12 Hz
Parkinsonovský tremor	3–10 Hz
Tremor RS	2–10 Hz
Holmesův tremor	2–5 Hz

Tabulka 2.1: Přibližné frekvenční rozsahy tremoru horních končetin, převzato z [15]

horní končetiny). Mezi další často postižované části ale také patří hlava, krk, hlasivky, trup a končetiny obecně. [16, 17] Pokud jde o amplitudy zrychlení, kterých třes u pacientů s RS dosahuje, jde většinou o hodnoty do 2 g. [18]

Převládajícím typem tremoru je u pacientů trpících RS tremor akční, konkrétně posturální a intenční. Naopak téměř vůbec se u nich nevyskytuje tremor klidový. Běžný je také tremor bilaterální, tedy tremor postižující obě strany těla. [16]

2.4.4 Měření tremoru

V závislosti na typu vyšetřovaného tremoru existuje celá řada metod jeho měření. S. Fahn a kolegové v roce 1984 navrhli škálu popisující neparkinsonovský třes. [14] Ta hodnotí míru tremoru všech částí těla podle držení určité polohy a během několika cílených pohybů.

Běžně používané klinické testy typicky zahrnují dotýkání se prstem nosu, pití z kelímku, devítikolíkový test (nine-hole-peg-test), psaní či malování zadaných útvarů. Často se v praxi také klasifikuje tremor pouze podle amplitudy do již zmíněných kategorií (lehký, střední, význačný a závažný). [16]

K objektivnímu stanovení míry tremoru se dá využít akcelerometrie, EMG, gyroskopy či analýza videa. Amplituda spolu s frekvencí třesu dané části těla se dají snadno zjistit právě pomocí akcelerometrie. Frekvenční pásma se však často u různých typů tremoru značně překrývají, a proto není možná diferenciální diagnóza pouze touto metodou. [16, 19]

Při měření akcelerometrem (případně gyroskopem) je důležitým faktorem jeho umístění. Nejčastěji využívané je přímé umístění na část těla, pro kterou se vyšetření tremoru dělá. Běžně se tedy umísťují na kotníky, holeně, zápěstí, hrudník nebo v pase. [20]

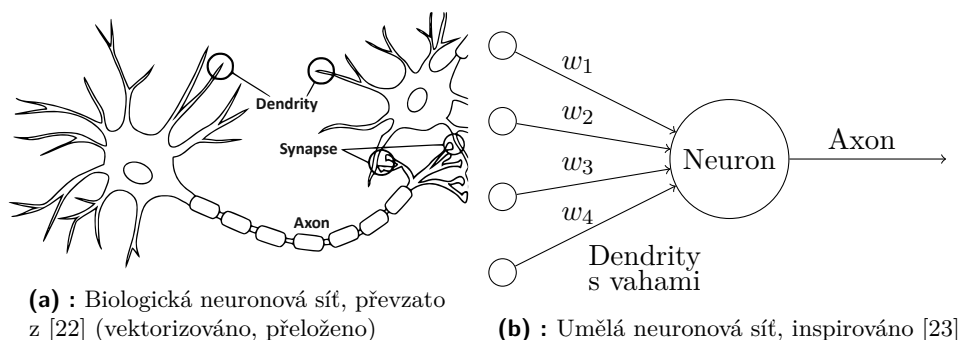
Dalším důležitým požadavkem je dodržení vzorkovacího teorému při akcelerometrickém snímání tremoru. Jelikož se zkoumané typy tremoru pro RS pohybují frekvenčně do 10 Hz, bylo by vhodné požadovat vzorkovací frekvenci přístroje alespoň 25 Hz. [21]

Kapitola 3

Neuronové sítě

Umělé neuronové sítě jsou metody strojového učení vycházející z biologických mechanismů v nervovém systému lidí. Tyto biologické neuronové sítě jsou tvořeny *neurony*, které jsou propojeny skrze své axony a dendrity. Síla těchto propojení, nazývaných *synapse*, je často závislá na externích podnětech a díky tomu je možné učení u živých organismů.

Umělé neuronové sítě (dále jen “neuronové sítě”) tyto vlastnosti emulují přiřazováním vah jednotlivým vstupům u každého neuronu. Síť poté počítá funkci vstupů pomocí propagování vypočtených hodnot ze vstupních neuronů do výstupních za použití nastavených vah pro každé propojení.



Obrázek 3.1: Synaptické propojení mezi neurony

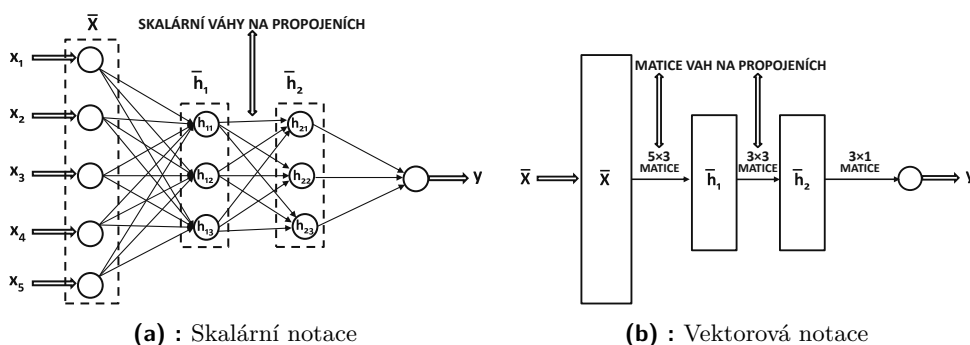
Proces učení pak probíhá jako systematické měnění vah, dle vstupních trénovacích dat a požadovaných výstupních dat pro tyto vstupy. Celé síti je tedy dodána sada trénovacích dat, která obsahuje vstupní data a k nim korespondující správná výstupní data. Neuronová síť si poté mění své váhy, aby byl její výstup co nejbližší tomu správnému v celé sadě dat. [23] Jde vlastně o optimalizační úlohu, kde je iteračními algoritmy minimalizována hodnota ztrátové funkce.

Samotné sítě jsou poté skládány z jednotlivých vrstev, jež jsou tvořeny mnoha umělými neurony. Tyto vrstvy jsou vzájemně propojené a výstup z jedné navazuje přímo na druhou (proto jsou také často nazývány *feed-forward sítěmi*). Takto se dají tyto sítě jednoduše popisovat pomocí acyklických výpočetních grafů. Délka tohoto řetězce následně určuje *hloubku* dané neuronové sítě. [24]

3.1 Plně propojené sítě

O plně propojených neuronových sítích se hovoří ve smyslu sítí, které se skládají z lineárních vrstev případně obohacených o aktivační funkce. Tyto sítě jsou velmi obecně aplikovatelné, ovšem kvůli velkému množství propojení je zapotřebí také mnoha parametrů, které je potřeba naučit.

Velké množství parametrů často znamená, že lze její vlastnosti vylepšit odstraněním nepotřebných propojení. Tím bude poté proces učení celé sítě snazší a tedy často bude mít i lepší výsledky. Zjednodušení tohoto typu však lze typicky provádět až ze specifických znalostí v dané oblasti. [23]



Obrázek 3.2: Příklad jednoduché architektury plně propojené neuronové sítě, převzato z [23] (přeloženo)

3.1.1 Lineární vrstva

Lineární vrstva je jednoduchá vrstva aplikující prostou lineární transformaci vstupních dat do vrstvy. Jde právě o již dříve zmíněný princip váhování jednotlivých vstupů, zde je však často implementován také posun, neboli *bias*. Pro tuto vrstvu pak platí jednoduchý vztah

$$\mathbf{y} = \mathbf{x}A^T + \mathbf{b}, \quad (3.1)$$

kde výstup je obecně označován \mathbf{y} , vstup poté jako \mathbf{x} , A je matice parametrů (vah) této vrstvy a \mathbf{b} je bias. [25]

3.2 Aktivační funkce

Kvůli vlastnosti linearit většiny základních vrstev neuronových sítí je zapotřebí tuto linearitu narušit mezi jednotlivými vrstvami. Pokud by tak nebylo provedeno a splňovaly by tedy všechny vrstvy podmínky linearit, bylo by možné celý výpočetní graf zjednodušit do pouze jedné lineární funkce, tedy jediné vrstvy.

Aktivační funkce jsou poté funkce používané za každým neuronem (resp. vrstvou) často k narušení právě této vlastnosti neuronových sítí. Používá se však také aktivační funkce *identita*, ta však neposkytuje žádnou nelinearitu a je

tedy využívána primárně u výstupních vrstev, kde už by obecně nelinearita neměla žádný efekt. V navržených architekturách budou u každé vrstvy zmíněny také využitě aktivační vrstvy, až na poslední vrstvu, kde bude automaticky předpokládána právě identita.

Jednou z prvních používaných aktivačních funkcí byla funkce signum (sign). Ta má vhodné vlastnosti pro mapování binárních výstupů, avšak její velkou nevýhodou je její nediferencovatelnost a případná nulová derivace. To narušuje proces učení sítě, kde je často využíváno jakobiánů.

$$\text{sign}(x) = \begin{cases} -1 & \text{pro } x < 0, \\ 0 & \text{pro } x = 0, \\ 1 & \text{pro } x > 0. \end{cases} \quad (3.2)$$

Sigmoidní funkce je často využívána v případech, kdy má být výstup interpretován jako pravděpodobnost, jelikož je její výstup vždy na intervalu $(0, 1)$. Má však derivaci velmi blízkou nulové hodnotě pro vstupy vzdálené od nuly a často tedy velmi zpomaluje proces učení.

$$\sigma(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}}. \quad (3.3)$$

Funkce tanh je svou funkcí i vlastnostmi velmi blízká sigmoidní funkci, ale je vhodnější v situacích, kde je potřeba, aby výstupy dosahovaly také záporných hodnot. Kvůli své nulové střední hodnotě je také obecně vhodnější pro učení.

$$\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} = 2\sigma(2x) - 1. \quad (3.4)$$

Aktuálně více využívanými alternativami jsou však jiné funkce, jednou z nichž je funkce Rectified Linear Unit (ReLU). Výhoda této funkce je její výpočetní nenáročnost a malý vliv na rychlost učení. Tato funkce však není diferencovatelná v nule a její derivace pro nulové hodnoty je nulová, což brání jakémukoli učení na tomto intervalu. [23]

$$\text{ReLU}(x) = \max\{x, 0\}. \quad (3.5)$$

Variantou ReLU, jež lze použít k opravení nulové derivace pro záporné hodnoty, je Leaky ReLU (LReLU). Tato aktivační funkce tuto vadu ReLU odstraňuje, avšak její nevýhodou je, že není shora ani zdola omezená. Z tohoto důvodu není používána až tak běžně.

$$\text{LReLU}(x) = \begin{cases} x & \text{pro } x \geq 0, \\ \alpha x & \text{jinak.} \end{cases} \quad (3.6)$$

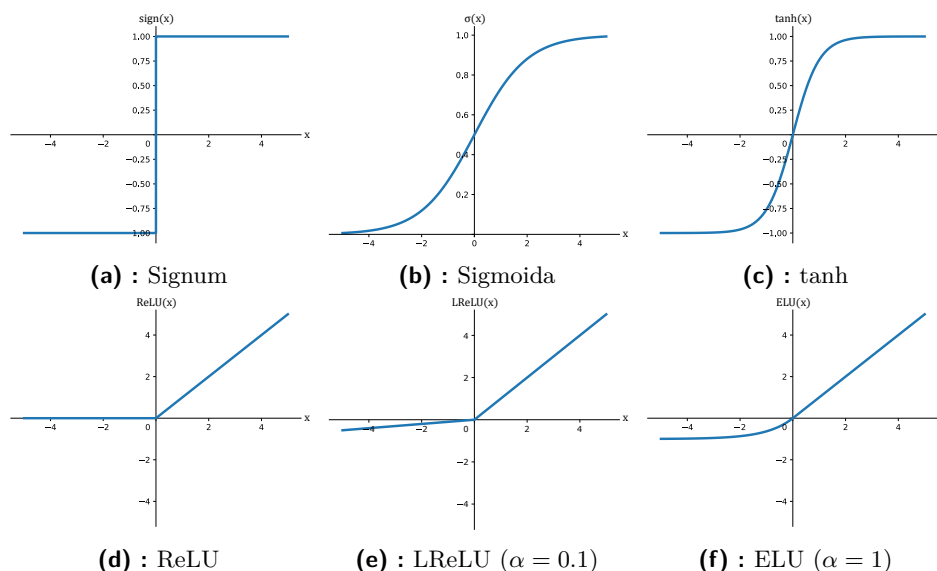
Obvykle je zde poté voleno $\alpha = 0.01$. [26]

Další úpravou funkce ReLU, která však tentokrát míří na zlepšení diferencovatelnosti této funkce, je aktivační funkce Exponential Linear Unit (ELU). Ta

má však zase nevýhodu v zavedené komplexitě do velmi jednoduché funkce, jako je původní ReLU.

$$\text{ELU}(x) = \begin{cases} x & \text{pro } x \geq 0, \\ \alpha(e^x - 1) & \text{jinak.} \end{cases} \quad (3.7)$$

V tomto případě je nejčastěji bráno $\alpha = 1$. [27]



Obrázek 3.3: Grafy zmíněných aktivačních funkcí

3.3 Konvoluční sítě

Konvoluční neuronové sítě (CNN) jsou typem neuronových sítí, které využívají konvoluční vrstvy. [23] Ty jsou založené na lineární matematické operaci zvané *konvoluce*. Díky tomu se vyhýbají plnému propojování neuronů, ale nahrazují to operací, která je provedena postupně na jednotlivých částech vstupu stejně, tedy se stejnými parametry. Právě proto je tento typ sítí nejčastěji využíván při detekci objektů ve 2D obrázcích, kde nezáleží na konkrétní poloze daného objektu v obrázku. Díky malému množství parametrů, tedy malému množství propojení, jsou také konvoluční sítě výrazně snazší na trénování v porovnání s plně propojenými sítěmi o stejných hloubkách. [24]

Samotné CNN jsou ale tvořeny celou řadou různých vrstev. Nejčastěji začínají několika konvolučními vrstvami, jež jsou vzájemně odděleny aktivačními funkcemi (většinou ReLU, jelikož má nejlepší výsledky a rychlost [28]) a případně také batch normalizačními vrstvami. Celou síť poté uzavírá jedna, či více plně propojených vrstev pro získání samotného výstupu. Tyto plně propojené vrstvy jsou samozřejmě opět proloženy aktivačními funkcemi.

Konvoluční sítě pracují s tzv. kanálovým rozměrem dat. To si lze u vstupních dat často snadno představit, například u obrázků jde jednoduše o RGB

hodnotu daného pixelu, kanálový rozměr má tedy v tomto případě tři hodnoty. U následujících vrstev se podobná informace zachovává, jelikož každá část vstupu může mít mnoho detekovaných příznaků. Hodnoty pro tyto jednotlivé příznaky jsou pak uloženy právě v tomto kanálovém rozměru. Je tedy běžné, že se velikost kanálového rozměru (hloubka dat) postupně skrz síť zvětšuje. [23]

3.3.1 Konvoluční vrstva

Konvoluční vrstva aplikuje na vstupní data lineární funkci konvoluce. Zde se budeme zabývat pouze přímo využitím konvoluce v této vrstvě neuronových sítí a nebude zde obecně matematicky definována. Dále budeme mluvit o konvoluci, přestože je myšlena spíše její implementace, označovaná jako vzájemná korelace.

Konvoluční vrstva má dva vstupy, jedním jsou samotná vstupní data I a druhým je tzv. jádro konvoluce K (kernel nebo také filtr konvoluce), které zde tvoří parametry této vrstvy. [24] Samotný výstup konvoluce je tedy počítán po složkách ze vstupu v 1D případě (velikost vstupu n) a 2D případě (velikost vstupu $n \times m$) jako

$$\text{conv1D}(I, K)_i = (I * K)_i = \sum_n I_{i+n} K_n, \quad (3.8)$$

$$\text{conv2D}(I, K)_{i,j} = (I * K)_{i,j} = \sum_n \sum_m I_{i+n,j+m} K_{n,m}. \quad (3.9)$$

Alternativní způsob, jak si tuto operaci představit, je, že každá složka výstupu je tvořena skalárním součinem všech hodnot, kde se překrývají vstup s aktuálním položením filtru. Poloha filtru je poté postupně posouvána po obrázku do všech možných poloh, čímž jsou vytvořeny jednotlivé složky výstupu. [23]

Jádro je většinou navrženo s menšími rozměry než samotný vstup a u 2D konvolucí se používají jádra převážně čtvercová. Důležitou vlastností konvoluční vrstvy totiž je, že redukuje rozměry vstupu, tedy že výstup je menších rozměrů než vstup, jak lze vidět na obr. 3.4. [24]

Kvůli této vlastnosti konvoluční vrstvy se zavádí i další parametry, které jsou však stejně jako rozměry jádra předem zadané v architektuře sítě a nejsou tedy předmětem učení. Těmito parametry jsou *stride*, *padding* a *dilation*. Zároveň se ke konvolučním vrstvám často přidává bias, stejně jako u vrstev lineárních.

Stride označuje o kolik prvků je posunuto výpočetní okno po každém výpočtu. Na obr. 3.4 je ve všech případech $\text{stride} = 1$. To však znamená, že čím větší stride konvoluční vrstva má, tím více bude redukovat rozměry vstupu.

Padding má tu funkci, že před počítáním samotné konvoluce rozšíří rozměry vstupu tím, že na jeho okraje přidá další hodnoty (standardně nulové). Typicky se padding zadává takový, aby mohl být filtr aplikován i na samotné okrajové hodnoty vstupu. Pokud by padding takto využit nebyl, výsledek konvoluce by dával menší váhu hodnotám na okrajích vstupu. $\text{padding} = 1$ by tedy

$$\begin{bmatrix} i_1 & i_2 & i_3 & i_4 \end{bmatrix} * \begin{bmatrix} k_1 & k_2 \end{bmatrix} = \begin{bmatrix} i_1k_1 + i_2k_2 & i_2k_1 + i_3k_2 & i_3k_1 + i_4k_2 \end{bmatrix}$$

(a) : Výpočet 1D konvoluce pro vstup o velikosti 4 a kernel velikosti 2

$$\begin{bmatrix} i_{1,1} & i_{1,2} & i_{1,3} & i_{1,4} \\ i_{2,1} & i_{2,2} & i_{2,3} & i_{2,4} \\ i_{3,1} & i_{3,2} & i_{3,3} & i_{3,4} \end{bmatrix} * \begin{bmatrix} k_{1,1} & k_{1,2} \\ k_{2,1} & k_{2,2} \end{bmatrix} = \begin{bmatrix} i_{1,1}k_{1,1} + i_{1,2}k_{1,2} + i_{2,1}k_{2,1} + i_{2,2}k_{2,2} & i_{1,2}k_{1,1} + i_{1,3}k_{1,2} + i_{2,2}k_{2,1} + i_{2,3}k_{2,2} & i_{1,3}k_{1,1} + i_{1,4}k_{1,2} + i_{2,3}k_{2,1} + i_{2,4}k_{2,2} \\ i_{2,1}k_{1,1} + i_{2,2}k_{1,2} + i_{3,1}k_{2,1} + i_{3,2}k_{2,2} & i_{2,2}k_{1,1} + i_{2,3}k_{1,2} + i_{3,2}k_{2,1} + i_{3,3}k_{2,2} & i_{2,3}k_{1,1} + i_{2,4}k_{1,2} + i_{3,3}k_{2,1} + i_{3,4}k_{2,2} \end{bmatrix}$$

(b) : Výpočet 2D konvoluce pro vstup 3×4 a kernel 2×2

$$\begin{bmatrix} 5 & 2 & -1 & 3 \\ -4 & 0 & 1 & 2 \\ -2 & 3 & 5 & -5 \\ 0 & 4 & 0 & -3 \end{bmatrix} * \begin{bmatrix} 2 & -1 \\ 1 & 0 \\ 0 & -2 \end{bmatrix} = \begin{bmatrix} -2 & -5 & 6 \\ -18 & 2 & 11 \end{bmatrix}$$

(c) : Číselný výpočet 2D konvoluce pro vstup 4×4 a kernel 3×2

Obrázek 3.4: Příklady výpočtu konvoluce, zvýraznění jsou pouze pro informaci, z jakých hodnot je daná hodnota výstupu odvozena

u 2D vstupu o rozměrech 3×3 způsobil, že by byl před samotnou konvolucí rozšířen na 5×5 , podobně jako na obr. 3.5. [23]

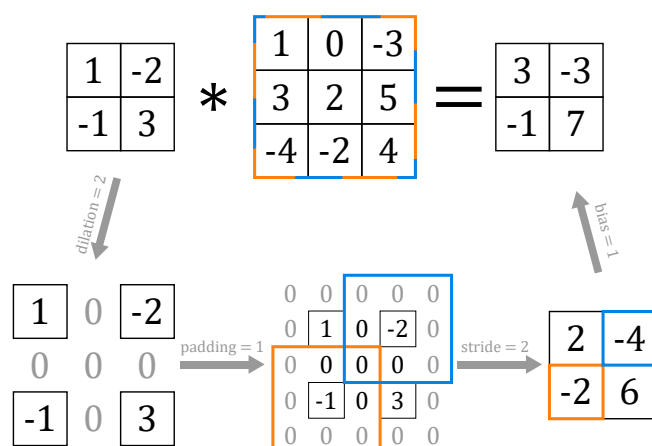
Dilation funguje podobně jako padding, avšak zde jsou hodnoty vkládány přímo mezi vstupní hodnoty. Dilation vyjadřuje, jak vzdálené od sebe mají být vstupní hodnoty, tedy dilation = 1 vstup nijak nezmění a dilation = 2 vloží mezi hodnoty nulu (viz obr. 3.5). Tento parametr ovšem není využíván tak často jako předchozí zmíněné.

Pro rozměry výstupu konvoluční vrstvy poté v 1D platí

$$L_{\text{out}} = \left\lfloor \frac{L_{\text{in}} + 2p - d(k - 1) - 1}{s} + 1 \right\rfloor, \quad (3.10)$$

kde L_{out} značí rozměry výstupu, L_{in} rozměry vstupu, p padding, d dilation, k velikost jádra (kernel_size) a s stride. U 2D konvoluce je výpočet velmi podobný, to lze vidět z obr. 3.5. [29]

S hloubkou vstupních dat konvoluční vrstva pracuje tak, že je jádro konvoluce vždy stejné hloubky jako samotný vstup. Výstup z jedné konvoluce (resp. konvolučního jádra) má poté vždy hloubku jedna. Toho, že se skrz síť postupně hloubka dat zvětšuje, je docíleno tak, že každá konvoluční vrstva obsahuje tolik konvolučních jader, kolik má být hloubka výstupních dat této vrstvy. U práce s 2D obrázky je tedy prováděna trojrozměrná konvoluce, právě



Obrázek 3.5: Příklad výpočtu konvoluce s parametry: `kernel_size = 3 × 3`, `bias = 1`, `stride = 2`, `padding = 1`, `dilation = 2`. Samotná operace konvoluce je provedena u šipky znázorňující `stride`.

kvůli třetímu kanálovému rozměru těchto dat. [23]

3.3.2 Max-pool vrstva

Dalším typem vrstev používaných v konvolučních sítích jsou vrstvy *poolingové*. Ty mají také zadanou velikost filtru jako u konvoluční vrstvy, avšak zde není použita konvoluce, ale operace jako maximum z daných hodnot. Takové vrstvě se poté říká *max-poolingová*. Dalším rozdílem od konvoluční vrstvy je, že zde je velikost filtru vždy pouze hloubky jedna a pozice filtru je postupně posouvána i v rámci kanálů. Tím je dosaženo toho, že je hloubka výstupních dat stejná jako vstupních.


U této vrstvy se také zavádí `stride`, který zde funguje naprosto analogicky ke konvoluční vrstvě. Standardně se používá `stride` stejný, jako je velikost filtru, není to však požadavkem.

Dají se zavést i poolingové vrstvy založené na jiných operacích než maximum (např. průměr, minimum). Ty se však obecně příliš nevyužívají a v praxi převládá právě max-pool.

Obecným účelem poolingových vrstev je zredukování rozměrů dat v síti, ale zachování jejich hloubky. U konvolučních vrstev chceme, aby se hloubka dat postupně zvětšovala, tím by však velmi rychle rostl počet parametrů, které jsou potřeba pro popsání všech jader těchto konvolucí. Proto jsou poolingové vrstvy primárně využívány právě k prokládání vrstev konvolučních a tím sníženy jejich rozměry a tedy i počet nutných parametrů. [23]

3.3.3 Batch normalizační vrstva

Jelikož by u hlubokých sítí bylo potřeba při samotném procesu učení používat velmi malých *learning rate*, jsou často místo toho používány batch normalizační (batch-norm, BN) vrstvy. Při tomto procesu se pro účely zrychlení



Obrázek 3.6: Příklad výpočtu max-pool vrstvy ve 2D případě. Velikost využitého filtru je 2 (znázorněno jako maxpool2) s nastavením stride 2.

výpočtů díky využívání GPU (grafických karet) zavádí tzv. batche (nebo také mini-batche). Batch je množina několika vstupních dat, která jsou poté sítí zpracovávána paralelně naráz.

Batch normalizační vrstva normalizuje daný batch \mathcal{B} z dat, která jsou získána právě z tohoto batche, a není tak nutné pro tento proces načítat všechna data. Samotný proces normalizace dat je poté proveden následovně

$$\mu_{\mathcal{B}} = \frac{1}{m} \sum_{i=1}^m x_i, \quad (3.11)$$

$$\sigma_{\mathcal{B}}^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_{\mathcal{B}})^2, \quad (3.12)$$

$$y_i = \frac{x_i - \mu_{\mathcal{B}}}{\sqrt{\sigma_{\mathcal{B}}^2 + \epsilon}} \gamma + \beta, \quad (3.13)$$

kde \mathcal{B} je batch velikosti m , x_i jsou jednotlivá data z tohoto batche, $\mu_{\mathcal{B}}$ je jejich střední hodnota, $\sigma_{\mathcal{B}}^2$ jejich standardní odchylka a y_i je výstup vrstvy. Dále je zaváděna také malá konstanta ϵ pro dosažení numerické stability a parametry γ a β , které jsou předmětem učení, a jejich účelem je zachovat význam dat v rámci sítě. [30]

3.4 Rekurentní sítě

Rekurentní neuronové sítě (RNN) jsou dalším typem neuronových sítí, který je přímo specializovaný na určité využití. Zde jde konkrétně o zpracovávání (případně generování) sekvencí dat. Těmito sekvencemi často bývají věty textu, časové sekvence naměřených dat nebo například sekvence biologického původu. Hlavními schopnostmi, kterými se RNN liší od jiných typů sítí, jsou zachycení vztahu mezi sousedními daty ve vstupní sekvenci a často také možnost pracovat se vstupy nezadané délky. Tyto schopnosti jsou důležité, jelikož například při zpracování vět textu je důležitý nejen význam jednotlivých slov, ale také jejich slovosled. Zároveň existují věty o velmi rozmanitých délkách. [23]

3.4.1 Rekurentní uzel

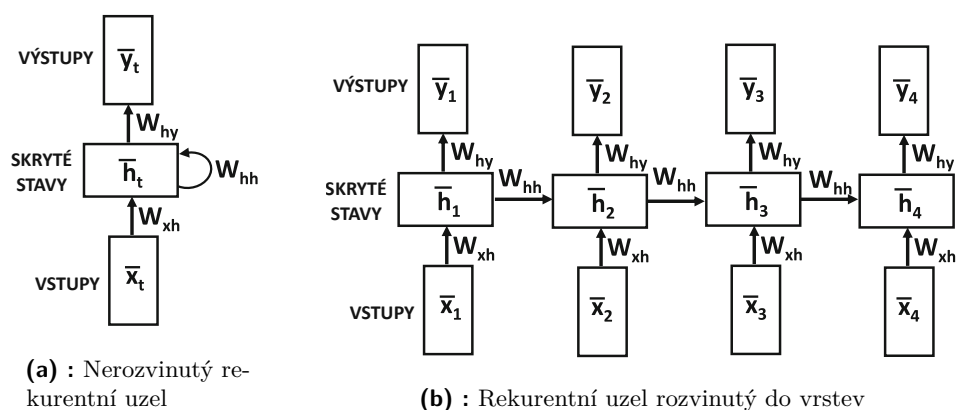
K zachycení pozičního vztahu mezi jednotlivými prvky v sekvenci se u RNN nedávají veškerá data hned na vstup první vrstvy, jako tomu je u jiných typů neuronových sítí, ale předá se jí pouze první časový záznam sekvence (time stamp, u textu či jiných obecně symbolických aplikací se samozřejmě o čase nehovoří). Výstupem této vrstvy jsou tzv. *skryté stavy*, které jsou předány vrstvě následující spolu s dalším časovým záznamem ze vstupní sekvence. Další vrstva má tedy přístup k jednomu danému časovému záznamu a zároveň ke skrytým stavům z předchozí vrstvy, které obecně vyjadřují vztahy mezi již zpracovanými daty spolu s jejich celkovým významem. Stejně se poté data předávají dále, až je zpracován celý vstup. [23]

Dalším důležitým prvkem RNN je možné vytvoření sítě bez zadané velikosti vstupních dat (ve smyslu kolik časových záznamů sekvence obsahuje). Takto by však bylo potřeba předem neznámý počet vrstev v síti, aby bylo vstup možné zpracovat již popsaným způsobem, to by ale znamenalo také neznámý počet parametrů sítě. Proto se zavádí sdílení parametrů mezi těmito vrstvami, tedy že všechny vrstvy jsou vlastně stejné, včetně parametrů, které využívají. To má zároveň případnou výhodu, že jsou veškeré záznamy v sekvenci zpracovány stejným způsobem. [23, 24]

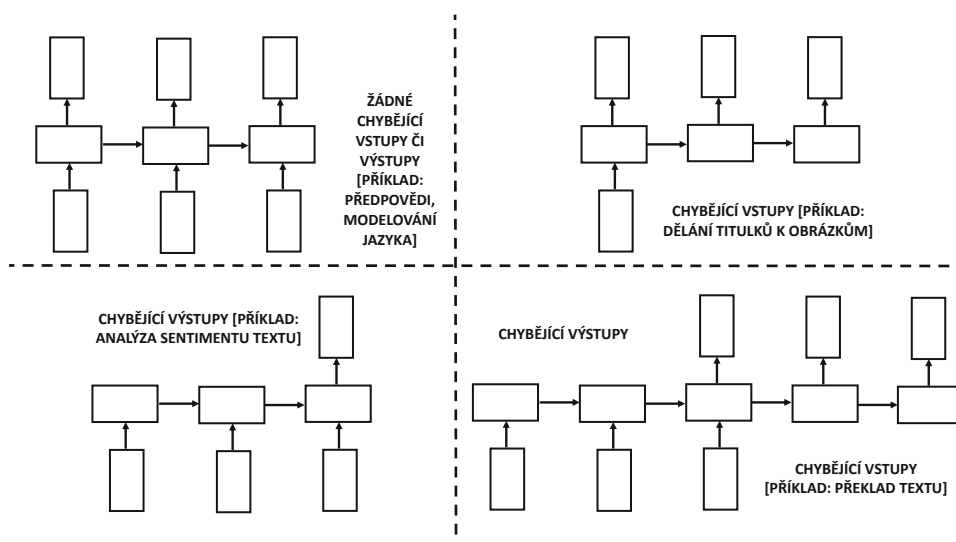
Hlavním prvkem RNN je tzv. *rekurentní uzel*, který vlastně souhrnně popisuje hned několik (často neznámý počet) vrstev sítě. Uzel má zadanou velikost vstupu v podobě jednotlivých časových záznamů a zároveň velikost skrytých stavů mezi svými vrstvami. Je možné požadovat u vrstev uzlu také výstupy. Těmi může být jak jeden výstup, podobně jako u například CNN, tak to může být i celá sekvence dat. U těchto sekvencí jsou jednotlivé záznamy vyváděny z příslušných vrstev podobně, jako jsou do nich zaváděny vstupy. Zároveň je ale také možné mít vrstvy, které jsou čistě výstupní a nemají vstupy. Tyto sekvencí výstupy se dají využít třeba při překládání textu. Tyto různé možnosti vstupů a výstupů lze vidět na obr. 3.8.

RNN fungují tedy principem velmi podobně jako prosté plně propojené sítě. Rozdíl je však takový, že jsou jednotlivé vrstvy identické a každá má svůj vstup případně výstup. Rekurentní uzly lze často zakreslovat dvěma způsoby. Prvním způsobem je vyznačení čistě samotného rekurentního uzlu a popsání jeho vstupů, výstupů a skrytých stavů. U neznámého počtu vrstev je to tedy i jediný způsob popisu. Pokud je však počet vrstev v rekurentním uzlu předem známý, lze uzel pro lepší představení (díky podobnosti právě s plně propojenými sítěmi) zakreslit také jako časově rozvinutý. Tím pádem budou vyznačeny přímo všechny vrstvy v uzlu. Porovnání těchto značení lze vidět na obr. 3.7.

Obecně jsou RNN velmi obecným nástrojem, který je tzv. *Turingovský úplný*. To znamená, že je lze při dostatku dat a času na trénování naučit řešit libovolný problém. V praxi je však často lepší, podobně jako u plně propojených sítí, využít místo těchto obecných metod spíše nástroj přímo specializovaný na daný problém, pokud nejde přímo o sekvencí data. [23]



Obrázek 3.7: Rozvinutí rekurentního uzlu do čtyř vrstev, převzato z [23] (přeloženo, upraveno)



Obrázek 3.8: Různé varianty rekurentních sítí s chybějícími vstupy či výstupy, převzato z [23] (přeloženo)

3.5 Ztrátové funkce

Důležitou částí každé neuronové sítě je její ztrátová funkce. Ta totiž poté z velké části definuje účelovou funkci, která je následně minimalizována při procesu učení. Ztrátové funkce mají jako vstupy výstupy celé sítě, tedy predikce sítě, spolu s reálnými hodnotami odpovídajícími daným vstupům. V případě například klasifikace písmen z obrázků je vstupem ztrátové funkce sítě predikované písmeno spolu s písmenem, které na obrázku reálně je. Z toho vychází nutnost pracovat s daty, která jsou označena jejich správnou hodnotou. Výstup této funkce budeme nazývat *loss* (\mathcal{L}).

Ztrátových funkcí lze definovat celá řada. Popsány však budou dvě základní, které jsou zároveň velmi často využívány.

3.5.1 Cross-entropy

V případě, že je výstupem sítě vektor obsahující pravděpodobnosti (není však nutné, aby byla normovaná) k jednotlivým třídám, lze použít ztrátová funkce *cross-entropy*. Ta se pokouší právě maximalizovat tuto pseudopravděpodobnost u správných predikcí a naopak minimalizovat u špatných. [23]

$$l_n = -\log \frac{e^{x_{n,y_n}}}{\sum_{c=1}^C e^{x_{n,c}}}, \quad (3.14)$$

$$\mathcal{L} = \sum_{n=1}^N \frac{1}{N} l_n, \quad (3.15)$$

kde $x_{n,c}$ je predikce c -té třídy pro n -tý vstup, x_{n,y_n} je predikce správné třídy pro n -tý vstup, C je celkový počet tříd a N velikost batche. V tomto případě jde o tzv. průměrovou redukci. Podobně lze však také zavést i sumová redukce jako

$$\mathcal{L} = \sum_{n=1}^N l_n. \quad (3.16)$$

Případně je možné také dodefinovat váhy k jednotlivým klasifikovaným třídám, pokud by v trénovací množině dat bylo nerovnoměrné zastoupení tříd. [31]

3.5.2 Logistická regrese

Pokud jde o síť, která má za úkol binární klasifikaci (třídy označené ± 1), a je tedy jejím výstupem pouze jediné reálné číslo, je vhodné využít jako ztrátovou funkci *logistickou regresi*. Tato ztrátová funkce se snaží co nejvíce zvětšit výstup ve směru, který je správný. Takže pro vstupy, které mají patřit do třídy -1 , se snaží výstup dostat do co nejvíce záporných hodnot a obráceně.

$$l_n = \log(1 + e^{-y_n \cdot x_n}), \quad (3.17)$$

$$\mathcal{L} = \sum_{n=1}^N \frac{1}{N} l_n, \quad (3.18)$$

kde $y_n \in \{-1, +1\}$ je správná klasifikace n -tého vstupu, x_n je predikce n -tého vstupu a N je velikost batche. Opět lze také využít jiného typu redukce stejně jako u cross-entropy.

3.6 Optimalizační algoritmy

Pro učení je také důležitá volba optimalizačního algoritmu, pomocí něhož si bude síť iterativně měnit své parametry, aby minimalizovala hodnotu ztrátové funkce (loss). K tomu existuje celá řada algoritmů. Zde budou vysvětleny základní myšlenky dvou nejčastěji používaných.

3.6.1 Stochastic Gradient Descend (SGD)

Základní metodou používanou při učení neuronových sítí je metoda SGD (Stochastic gradient descend). Ta je založena na běžném gradientním sestupu, kdy je u ztrátové funkce hledáno minimum tak, že je spočten její gradient a veškeré váhy jsou dle něho upraveny v opačném směru. [24]

$$W \leftarrow W - \alpha \frac{\partial \mathcal{L}}{\partial W}, \quad (3.19)$$

kde parametr α je nazýván *learning rate*. [23]

Stochastický gradientní sestup tuto metodu upravuje tak, že je gradient pouze odhadován z menší množiny vzorků. Díky tomu je oproti klasickému gradientnímu sestupu vhodnější pro využití s větším množstvím dat, jelikož není tak paměťově náročný. [24]

Často je tento algoritmus také doplňován o setrvačnost (momentum). To má výhodu rychlejšího nalezení optima, ale často poté dochází ke kmitání kolem něho. Další často žádanou vlastností této úpravy je, že dochází k přeskokování ostrých minim ztrátové funkce.

$$v \leftarrow \beta v - \frac{\partial \mathcal{L}}{\partial W}, \quad (3.20)$$

$$W \leftarrow W - \alpha v. \quad (3.21)$$

Výhodou této skupiny algoritmů je jejich jednoduchost. Nejsou však ideální pro všechny aplikace, jelikož pro malé gradienty dochází k minimálním změnám.

3.6.2 Adam

Adam je složitější algoritmus, který kombinuje výhody dvou algoritmů, těmi jsou AdaGrad a RMSProp. [32]

Metoda AdaGrad dynamicky mění learning rate pro jednotlivé váhy během procesu učení. Zároveň dochází k postupnému zmenšování všech hodnot learning rate.

RMSProp je algoritmus velmi podobný AdaGrad. RMSProp je odlišný tím, že nedochází právě k postupnému zmenšování learning rate.

Algoritmus Adam tyto přístupy kombinuje a zároveň je doplňuje o setrvačnost. Jde o v současnosti jednu z nejpoužívanějších metod pro optimalizaci ztrátových funkcí v oblasti neuronových sítí. [23]

3.7 Učení neuronových sítí

Samotný proces trénování neuronových sítí, jak bylo již zmíněno, probíhá jako iterační řešení optimalizační úlohy. Úloha spočívá v minimalizaci ztrátové (loss) funkce pomocí zvoleného optimalizačního algoritmu, kdy optimalizované parametry jsou váhy jednotlivých vrstev dané sítě.

Celý tento proces optimalizace je prováděn na vstupní množině dat zvané trénovací (training dataset). Ta obsahuje pro každý zadaný vstup také požadovaný výstup. Je tedy nutné mít data označená.

Důležitá u neuronových sítí je však také jejich vlastnost zobecňování. Proto je nutné mít i druhou množinu označených dat, na níž bude také měřena ztráta, avšak optimalizační algoritmus k této množině nebude mít přístup. Tato množina bude nazývána validační (validation dataset). Pro správné zobecnění je důležité, aby tato množina byla nezávislá na trénovací, ale pocházela ze stejného pravděpodobnostního rozdělení (independent and identically distributed).

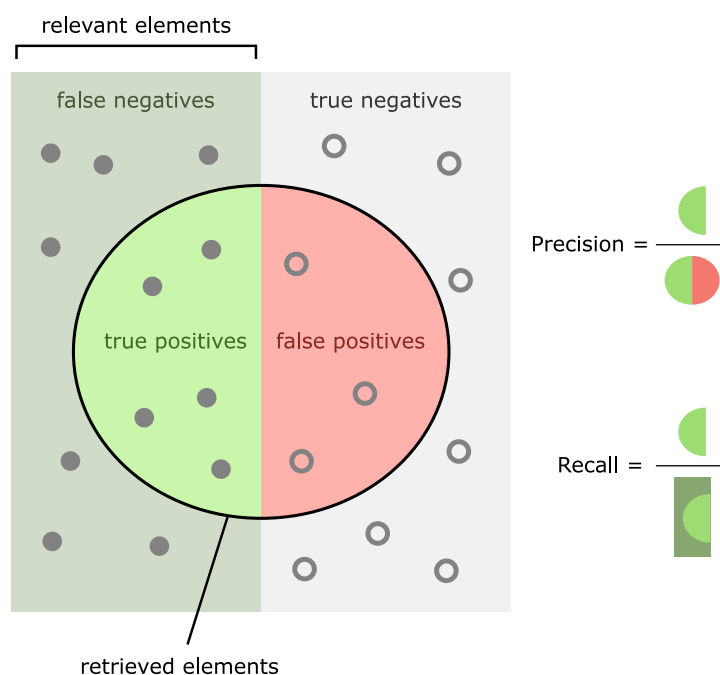
Pro dosažení dostatečného zobecnění dochází k potřebě co nejvíce přiblížit validační ztrátu k té trénovací, zatímco je trénovací minimalizována. S tím souvisí dva hlavní problémy trénování neuronových sítí. Prvním je *underfitting*, který nastává, když optimalizační algoritmus není schopen dosáhnout dostatečně nízké trénovací ztráty. Zjednodušeně lze říci, že jde o problém, kdy model není schopen vystihnout složitost trénovací množiny. K druhému problému zvanému *overfitting* dochází, když je dosaženo velmi nízké trénovací ztráty, avšak validační zůstává stále velmi vysoká. Opět lze říci, že jde o jev, kdy si model začne všimnout faktorů v jednotlivých vstupech trénovací množiny, nikoli jejich obecných vlastností.

Z těchto potenciálních problémů vyplývá několik požadavků na celý proces učení těchto sítí. Prvním je dostatečná složitost modelu, aby vystihoval zadaná data a tedy aby nedocházelo k *underfittingu*. Ze stejného důvodu je také potřeba mít dostatečný počet trénovacích dat, aby co nejlépe zachycovala všechny vlastnosti této množiny. Proces učení je potřeba na rozdíl od klasické optimalizační úlohy včas zastavit. Tím se do jisté míry zabrání případnému *overfittingu*. Také je případně potřeba nemít model přespříliš složitý, jelikož poté nemusí být trénovací dataset dostatečně velký pro natrénování všech vah a může tedy docházet jak k *overfittingu*, tak k *underfittingu*. [24]

3.8 Metriky klasifikátorů

Porovnávání jednotlivých sítí, které mají stejné formáty vstupů, výstupů i dat, na nichž jsou trénované, lze provádět jednoduchým porovnáváním jejich validačních ztrát. Pro obecné popsání schopností klasifikace jednotlivých sítí je však vhodné zavést další parametry.

Popsané metriky budou počítány na validační množině pro zachycení obecnosti trénovaného modelu. P bude označovat celkový počet vstupů z validační množiny s pozitivním výstupem, jde tedy o záznamy pacientů trpících RS. N označuje ty počet s negativním výstupem, tedy pacienty bez RS. TP neboli *true positives* vyjadřuje počet pacientů trpících RS, které daná síť klasifikovala správně jako pozitivní. *True negatives* TN označuje počet pacientů bez RS, kteří byli neuronovou sítí správně klasifikováni jakožto bez RS. FP nebo *false positives* vyjadřuje počet pacientů bez RS, kteří byli špatně klasifikováni jako pozitivní, a FN neboli *false negatives* pacienty, kteří jsou trpící RS, ale klasifikátor to u nich nepoznal.



Obrázek 3.9: Precision a recall, převzato z [33]

S těmito základními parametry můžeme již zavést další. Prvním bude *recall* (také zvaný senzitivita, hit rate či true positive rate - TPR) vyjadřující poměr, kolik z pozitivních pacientů bylo klasifikováno správně

$$recall = \frac{TP}{P} = \frac{TP}{TP + FN}. \quad (3.22)$$

Další metrikou často používanou k porovnávání klasifikátorů je *precision* (nebo také positive predictive value), která vyjadřuje poměr, kolik z pozitivně klasifikovaných bylo klasifikováno správně [34]

$$precision = \frac{TP}{TP + FP}. \quad (3.23)$$

Jelikož je obecně úkolem minimalizovat *FP* a *FN*, ideální klasifikátor by měl mít *recall* a *precision* co možná nejbližší jedné. To se často vyjadřuje pomocí *F-measure* jako

$$F_1 = \frac{2 \cdot recall \cdot precision}{recall + precision}, \quad (3.24)$$

nebo obecněji jako [35]

$$F_\beta = \frac{(\beta^2 + 1) \cdot recall \cdot precision}{recall + \beta^2 \cdot precision}. \quad (3.25)$$

Další metrikou, která tentokrát popisuje klasifikaci negativních vstupů, je *false positive rate* (*FPR*, také zvaný fall-out). Ta popisuje opačný jev ku

recallu, tedy kolik z negativních pacientů bylo klasifikováno správně

$$FPR = \frac{FP}{N} = \frac{FP}{FP + TN}. \quad (3.26)$$

Je vhodné uvádět i tuto metriku, jelikož veškeré předchozí zmíněné se zaměřují pouze na pozitivní případy a mohou tedy být zavádějící pro množiny s nerovnoměrným zastoupením tříd. [34]

Kapitola 4

Klasifikace tremoru

Ke zpracování dodaných naměřených signálů byl využit programovací jazyk Python. Tento jazyk byl primárně zvolen z důvodu snazší implementace neuronových sítí.

Jednotlivé klasifikátory byly porovnávány na základě dříve popsaných metrik. Jelikož je hlavním cílem detekce RS, bude nejdůležitější metrikou hned po validační ztratě recall. Precision je poté braný jako sekundární a FPR je uveden pouze jako informační. Vzhledem k požadavku větší váhy recallu je také informačně uveden F-measure parametr F_2 .

4.1 Použitá data

V této práci byla využita data ze signálové databáze získané v rámci [36]. Databáze obsahuje dvě skupiny probandů, skupinu 16 pacientů trpících RS (3 muži a 13 žen) a kontrolní skupinu 18 probandů (9 mužů a 9 žen), kteří neměli žádnou neurologickou poruchu a byli bez úrazu či operace ovlivňující pohyb horních končetin za posledních 5 let. Průměrný věk první skupiny byl $52,1 \pm 9,5$ let a druhé skupiny byl $52,9 \pm 12,4$ let. Dominantní ruka všech probandů byla pravá. [36]

Měření posturálního tremoru horních končetin bylo prováděno u všech probandů pomocí zařízení vybaveného čipem s 3-osým akcelerometrem a 3-osým gyroskopem (MotionTracking senzor MPU-6050). Signál byl vzorkován s frekvencí 100 Hz a naměřená data byla uložena na SD kartu. Byl tedy s rezervou dodržen vzorkovací teorém. Použité zařízení bylo prezentováno v rámci [37].

Databáze obsahovala akcelerometrické a gyroskopické záznamy pacientů ze čtyř měření - na pravé a levé ruce, s otevřenýma a zavřenýma očima. Měření trvalo u každého probanda kolem jedné minuty, bylo tedy zaznamenáno při každém měření zhruba 6000 vzorků akcelerometrem i gyroskopem. Takovýchto záznamů bylo u každého pacienta získáno osm (čtyři akcelerometrické a čtyři gyroskopické).

Měření posturálního třesu bylo na probandech prováděno vestoje s předpaženou měřenou horní končetinou. U některých pacientů bylo však nutné měřit vsedě. [18]

Zároveň každý z probandů vyplnil anamnestický dotazník, kde uvedl svou váhu, věk, pohlaví, zda kouří, pije atp. Pacienti s RS zároveň uvedli informace

o průběhu onemocnění.

Z původní signálové databáze byla vynechána jedna z pacientek z první skupiny, vzhledem k neúplnému měření. Měření bylo totiž přerušeno již po 15 vteřinách z důvodu únavy. [36]

Vzhledem k procesu sběru dat se předpokládá, že veškerá použitá data od různých pacientů jsou i.i.d., tedy že jsou ze stejného pravděpodobnostního rozdělení a jsou nezávislá.

■ 4.1.1 Klinický souhlas

Tato práce proběhla se souhlasem Etické komise fakultní nemocnice Královské Vinohrady (EK - VP/23/0/2014). Využití signály byly získány v rámci projektu *Vliv fyzioterapeutických facilitačních technik a virtuální reality na funkci horní končetiny u pacientů s roztroušenou sklerózou* ve Fakultní nemocnici Královské Vinohrady. Všichni účastníci studie byli seznámeni s obsahem studie a dobrovolně podepsali informovaný souhlas. Souhlas etické komise je v příloze A a informovaný souhlas v příloze B.

■ 4.2 Příprava dat

Před samotným zpracováním signálů a jejich klasifikací bylo potřeba hrubá data ze sensorů předzpracovat a uspořádat do strukturovaných objektů.

■ 4.2.1 Databáze signálů

Dodaná databáze byla v podobě adresáře se soubory ve formátu CSV. Každý tento soubor byl záznamem jednoho měření, tedy ke každému pacientu příslušely čtyři tyto soubory. Dále byla dodána také tabulka znázorňující, které záznamy patří ke kterému probandovi a zároveň jakého typu dané měření bylo (levá, nebo pravá ruka, otevřené, nebo zavřené oči). V této tabulce byly také doplňující informace o pacientovi získané z anamnestického dotazníku.

Jednotlivé CSV soubory v této databázi měly formát, kdy první sloupec vyjadřoval čas daného vzorku v jednotkách μs . Následující tři sloupce obsahovaly velikost aktuálního zrychlení v pořadí os x , y a z . Tyto údaje byly uvedeny v tisícinách gravitačního zrychlení g . Poslední tři sloupce dat pak zaznamenávaly aktuální hodnoty změřené gyroskopem se stejným pořadím os a v jednotkách $^{\circ}/\text{s}$. Část jednoho z těchto souborů lze vidět v tab. 4.1.

17778964	0.02	0.10	-0.21	1.70	5.40	-1.64
17788976	0.00	0.10	-0.18	0.44	2.73	-0.89
17798968	0.00	0.09	-0.16	-1.62	-1.31	-1.36

Tabulka 4.1: Ukázka části dodaného CSV souboru (soubory nemají hlavičku)

■ 4.2.2 Předzpracování signálů

Předzpracování signálů z databáze bylo provedeno pomocí postupu z dodaného Matlab skriptu “processData.m”. Tento postup byl však převeden do programovacího jazyka Python pro konzistenci se zbytkem práce.

Nejdříve byly u signálů z akcelerometru spočteny velikosti zrychlení v jednotlivých časových momentech. To bylo provedeno jako prostý výpočet velikosti vektoru z jeho hodnot v jednotlivých osách senzoru. Stejný proces byl proveden i pro úhlovou rychlost z gyroskopu. Signál z akcelerometru byl však poté přeškálován, aby odpovídal jednotkám m s^{-2} . V případě gyroskopu tento krok není potřeba, jelikož hodnoty již odpovídaly $^{\circ}/\text{s}$.

Následně byly signály zachycující velikosti zrychlení a úhlové rychlosti filtrovány pomocí hornopropustního filtru. Využit byl Butterworthův filtr 2. řádu s mezní frekvencí 0,5 Hz.

Pro lepší zpracování byla u výsledných signálů spočtena jejich výkonová spektrální hustota (power spectral density - PSD). Pro tento výpočet byla využita Welchova metoda s velikostí okna 128 vzorků a překryvem 50 %.

■ 4.2.3 Struktura dat pacientů

Pro lepší strukturalizaci dat o pacientech bylo vytvořeno několik objektů v jazyce Python. Každému pacientovi bylo poté přiřazeno identifikační číslo (ID) a byl pro něho vytvořen objekt *Patient*.

- Objekt *Patient* - Obsahuje základní informace o samotném pacientovi, jeho ID, věk, pohlaví, zda je pravák, či levák a hlavně, zda trpí RS. Dále objekt také drží informace o všech čtyřech měřeních provedených na tomto pacientovi ve formě objektů *Recording*.
- Objekt *Recording* - Obsahuje název souboru daného měření a data z akcelerometru a gyroskopu z tohoto měření jako objekty *Data*.
- Objekt *Data* - Drží filtrovaná data ze senzoru společně s jejich PSD ve formě objektu *Spectrum*. Umožňuje vykreslení filtrovaných dat či jejich spektrogramu.
- Objekt *Spectrum* - Obsahuje data samotného PSD daného signálu. Poskytuje funkci vykreslení spektra.

■ 4.2.4 Příprava datasetu

Samotná spektra všech naměřených signálů jsou shrnuta do datasetu pro následnou klasifikaci. Dataset sestává ze tří polí knihovny numpy.

První pole je trojrozměrné a obsahuje informace o spektrech z akcelerometrů. První rozměr tohoto pole pak vyjadřuje ID pacienta, druhý vyjadřuje samotné PSD pro jednotlivé frekvence a poslední poté typ měření (levá ruka s otevřenýma očima atp.). Standardní rozměry tohoto pole jsou pak tedy $34 \times 65 \times 4$.

Druhé numpy pole je velmi podobné prvnímu, obsahuje však data z gyroskopu místo akcelerometru.

Poslední pole je pak pouze jednorozměrné a obsahuje třídy daných dat, tedy zda pacient s daným ID trpí RS. Standardně je toto pole délky 34.

Tato tři pole jsou uložena do adresáře "data" jako soubory "acc_spectrums.npy", "gyro_spectrums.npy" a "patient_labels.npy" pro další zpracování. Akcelerometrická a gyroskopická data však byla následně hned propojena zpět do jednoho datasetu. Soubory byly ponechány oddělené pro snazší orientaci.

4.2.5 Rozdělení datasetu

Dataset byl před jakýmkoli využitím náhodně rozdělen na dvě oddělené části. Části jsou stejných velikostí, tedy obě obsahují záznamy o 17 pacientech. Jediné, na co bylo při rozdělování dbáno, bylo, aby v obou disjunktních množinách pacientů byl stejný či velmi blízký poměr pacientů zdravých a nemocných. Výsledné množiny (resp. datasety) budou nazývány jako trénovací a validační.

4.3 Proces učení modelů

Většina navržených neuronových sítí využívá jako aktivační funkce ReLU. To s sebou nese již zmíněné nevýhody ohledně nulové derivace pro záporné vstupy. Tento problém je však možné ignorovat, jelikož jsou v sítích vždy společně s aktivačními funkcemi použity také batch-norm vrstvy, které zabraňují tomu, aby tento problém vadil při učení. Zároveň díky těmto batch-norm vrstvám není nutné implementovat dropout do navržených sítí.

Před začátkem učení je nutné všechny parametry vrstev, které budou předmětem učení, inicializovat. Prostá inicializace samými nulami by v tomto případě nebyla vhodná, jelikož by učení mělo velké tendence k pohybu v určitých krocích. Například u konvolučních sítí by se všechna jádra učila identicky a detekovala by tedy všechny stejné vlastnosti. [23] U použitých sítí se pro inicializaci použila metoda rovnoměrné Xavierovy inicializace (Uniform Xavier Initialization). Ta, jak název napovídá, inicializuje váhy podle rovnoměrného rozdělení

$$W \sim U \left[-\frac{\sqrt{6}}{\sqrt{n_j + n_{j+1}}}, \frac{\sqrt{6}}{\sqrt{n_j + n_{j+1}}} \right], \quad (4.1)$$

kde n_j označuje počet vstupů do dané vrstvy a n_{j+1} počet výstupů. [38]

Vstupem do všech navržených sítí jsou spektra všech měření provedených na daném pacientu. Jde tedy o matici o rozměrech 65×8 , kdy druhý rozměr je brán jako kanálový.

Před zpracováním sítí jsou data normalizována pro dosažení lepších výsledků. Jelikož mohou být vstupní data teoreticky neomezeně velká či malá, avšak vždy nezáporná, byl zvolen následující postup

$$y_{i,j} = \tanh(0,1 \cdot \log_{10}(x_{i,j})), \quad i = 1, \dots, 65, j = 1, \dots, 8, \quad (4.2)$$

kde $x_{i,j}$ označuje jednotlivé prvky vstupní matice a $y_{i,j}$ prvky matice normalizované. Takto je dosaženo výstupní matice, v níž jsou pouze prvky o hodnotách na intervalu $[-1, 1]$. Konstanta 0,1 byla přidána, aby většina naměřených hodnot nebyla velmi blízká hodnotě -1 .

Následně je také tato matice Y transponována pro dodržení formátu zavedeného knihovnou pytorch, která požaduje, aby byl rozměr vyjadřující kanály první.

Výstup celé sítě je poté dvousložkový vektor. Hodnoty tohoto vektoru odpovídají míře, do jaké si síť myslí, že pacient patří do dané skupiny. První složka pak odpovídá skupině zdravých pacientů a druhá nemocným, tedy popisuje odhadnutou míru tremoru u probanda. Tento výsledek lze převést na pravděpodobnost pomocí

$$p(a = 1|\mathbf{z}) = \frac{\sigma(z_2)}{\sigma(z_1) + \sigma(z_2)}, \quad (4.3)$$

kde \mathbf{z} označuje výstupní vektor, σ sigmoidní funkci a a je diskretní veličina, kdy $a = 0$ má význam, že je daný pacient zdravý a $a = 1$, že je nemocný. Dvousložkový vektor byl zvolen namísto jednosložkového z důvodu snazší rozšiřitelnosti v případě zavádění více klasifikovaných tříd.

Všechny sítě byly učeny pomocí ztrátové funkce cross-entropy a optimalizačního algoritmu Adam.

Průběh učení měl podobu, kdy byla jako první spuštěna iterace trénovací smyčky. V této smyčce byly spočteny hodnoty v jednotlivých vrstvách sítě pro jednotlivé vstupy z trénovací množiny (tzv. *forward pass*) a poté gradienty výsledku ztrátové funkce vzhledem k parametrům jednotlivých vrstev (*backward pass*). Tyto gradienty byly následně využity pro provedení kroku optimalizačního algoritmu. Takto byla vytvořena další epocha parametrů sítě.

Dále byla provedena iterace validační smyčky, kde byl zjištěn výstup sítě pro jednotlivé vstupy z množiny validační. Poté byla určena klasifikace daného pacienta prostým zjištěním, která ze složek výstupu byla vyšší, a z těchto klasifikací byly určeny metriky sítě v dané epoše.

Po inicializaci bylo provedeno zadané množství epoch (v závislosti také na zvoleném *learning rate* algoritmu), a pokud učení nedosáhlo značného zlepšení od inicializace, byla inicializace provedena znovu a celý proces zopakován.

Celý tento postup byl implementován vektorově po tzv. batchích pro výrazně rychlejší učení. Vzhledem k malé velikosti trénovacího i validačního datasetu, byl nastaven batch size takový, aby bylo možné paralelně zpracovávat celé datasety (tedy *batch_size = 17*).

Znázorněná funkce `flatten` se zbaví kanálového rozměru dat tím, že jednotlivá data naskládá za sebe. To je potřebné pro následující zpracování lineárními vrstvami.

4.4 Konvoluční neuronové sítě

Byla vytvořena řada modelů konvolučních sítí pro klasifikaci tremoru pacientů přímo z celých spekter naměřených dat. Tyto sítě obsahují vrstvy konvoluční,

max-poolingové a batch-norm a aktivační funkce pro porušení jejich linearity. Na výstup z této první části sítě poté navazuje část plně propojená s jednou či více lineárními vrstvami, opět proloženými aktivačními funkcemi.


Je nutné podotknout, že přestože jsou konvoluční vrstvy využívány v navržených modelech vyznačené jako “conv1D”, doopravdy tyto vrstvy provádějí operaci 2D konvoluce, jelikož je jednou dimenzí klasický vstup a druhou dimenzí jsou jeho kanály.

U všech konvolučních vrstev je také použit $stride = 1$, $dilation = 1$ a $padding = 0$. Kvůli takovému paddingu jsou okraje vstupu brány s menší váhou, jelikož nefigurují v tolika operacích v konvoluci. To však ničemu nevádí, jelikož nejsou očekávány žádné výrazně užitečné informace na krajích vstupů.

U max-poolingových vrstev je vždy vyznačen jejich stride, který je stejný jako velikost jádra dané vrstvy.

4.4.1 Komplexní model (CNN-1)

Jako první byl navržen model konvoluční sítě s pěti konvolučními vrstvami následovanými batch-norm vrstvami a ReLU aktivačními funkcemi, poté dvěma max-poolingovými vrstvami a vše je uzavřeno třemi plně propojenými vrstvami. Kompletní strukturu sítě lze vidět na obr. 4.1.



Obrázek 4.1: Struktura komplexního modelu konvoluční sítě


Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
95	10^{-4}	75 %	86 %	0,77	11 %

Tabulka 4.2: Metriky komplexního modelu konvoluční sítě


Tento model bylo však velmi obtížné trénovat. Důvodem pro tyto problémy je nejspíše malé množství trénovacích dat oproti velkému množství trénovaných parametrů sítě, dochází tedy pravděpodobně k overfittingu.

4.4.2 Obecně zjednodušený model (CNN-2)


Jako další byl navržen model, který byl obecně jednodušší, obsahoval pouze dvě konvoluční vrstvy s batch-norm vrstvami a ReLU funkcemi, jednu max-pool vrstvu a čtyři plně propojené vrstvy. Cílem bylo redukovat množství parametrů sítě a pokusit se více přiblížit plně propojené síti.



Obrázek 4.2: Průběh učení komplexního modelu konvoluční sítě



Obrázek 4.3: Struktura obecně zjednodušeného modelu konvoluční sítě



Obrázek 4.4: Průběh učení obecně zjednodušeného modelu konvoluční sítě


Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
128	10^{-4}	88 %	100 %	0,902	0 %

Tabulka 4.3: Metriky obecně zjednodušeného modelu konvoluční sítě


Sít bylo značně jednodušší trénovat a její výsledky jsou velmi kvalitní. Stále obsahuje však velké množství parametrů, které je potřeba natrénovat konkrétně v první plně propojené vrstvě sítě.

4.4.3 Model se zjednodušenou plně propojenou částí (CNN-3)

Následně byl navržen model, který se snažil co nejvíce minimalizovat počet parametrů v plně propojené části sítě. Tento model je tedy velmi podobný předchozímu, jen obsahuje o jednu max-pool vrstvu více a naopak o dvě plně propojené vrstvy méně.



Obrázek 4.5: Struktura modelu sítě se zjednodušenou plně propojenou částí



Obrázek 4.6: Průběh učení modelu sítě se zjednodušenou plně propojenou částí


Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
124	3×10^{-5}	100 %	89 %	0,976	11 %

Tabulka 4.4: Metriky modelu sítě se zjednodušenou plně propojenou částí

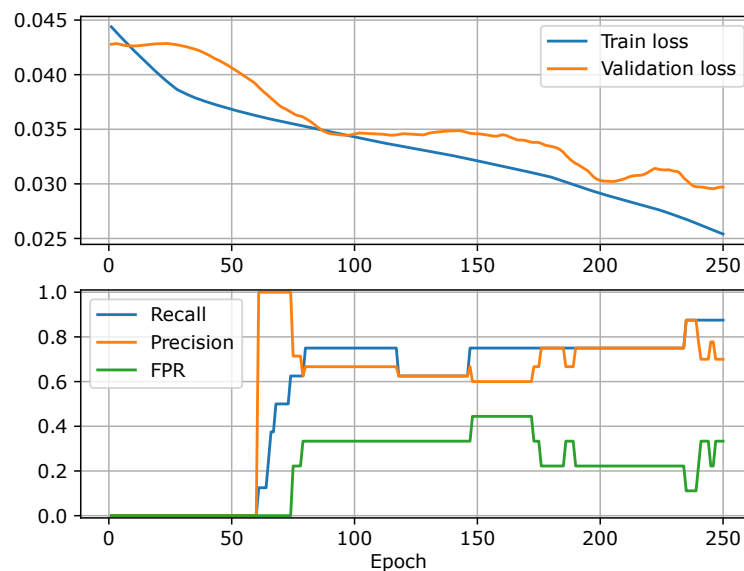
Učení tohoto modelu bylo rychlé v porovnání s předchozími a zároveň dosahoval velmi kvalitních výsledků.

4.4.4 Kombinovaný model (CNN-4)

Jako poslední model konvoluční sítě byl navržen model kombinující jednoduchost modelu 4.5 s hloubkou plně propojené části modelu 4.3. Model tedy má dvě konvoluční vrstvy s batch-norm vrstvami a ReLU funkcemi, dvě max-poolingové vrstvy a vše je poté zakončeno čtyřmi plně propojenými vrstvami, které však nemají moc rozměrů, aby nebyly náročné na učení.



Obrázek 4.7: Struktura kombinovaného modelu konvoluční sítě



Obrázek 4.8: Průběh učení kombinovaného modelu konvoluční sítě

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
237	3×10^{-5}	88 %	88 %	0,88	11 %

Tabulka 4.5: Metriky kombinovaného modelu konvoluční sítě


I přes snahu zachovat nižší množství parametrů sítě bylo obtížné tento model učít. To však v tomto případě bude nejspíše zapříčiněné tím, že model není vhodný pro potřebný účel, ve většině případů učení bylo totiž značně obtížné snižovat samotnou trénovací ztrátu, což poukazuje na underfitting.

4.5 Plně propojené neuronové sítě

Otestováno bylo také několik modelů plně propojených neuronových sítí. Tyto sítě používají pouze plně propojené (lineární) vrstvy proložené aktivačními funkcemi.

4.5.1 Nejjednodušší model (FNN-1)

Jako první byl navržen model plně propojené sítě, který je nejjednodušší, co lze navrhnout, tedy model pouze s jednou plně propojenou (lineární) vrstvou. V tomto případě jde vlastně pouze o lineární klasifikátor.



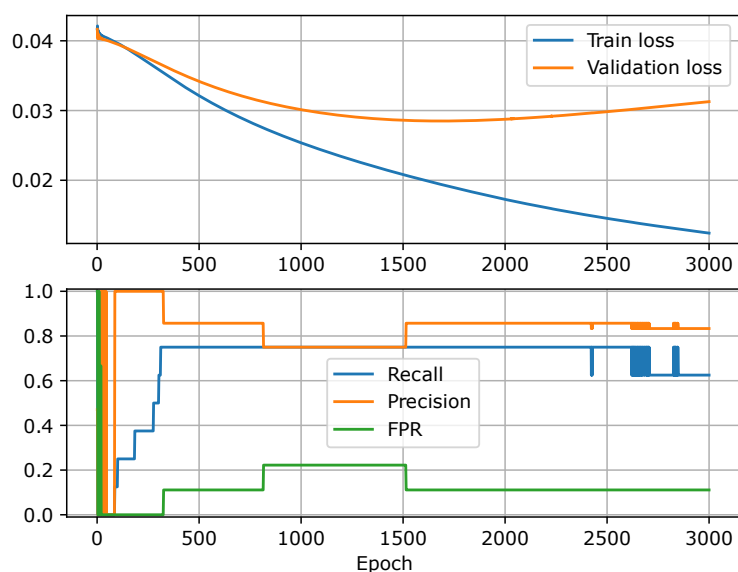
Obrázek 4.9: Struktura nejjednoduššího modelu plně propojené sítě

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
1692	10^{-3}	75 %	86 %	0,77	11 %

Tabulka 4.6: Metriky nejjednoduššího modelu plně propojené sítě

Pro učení tohoto modelu bylo potřeba využít vyššího *learning rate* a učení provádět v mnoha epochách. Pokud to nebylo provedeno takto, učení mívalo tendence se zachytávat v lokálních minimech ztrátové funkce. I z grafu na obr. 4.10 lze na začátku učení vidět kmitání, které je zapříčiněno pravděpodobně právě lokálním minimem.


Jinak jsou výsledky tohoto modelu překvapivě dobré a díky jednoduchosti tohoto modelu ho snadno můžeme používat pro porovnávání s ostatními navrženými modely.



Obrázek 4.10: Průběh učení nejjednoduššího modelu plně propojené sítě

4.5.2 Model s postupnou redukcí kanálů (FNN-2)

Další byl navržen model, který má tři plně propojené vrstvy proložené ReLU funkcemi. Tento model postupně redukuje počet kanálů až na požadované dva.

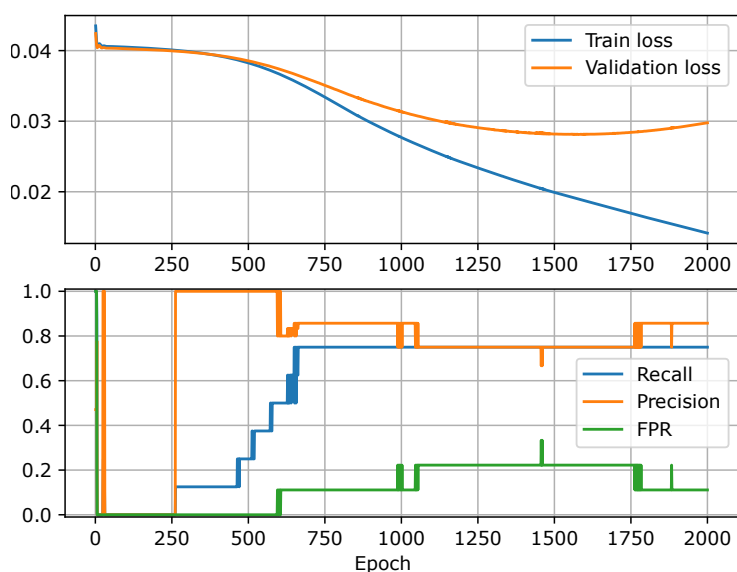


Obrázek 4.11: Struktura modelu s postupnou redukcí kanálů

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
1790	10^{-4}	75 %	86 %	0,77	11 %

Tabulka 4.7: Metriky modelu s postupnou redukcí kanálů


Tento model bylo obtížné učit, primárně kvůli velkému množství parametrů v první lineární vrstvě. I po naučení měl model prakticky identické výsledky jako čistě lineární klasifikátor na obr. 4.9. Z těchto důvodů není tento model vhodný pro klasifikaci tremoru s malým množstvím trénovacích dat.



Obrázek 4.12: Průběh učení modelu s postupnou redukcí kanálů

4.5.3 Model s identickými vrstvami (FNN-3)

Otestován byl i model, který hned první vrstvou zredukuje počet kanálů a následně má několik vrstev, které počet kanálů nijak nemění. Model celkem využívá pěti lineárních vrstev, jak lze vidět na obr. 4.13.

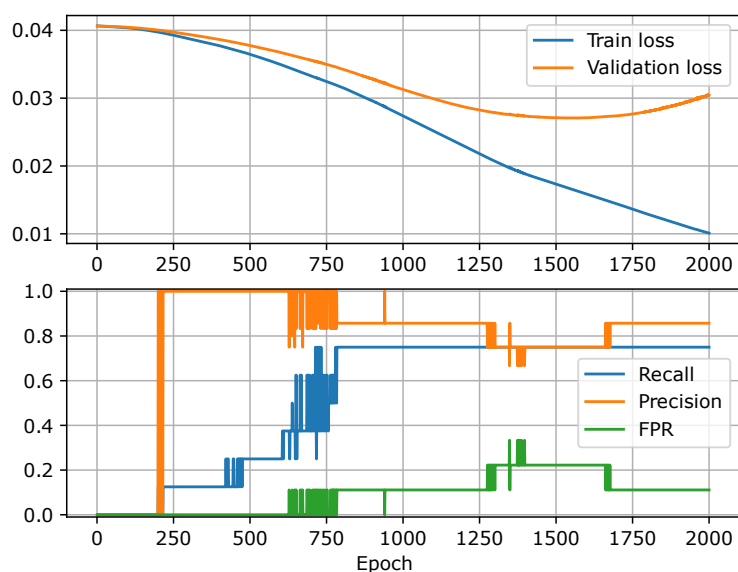


Obrázek 4.13: Struktura modelu s identickými vrstvami

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
1693	10^{-4}	75 %	86 %	0,77	11 %

Tabulka 4.8: Metriky modelu s identickými vrstvami


Tento model bylo snazší učit než model předchozí, avšak bylo dosaženo prakticky stejných neuspokojivých výsledků. Nejspíše by mohlo jít o problém s underfittingem.



Obrázek 4.14: Průběh učení modelu s identickými vrstvami

4.5.4 Semilineární model (FNN-4)

Jako poslední model plně propojené sítě byl vytvořen model, který využívá i jednu konvoluční a max-poolingovou vrstvu pro redukování rozměrů, se kterými plně propojená část pracuje. Jde tedy ale spíše již o konvoluční síť, než čistě plně propojenou. Jelikož je však model velmi založen na FNN-3, byl zařazen zde.




Obrázek 4.15: Struktura semilineárního modelu

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
347	10^{-4}	100 %	73 %	0,931	33 %

Tabulka 4.9: Metriky semilineárního modelu

Trénování tohoto modelu bylo velmi nespolehlivé. Již z obr. 4.16 lze vidět, že ztrátová funkce na validační množině je značně nestabilní. Metriky modelu však dosahují v určité fázi učení velmi kvalitních hodnot, avšak právě validační ztrátová funkce je zde poměrně vysoká a dalo by se tedy debatovat



Obrázek 4.16: Průběh učení semilineárního modelu

o spolehlivosti těchto výsledků v obecné situaci, jelikož jde nejspíše o náhodný projev overfittingu.

4.6 Rekurentní neuronové sítě

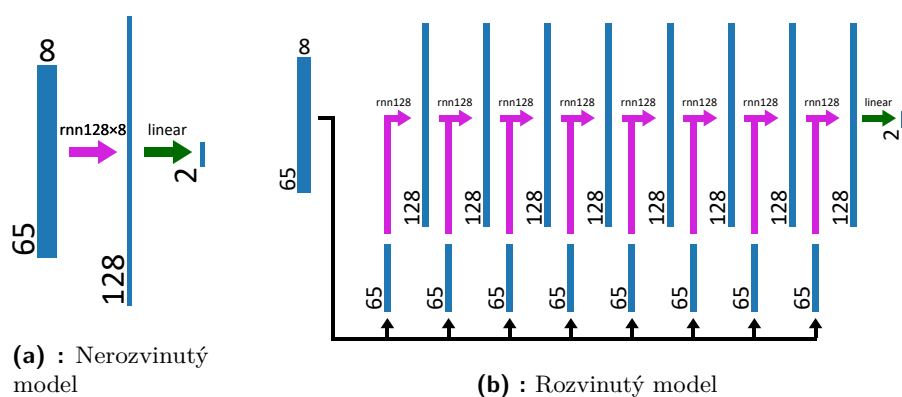
Dále byly vyzkoušeny dva jednoduché modely rekurentních sítí. Tyto rekurentní modely využívají jako “časový” rozměr stejný rozměr vstupních dat, jaký byl u CNN využit jako kanálový. Těmto sítím jsou tedy na vstupy postupně dávány PSD jednotlivých měření, nikoli jednotlivé hodnoty těchto PSD. To bylo provedeno z důvodu zachování jednoduchosti sítě, jelikož RNN často trpí na problém tzv. explodujícího nebo naopak mizejícího gradientu. [23] Postačující zde byl pouze jeden výstup na konci každého rekurentního uzlu, na který následně navazovala plně propojená část sítě.

4.6.1 Model s jedním rekurentním uzlem (RNN-1)


První navržený model RNN je jednoduchý model s pouze jedním rekurentním uzlem, na který následně navazuje jediná plně propojená vrstva pro dosažení požadovaného formátu výstupu. Pro zpracování veškerých vstupních dat byla potřeba uzlů rozvíjet do osmi vrstev. Počet skrytých stavů byl zvolen 128.

Tento model se kvůli pouze jednomu rekurentnímu uzlu tedy chová k akcelerometrickým vstupům a gyroskopickým vstupům daného pacienta absolutně stejně.

Model bylo velmi obtížné trénovat kvůli jeho nestabilitě při trénování, kterou lze značně vidět i z procesu učení na obr. 4.18, kdy i samotný trénovací loss velmi kmital.



Obrázek 4.17: Struktura modelu s jedním rekurentním uzlem



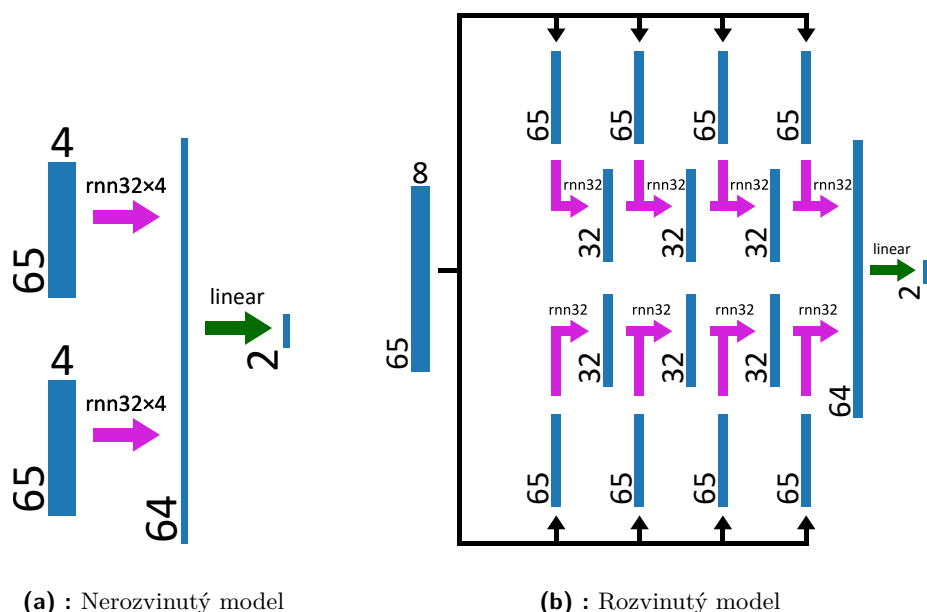
Obrázek 4.18: Průběh učení modelu s jedním rekurentním uzlem

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
665	10^{-4}	75 %	100 %	0,789	0 %

Tabulka 4.10: Metriky modelu s jedním rekurentním uzlem

4.6.2 Model s rekurentními uzly pro akcelerometrická a gyroskopická data (RNN-2)

Zřejmě možné vylepšení předchozího modelu je odlišné pracování s daty z akcelerometru a z gyroskopu. Toho bylo dosaženo prostým zavedením dvou rekurentních uzlů místo jednoho, kde se každý rozvíjel do čtyř vrstev. Oba tyto uzly měly 32 skrytých stavů, jelikož se zavedením druhého uzlu zvýšila složitost modelu.

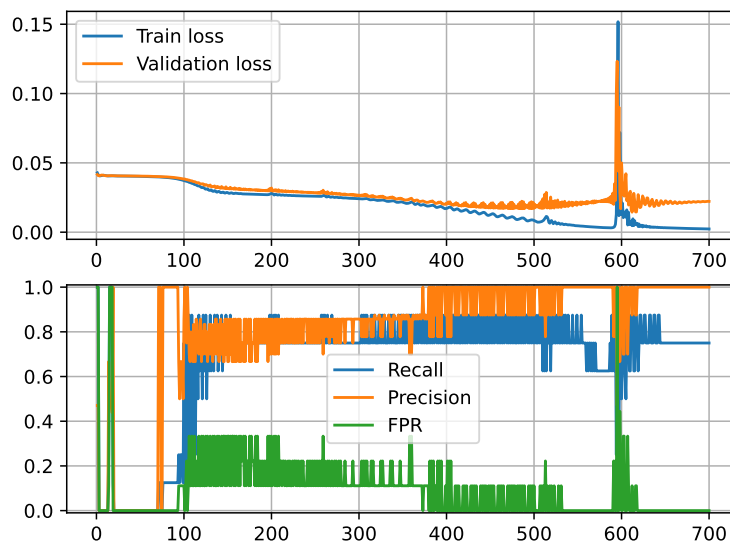


Obrázek 4.19: Struktura modelu s rekurentními uzly pro akcelerometrická a gyroskopická data

Zvolená epocha	Learning Rate	Recall	Precision	F_2	FPR
491	3×10^{-4}	88 %	100 %	0,902	0 %

Tabulka 4.11: Metriky modelu s rekurentními uzly pro akcelerometrická a gyroskopická data

Tento model měl velmi podobný proces učení jako model předchozí. Docházelo ke značným oscilacím dokonce i v hodnotách trénovacího lossu, avšak zde nebyly nestability po většinu času až tak výrazné. Celkově dosáhl tento model v určitých fázích až překvapivě dobrých výsledků.



Obrázek 4.20: Průběh učení modelu s rekurentními uzly pro akcelerometrická a gyroskopická data

4.7 Výsledky

Dosažené výsledky všech sítí lze vidět v tab. 4.12. V případě porovnání jednotlivých sítí podle navržené metriky F_2 , lze říci, že obecně nejlepších výsledků dosahovaly sítě konvoluční, kdy nejlepším modelem byl model CNN-3.

Model	Learning Rate	Recall	Precision	F_2	FPR
CNN-1	10^{-4}	75 %	86 %	0,77	11 %
CNN-2	10^{-4}	88 %	100 %	0,902	0 %
CNN-3	3×10^{-5}	100 %	89 %	0,976	11 %
CNN-4	3×10^{-5}	88 %	88 %	0,88	11 %
FNN-1	10^{-3}	75 %	86 %	0,77	11 %
FNN-2	10^{-4}	75 %	86 %	0,77	11 %
FNN-3	10^{-4}	75 %	86 %	0,77	11 %
FNN-4	10^{-4}	100 %	73 %	0,931	33 %
RNN-1	10^{-4}	75 %	100 %	0,789	0 %
RNN-2	3×10^{-4}	88 %	100 %	0,902	0 %

Tabulka 4.12: Metriky jednotlivých natrénovaných modelů na validační množině

Kapitola 5

Diskuse

Byla navržena řada modelů neuronových sítí. Konvoluční sítě obecně fungovaly nejlépe. Bylo tomu tak nejspíše z důvodu menších nároků na velikost trénovacího datasetu, konvoluční sítě totiž obecně mají poměrně málo parametrů, které je potřeba trénovat. Z této kategorie byl nejlepší model CNN-3. Důvodem je pravděpodobně velmi krátká plně propojená část, kde i samotné lineární vrstvy mají velmi málo parametrů. Naopak nejhorších výsledků dosáhla velmi komplexní síť CNN-1.

U plně propojených sítí dosáhla většina navržených modelů neuspokojivých výsledků vzhledem k ostatním kategoriím. Důvodem je nejspíše velké množství využitých parametrů u těchto modelů. V této kategorii byl otestován i nejjednodušší možný model FNN-1, který lze tedy snadno využít pro porovnání s ostatními navrženými architekturami. Nejlepším modelem z této skupiny byl model FNN-4, který však využíval již některé funkce konvolučních sítí a nelze ho tedy prohlásit za čistě plně propojenou síť. Tyto čistě plně propojené sítě však dopadly všechny naprosto identicky jako model FNN-1 a jsou tedy velmi nevhodné.

Rekurentní sítě by měly mít stejnou výhodu jako sítě konvoluční tím, že využívají menší množství parametrů, avšak navržené modely měly velké problémy při učení. To je nejspíše z důvodu nevhodně navržené podoby modelů. Zmíněné RNN modely se chovají k celým datům PSD vlastně pouze jako klasické plně propojené sítě, jen jsou vstupy do sítě zaváděny postupně. Lepší z této kategorie byl model RNN-2, jelikož již rozlišoval mezi různými typy vstupních dat.

Model	Recall	Precision	F_2	FPR
CNN-3	100 %	89 %	0,976	11 %
FNN-4	100 %	73 %	0,931	33 %
RNN-2	88 %	100 %	0,902	0 %

Tabulka 5.1: Metriky nejlepších natrénovaných modelů z každé kategorie

Je nutné podotknout, že z důvodu malého trénovacího i validačního datasetu mohou být výsledky jednotlivých modelů do značné míry zavádějící a v obecné míře hůře aplikovatelné. Dodaný dataset nemusí plně vystihovat celou množinu pacientů trpících RS, případně je pravděpodobné, že jednotlivé příznaky

nevystihuje s jejich reálným rozdělením. Kvůli opakované náhodné inicializaci může také docházet k čistě náhodnému overfittingu na validační dataset a tedy falešně dobrým výsledkům.

Práce by se následně dala rozšířit o další možné modely RNN. Obecně lepší postup jejich využití pro tuto aplikaci by bylo využít jako “časový” kanál druhý kanál (kanál vyjadřující PSD pro dané frekvence). Tím by rekurentní síť dostávala postupně data, která spolu doopravdy blízce souvisí. To však nebylo v tomto případě možné úspěšně zavést nejspíše z důvodu malého množství dat.

Další možností využití RNN, která by mohla vykazovat kvalitní výsledky, by bylo využít jako vstupy filtrovaná data ze sensorů a ne jejich PSD. Rekurentní síť by byly schopny si poradit s proměnnými délkami měření na rozdíl od jiných typů sítí. Výhodou by bylo přímé zpracování hrubých naměřených dat, která by se mohla projevit jako přesnější. Kvůli velké délce vstupních dat by však mohl nastat problém s explodujícím, či naopak mizejícím gradientem.

Veškeré navržené síťe mají výstup dvousložkový vektor. To se dá prohlásit jako redundantní vzhledem k cíli práce, kterým bylo pouhé stanovení míry tremoru, které by se dalo vyjádřit jediným číslem. Jednou z výhod zavedené podoby výstupu je snadné určení případu, kdy síť není jistá výstupem a bude tedy mít obě hodnoty značně vysoké. Hlavním důvodem pro zavedení této podoby výstupu však byla možnost snadného rozšíření pro klasifikaci tremoru do více tříd, například dle typu tremoru či jeho původu. K jednotlivým třídám by pak byla na výstupu přiřazena čísla jejich pseudopravděpodobnosti. Ze stejného důvodu byla využita ztrátová funkce cross-entropy místo logistické regrese.

Kapitola 6

Závěr

Cílem práce bylo zpracování dodané signálové databáze obsahující kompletní akcelerometrické a gyroskopické záznamy u 34 pacientů za účelem stanovení míry jejich tremoru.

Veškeré signály byly nejdříve předzpracovány pomocí hornopropustní filtrace a následného odhadnutí jejich výkonové spektrální hustoty. Z těchto dat byly následně vytvořeny dva datasety určené pro učení klasifikátorů.

Pro samotné určení míry tremoru bylo využito různých modelů neuronových sítí. Jejich výstupem byla dvojice čísel stanovující míru tremoru a číslo tomu obrácené. Tyto sítě byly učeny jako klasifikátory, kdy za klasifikovanou třídu bylo považováno číslo s větší hodnotou.

Nejdříve bylo navrženo několik modelů konvolučních neuronových sítí. Tyto sítě se prokázaly velmi kvalitními výsledky a byly obecně nejlepšími navrženými klasifikátory. Patřila mezi ně síť s nejlepšími výsledky pojmenovaná CNN-3, jež dosáhla hodnoty recall 100 % a precision 89 %.

Další skupinou navržených neuronových sítí byly sítě plně propojené. Ty měly po natrénování naopak nejhorší výsledky, kdy většina z nich dopadla velmi podobně bez ohledu na jejich složitost.

Poslední skupinou, z níž byly navrženy jednoduché modely, byly rekurentní neuronové sítě. Navržené modely těchto sítí měly výsledky jen lehce horší než sítě konvoluční, avšak jejich procesy učení byly velmi nestabilní. Byla však prozkoumána jen úzká část tohoto typu sítí.



Bibliografie

- [1] Vladimíra Sládková. “Diagnostika roztroušené sklerózy, typické klinické příznaky”. In: *Medicína pro praxi* 12.5 (2015), s. 236–242. URL: <https://www.medicinapropraxi.cz/artkey/med-201505-0007.php>.
- [2] Eva Meluzínová. “Současné možnosti léčby roztroušené sklerózy”. In: *Neurologie pro praxi* 11.5 (2010), s. 307–311. URL: <https://www.neurologiepropraxi.cz/artkey/neu-201005-0007.php>.
- [3] Eva Havrdová et al. *Roztroušená skleróza v praxi*. Galén, 2015. ISBN: 978-80-7492-209-1.
- [4] Dana Horáková. “Roztroušená skleróza - naše současné možnosti při diagnostice, stanovení prognózy nemoci a sledování efektivity léčby”. In: *Neurologie pro praxi* 12.4 (2011), s. 265–269. URL: <https://www.neurologiepropraxi.cz/artkey/neu-201104-0012.php>.
- [5] R. Dobson a G. Giovannoni. “Multiple sclerosis – a review”. In: *European Journal of Neurology* 26.1 (2019), s. 27–40. DOI: <https://doi.org/10.1111/ene.13819>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/ene.13819>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1111/ene.13819>.
- [6] Polman C. H. et al. “Diagnostic criteria for multiple sclerosis: 2010 revisions to the McDonald criteria”. In: *Ann Neurol* 69.2 (2011).
- [7] Thompson A. J. et al. “Diagnosis of multiple sclerosis: 2017 revisions of the McDonald criteria”. In: *Lancet Neurol* 17.2 (2018).
- [8] Peter Valkovič a Ján Benetin. “Tremor z pohľadu klinického neurológa”. In: *Neurologie pro praxi* 12.1 (2011), s. 12–15. URL: <https://www.neurologiepropraxi.cz/artkey/neu-201101-0004.php>.
- [9] Jalesh Panicker a Pramod Pal. “Clinical features, assessment and treatment of essential tremor”. In: *The Journal of the Association of Physicians of India* 51 (dub. 2003), s. 276–279.
- [10] Karim Makhoul et al. “Tremor in Multiple Sclerosis—An Overview and Future Perspectives”. In: *Brain Sciences* 10.10 (2020). ISSN: 2076-3425. DOI: [10.3390/brainsci10100722](https://doi.org/10.3390/brainsci10100722). URL: <https://www.mdpi.com/2076-3425/10/10/722>.

- [11] Ondrej Fiala a Evžen Růžička. “Dyskinetické syndromy dětského věku”. In: *Postgraduální medicína : odborný časopis pro lékaře* 8 (led. 2006), s. 529–534.
- [12] Günther Deuschl et al. “Consensus Statement of the Movement Disorder Society on Tremor”. In: *Movement Disorders* 13.S3 (1998), s. 2–23. DOI: <https://doi.org/10.1002/mds.870131303>. eprint: <https://movementdisorders.onlinelibrary.wiley.com/doi/pdf/10.1002/mds.870131303>. URL: <https://movementdisorders.onlinelibrary.wiley.com/doi/abs/10.1002/mds.870131303>.
- [13] Olga Ulmanová a Evžen Růžička. “Diferenciální diagnóza třesu”. In: (2003). URL: <https://zdravi.euro.cz/clanky/diferencialni-diagnoza-tresu/>.
- [14] S. Fahn, Eduard Tolosa a C. Marin. “Clinical Rating Scale for Tremor”. In: 2 (led. 1988), s. 271–280.
- [15] P. G. Bain. “Tremor”. In: *Parkinsonism & Related Disorders* 13.3 (2007), s. 369–374. DOI: 10.1016/S1353-8020(08)70032-4.
- [16] Marcus Koch et al. “Tremor in multiple sclerosis”. In: *Journal of neurology* 254.2 (2007), s. 133–145.
- [17] S. H. Alusi et al. “Tremor in multiple sclerosis”. In: *Journal of Neurology, Neurosurgery & Psychiatry* 66.2 (1999), s. 131–134. ISSN: 0022-3050. DOI: 10.1136/jnnp.66.2.131. eprint: <https://jnnp.bmj.com/content/66/2/131.full.pdf>. URL: <https://jnnp.bmj.com/content/66/2/131>.
- [18] Jan Havlík et al. “The Evaluation of the Tremor: Signal Database of Healthy Control Subjects”. In: *World Congress on Medical Physics and Biomedical Engineering 2018*. Ed. Lenka Lhotska et al. Singapore: Springer Singapore, 2019, s. 547–550. ISBN: 978-981-10-9038-7.
- [19] A. Boika. “1.268 Postural tremor in Parkinson’s disease (PD): Types of accelerometer traces”. In: *Parkinsonism & Related Disorders* 13 (2007). Abstracts of the XVII WFN Congress on Parkinson’s Disease and Related Disorders, S69. ISSN: 1353-8020. DOI: [https://doi.org/10.1016/S1353-8020\(08\)70508-X](https://doi.org/10.1016/S1353-8020(08)70508-X). URL: <https://www.sciencedirect.com/science/article/pii/S135380200870508X>.
- [20] A. Godfrey et al. “Direct measurement of human movement by accelerometry”. In: *Medical Engineering & Physics* 30.10 (2008), s. 1364–1386. ISSN: 1350-4533. DOI: <https://doi.org/10.1016/j.medengphy.2008.09.005>. URL: <https://www.sciencedirect.com/science/article/pii/S1350453308001653>.
- [21] Brian Barkley Graham. “Using an accelerometer sensor to measure human hand motion”. Dipl. pr. Massachusetts Institute of Technology, 2000.
- [22] URL: <https://openbooks.lib.msu.edu/neuroscience/chapter/synapse-structure/>.

- [23] Charu C. Aggarwal. *Neural Networks and Deep Learning. A Textbook*. Springer Cham, 2018. ISBN: 978-3-319-94463-0.
- [24] Ian Goodfellow, Yoshua Bengio a Aaron Courville. *Deep Learning*. <http://www.deeplearningbook.org>. MIT Press, 2016.
- [25] URL: <https://pytorch.org/docs/stable/generated/torch.nn.Linear.html>.
- [26] Andrew L. Maas, Awni Y. Hannun a Andrew Y. Ng. *Rectifier Nonlinearities Improve Neural Network Acoustic Models*. 2013.
- [27] Djork-Arné Clevert, Thomas Unterthiner a Sepp Hochreiter. “Fast and accurate deep network learning by exponential linear units (elus)”. In: *arXiv preprint arXiv:1511.07289* (2015).
- [28] Alex Krizhevsky, Ilya Sutskever a Geoffrey E. Hinton. “ImageNet Classification with Deep Convolutional Neural Networks”. In: *Commun. ACM* 60.6 (květ. 2017), s. 84–90. ISSN: 0001-0782. DOI: 10.1145/3065386. URL: <https://doi.org/10.1145/3065386>.
- [29] URL: <https://pytorch.org/docs/stable/generated/torch.nn.Conv1d.html#torch.nn.Conv1d>.
- [30] Djork-Arné Clevert, Thomas Unterthiner a Sepp Hochreiter. “Fast and accurate deep network learning by exponential linear units (elus)”. In: *arXiv preprint arXiv:1511.07289* (2015).
- [31] URL: <https://pytorch.org/docs/stable/generated/torch.nn.CrossEntropyLoss.html#torch.nn.CrossEntropyLoss>.
- [32] Diederik P Kingma a Jimmy Ba. “Adam: A method for stochastic optimization”. In: *arXiv preprint arXiv:1412.6980* (2014).
- [33] URL: <https://commons.wikimedia.org/wiki/File:Precisionrecall.svg>.
- [34] David MW Powers. “Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation”. In: *arXiv preprint arXiv:2010.16061* (2020).
- [35] Yutaka Sasaki. “The truth of the F-measure”. In: *Teach Tutor Mater* (led. 2007).
- [36] Petra Kotíková. “Jak vypovídá vyšetření akcelerometrem o funkci horních končetin u nemocných s roztroušenou sklerózou mozkomíšní?“. Bak. pr. Třetí lékařská fakulta, univerzita Karlova v Praze. 2019.
- [37] Jan Havlík et al. “Monitoring and Classification of Tremor: Design and Realization of Measuring Device”. In: *The Seventh Young Biomedical Engineers and Researchers Conference 2016 (YBERC 2016)*. Ed. Vysoká škola báňská - Technická univerzita Ostrava. 2016. ISBN: 978-80-248-4000-0.
- [38] Xavier Glorot a Y. Bengio. “Understanding the difficulty of training deep feedforward neural networks”. In: *Journal of Machine Learning Research - Proceedings Track 9* (led. 2010), s. 249–256.

Příloha A

Souhlas etické komise



ETICKÁ KOMISE
FAKULTNÍ NEMOCNICE KRÁLOVSKÉ VINOHRADY
MEDICAL FACULTY OF CHARLES UNIVERSITY

ROZHODNUTÍ MULTICENTRICKÉ ETICKÉ KOMISE FAKULTNÍ NEMOCNICE KRÁLOVSKÉ VINOHRADY

EK-VP/01/0/2018

NÁZEV PROJEKTU:

Využití virtuální reality ve fyzioterapii na funkci horní končetiny u pacientů s roztroušenou sklerózou

Hlavní řešitel ve FNKV:

Doc. PhDr. Kamila Řasová, Ph.D.
Klinika rehabilitačního lékařství

Etická komise na svém zasedání dne **10. ledna 2018** projednala návrh vědeckého projektu doloženého následujícími dokumenty:

1. Žádost
2. Anotace projektu
3. Informovaný souhlas pacienta
4. Životopisy členů týmu
5. Souhlas přednostky kliniky

Na základě hlasování EK vydává

- Souhlasné stanovisko**
 Nesouhlasné stanovisko

Upozornění ke stanovisku EK FNKV:

- Hlavní řešitel je povinen ohlásit EK FNKV datum zahájení a ukončení projektu a zaslat závěrečnou zprávu.
- V případě, že z projektu vzejde publikace, je hlavní řešitel povinen publikaci dedikovat FNKV.

Seznam členů etické komise

Jméno a příjmení	Muž/ Žena	Odbornost	Zaměstnanec zřizovatele EK*		Funkce v EK	Přítomen		Hlasoval	
			Ano	Ne		Ano	Ne	Ano	Ne
prof. MUDr. Jan Pachel, CSc.	M	anesteziolog	<input checked="" type="checkbox"/>	<input type="checkbox"/>	předseda	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
MUDr. Martin Herold	M	kardiolog	<input checked="" type="checkbox"/>	<input type="checkbox"/>	místopředseda	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
MUDr. Milan Brychta	M	onkolog	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
Jarmila Folprechtová	F	zástupce pacientů	<input type="checkbox"/>	<input checked="" type="checkbox"/>	člen	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
PhDr. Libuše Gavlasová	F	zdravotní sestra	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>
MUDr. Nikola Mejzliková	F	internistka	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>
Dana Kovandová	F	tajemnice	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
MUDr. Eva Krpenská	M	chirurg	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
Mgr. Petr Mlynář	M	farmakolog	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
Luboš Olejář	M	zástupce pacientů	<input type="checkbox"/>	<input checked="" type="checkbox"/>	člen	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
MUDr. Leo Slavkovský	M	anesteziolog	<input checked="" type="checkbox"/>	<input type="checkbox"/>	člen	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>

(pozn: *Zaměstnanec zřizovatele EK)

Etická komise prohlašuje, že byla ustavena a pracuje podle jednacího řádu v souladu se správnou klinickou praxí (GCP) a platnými právními předpisy: Ano Ne

10.1.2018
Datum

Prof. MUDr. Jan Pachel, CSc.
předseda EK FNKV

Podpis předsedy/místopředsedy EK

Kučy
FAKULTNÍ NEMOCNICE
KRÁLOVSKÉ VINOHRADY
Srbářova 50, 100 34 Praha 10
ETICKÁ KOMISE

Příloha B

Informovaný souhlas

Informovaný souhlas účastníka studie

Vliv fyzioterapeutických facilitačních technik funkce horní končetiny u pacientů s roztroušenou sklerózou

Průběh a popis studie

Cílem tohoto projektu je zjistit vliv fyzioterapeutických intervencí na funkci horních končetin. Ve studii budou zaznamenány některé demografické údaje (věk, pohlaví, váha a výška) a data vztahující se k onemocnění (stupeň neurologického postižení, typ RS, délka trvání onemocnění, užívání léků).

Na hodnocení funkce horních končetin budou použity různé validované klinické testy (hodnotící sílu stisku a úchopu ruky, jemné a hrubé manuální zručnosti, manipulace s předměty, rychlost a koordinaci horních končetin) dotazníkové testy pro subjektivní hodnocení funkce a aktivity horních končetin (škála spasticity, zraková analogová škála hodnotící slabost, únavu, citlivost; měření manuální schopnosti, dotazník hodnotící obtíže při provádění aktivit denního života, záznam motorické aktivity horní končetiny, motorické oslabení trupu při dynamických a statických pozicích v sedě).

Vyšetření třesu bude realizované pomocí akcelerometru, fixovaného na III. prst ruky pomocí akrylátového prstýnku (naměřený záznam bude přenesen do počítače, z kterého se budou odečítat potřebné hodnoty). Dále bude sledována variabilita srdečního rytmu.

Tato vyšetření budou provedena vyškoleným nezávislým fyzioterapeutem, a to celkem čtyřikrát v čase – měsíc před začátkem terapie, před terapií, hned po skončení rehabilitace a s odstupem dvou měsíců. Každé z těchto čtyř měření bude trvat 1-1,5 hodiny a budou probíhat na Neurologické klinice FNKV v Praze. V případě potřeby budou dělané přestávky, celková doba bude přizpůsobena Vaší fyzické a psychické kondici.

V rámci studie podstoupíte ambulantní fyzioterapeutický program zaměřen na funkci horních končetin a aktivity denního života (2 terapie dvakrát týdně po dobu jedné hodiny) v rozsahu dvou měsíců (16 terapeutických jednotek). V terapiích se bude vycházet z přirozených pohybů zdravého člověka a z pohybů denních činností.

Já, níže uvedený, dávám souhlas k účasti ve studii s názvem:

Vliv fyzioterapeutických facilitačních technik funkce horní končetiny u pacientů s roztroušenou sklerózou

Jméno:

Rodné číslo:

Identifikační kód.....

B. Informovaný souhlas

1. Zcela dobrovolně souhlasím s účastí v této studii.
2. Byl(a) jsem plně informován(a) o účelu této studie, o procedurách s ní souvisejících a o tom, co se ode mne očekává. Měl(a) jsem možnost položit jakýkoliv dotaz, týkající se použité metody i účelu této studie a potvrzuji, že všechny mé dotazy byly zodpovězeny.
3. Souhlasím, že budu plně spolupracovat s lékaři studie a budu je ihned informovat, pokud se objeví změny mého zdravotního stavu nebo nečekané či neobvyklé projevy.
4. Vím, že mohu kdykoli svobodně ze studie odstoupit, aniž by to mělo vliv na kvalitu mého dalšího léčení.
5. Chápu, že informace v mé zdravotnické dokumentaci jsou významné pro vyhodnocení výsledků studie. Souhlasím s využitím těchto informací s vědomím, že bude zachována důvěrnost těchto informací.

Koordinátor studie: PhDr. Kamila Řasová, Ph.D., kamila.rasova@gmail.com, 604511416

Podpis pacienta: „Souhlasím“

Jméno pacienta:

Datum:

Já, níže podepsaný (klinický pracovník), tímto prohlašuji, že jsem dle mého nejlepšího vědomí vysvětlil/a cíle, postupy, výhody a rovněž také rizika a diskomfort vyplývající z této studie účastníku této studie nebo jeho zákonnému zástupci (jméno a příjmení)..... Účastník poskytl svůj informovaný souhlas k účasti ve studii. Kopie informovaného souhlasu bude dobrovolníkovi poskytnuta.

Datum:

Podpis výzkumného pracovníka: