

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE

Brno, 2024

Martin Kostial



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

ROZPOZNÁVÁNÍ GEST HORNÍ KONČETINY Z EMG ZÁZNAMU

UPPER LIMB GESTURE RECOGNITION FROM EMG RECORDINGS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Martin Kostial

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Vratislav Harabiš, Ph.D.

BRNO 2024

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Martin Kostial

ID: 237478

Ročník: 3

Akademický rok: 2023/24

NÁZEV TÉMATU:

Rozpoznávání gest horní končetiny z EMG záznamu

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami pro rozpoznávání gest horní končetiny z EMG záznamů. 2) Vypracujte rešerši využívaných metod, zaměřte se zejména na metody využívající strojového učení. 3) Vyhledejte vhodné databáze EMG záznamů. 4) Zvolte vhodnou architekturu sítě pro klasifikaci EMG záznamů. 5) Naučte zvolenou síť a výsledky správně vyhodnoťte, robustnost naučeného modelu vyhodnoťte i na vlastních datech. 6) Proveďte vyhodnocení dosažených výsledků.

DOPORUČENÁ LITERATURA:

- [1] VALDIVIESO CARAGUAY, Ángel Leonardo, Juan Pablo VÁSCONEZ, Lorena Isabel BARONA LÓPEZ a Marco E. BENALCÁZAR, 2023. Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks. Sensors [online]. 23(8), 3905. ISSN 1424-8220. doi:10.3390/s23083905
- [2] NUZZI, Cristina, Simone PASINETTI, Matteo LANCINI, Franco DOCCHIO a Giovanna SANSONI. Deep Learning Based Machine Vision: First Steps Towards a Hand Gesture Recognition Set Up for Collaborative Robots. In: 2018 Workshop on Metrology for Industry 4.0 and IoT [online]. IEEE, 2018, s. 28-33. ISBN 978-1-5386-2497-5. doi:10.1109/METROI4.2018.8439044

Termín zadání: 5.2.2024

Termín odevzdání: 29.5.2024

Vedoucí práce: Ing. Vratislav Harabiš, Ph.D.

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

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

Abstrakt

Tato práce se zabývá rozpoznáváním gest ze sEMG záznamu horní končetiny, návrhem vlastního klasifikátoru použitím strojového učení. Práce je rozdělena do šesti kapitol – v první jsou popsány vlastnosti EMG signálu, v druhé jsou rozepsány současné metody vyhodnocování EMG využívající strojové učení, ve třetí je samotná realizace rozpoznávacího algoritmu, ve čtvrté popisují snímání vlastních EMG záznamů a v páté je diskuse získaných výsledků.

Klíčová slova

EMG, elektromyografie, strojové učení, Python, zpracování signálů, AI

Abstract

This work covers gesture recognition from upper limb sEMG recordings, designing a custom classifier using machine learning. The thesis is divided into six chapters – the first describes the EMG signal properties, the second discusses current EMG evaluation methods using machine learning, the third presents the actual implementation of the recognition algorithm, the fourth one deals with capturing the actual EMG recordings, and the fifth one is a discussion of the obtained results.

Keywords

EMG, electromyography, machine learning, Python, signal processing, AI

KOSTIAL, Martin. *Rozpoznávání gest horní končetiny z EMG záznamu*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2024, 57 s. Bakalářská práce. Vedoucí práce: Ing. Vratislav Harabiš, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta:	Martin Kostial
VUT ID studenta:	237478
Typ práce:	Bakalářská práce
Akademický rok:	2023/24
Téma závěrečné práce:	Rozpoznávání gest horní končetiny z EMG záznamu

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucího závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

V Brně dne: 29. května 2024

podpis autora

Poděkování

Rád bych tímto poděkoval vedoucímu své práce, panu Ing. Vratislavu Harabišovi, Ph.D. za odborné vedení a podnětné návrhy při vypracování práce. Dále také své rodině a okolí za podporu a zázemí po celou dobu studia.

Obsah

SEZNAM OBRÁZKŮ.....	9
SEZNAM TABULEK	10
ÚVOD.....	11
1. VLASTNOSTI A AKVIZICE EMG SIGNÁLU	12
1.1 EMG SIGNÁL	12
1.2 PŘÍZNAKY EMG SIGNÁLU Z POHLEDU ROZPOZNÁVÁNÍ GEST	13
1.2.1 <i>Příznaky z časové domény</i>	13
1.2.2 <i>Příznaky z frekvenční a časově frekvenční domény</i>	14
1.3 AKVIZICE EMG.....	14
2. SOUČASNÉ METODY VYHODNOCOVÁNÍ EMG	17
2.1 SVM.....	17
2.2 KNN.....	17
2.3 CNN.....	18
2.4 LSTM.....	19
2.5 DQN A DOUBLE DQN	19
3. REALIZACE ALGORITMU ROZPOZNÁVÁNÍ GEST	22
3.1 1D CNN	24
3.2 2D CNN	25
3.3 DVOUSTUPŇOVÝ KLASIFIKÁTOR	28
4. REALIZACE SNÍMÁNÍ EMG SIGNÁLU	29
4.1 FYZICKÝ NÁVRH ZAŘÍZENÍ PRO SNÍMÁNÍ EMG	29
4.2 PROGRAM PRO SBĚR DAT S ARDUINEM	31
5. VÝSLEDKY A DISKUSE.....	34
6. ZÁVĚR.....	37
LITERATURA.....	38
SEZNAM SYMBOLŮ A ZKRATEK.....	46
SEZNAM PŘÍLOH.....	47

SEZNAM OBRÁZKŮ

Obrázek 1 Grafické znázornění kompozice EMG, převzato a přeloženo z [3]	12
Obrázek 2 Ukázka vpichové elektrody (a), povrchové elektrody (b), a schématická reprezentace dekompozice myoelektrického signálu, tj. ukázka tvorby akčních potenciálů motorické jednotky (Převzato z [18], upraveno)	15
Obrázek 3 Naznačení struktury extrakce vlastností použité sítě. a) struktura vrstev skládající se z paralelních konvolučních vrstev a reziduálních bloků, b) detail vlastní logiky paralelizace konvolučních vrstev (Převzato z [53], přeloženo).....	20
Obrázek 4 Znázornění schématu použitého datasetu EMG-EPN-612 (Převzato z [52])	22
Obrázek 5 Schéma neuronové sítě s pěti 1D konvolučními vrstvami	25
Obrázek 6 Vývoj hodnotících metrik v průběhu učení modelu s pěti 1D konvolučními vrstvami	25
Obrázek 7 Schéma neuronové sítě se třemi 2D konvolučními vrstvami	26
Obrázek 8 Vývoj hodnotících metrik v průběhu učení modelu se třemi 2D konvolučními vrstvami.....	27
Obrázek 9 Schéma neuronové sítě s pěti 2D konvolučními vrstvami	27
Obrázek 10 Vývoj hodnotících metrik v průběhu učení modelu s pěti 2D konvolučními vrstvami.....	27
Obrázek 11 Souvislost mezi výskytem gesta a překročením prahové hodnoty sumy spektrogramu v okně (trénovací dataset, user10, idx_100)	28
Obrázek 12 Popis kanálů Myo Armband a umístění na ruce. Převzato z [66]	29
Obrázek 13 Schéma zapojení vlastního snímacího zařízení	30
Obrázek 14 Návrh konzole pro snímače Myoware	31
Obrázek 15 Ukázka driftu hodnot naměřeného signálu, červeně vyznačená oblast je se stlačeným tlačítkem.....	36
Obrázek 16 Matice záměn pro hodnocení datasetů modelem „EMG_1D_5L_5KS“	48
Obrázek 17 Matice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS“	49
Obrázek 18 Matice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS_re“	50
Obrázek 19 Matice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS_abs“	51
Obrázek 20 Matice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS_posneg“	52
Obrázek 21 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS“	53
Obrázek 22 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS_re“	54
Obrázek 23 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS_abs“	55
Obrázek 24 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS_posneg“	56

SEZNAM TABULEK

Tabulka 1 Rozmístění elektrod na svalech předloktí, převzato z [66], přeloženo	29
Tabulka 2 Hodnotící metriky pro naučené sítě na trénovacích, testovacích, validačních a vlastních naměřených datech	35

ÚVOD

Ztráta horní končetiny amputací může zcela změnit život jedince. Soběstačnost, kterou bereme jako každodennost, stejně jako kvalita života se značně sníží. Naštěstí využití robotických protéz dokáže pomoci s překonáváním problémů pacientů s transradiální amputací. V posledních desetiletích získalo rozpoznávání gest zájem výzkumníků, což vedlo k rozvoji nejen ke zlepšení interakce člověka a počítače, lékařské rehabilitace ale i právě pohyblivých protetických končetin. Jedním ze základních nástrojů pro ovládání je elektromyografický záznam zpracováváný v téměř reálném čase, který analyzuje elektrickou aktivitu svalů. Přesná klasifikace gest ruky pomocí levných EMG nástrojů otevírá nové možnosti pro zlepšení kvality života mnoha lidí, jelikož cena kvalitních zařízení stále limituje jejich dostupnost pro širokou veřejnost.

V této bakalářské práci se zaměřuji na vývoj a implementaci metod pro klasifikaci jednoduchých gest horní končetiny z EMG záznamů s využitím metod strojového učení. Inspirací pro tento výzkum byla nespokojenost s kvalitou a cenou aktuálně nabízených komerčních produktů, a tudíž snaha vytvoření kvalitních a přesných algoritmů pro rozpoznávání a řízení protetických končetin, což je integrální pro začlenění takto zdravotně znevýhodněných jedinců do každodenního života.

V rámci této práce je poskytnut přehled současných technik a metod užívaných ke klasifikaci gest z EMG, včetně krátké diskuse o jejich výhodách a potenciálních nevýhodách. Přestože články ukazující pokrok vycházejí prakticky neustále, ještě stále nebylo dosaženo klinicky dostatečné a využitelné úspěšnosti, rychlosti vyhodnocování či adaptability těchto systémů. Navíc tyto algoritmy jsou zatíženy obtížemi spojenými s rozpoznáváním pouze pár základních gest. V reakci na tyto výzvy představuje tato práce nový algoritmus s potenciálem zvýšit efektivitu a přesnost klasifikace gest zachycených pomocí EMG signálů.

Struktura této práce je následující – v první kapitole se věnuji zevrubnému přiblížení EMG signálu, poté příznakům z něj získaných, které se aktuálně používají a popisu možností snímání elektromyografického záznamu. Ve druhé se zmiňuji o pár nejčastějších klasifikačních přístupech a popisu některých zajímavých prací, které je využívají. Ve třetí kapitole už se zabývám realizací vlastního algoritmu rozpoznávání gest, jeho implementací a technickými výzvami. V následující se nachází rozbor snímacího zařízení a potřebné algoritmy, v kapitole páté uvádím výstupy získané v rámci této práce, pak diskutuji a v závěru shrnuji všechny zjištěné poznatky.


1. VLASTNOSTI A AKVIZICE EMG SIGNÁLU

1.1 EMG signál

Elektromyografický signál je záznam elektrické aktivity generované stahujícím se svalem. Během svalové činnosti dochází k toku iontů přes membrány svalových buněk [1]. Rozdíl potenciálů vytvořených tímto tokem lze detekovat pomocí elektrod umístěných na povrchu kůže, nebo vpichovou elektrodou přímo do svalu [2] (více v 1.3). Jelikož při kontrakci je málokdy aktivní pouze jedna motorická jednotka (Motor Unit, MU), dochází tudíž k interferencím jejich signálů. Mechanismy ovlivňující velikost a „hustotu“ pozorovaných jevů v signálech jsou nábor akčních potenciálů motorických jednotek (Motor Unit Action Potential, MUAP), a impulzy motorické jednotky (Motor Unit Firing). Příklad superpozice takových signálů je znázorněn na Obrázku 1.

Amplitudový rozsah raw signálu se pohybuje v rozmezí +/- 5 mV (u sportovců) [3] (až +/- 10 mV podle [1]) a frekvence se pohybuje v rozmezí 6 a 500 Hz, s majoritními frekvencemi mezi 20 ~ 150 Hz [3] (50 ~ 150 Hz podle [4]).

Napětí měřené na povrchu kůže je ovlivněno mnoha faktory, jako např. vlastnostmi tkáně (tloušťka, vodivost samotného svalu, podkoží a kůže) [2], fyziologickými přeslechými (obvykle do 10 až 15 % obsahu signálu) [3], změnami způsobenými fyzickým



Obrázek 1 Grafické znázornění kompozice EMG, převzato a přeloženo z [3]

pohnutím elektrody [2], okolním šumem a vlastnostmi samotné elektrody, kabeláže a zesilovačů [3].

1.2 Příznaky EMG signálu z pohledu rozpoznávání gest

Příznak je název pro jakoukoliv relevantní charakteristiku extrahovatelnou ze signálu [5], např. ve frekvenční, časové nebo časově-frekvenční doméně [6], která slouží k interpretaci a charakterizaci daného signálu také použitelnou v klasifikaci [7], (jež si příznaky neextrahuje sama – často např. KNN či SVM – popsané v kapitole 2).

Je třeba vzít v úvahu zvolenou délku okna. Jelikož s rostoucí délkou okna roste i stabilita příznaků, snižuje se rozptyl a zvyšuje se klasifikační úspěšnost [5], také však prodlužuje samotné zpracování a čas potřebný ke klasifikaci. Podle [5] je optimální délka okna mezi 150 a 250 ms, podle [6] až 300 ms, pro zachování real-time zpracování.

1.2.1 Příznaky z časové domény

Příznaky v časové doméně jsou obvykle rychle a snadno implementovatelné, jelikož nevyžadují žádnou transformaci [8]. Hlavní nevýhoda těchto vlastností náleží v nestacionarosti EMG signálu, kdy tyto příznaky předpokládají stacionární data [8].

Autoregresivní model (Autoregressive model coefficients, AR) – predikční model vytvářející lineární součet předchozích prvků a chybového signálu (bílého šumu). Při klasifikaci se využívá koeficientů α_p [9]. Využití nachází při analýze dynamické svalové aktivity nebo svalové únavy [10].

Střední kvadratický průměr (Root Mean Square, RMS) – druhá odmocnina aritmetického průměru kvadrátů daných hodnot [9]. Pomáhá kvantifikovat fyziologickou aktivitu během kontrakce, předpovídat např. maximální kontraktilní rychlost svalu nebo nervové změny po tréninku [11].

Průchod nulou (Zero Crossing, ZC) – počet, kolikrát signál protne nulovou linii. Může indikovat frekvenční vlastnosti signálu (vyšší frekvence značí vyšší počet průtů nulové linie) [9]. Využívá se např. při rozlišení vzorců svalové aktivity [12].

Změna znaménka stoupání (Slope Sign Change, SSC) – počítá, kolikrát se v daném okně změní znaménko stoupání funkce. Obdobně jako průchod nulou má návaznost na frekvenci signálu, je užitečná pro určení počátku svalové aktivity a různých vzorů svalové kontrakce [9]. Zavádí se také práh pro eliminaci nadhodnocení kvůli šumu [13].

Waveform Length (WF) – kumulativní délka signálu v rámci jednoho okna. Zahrnuje v sobě informaci jak o frekvenci, tak amplitudě a podává informaci ohledně komplexnosti signálu [14]. Tento příznak je užitečný pro analýzu svalové únavy či sílu kontrakce [15].

Průměrná absolutní hodnota (Mean Absolute Value, MAV) – průměr absolutních hodnot daného okna [9]. Využívá se k odhadu úrovně svalové kontrakce.

Další extrahovatelné vlastnosti jsou např. Simple Square Integral (SSI) (pro ohodnocení celkové energie obsažené v signálu), Variance of EMG (variabilita a distribuce svalové aktivity), Log detector (zlogaritmování signálu, snížení vlivu extrémních rozdílů amplitud), Myopulse Percentage rate (sledování trvání a intenzity svalové aktivity) a další [8].


1.2.2 Příznaky z frekvenční a časově frekvenční domény

Charakteristiky ve frekvenční doméně se používají především pro hodnocení svalové únavy nebo analýzy náboru motorických jednotek (Recruitment of Motor Units). Výkonová spektrální hustota (Power Spectral Density, PSD) se stává hlavní analýzou ve frekvenční oblasti, jelikož je definována jako Furierova transformace autokorelační funkce signálu. Mezi vlastnosti získané z PSD patří např. celkový výkon (Total Power, TTP), střední výkon (Mean Power, MNP) či spektrální momenty (Spectral Moments, SM) [16]. Podle [8] se jedná např. ještě o průměrnou frekvenci (Mean Frequency) nebo medián frekvencí (Median frequency). Tyto vlastnosti mohou poskytovat informace podobné některým příznakům v časové oblasti, zejména těm, které jsou založeny na informacích o energii [16] – jako je integrované EMG (IEMG), střední kvadratická hodnota (RMS), střední absolutní hodnota (MAV) a variance EMG (VAR).

Pro úplnost ještě dodejme, že existují i příznaky extrahovatelné z časově frekvenční domény pomocí vlnkové transformace, kontinuální vlnkové transformace, diskrétní vlnkové transformace, nebo krátkodobé Fourierovy transformace [6], které se využívají společně s ostatními příznaky, např. v práci [17].

1.3 Akvizice EMG

K měření EMG signálu se používají dva hlavní typy elektrod – jehlové a povrchové [18]. Jehlové elektrody (Obrázek 2 a) se dále dělí na tři druhy – unipolární jednoduché elektrody, single-fiber EMG elektrody a koncentrické EMG elektrody. Jehlové elektrody, přibližně 1 mm² v průměru, umožňují snímání signálu z malé oblasti, tj. malého počtu motorických jednotek (motor unit, MU). Povrchové elektrody (Obrázek 2 b) jsou široké 0,5-2,5 cm a hlavně, díky svému umístění, jsou neinvazivní [19]. Povrchové elektrody pracují na principu detekce změny chemické rovnováhy mezi povrchem svalu a kůží těla prostřednictvím vedení iontů v elektrolytech. Povrchové elektrody jsou dvojího typu – gelové EMG elektrody a suché EMG elektrody.



Obrázek 2 Ukázka vpichové elektrody (a), povrchové elektrody (b), a schématická reprezentace dekompozice myoelektrického signálu, tj. ukázka tvorby akčních potenciálů motorické jednotky (Převzato z [18], upraveno)

Zástupcem zařízení využívajících suchých elektrod ke snímání povrchového EMG v akademické sféře je Myo Armband společnosti Thalmic labs. Ačkoliv se zařízení přestalo prodávat v roce 2018 [20], stále se užívá k akvizici dat (např. v [21], [22]), jelikož se jedná o bezdrátové, lehké zařízení obsahující osm EMG svodů (skládající se ze dvou 100 mm² plošek a jedné menší (nespecifikované velikosti), reprezentující elektrodu referenční, pomocnou a pracovní, všechny s povrchem z nerezové oceli) [23] – každý EMG kanál je snímán s frekvencí 200 Hz a hloubkou 8 bitů. Zařízení dále obsahuje inerciální jednotku pro měření polohy (tříosý gyroskop), zrychlení (tříosý akcelerometr) a magnetického pole (tříosý magnetometr) – dohromady nazývané jako Inertial Measurement Unit (IMU), se vzorkovací frekvencí 50 Hz [23]. O napájení se stará Li-Pol baterie. Bezdrátový přenos je zabezpečen pomocí Bluetooth LE v4.0 (BLE 4.0) [23], zařízení se tedy nestará o odstranění síťového rušení, má však integrované filtry pro přenos cca 5~100 Hz pro EMG signál [23] (dolní frekvence není přesně specifikovaná). Další výhodou tohoto zařízení byla relativní cenová dostupnost, a to 200 USD MSRP [24] [23].

Mezi další zařízení vykonávající obdobnou činnost se dá zařadit Ctrl-kit od Ctrl-labs (nyní spadající pod Facebook Reality Labs [25]), jež by dle vyjádření [26] mělo být duchovním nástupcem právě Myo Arbandu, ze kterého bere inspiraci [26]. Z volně dostupných informací je hlavní rozdíl počet kanálů (16 vs 8), a materiál elektrod [25]. Dostupnost, případně cena a další parametry jsou však neznámou, jelikož poslední zmínka o prototypu byla přes blog v roce 2021 [27].

Další komerční produkt pro snímání EMG je BITalino zastřešované společností PLUX – Wireless Biosignals. Jedná se o všestrannou platformu umožňující snímání vícero typů analogových signálů v závislosti na zvoleném modulu. Deska, starající se o celé měření, se v nejnovější verzi jmenuje BITalino (r)evolution a nabízí široké spektrum nastavení pro snímání (nastavení dostupné v aplikaci OpenSignals) [28]. Základem je mikrokontroler (MCU), Bluetooth 2.0 modul s technologií Enhanced Data Rate (nespecifikované verze) pro BT verzi, nebo Bluetooth LE 4.1 (BLE verze) modul, čtyři 10bit analogové vstupní porty (A1-A4), dva 6bit analogové vstupy (A5, A6)

a další elektronika [28]. O napájení se stará Li-Pol baterie dobíjená přes micro-USB (5 V DC 400 mA, pouze mimo probíhající měření), vzorkovací frekvence pro všechny vstupy je nastavitelná na 1/10/100/1000 Hz [28]. Pro tuto práci je zajímavý přídavný EMG modul, který dokáže snímat signál v rozmezí frekvencí 25~482 Hz [29], přítomnost jakýchkoliv dalších filtrů není výrobcem zmíněna. Připojení samotných elektrod je pomocí barevně označených vodičů – červená je kladný, černá záporný a bílá referenční (BITalino specifikuje i dvou vodičové zapojení (bez reference), což není případ EMG modulu) [29], kdy referenci je doporučeno umístit na kost v okolí.

Další zástupce z řady senzorů je MyoWare. Jedná se o snímač EMG, využívaný hlavně v oblastech rehabilitace či protetiky. Pro snímání signálu využívá navrhávací elektrody, kdy referenční je jediná s prodlužovacím vodičem. Zařízení dále obsahuje sadu filtrů – jednu aktivní horní propust prvního řádu s mezní frekvencí 20,8 Hz, jednu aktivní dolní propust prvního řádu s mezní frekvencí 498,4 Hz a pasivní lineární filtr prvního řádu s mezní frekvencí 3,6 Hz starající se o rektifikaci [30]. Výstupem senzoru je analogový signál buď v „raw“ (neupravovaný, výchylky kladné i záporné) nebo v rektifikované formě – volba výstupu se volí pomocí fyzického výběru výstupního konektoru [30]. Výrobce doporučuje zařízení připojit k Arduino pomocí MyoWare Link Shield, který umí připojit až 6 modulů MyoWare [31].

2. SOUČASNÉ METODY VYHODNOCOVÁNÍ EMG

Zpracování EMG signálů hraje zásadní roli v rozpoznávání a klasifikaci gest horní končetiny. V poslední době se využívají pokročilé metody strojového a hlubokého učení k efektivnímu a přesnému zpracování naměřených dat. Tyto metody umožňují přesnější interpretaci EMG signálů oproti metodám využívajících pouze prahování [6]. V této kapitole se budu zabývat několika klíčovými metodami, včetně jejich principů, výhod a nevýhod.

2.1 SVM

Metoda podpůrných vektorů (Support Vector Machine, SVM) jsou třídou modelů učení s učitelem, používaných pro klasifikaci a regresi. Fungují na základě hledání nadroviny, která nejlépe odděluje různé třídy v prostoru vstupních parametrů (tj. příznaků). SVM jsou účinné ve vícedimenzionálních prostorech a jsou univerzálně využitelné, kvůli možnosti specifikovat různé funkce jádra (kernelu) pro oddělení skupin [32] (např. lineární, polynomiální, RBF (Radial Basis function – radiální bázová funkce) a jiné). Výhodami jsou robustnost vůči přeučení, zejména ve vícedimenzionálním prostoru [33]. Naopak, SVM zaostává na velmi velkých datasetech kvůli své výpočetní složitosti a může mít špatné výsledky na silně zkreslených či nevyvážených datasetech [34]. Vyžaduje také pečlivé ladění jejich parametrů (např. regularizace) nebo výběr jádra [35].

V práci [36] se snažili naparametrizovat SVM pro detekci 13 gest z EMG a vybrat optimální funkci jádra. Nejlepší výsledky podávalo radiální jádro (RBF) s přesností 79,36 %, polynomiální a sigmoidální funkce dosahovaly úspěšnosti pod 60 %. Autoři se však nezmiňují o příznacích užitých k rozpoznávání.

V další práci [37] porovnávali autoři více metod (umělé neuronové sítě – ANN, SVM, Random Forest a Logistic Regression) pro klasifikaci gest. Při využití 6 parametrů, získaných z časové domény (RMS, variance, střední absolutní hodnota, změna znaménka stoupání, průchod nulou, waveform length) byl průměr přesnosti klasifikace SVM 87,4 %, nejlépe skončila ANN s průměrem 94 % z 10 měření.

2.2 KNN

Algoritmus k-Nearest Neighbors (kNN) je základní metodou v oblasti strojového učení, používaný jak pro klasifikační, tak pro regresní úlohy. Funguje na bázi identifikace k nejbližších bodů (tj. sousedů) k dotyčnému bodu a na základě těchto sousedů provádí predikce – pro klasifikaci volí nejčastější třídu mezi nimi, pro regresi obvykle používá průměr nebo medián jejich hodnot. Jednou z hlavních výhod kNN je jednoduchost a intuitivnost, dále také fakt, že nevyžaduje fázi trénování modelu [38] [39], což zjednodušuje jeho implementaci. Nicméně kNN činí problémy práce s velkými

datasety (kvůli vysokým nárokům na výpočetní výkon při výpočtu vzdáleností pro každou predikci) [40]. Navíc je citlivý na irelevantní příznaky [41] a může mít problémy ve mnohadimenzionálních prostorech kvůli tzv. „prokletí dimenzionality“ (angl. curse of dimensionality) [41]. Přesto zůstává kNN populární volbou díky své snadné pochopitelnosti a implementaci v různých kontextech strojového učení [42].

Článek [43] využívá kNN k rozlišení EMG záznamů 21 gest ruky snímaných pomocí Myo Arm band a signálů z odporových senzorů síly (Force Sensitive Resistor – FSR). Po vybrání 50 nejpřínosnějších příznaků (z původních 104) z obou sad signálů dosáhli autoři až 96 % přesnost klasifikace pohybu samotné ruky a 68–83 % při zahrnutí gest používající prsty.

Další práce [44] se zabývá tvorbou co nejefektivnějšího systému na rozpoznávání gest. Tudiž autoři zkusili vyvinout FPGA, a poté využili pouze RMS ke klasifikaci s kNN. Přesnost jejich klasifikace je 93,4 %.

2.3 CNN

Konvoluční neuronové sítě (Convolutional Neural Networks, CNN) jsou algoritmy hlubokého učení zvláště účinné při zpracování dat s maticovou topologií, jako obrazy a útvary vyšší dimenze. CNN využívají vrstvy s konvolučními filtry (maskami), které automaticky a adaptivně extrahují příznaky a učí se prostorové hierarchie těchto příznaků od jednoduchých až po komplikované vzory. Vynikají právě v úlohách jako je rozpoznávání a klasifikace obrazů [45]. Mezi jejich výhody patří efektivita při zpracování velkých objektů a schopnost zachytit prostorové či časové závislosti, častokrát nerozpoznatelné okem. Nicméně CNN vyžadují velké množství trénovacích dat pro dobrý klasifikační výkon a mohou být výpočetně náročné, zvláště při práci s hlubokými architekturami a velkými datovými sadami [46].

Práce [47] se zabývá tvorbou kompaktního modelu CNN sítě trénovaná na datasetu Ninapro DB5. Celá síť obsahuje 4 konvoluční vrstvy s 3×3 jádrem, ReLU aktivační funkcí a výstupní pooling vrstvu – návrh nevyužívá flattening pomocí plně propojené vrstvy, namísto toho zakomponoval adaptivní average-pooling vrstvu. Při klasifikaci dosahuje model, dle tvrzení autorů, přesnosti až 98,81 %.

Další práce [48] se zabývá zkvalitněním života lidí s amputovanou částí horní končetiny pomocí snímání osmikanálového sEMG pomocí náramku Myo Armband. Klasifikační klouzavé okno je nastavené na relativně střízlivých 285 ms (což odpovídá 57 vzorkům), s maximální dosažitelnou latencí záznamu a zpracování pod 300 ms. Autoři také počítají spektrogram pro každý kanál zvlášť, s délkou 30 vzorků Hammingova okna pro zabránění rozmazání spektra (frequency leakage). Autoři implementovali dvoustupňový klasifikační CNN algoritmus (oba stupně mají stejnou CNN architekturu), kdy první stupeň se stará o binární klasifikaci neutrálního gesta – při negativním výstupu se klasifikuje, které z 6 přednaučených gest se v signálu vyskytuje. V článku se přímo nezmiňují parametry sítě, pouze se zde vyskytuje obrázek

o nízké kvalitě naznačující užití pěti konvolučních vrstev a dvou lineárních. Průměrná přesnost pro detekci gest je uváděna na 93,14 %.

2.4 LSTM

Sítě s dlouhou-krátkodobou pamětí (Long Short-term memory) jsou typ rekurentních sítí a slouží pro analýzu sekvenčních dat, což je výhodné pro zpracování časově závislého sekvenčního záznamu. Charakteristické pro jejich použití jsou brány (zapomínací, vstupní, výstupní), díky kterým LSTM efektivně řídí tok informací skrz síť, udržuje nebo odstraňuje data po různě dlouhém období, a tím řeší problém mizejícího gradientu typickým pro tradiční rekurentní neuronové sítě, čímž dokáže zachytit i dlouhodobější závislosti [49]. Nevýhodou je potřeba značných paměťových a výpočetních zdrojů a, jako u většiny metod hlubokého učení, mají tendenci k přeučení na malých učicích datasetech. V klasifikaci gest z EMG LSTM excelují v interpretaci časových řad z pohybů svalů, zachycují časovou dynamiku nezbytnou pro rozlišení různých gest. Tato schopnost je činí ideálními pro reálné, přesné rozpoznání gest v oblastech jako je řízení protéz nebo interakce člověka s počítačem, ačkoliv jejich výpočetní nároky a potenciál přeučení vyžadují uvážlivý návrh a trénink modelu [50].

V práci [50] autoři porovnávali různé modely neuronových sítí pro klasifikaci gest z EMG záznamů – LSTM, RNN (obecný model rekurentní neuronové sítě), GRN (Gated Recurrent Unit) a FFNN (Feed-forward Neural Network). Výsledky na validační množině (která je definovaná jako 20 % celých použitých datasetů NinaPro DB5 a UC2018 DualMyo) jsou 94,87 % Frame-wise Accuracy (FWA, přesnost klasifikace v okně) a 98,31 % Detection Accuracy (DA, přesnost klasifikace na celém signálu). Pro porovnání, FFNN měla na stejné množině FWA 96,33 % a DA 98,55 % nebo obecná rekurentní síť dosáhla FWA 94,73 % a DA 98,97 %.

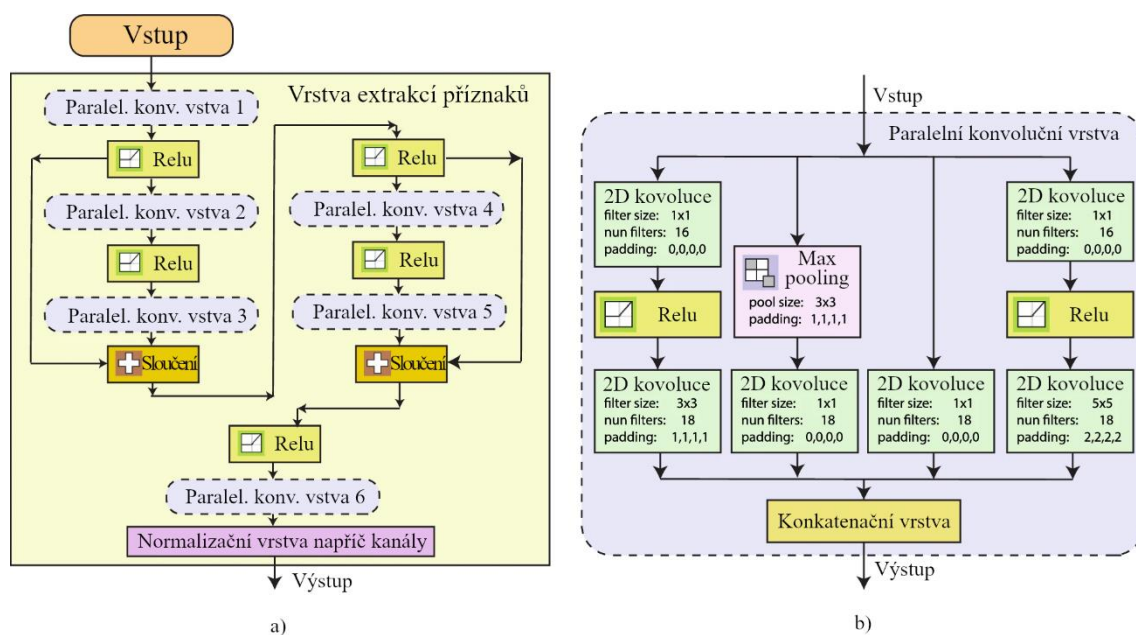
Další článek [51] se soustředí na vytvoření real-time klasifikátoru gest z EMG záznamu pomocí LSTM sítě (1 LSTM vrstva a několik lineárních vrstev – není specifikováno kolik). Jako dataset bylo využito autory naměřené čtyřkanálové EMG pomocí vlastního náramku. Přesnost testování/validace je uváděna na 99 % a 87 ± 7 % pro „real-time testing“.

2.5 DQN a Double DQN

Deep Q Networks (ještě nemá zcela ustálený český překlad) je metoda integrující hluboké neuronové sítě a Q-learning (metoda zpětnovazebného učení (reinforcement learning)) založená na maximalizaci odměny (např. přesnost rozpoznávání jednotlivých gest). Rozdíl mezi uvedenými je ve způsobu vyhodnocování prediktivní Q-hodnoty, kdy DQN mívá tendence k nadhodnocování, kdežto Double DQN využívá pro hodnocení kvality akce dvě sítě – první odhaduje kvalitu, druhá tuto hodnotu ověřuje.

Využitím těchto metod se zabývala práce [52]. V ní autoři vytvářeli dvě varianty s agenty DQN a Double DQN, v kombinaci s využitím klasické dopředné neuronové sítě (nazývanou zde FFANN – Feed-forward Artificial Neural Network) a neuronovou síť s LSTM vrstvou. Při využití Double DQN vyzkoušeli i kombinaci s různou frekvencí aktualizace vah. Bohužel se autoři více o architekturu jednotlivých sítí nezmiňují. Jako zdroj svých dat si autoři zvolili dataset EMG-EPN-612. Ze zajímavých výsledků by stálo zmínit kombinaci DQN a FFANN s Classification Accuracy 85,7 % \pm 3,8 % (přesnost rozpoznání gesta v konkrétním okně) a Recognition Accuracy 84,1 % \pm 12 % (přesnost rozpoznání gesta v celém signálu) nebo kombinace Double DQN s FFANN při Classification Accuracy 82,7 % \pm 3,3 % a Recognition Accuracy 80,7 % \pm 9,6 %.

Další článek [53] se snaží vytvořit systém na ovládání dvou robotických platform pomocí vlastních snímaných EMG dat z Myo Arm bandu. Architekturu klasifikátoru staví na DQN s konvoluční neuronovou sítí, ve které napodobují inception moduly a využívají paralelní konvoluční vrstvy pro extrakci vlastností. Struktura takové sítě je naznačena níže na Obrázku 3. Autoři zmiňují i zvolený systém odměn, kdy za správnost (nesprávnost) ohodnocení jednoho okna dostane odměnu +1 (-1, respektive), a po ukončení učící epochy, pokud alespoň 70 % oken klasifikováno správně, model dostane jednorázovou odměnu +10. V rámci post processingu autoři vezmou nejčastější gesto z daného signálu a aplikují jej přes jiná ostatní navrhovaná gesta, pro nahrazení chybných klasifikací. V textu je také zmíněno, že na validačním datasetu bylo dosaženo Classification Accuracy 95,7 % \pm 3,34 % a Recognition Accuracy 86,2 % \pm 10,27 %.



Obrázek 3 Naznačení struktury extrakce vlastností použité sítě. a) struktura vrstev skládající se z paralelních konvolučních vrstev a reziduálních bloků, b) detail vlastní logiky paralelizace konvolučních vrstev (Převzato z [53], přeloženo)

Existují i různé kombinace výše uvedených metod, jako například kombinace LSTM a CNN, např. v práci [54], [55], [56], [57], nebo SVM a CNN [58],[59], či KNN s CNN [59].

3. REALIZACE ALGORITMU ROZPOZNÁVÁNÍ GEST

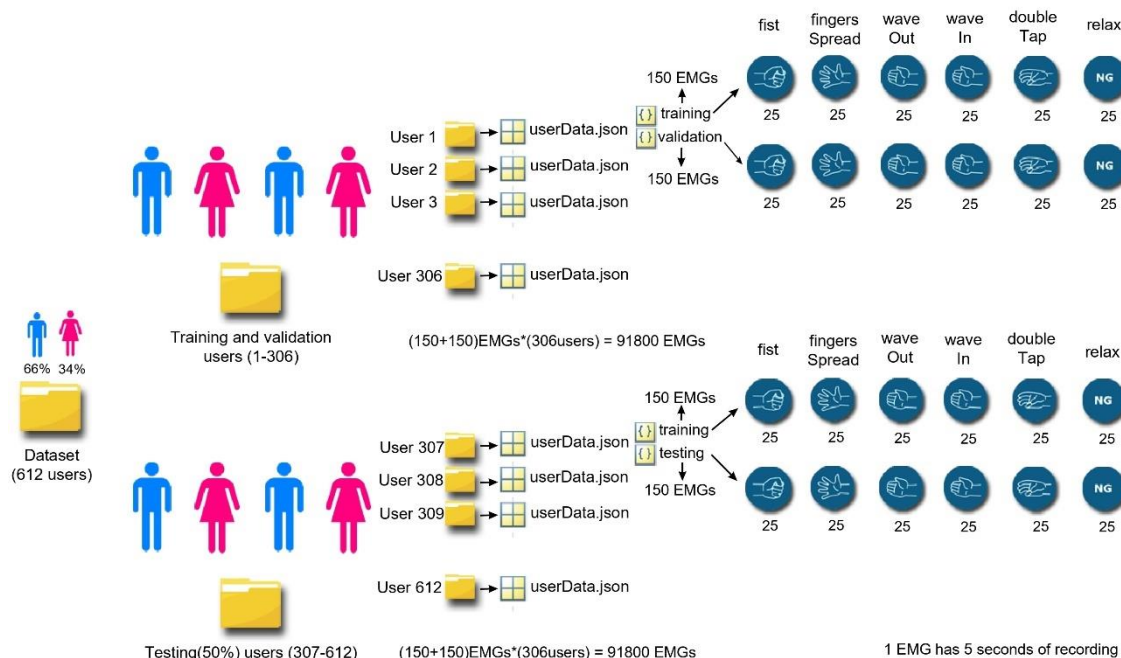
Obecně a často využívané datasety jsou Ninapro (db1 až db10) [6][60][50], EMG-EPN-612 [61], CapMyo [62] a další. Jelikož druhý zmíněný použili autoři v práci [52], a svou složitostí vyhovoval našim požadavkům na velikost a jednoduchost, byl použit i v této.

Dataset je již v základu rozdělen na trénovací a testovací část, kde obě jsou stejně velké (306 pacientů v každé – zde nazývaných „uživatelé“), každý subjekt má ještě svou část trénovací a validační.

Struktura .json formátu je sice přehledná, přesto absence podrobnější dokumentace a nízká rychlost poskytnutého skriptu při práci s takovou strukturou nutí k vytvoření vlastní datové struktury v Pythonu.

Na Obrázku 4 je naznačená struktura datasetu. Pro naše účely jsme zvolili mírně jiné rozdělení než v původních datech. Data uživatelů 307–612 byla použita jako validační množina, vzorky v podsložce testing jsou však neoznačené, a tudíž pro nás nepoužitelné. Vzorky naměřené jako „validation“ uživatelů 1–306 jsme využili k out-of-sample testování, záznamy „training“ k trénování a in-sample testování naší sítě.

V rámci přípravy dat prováděli autoři datasetu pro každého uživatele nejdříve filtraci Butterworthovou dolní propustí pátého řádu s mezní frekvencí 0,1 Hz, dále normalizaci dat na hodnoty v intervalu $\langle -1;1 \rangle$ (z původních $\langle -128,128 \rangle$), poté rektifikaci pomocí absolutní hodnoty. Vytvořením klouzavého okna o délce 0,5s, v něm počítáním spektrogramu a sumací hodnot jednotlivých frekvenčních složek s prahovou



Obrázek 4 Znárodnění schématu použitého datasetu EMG-EPN-612 (Převzato z [52])

hodnotou 0,86 (není uvedeno proč, pravděpodobně empirická hodnota) získali začátek a konec užitečného signálu (tj. aktivní region). Tuto část si z původního signálu extrahovali, pomocí funkce na výpočet DTW (Dynamic Time Wrapping) stanovili nejrepresentativnější záznam a k němu vytvořili příslušný one-hot vektor. Tyto dva soubory dat následně používali k učení neuronové sítě pomocí Python knihoven Keras a TensorFlow.

Tento přístup učení je neefektivní k výpočetním prostředkům a počítá s ukončeným signálem. V této práci byla zvolena cesta klasifikátoru využívající klouzavé okno o velikosti 25 vzorků (125 ms) a posunu o 10 vzorků (v přejaté práci bylo využíváno posunu o 15 vzorků, snížení na 10 vzorků bylo snadnou cestou augmentace dat). Výpočet přítomnosti gesta v aktuálním okně se opíral o konstanty „groundTruth“ udávající index začátku a konce gesta, uvedené jako jeden z atributů pro každý záznam. Společně s daným signálem byl vytvořen i one-hot vektor pro jednotlivá gesta v pořadí: "noGesture", "waveOut", "pinch", "fist", "waveIn" a "open".

Klasifikační stabilita při rozšíření velikosti okna na 50 vzorků (250 ms) sice vzrostla, ovšem pro zachování jisté formy zpětné kompatibility s přejatým kódem bylo od tohoto přístupu upuštěno.

Další snahou pro zkvalitnění procesu učení a generalizace bylo vytvořit vybalancovaný dataset – skoro 80 % všech získaných oken obsahovalo signál bez gesta. Při vynechání náhodně vybraných oken a poměrném zastoupení všech šesti skupin v trénovacím datasetu klesla úspěšnost klasifikace o zhruba 10 %, tudíž bylo od tohoto přístupu také upuštěno.

Následně byla navrhována konvoluční neuronová síť (ze které se postupně vyvinuly čtyři hlavní větve vývoje – viz. kap. 3.1, 3.2 a 3.3. Za kritériální (angl. loss) funkci byla vybrána Cross Entropy, pro schopnost zajištění konvergence v pozdějších fázích učení – a oproti např. střední kvadratické odchylce (MSE), která má v pozdějších fázích velmi malé gradienty, a tudíž pomalé učení, nehledě na fakt, že MSE se využívá primárně při regresních úlohách – při kategoričkových nabývá pouze dvou hodnot (0 a 1), což snižuje efektivitu učení [63]. S její implementací se také vázala nemožnost využití kódování skupin pomocí one-hot vektorů (není v Pytorch implementováno), a tudíž se přešlo na číselné kódování pomocí čísel 0-5 (formátu long, pro který je Cross Entropy nativně podporována).

Jako optimalizační metoda (angl. optimizer) byl zvolen Adam, pro svou relativní výpočetní efektivitu [64] [65], jednoduchost implementace (nepotřebu složité parametrizace) a popularitu v literatuře při učení NN.

Pro urychlení práce byl signál (předem rozdělen do oken) uložen do serializované Pytorch proměnné s přesností float16 (ušetření přes 85 % místa oproti float64) a později načítán do float32, čímž se dosáhlo střední cesty mezi možnostmi klasifikačního výkonu a prostorovými nároky v paměti.

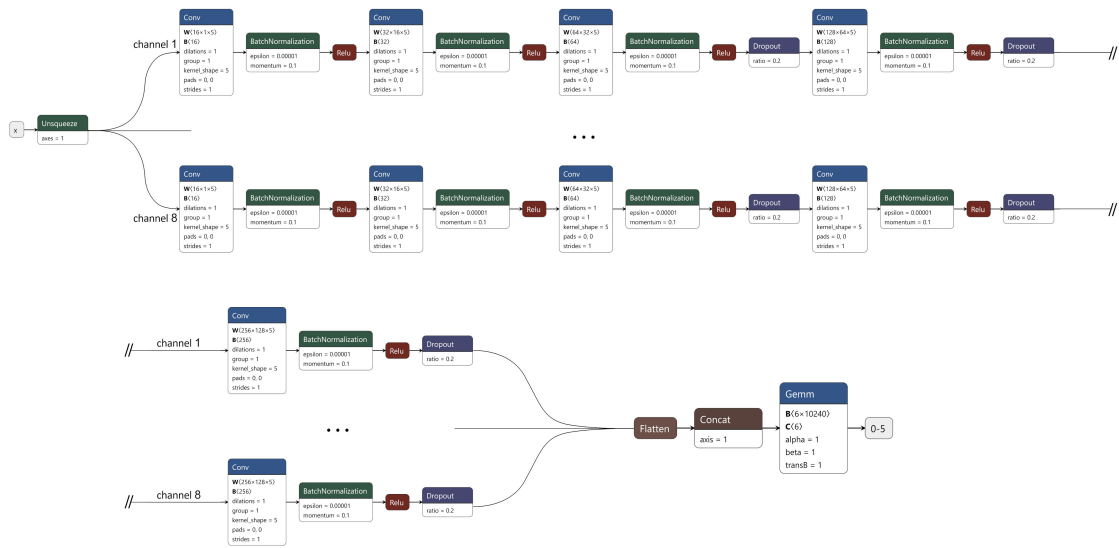
K potřebám testování byla definována funkce *evaluate_metrics*, využitelná pro in-sample a out-of-sample testování i validaci. Umí vypočítat přesnost (accuracy), F1 skóre a matici záměn. Původně byla snaha zakomponovat i oblast pod ROC křivkou (ROC AUC), ale pro nutnost vlastní implementace a fakt, že metrika není v literatuře (v kap. 2) příliš využívána, a tudíž zde není možnost následného porovnání, byla odstraněna.

U všech modelů konvolučních sítí byl implementován early-stopping pro zamezení přeučení (overfittingu), learning-rate scheduler ReduceLRonPlateau pro možnost nalezení optima kroku učení v pozdějších fázích učícího procesu, batching (mini-batching) pomocí funkce DataLoader, z důvodu optimalizace učení na CUDA jádrech GPU, dropout vrstvy s pravděpodobností vynulování vstupu 0,2 – pro další omezení možného overfittingu (p-hodnota musela být zároveň dostatečně nízká i pro eliminaci nedoučení – underfittingu) a batch normalisation vrstvy pro rychlejší konvergenci či zvýšení stability učení (možnost využití vyšších kroků učení).

3.1 1D CNN


První naivní návrhy modelů počítaly s 1D konvolucí o velikosti kernelu 1×3 nebo 1×5 . V průběhu učení bylo ověřeno, že větší jádro znamená vyšší klasifikační stabilitu, proto bylo od první možnosti upuštěno. Na Obrázku 5 je možno vidět, že se využilo stejné architektury pro každý cyklus – pěti konvolučních vrstev (každá s Batch normalizací a ReLU aktivační funkcí), postupně s 8, 16, 32, 64, 128 a 256 filtry, po třetí a každé další také dropout vrstvy s koeficientem 0,2, zaobalené do jednoho for cyklu s iterací přes všech 8 kanálů. Pro možnost využití následné fully connected vrstvy bylo nutné inkorporovat konkatenaci výstupů z jednotlivých iterací do proměnné a následný flattening do vektoru (blok „Gemm“ ve schématu). Nevýhody takového přístupu jsou popsány v kap. 3.2.

Z Obrázku 6 lze vyčíst postup hodnotících metrik pro tento model. Trénovací F1 skóre a testovací F1 skóre se prakticky překrývají, obdobně i u trénovací a testovací přesnosti. Je očividné, že k žádnému značnému zlepšení klasifikačních vlastností během učení nedošlo, oproti modelům popsaným v kapitole 3.2 je patrný markantní rozdíl v F1 skóre daný vlastnostmi spojenými s 1D architekturou.



Obrázek 5 Schéma neuronové sítě s pěti 1D konvolučními vrstvami

Vývoj hodnotících metrik v průběhu učení



Obrázek 6 Vývoj hodnotících metrik v průběhu učení modelu s pěti 1D konvolučními vrstvami

3.2 2D CNN

Obě sítě využívající 2D konvoluci mají stejný základ, resp. z hlediska časové posloupnosti vývoje je třívrstvý model odlehčeným derivátem sítě složitější. Základem myšlenky pro tyto modely je dekompozice signálů jednotlivých motorických jednotek a při různých anatomických „vlastnostech“ rukou různých jednotlivců může docházet k překryvu signálů více svalů v jednom kanálu (nebo naopak více kanálů může snímat různé motorické jednotky jednoho svalu), nehledě na nutnost snímání elektrodami v přesném umístění na kůži, aby signál jednoho kanálu pokrýval stále stejné svaly, dále také možnost zachycení vzorců signálu ve více kanálech. 2D konvoluce tento problém

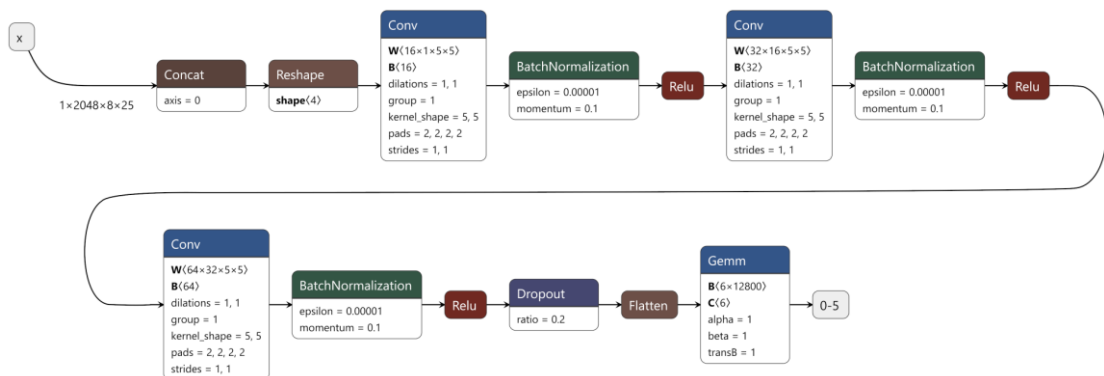
řeší tím, že bere v potaz i okolní záznamy.

Jelikož signál kanálu 1 a 8 jsou fyzicky vedle sebe, ale konvoluce by to nebrala v úvahu, byla zavedena tzv. „cylindrické projekce“ vstupního signálu, kdy byla samotná vstupní matice rozšířena o počet kanálů odpovídající operaci „floor division“ polovině velikosti kernelu (tudíž, při velikosti jádra (5,5) byl vedle kanálu 1 přidán také 8 a 7, analogicky u kanálu 8) – odpovídající prvnímu bloku „concat“ na Obrázku 7 a 9.

Jak bylo již zmíněno výše, síť se třemi 2D konvolučními vrstvami je jednodušší varianta sítě uvedené níže, resp. jedná se o pokus, jaké klasifikační úrovně lze dosáhnout s mnohem jednodušším modelem, přívětivějším na výpočetní prostředky. Počet filtrů konvoluce byl empiricky nastaven na 16, 32 a 64 pro poslední vrstvu, následně využito „flatteningu“ a vzniklý vektor byl předán plně propojené vrstvě (angl. dense, fully connected – na Obrázku 7, pod jménem „Gemm“), která dala na výstupu číslo skupiny.


Na Obrázku 8 jsou vyneseny průběhy dvou hodnotících metrik – F1 skóre a přesnosti. Ze závislostí můžeme konstatovat, že učení po cca epoše 20 nebylo již přínosné z hlediska zvyšování generalizačních klasifikačních schopností sítě.

Model s pěti 2D konvolučními vrstvami je odvozený od předešlého – resp. po ReLU aktivační vrstvu po výstupu třetí konvoluční vrstvy se shodují, je rozšířen o další dva konvoluční bloky o 128 a 256 filtrech, po každé z nich navíc dropout blok, viz Obrázek 9, naznačení vývoje jeho hodnotících metrik je na Obrázku 10, složitost sítě značně zpomalovala učení. I po optimalizaci na straně značné redukce evaluačních ukazatelů trvá učení jedné epochy cca 20 minut. Hodnoty v grafu musíme brát s jistou tolerancí, jelikož záznam probíhal každých 5 epoch, a tudíž se zde zobrazují dlouhodobější trendy, než konkrétnější hodnoty. Peak generalizace se vyskytuje kolem epochy 30, od které již validační i testovací F1 skóre kulminuje.

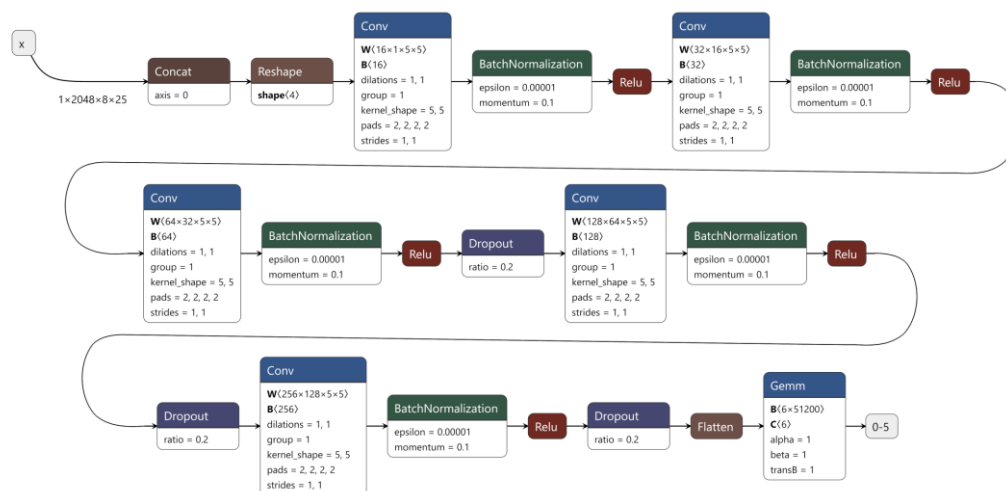


Obrázek 7 Schéma neuronové sítě se třemi 2D konvolučními vrstvami

Vývoj hodnotících metrik v průběhu učení




Obrázek 8 Vývoj hodnotících metrik v průběhu učení modelu se třemi 2D konvolučními vrstvami



Obrázek 9 Schéma neuronové sítě s pěti 2D konvolučními vrstvami

Vývoj hodnotících metrik v průběhu učení



Obrázek 10 Vývoj hodnotících metrik v průběhu učení modelu s pěti 2D konvolučními vrstvami

3.3 Dvoustupňový klasifikátor

Při pozorování chování a překážek při učení konvolučních sítí a tvorbě vybalancovaného datasetu přišla myšlenka na dvoustupňový klasifikátor, kdy první stupeň byl obstarán prahováním sumy spektrogramu, a druhý by byla konvenční konvoluční neuronová síť, kdy první stupeň by obstarával zjišťování přítomnosti či nepřítomnosti gesta. Při kladném výsledku by byla aktivována CNN a rozhodla, o které z pěti gest se jedná.

Při porovnání grafů závislosti „groundTruth“ (tj. binární hodnota označující přítomnost gesta, poskytnutá autory datasetu) na vzorcích signálu a oknech v kterých došlo k překročení prahu (oba grafy vycházejí přímo z přejatého kódu), můžeme vidět jistou souvislost, avšak ne přímou závislost mezi překročením prahu 0,86 ve spektrogramu a ohraničením oblasti, ve které se vyskytuje gesto – viz Obrázek 11. Pozorováním a vyhodnocováním trénovacích dat vyšlo najevo, že pouze 54,3 % z celkového výskytu překročení stanoveného prahu se vyskytuje v oblasti „groundTruth“, 43,6 % se vyskytuje v signálech s gestem, avšak mimo zmíněnou oblast a 1,98 % se vyskytuje v signálech bez přítomného gesta.

Z tohoto vyplývá, že dvoustupňový klasifikátor není spolehlivá cesta, jak rozlišit přítomnost či nepřítomnost gesta a oba stupně by se musely překrývat a doplňovat, aby bylo možné dosáhnout požadované klasifikační úspěšnosti.



Obrázek 11 Souvislost mezi výskytem gesta a překročením prahové hodnoty sumy spektrogramu v okně (trénovací dataset, user10, idx_100)


4. REALIZACE SNÍMÁNÍ EMG SIGNÁLU

V této kapitole se zaměřím na praktickou realizaci snímání EMG signálů, přičemž s pomocí deseti subjektů si vytvořím vlastní dataset. Cílem bude podrobně popsat jak fyzický návrh, tak i algoritmus podporující tento přípravek, různé vývojové větve a obecně celý proces od snímání až po následné úpravy, aby byla data ztotožnitelná s měřením pomocí Myo Armband. V této části bylo využito nástroje generativní umělé inteligence ChatGPT od společnosti OpenAI, s cílem debugování a konzultace při psaní kódu.

4.1 Fyzický návrh zařízení pro snímání EMG

Nutností pro vytvoření datasetu obdobných signálů, snímaných pomocí Myo Armband, je napodobení i fyzických vlastností, co se týče nejen vzorkovací frekvence a rozlišení, ale také např. fyzického umístění jednotlivých kanálů v rámci předloktí.

Z dostupných zdrojů, např. z práce [66] je patrné rozmístění každého ze svodů. To je navíc vhodně doplněno o tabulku s informací, který sval má který kanál snímat. Z těchto snímků (Obrázek 12) je patrné, že náramek se orientuje podle LED světýlka a loga na kanálu 4.



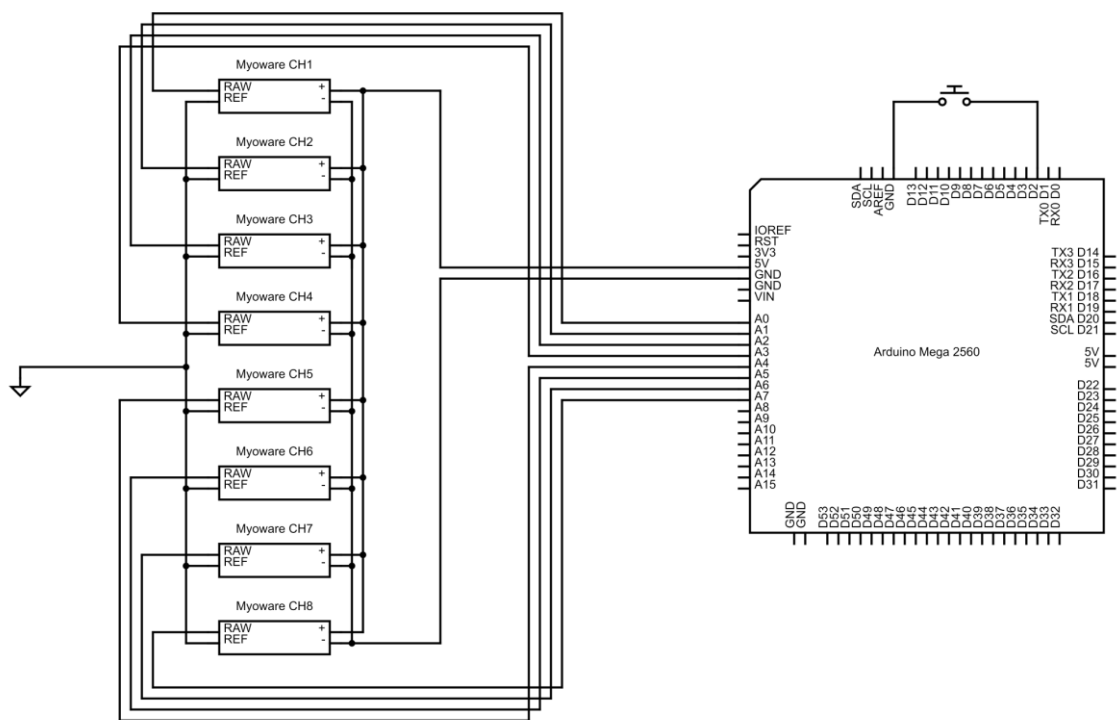
Obrázek 12 Popis kanálů Myo Armband a umístění na ruce. Převzato z [66]

Tabulka 1 Rozmístění elektrod na svalech předloktí, převzato z [66], přeloženo


Myo Armband	Sval
Kanál 1	Extensor Digitorum Cummunis
Kanál 2	Extensor Carpi Radialis
Kanál 3	Brachioradialis
Kanál 4	Pronator Teres
Kanál 5	Flexor Digitorum Sublimas
Kanál 6	Flexor Carpi Ulnaris
Kanál 7	Flexor Digitorum Profundus
Kanál 8	Extensor Carpi Ulnaris

Z těchto dostupných informací je možno vyvodit, že náramek se dá nosit na obou rukách, musí se ale dávat pozor na umístění kanálů – toho jsme využili v návrhu vlastního řešení, kdy bylo snímáno signálů z levého předloktí.

Jako základ celého návrhu jsme zvolili Arduino Mega 2560, které splňovalo naše požadavky v počtu analogových vstupů, dále jsme použili nepájivé pole a sadu spojovacích drátů s DuPont koncovkami pro snadnou organizaci a logiku samotného zapojení (+5 V, GND, společná signálová zem a kabely vedoucí nasnímaný signál), schéma je na Obr. 13. Pro svou cenovou dostupnost byly zvoleny zacvakávací EKG elektrody (vhodně prostorově zmenšené), jelikož na jeden subjekt se jich spotřebuje 17 (2 na kanál, jedna referenční na lokti). Senzory Myoware byly umístěny do vytištěných plastových držáků (obdobu návrhu na Obrázku 14), a pro jednodušší manipulaci umístěny na pásek suchého zipu, který se po přiložení elektrod na kůži zapnul. Výstupy jednotlivých kanálů byly zprostředkovány pomocí delší kabeláže zapletené do sebe (z měření interferencí bylo patrné mírné zašumění z okolí na nezapletených kabelech). Naposled bylo do návrhu přidáno tlačítko (více v kap. 4.2)



Obrázek 13 Schéma zapojení vlastního snímacího zařízení



Obrázek 14 Návrh konzole pro snímače Myoware

Jak již bylo zmíněno výše, měření probíhalo na deseti subjektech (3 ženy, 7 mužů, věk 19–54 let), všem byla snímána aktivita z levého předloktí (paže podepřená oporou, např. o područku židle) dobu 5 s, při pěti předdefinovaných gestech. Poslední záznam byly svalové projevy při relaxované paži. Každý záznam byl proveden pětkrát, tudíž vzniklo dohromady 300 záznamů.

4.2 Program pro sběr dat s Arduinem

Při rešerši ohledně snímání analogového signálu jsme narazili na problém, kdy využití funkce `delay()` zastaví běh jakéhokoliv kódu, a tudíž nedrží konstantní vzorkovací frekvenci. Tento problém bychom mohli řešit pomocí následné interpolace variabilně vzorkovaného signálu. Obecně lepší řešení je využití funkce `milis()` nebo `micros()`, která počítá rozdíly v časech, ale nepozastavuje běh kódu, počítající v řádu milisekund (resp. mikrosekund).

Výchozí požadavky na fyzickou implementaci snímání byly dva následující: vzorkovací frekvence 1000 Hz a zobrazení snímaného signálu v reálném čase pomocí Arduino IDE utility Serial Plotter. Takový návrh s sebou přinesl úskalí ve formě omezení průchodnosti sériové komunikace. V první fázi byly implementovány myšlenky na použití bufferu, který by se 100 ms plnil snímaným osmikanálovým signálem, a následně se jako celek přesunul po USB.

Při další analýze bylo zjištěno, že tento přístup pravděpodobně není dostatečně robustní, resp. kdyby se data během vyhrazeného 100 ms okna neposlala, došlo by k jejich postupnému přepisování, což by značně znehodnotilo snímaný signál. Navrhované řešení bylo využívat dynamicky alokovaný buffer s maximální velikostí

200 vzorků při zachování velikosti časového okna pro přenos. Při testování jsme narazili na občasné problémy s neúplným přenosem. Nejjednodušší řešení tedy bylo zvýšit přenosovou rychlost (baud rate) na 1000000 bps (při frekvenci čipu ATmega2560 16 Mhz [67] se jedná o maximální rychlost, doplněno s tabulkou z [68]). Pro úplnost dodejme, že po každém odeslání bufferu se využitá místa uvolní z paměti, aby bylo rozumněji využíváno dostupných prostředků.

Toto řešení by ale postupem času mohlo narážet na více problémů, včetně fragmentace dat, či implementace algoritmu ukládání přenesených dat. Proto byl po dalším hledání nalezen značně jednodušší způsob, který přenesou většinu výpočetních problémů na kód použitý v Pythonu, a Arduino bude obstarávat jenom samotné časování, vyčítání hodnot a posílání po sběrnici (lze najít v příloze pod názvem „Arduino_sampler_V2.ino“).

Jediné z již zmíněných řešení bylo využito i zde, specificky se jedná o přenosovou rychlost 1000000 bps. Pro zvýšení rychlosti řešení, a vůbec pro umožnění vzorkování osmikanálového signálu při ~ 1000 Hz bylo nutno upustit od ASCII kódování přenosu a přejít na odesílání samotných hodnot bajtů z paměti. Což zapříčinilo zavedení synchronizační sekvence pro ustanovení stability přenosu, kdy před přenosem každé časové známky (označující číslo vzorku – pro možnost zpětné kontroly) je odeslána sekvence '\xFF\xFF\xFF\xFF'. Toto řešení bylo nutné, z důvodu nestabilně dosahovaných požadovaných hodnot čísla vzorků při testování, jelikož docházelo k chybné interpretaci některých bitů v komunikaci, vedoucí k vyčítání nesmyslných hodnot. Dále bylo upuštěno od přenosu osmibitových hodnot a zasílají se přímo 10bitové hodnoty vyčtené na analogovém vstupu (odešle se jako dva bajty, kdy se nejdříve přenesou „low byte“ a následně „high byte“, obě jako unsigned 8bitový integer). Podle Arduino dokumentace [69] trvá vyčtení hodnoty z jednoho analogového vstupu přibližně 100 μ s, tudíž na odeslání těchto 184 b (32 b synchronizační sekvence, 16 b časová známka, 128 b (8x 16 b) vyčtené hodnoty, 8 b stav tlačítka) zbylo okno takřka 200 μ s čili přenosová rychlost musí být skoro 1 Mb/s. Výše popsaný „stav tlačítka“ byl později přidán z důvodu nespolehlivé funkčnosti poskytnutého kódu v rámci práce [52], který měl označit začátek a konec svalové aktivity. Jelikož tento algoritmus, měl v rámci 1000 vzorků dlouhého signálu (5 s, 200 Hz) rozptýlit i 400 vzorků a zanesl by do vyhodnocení značnou chybu. Bylo zvoleno značně jednodušší řešení, kdy uživatel během provádění gesta držel tlačítko (logická 1), při neaktivitě byla vyčítána logická 0.

Na straně odposlechu sériové komunikace pomocí Python kódu jsou data vyčítána pomocí nekonečného cyklu, zároveň je rekonstrukce opatřena podmínkou délky přijaté sekvence na 21 bajtů, jinak je přenesená informace považována za neplatnou. V případě úspěchu se ještě musí rekonstruovat 10bitové hodnoty z analogových vstupů, časová známka a logický stav tlačítka. Nakonec se všechno vytiskne do konzole a uloží do .csv souboru.

Před validací jednotlivých sítí na těchto datech byla provedena filtrace dolní propustí na požadovanou frekvenci 200 Hz, následně také normalizace získaných 10bit hodnot na interval $\langle -1;1 \rangle$, a takový signál byl následně rozdělen do překrývajících se oken.

5. VÝSLEDKY A DISKUSE

Cílem této kapitoly je prezentace a diskuze výsledků získaných učením celkem devíti modelů (1x 1D a 8x 2D) vytvořených za účelem klasifikace gest ruky (5 gest a signál bez gesta) z EMG záznamů. Pro snazší orientaci byl vytvořen mustr pojmenování, kdy předpona „EMG“ značí účel modelu, další pozice jsou dimenzionalita konvoluce modelu, počet vrstev, velikost jádra a jako poslední pozice je dobrovolná poznámka – např. „EMG_2D_5L_5KS_abs“ znamená síť s 2D konvolucí, pěti vrstvami, čtvercovým kernelem velikosti 5, a model pracující s rektifikovaným signálem. Pro úplnost dodejme význam ostatních zkratk – „posneg“ je označení, kdy učení probíhalo na datech originálních, a zároveň na datech s otočenou polaritou (simulující prohození elektrod) a „re“ znova učený model s augmentací gausovským šumem.

K hodnocení výkonnosti byly použity metriky přesnost (accuracy) a F1 skóre, jelikož jsme pracovali s nevyváženými daty. K lepšímu pochopení chyb modelů byly využity i matice záměn, uvedené níže v Příloze A - Naměřené hodnoty.

Podrobné výsledky hodnocení klasifikačních schopností jednotlivých sítí jsou shrnuté v Tab. 2 na třech datasetech získaných z „EMG-EPN-612“ (popsáno podrobněji v kap. 3), a také datech získaných vlastním měřením uvedeným v kap. 4, označená příznakem „vlastní“.

Z nich je patrné, že model „EMG_1D_5L_5KS“ vykazuje stabilní výkonnost na všech třech datasetech, porovnatelnou se sítěmi uvedenými v kap. 2.5 – přesnost se pohybuje kolem 87 % a F1 skóre okolo 0,55 také naznačuje, že návrh má velký prostor pro zlepšení. Nejvyšší úspěšnost v rozlišování pěti gest (a signálu bez gesta) v okně o délce 125 ms měla ve všech ohledech síť „EMG_2D_5L_5KS“ s přesnostmi 92,51 %, 91,49 %, 89,04 % a F1 skóre 0,77, 0,74, 0,65 na trénovacím, testovacím a validačním datasetu, následovanou překvapivě sítí „EMG_2D_3L_5KS“ s přesnostmi 91,67 %, 90,17 %, 88,8 % a F1 skóre 0,74, 0,68, 0,64 při stejném pořadí datasetů.

Nejhůře naopak dopadly sítě „posneg“ simulující záměnu elektrod, kdy třívrstvý „EMG_2D_3L_5KS_posneg“ dosáhl přesnosti okolo 83 % a F1 skóre jen 0,4. Obdobně skončil i pětivrstvý „EMG_2D_5L_5KS_posneg“ s přesnostmi přesahujícími 84 % a stejně nízkým F1 skóre. To také naznačuje největší slabinu tohoto návrhu a ukazuje, že při měření vlastních dat je vždy třeba dávat pozor na umístění elektrod.

Porovnáním 2D a 1D modelů můžeme vidět trend, který jsme naznačili výše v kap. 3.2, kdy 2D model dosahuje mnohem lepších výsledků právě proto, že dokáže zachytit prostorové vztahy mezi kanály.

Matice záměn, dostupné v Příloze A, poskytují mnohem detailnější pohled na klasifikaci a vzájemnou podobnost mezi gesty. Např. pro model „EMG_2D_5L_5KS“ můžeme konstatovat, že každé gesto má zhruba 20-25% chybnou klasifikaci právě záměnou se signálem bez gesta.


Tabulka 2 Hodnotící metriky pro naučené sítě na trénovacích, testovacích, validačních a vlastních naměřených datech

	model	dataset	přesnost [%]	F1 skóre [-]
1D	EMG_1D_5L_5KS	trénovací	87,22	0,56
		testovací	87,17	0,55
		validační	86,96	0,54
		vlastní	73,23	0,16
2D	EMG_2D_3L_5KS	trénovací	91,67	0,74
		testovací	90,17	0,68
		validační	88,80	0,64
		vlastní	29,39	0,14
	EMG_2D_3L_5KS_abs	trénovací	90,94	0,71
		testovací	89,58	0,66
		validační	88,19	0,62
		vlastní	57,52	0,17
	EMG_2D_3L_5KS_posneg	trénovací	83,46	0,41
		testovací	83,41	0,41
		validační	82,91	0,40
		vlastní	40,12	0,15
	EMG_2D_3L_5KS_re	trénovací	87,72	0,59
		testovací	87,63	0,59
		validační	87,20	0,56
		vlastní	66,76	0,15
	EMG_2D_5L_5KS	trénovací	92,51	0,77
		testovací	91,49	0,74
		validační	89,04	0,65
		vlastní	36,45	0,14
	EMG_2D_5L_5KS_abs	trénovací	88,99	0,64
		testovací	88,82	0,63
		validační	88,10	0,60
		vlastní	65,84	0,17
	EMG_2D_5L_5KS_posneg	trénovací	84,45	0,41
		testovací	84,44	0,41
		validační	84,44	0,40
		vlastní	73,69	0,16
EMG_2D_5L_5KS_re	trénovací	89,14	0,65	
	testovací	88,97	0,64	
	validační	88,11	0,61	
	vlastní	69,20	0,17	

Z uvedených výsledků i matic záměn je také zřejmé, že klasifikace na vlastním datasetu přináší velmi špatné výsledky, což může být způsobeno několika faktory.

První možnost je, že došlo k odchylkám v metodice měření, jelikož je metodika snímání původního datasetu fakticky nepopsaná čili je pravděpodobné, že došlo k odchylkám, což mohlo mít za následek drobné odlišnosti signálu. Další je, že se přítomnost gesta vlastních signálů spoléhá na uživatele a jeho schopnost mačkat tlačítko ve stejný čas, co započne svalovou aktivitu. Hlavní domněnkou je, že při snímání docházelo k pohybovým artefaktům ve výsledném signálu, který vedl ke driftu hodnot v jednotlivých svodech, jak lze vidět na Obrázku. 15. Některé signály byly také vyřazeny z hodnocení (a označeny příponou „faulty“), nejčastěji z technických komplikací vzniklých při měření (např. stav tlačítka byl konstantně 0, což neodpovídalo naměřenému signálu).

Lze také vyzorovat, že nevyvážený dataset představoval výzvu pro učení všech modelů, jelikož může preferovat v rozhodování nejčastější třídu („noGesture“ v našem případě) a upozdat ostatní. Krom již zmíněného F1 skóre pro hodnocení, proběhlo i pilotní učení na datasetu vzniklém náhodným výběrem „oken“ a normalizací zastoupení jednotlivých tříd. Výsledkem byl model, který měl přesnost o více než 10 % nižší než na původním datasetu, lze tedy předpokládat, že došlo k nedoučení a tím pádem byl tento přístup dále nerozvíjen.



Obrázek 15 Ukázka driftu hodnot naměřeného signálu, červeně vyznačená oblast je se stlačeným tlačítkem

6. ZÁVĚR

Tato bakalářská práce se zabývá problematikou rozpoznávání gest horní končetiny z EMG záznamu za použití metod strojového učení. Cílem bylo zpracovat rešerši zaměřenou na vývoj v této oblasti a aktuálně používané metody, čímž se zabývají první dvě kapitoly, volba vhodné architektury, nalezení vyhovujících databází s EMG záznamy, na kterých by se tato síť učila. Dalším postupem bylo naměření vlastní sady záznamů, obdobných těm se zvolenou databází, a vyhodnocení výkonnosti modelu na tato data.

V druhé kapitole byl kladen speciální důraz na metody využívající konvoluční neuronové sítě, které byly následně použity pro svou všestrannost a relativně snadnou implementovatelnost. Celkem jich vzniklo devět, přičemž bylo zkoumáno široké spektrum konfigurací a technik s cílem maximalizovat klasifikační schopnost a robustnost, a zároveň zabránit přeučení.

Náš vývoj potvrdil, že 2D konvoluční modely dosahují lepších výsledků, než jejich 1D protějšky, což lze přičítat schopnosti lépe zachytit prostorové vztahy v EMG datech. Z nich nejvíce vyniká pětivrstvý „EMG_2D_5L_5KS“, který na neznámých (testovacích) datech dosahoval přesnosti 91,49% a F1 skóre 0,74, což odpovídá úrovni ostatních výzkumů.

Při hodnocení výkonu klasifikace byly používány metriky přesnost a F1 skóre, které nám umožnilo lepší představu schopností u nevyváženého datasetu. Další zaznamenanou metrikou byly matice záměn, které poskytly hlubší vhled do chyb a záměn mezi jednotlivými gesty s obdobnými vzorci v signálu.

Dalším cílem bylo sestrojít funkční zařízení na snímání záznamů z předloktí. Což bylo úspěšně splněno, proběhlo měření na deseti subjektech, a takto vzniklá osmikanálová data byla následně použita k validaci již naučených modelů. Toto testování přineslo u některých sítí přesnost i přes 70 %, F1 skóre bylo maximálně 0,17.

LITERATURA

- [1] JAMAL, Muhammad Zahak. Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. In: . Rijeka: IntechOpen, 2012, Ch. 18. Dostupné z: <https://doi.org/10.5772/52556>.
- [2] MCMANUS, Lara; DE VITO, Giuseppe a LOWERY, Madeleine M. Analysis and Biophysics of Surface EMG for Physiotherapists and Kinesiologists: Toward a Common Language With Rehabilitation Engineers: Toward a Common Language With Rehabilitation Engineers. *Frontiers in Neurology*. 2020, roč. 11. ISSN 1664-2295. Dostupné také z: <https://www.frontiersin.org/articles/10.3389/fneur.2020.576729>.
- [3] KONRAD, Peter. *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Online. Noraxon U.S.A, 2006. ISBN 0-9771622-1-4. Dostupné z: <https://www.noraxon.com/wp-content/uploads/2014/12/ABC-EMG-ISBN.pdf>.
- [4] AZAB, Ahmed; ONSY, Ahmed a EL-MAHLAWY, Mohamed. *Monitoring of Upper-Limb EMG Signal Activities Using a Low Cost System; Towards a Power-Assist Robotic Arm*. 2015/05/12.
- [5] CALADO, Alexandre. *Comparison between Low-Cost and High-End sEMG Sensors for the Control of a Transradial Myoelectric Prosthesis*. Diplomová práce. Via Cracovia, 50, 00133 Roma RM, Italy: University of Rome Tor Vergata, 2017/11/03. Dostupné z: <https://doi.org/10.13140/RG.2.2.18311.04008>.
- [6] XIONG, Dezhen; ZHANG, Daohui; ZHAO, Xingang a ZHAO, Yiwen. Deep Learning for EMG-based Human-Machine Interaction: A Review. Online. *IEEE/CAA Journal of Automatica Sinica*. 2021, roč. 8, č. 3, s. 512-533. ISSN 2329-9266. Dostupné z: <https://doi.org/10.1109/JAS.2021.1003865>.
- [7] MERLETTI, Roberto a PARKER, Philip J. *Electromyography: physiology, engineering, and non-invasive applications: physiology, engineering, and non-invasive applications*. 11. John Wiley, 2004. ISBN 0471675806.
- [8] PHINYOMARK, Angkoon; PHUKPATTARANONT, Pornchai a LIMSAKUL, Chusak. Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*. 2012, roč. 39, č. 8, s. 7420-7431. ISSN 0957-4174. Dostupné z: <https://doi.org/https://doi.org/10.1016/j.eswa.2012.01.102>.
- [9] BHATTACHARYA, A.; SARKAR, A. a BASAK, P. Time domain multi-

- feature extraction and classification of human hand movements using surface EMG. In: *2017 4th International Conference on Advanced Computing and Communication Systems (ICACCS)*. 2017, s. 1-5. Dostupné z: <https://doi.org/10.1109/ICACCS.2017.8014594>.
- [10] KARTHICK, P.A. a RAMAKRISHNAN, S. Surface electromyography based muscle fatigue progression analysis using modified B distribution time–frequency features. *Biomedical Signal Processing and Control*. 2016, roč. 26, s. 42-51. ISSN 1746-8094. Dostupné z: <https://doi.org/https://doi.org/10.1016/j.bspc.2015.12.007>.
- [11] FELICI, Francesco a DEL VECCHIO, Alessandro. Surface Electromyography: What Limits Its Use in Exercise and Sport Physiology?: What Limits Its Use in Exercise and Sport Physiology? *Frontiers in Neurology*. 2020, roč. 11. ISSN 1664-2295. Dostupné také z: <https://www.frontiersin.org/articles/10.3389/fneur.2020.578504>.
- [12] IVANENKO, Y. P.; POPPELE, R. E. a LACQUANITI, F. Five basic muscle activation patterns account for muscle activity during human locomotion. *The Journal of Physiology*. 2004/04/01, roč. 556, č. 1, s. 267-282. ISSN 0022-3751. Dostupné z: <https://doi.org/https://doi.org/10.1113/jphysiol.2003.057174>.
- [13] ENGLEHART, K. a HUDGINS, B. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*. 2003, roč. 50, č. 7, s. 848-854. ISSN 1558-2531. Dostupné z: <https://doi.org/10.1109/TBME.2003.813539>.
- [14] TKACH, Dennis; HUANG, He a KUIKEN, Todd A. Study of stability of time-domain features for electromyographic pattern recognition. *Journal of NeuroEngineering and Rehabilitation*. 2010, roč. 7, č. 1, s. 21. ISSN 1743-0003. Dostupné z: <https://doi.org/10.1186/1743-0003-7-21>.
- [15] KIM, Jin Su a PAN, Sung Bum. A Study on EMG-based Biometrics. *J. Internet Serv. Inf. Secur.* 2017, roč. 7, č. 2, s. 19-31.
- [16] PHINYOMARK, Angkoon; THONGPANJA, Sirinee; HU, Huosheng; PHUKPATTARANONT, Pornchai a LIMSAKUL, Chusak. The Usefulness of Mean and Median Frequencies in Electromyography Analysis. In: . Rijeka: IntechOpen, 2012, Ch. 8. Dostupné z: <https://doi.org/10.5772/50639>.
- [17] SAPSANIS, C.; GEORGOULAS, G. a TZES, A. EMG based classification of basic hand movements based on time–frequency features. In: *21st Mediterranean Conference on Control and Automation*. 2013, s. 716-722. Dostupné z: <https://doi.org/10.1109/MED.2013.6608802>.

- [18] GOHEL, Vidhi a MEHENDALE, Ninad. Review on electromyography signal acquisition and processing. *Biophysical Reviews*. 2020, roč. 12, č. 6, s. 1361-1367. ISSN 1867-2469. Dostupné z: <https://doi.org/10.1007/s12551-020-00770-w>.
- [19] MERLO, A.; FARINA, D. a MERLETTI, R. A fast and reliable technique for muscle activity detection from surface EMG signals. *IEEE Transactions on Biomedical Engineering*. 2003, roč. 50, č. 3, s. 316-323. ISSN 1558-2531. Dostupné z: <https://doi.org/10.1109/TBME.2003.808829>.
- [20] *Ending Sales of Myo, Preparing for the Future*. Online. 2018. Dostupné z: <https://medium.com/@srlake/ending-sales-of-myo-preparing-for-the-future-281af9bbcac2>. [cit. 2023-12-24].
- [21] BENALCAZAR, Marco E; BARONA, Lorena; VALDIVIESO, Leonardo; AGUAS, Xavier a ZEA, Jonathan. *EMG-EPN-612 Dataset*. Zenodo, 2021. Dostupné z: <https://doi.org/10.5281/zenodo.4421500>.
- [22] KRILOVA, N.; KASTALSKIY, I.; KAZANTSEV, V.; MAKAROV, V.A. a LOBOV, S. *EMG data for gestures*. 2019.
- [23] CÔTÉ ALLARD, Ulysse; GAGNON-TURCOTTE, Gabriel; LAVIOLETTE, Francois a GOSSELIN, Benoit. A Low-Cost, Wireless, 3-D-Printed Custom Armband for sEMG Hand Gesture Recognition. *Sensors*. 2019/06/24, roč. 19, s. 2811. Dostupné z: <https://doi.org/10.3390/s19122811>.
- [24] *This Futuristic Armband Lets You Control Your Computer Like Magic*. Online. EADICICCO, Lisa. Time. 2016. Dostupné z: <https://time.com/4173507/myo-armband-review/>. [cit. 2023-12-24].
- [25] BARBRE, Curtis. *Wearable Neural Interface - CTRL-labs*. Online. 2018. Dostupné z: <https://www.curtisbarbre.com/ctrl-kit>. [cit. 2023-12-24].
- [26] *I tried the wristband that lets you control computers with your brain*. Online. ROBERTSON, Adi. The Verge. 2018. Dostupné z: <https://www.theverge.com/2018/6/6/17433516/ctrl-labs-brain-computer-interface-armband-hands-on-preview>. [cit. 2023-12-24].
- [27] META. *Inside Facebook Reality Labs: Wrist-based interaction for the next computing platform*. Online. META. Tech at Meta. 2021. Dostupné z: <https://tech.facebook.com/reality-labs/2021/3/inside-facebook-reality-labs-wrist-based-interaction-for-the-next-computing-platform/>. [cit. 2023-12-24].
- [28] *BITalino (r)evolution User Manual*. PDF. 2020. Dostupné z: <https://support.pluxbiosignals.com/wp-content/uploads/2021/11/bitalino-revolution-user-manual.pdf>. [cit. 2023-12-25].

- [29] *BITalino Electromyography (EMG) Sensor User Manual*. PDF. 2020. Dostupné z: <https://www.bitalino.com/storage/uploads/media/electromyography-emg-user-manual.pdf>. [cit. 2023-12-25].
- [30] *MYOWARE 2.0 Technical Specifications*. Online. MYOWARE. C2023. Dostupné z: <https://myoware.com/products/technical-specifications/#muscle-sensor>. [cit. 2023-12-27].
- [31] *LINK & ARDUINO SHIELDS*. Online. MYOWARE. C2023. Dostupné z: <https://myoware.com/products/link-and-arduino-shields/>. [cit. 2023-12-27].
- [32] PATLE, A. a CHOUHAN, D. S. SVM kernel functions for classification. In: *2013 International Conference on Advances in Technology and Engineering (ICATE)*. 2013, s. 1-9. Dostupné z: <https://doi.org/10.1109/ICAdTE.2013.6524743>.
- [33] HAN, Henry a JIANG, Xiaoqian. Overcome support vector machine diagnosis overfitting. *Cancer Inform.* 2014, roč. 13, č. Suppl 1, s. 145-158. ISSN 1176-9351. Dostupné z: <https://doi.org/10.4137/CIN.S13875>.
- [34] CERVANTES, Jair; LI, Xiaoou; YU, Wen a LI, Kang. Support vector machine classification for large data sets via minimum enclosing ball clustering. *Neurocomputing*. 2008, roč. 71, č. 4, s. 611-619. ISSN 0925-2312. Dostupné z: <https://doi.org/https://doi.org/10.1016/j.neucom.2007.07.028>.
- [35] BOSER, Bernhard; GUYON, Isabelle a VAPNIK, Vladimir. A Training Algorithm for Optimal Margin Classifier. *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*. 1996/08/09, roč. 5. Dostupné z: <https://doi.org/10.1145/130385.130401>.
- [36] POMBOZA-JUNEZ, G. a TERRIZA, J. H. Hand gesture recognition based on sEMG signals using Support Vector Machines. In: *2016 IEEE 6th International Conference on Consumer Electronics - Berlin (ICCE-Berlin)*. 2016, s. 174-178. Dostupné z: <https://doi.org/10.1109/ICCE-Berlin.2016.7684748>.
- [37] LEE, Kyung H.; MIN, Ji Y. a BYUN, Sangwon. Electromyogram-Based Classification of Hand and Finger Gestures Using Artificial Neural Networks. Online. *Sensors*. 2022, roč. 22, č. 1. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s22010225>.
- [38] AHA, David W.; KIBLER, Dennis a ALBERT, Marc K. Instance-based learning algorithms. *Machine Learning*. 1991, roč. 6, č. 1, s. 37-66. ISSN 1573-0565. Dostupné z: <https://doi.org/10.1007/BF00153759>.
- [39] COVER, T. a HART, P. Nearest neighbor pattern classification. *IEEE*

- Transactions on Information Theory*. 1967, roč. 13, č. 1, s. 21-27. ISSN 1557-9654. Dostupné z: <https://doi.org/10.1109/TIT.1967.1053964>.
- [40] DUDANI, S. A. The Distance-Weighted k-Nearest-Neighbor Rule. *IEEE Transactions on Systems, Man, and Cybernetics*. 1976, roč. SMC-6, č. 4, s. 325-327. ISSN 2168-2909. Dostupné z: <https://doi.org/10.1109/TSMC.1976.5408784>.
- [41] BEYER, Kevin; GOLDSTEIN, Jonathan; RAMAKRISHNAN, Raghu a SHAFT, Uri. When Is “Nearest Neighbor” Meaningful? In: . Berlin, Heidelberg: Springer Berlin Heidelberg, 1999, s. 217-235. ISBN 978-3-540-49257-3.
- [42] PAPANIKOLAOU, M.; EVANGELIDIS, G. a OUGIAROGLOU, S. Dynamic k determination in k-NN classifier: A literature review: A literature review. In: *2021 12th International Conference on Information, Intelligence, Systems & Applications (IISA)*. 2021, s. 1-8. Dostupné z: <https://doi.org/10.1109/IISA52424.2021.9555525>.
- [43] WAN, B.; WU, R.; ZHANG, K. a LIU, L. A new subtle hand gestures recognition algorithm based on EMG and FSR. In: *2017 IEEE 21st International Conference on Computer Supported Cooperative Work in Design (CSCWD)*. 2017, s. 127-132. Dostupné z: <https://doi.org/10.1109/CSCWD.2017.8066682>.
- [44] Z., C. Cedeño; CORDOVA-GARCIA, J.; A., V. Asanza; PONGUILLO, R. a M., L. Muñoz. K-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources. In: *2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*. 2019, s. 812-817. Dostupné z: <https://doi.org/10.1109/SmartWorld-UIC-ATC-SCALCOM-IOP-SCI.2019.00170>.
- [45] KRIZHEVSKY, Alex; SUTSKEVER, Ilya a HINTON, Geoffrey. ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*. 2012/01/01, roč. 25. Dostupné z: <https://doi.org/10.1145/3065386>.
- [46] LECUN, Yann; BENGIO, Y. a HINTON, Geoffrey. Deep Learning. *Nature*. 2015/05/28, roč. 521, s. 436-44. Dostupné z: <https://doi.org/10.1038/nature14539>.
- [47] CHEN, Lin; FU, Jianting; WU, Yuheng; LI, Haochen a ZHENG, Bin. Hand Gesture Recognition Using Compact CNN via Surface Electromyography

- Signals. Online. *Sensors*. 2020, roč. 20, č. 3. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s20030672>.
- [48] ALLARD, U. Côté; NOUGAROU, F.; FALL, C. L.; GIGUÈRE, P.; GOSSELIN, C. et al. A convolutional neural network for robotic arm guidance using sEMG based frequency-features. In: *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2016, s. 2464-2470. ISSN 2153-0866. Dostupné z: <https://doi.org/10.1109/IROS.2016.7759384>.
- [49] GERS, Felix A.; SCHMIDHUBER, Jürgen a CUMMINS, Fred. Learning to Forget: Continual Prediction with LSTM: Continual Prediction with LSTM. *Neural Computation*. 2000, roč. 12, č. 10, s. 2451-2471. ISSN 0899-7667. Dostupné z: <https://doi.org/10.1162/089976600300015015>.
- [50] SIMÃO, Miguel; NETO, Pedro a GIBARU, Olivier. EMG-based online classification of gestures with recurrent neural networks. *Pattern Recognition Letters*. 2019, roč. 128, s. 45-51. ISSN 0167-8655. Dostupné z: <https://doi.org/https://doi.org/10.1016/j.patrec.2019.07.021>.
- [51] TORO-OSSABA, Alejandro; JARAMILLO-TIGREROS, Juan; TEJADA, Juan C.; PEÑA, Alejandro; LÓPEZ-GONZÁLEZ, Alexandro et al. LSTM Recurrent Neural Network for Hand Gesture Recognition Using EMG Signals. Online. *Applied Sciences*. 2022, roč. 12, č. 19. ISSN 2076-3417. Dostupné z: <https://doi.org/10.3390/app12199700>.
- [52] VALDIVIESO CARAGUAY, Ángel Leonardo; VÁSCONEZ, Juan Pablo; BARONA LÓPEZ, Lorena Isabel a BENALCÁZAR, Marco E. Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks. Online. *Sensors*. 2023, roč. 23, č. 8, article 23(8), s. 3905. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s23083905>.
- [53] CRUZ, Patricio J.; VÁSCONEZ, Juan Pablo; ROMERO, Ricardo; CHICO, Alex; BENALCÁZAR, Marco E. et al. A Deep Q-Network based hand gesture recognition system for control of robotic platforms. *Scientific Reports*. 2023, roč. 13, č. 1, s. 7956. ISSN 2045-2322. Dostupné z: <https://doi.org/10.1038/s41598-023-34540-x>.
- [54] WU, Y.; ZHENG, B. a ZHAO, Y. Dynamic Gesture Recognition Based on LSTM-CNN. In: *2018 Chinese Automation Congress (CAC)*. 2018, s. 2446-2450. Dostupné z: <https://doi.org/10.1109/CAC.2018.8623035>.
- [55] YANG, Zhiwen; JIANG, Du; SUN, Ying; TAO, Bo; TONG, Xiliang et al. Dynamic Gesture Recognition Using Surface EMG Signals Based on Multi-Stream Residual Network. *Frontiers in Bioengineering and Biotechnology*.

- 2021, roč. 9. ISSN 2296-4185. Dostupné také z:
<https://www.frontiersin.org/articles/10.3389/fbioe.2021.779353>.
- [56] LI, Q. a LANGARI, R. Myoelectric Human Computer Interaction Using CNN-LSTM Neural Network for Dynamic Hand Gestures Recognition. In: *2021 IEEE International Conference on Big Data (Big Data)*. 2021, s. 5947-5949. Dostupné z:
<https://doi.org/10.1109/BigData52589.2021.9671283>.
- [57] RAHIMIAN, E.; ZABIHI, S.; ASIF, A. a MOHAMMADI, A. Hybrid Deep Neural Networks for Sparse Surface EMG-Based Hand Gesture Recognition. In: *2020 54th Asilomar Conference on Signals, Systems, and Computers*. 2020, s. 371-374. ISSN 2576-2303. Dostupné z:
<https://doi.org/10.1109/IEEECONF51394.2020.9443400>.
- [58] CHEN, H.; TONG, R.; CHEN, M.; FANG, Y. a LIU, H. A Hybrid Cnn-Svm Classifier For Hand Gesture Recognition With Surface Emg Signals. In: *2018 International Conference on Machine Learning and Cybernetics (ICMLC)*. 2018, s. 619-624. ISSN 2160-1348. Dostupné z:
<https://doi.org/10.1109/ICMLC.2018.8526976>.
- [59] WANG, S. a CHEN, B. Split-Stack 2D-CNN for Hand Gestures Recognition Based on Surface EMG Decoding. In: *2020 Chinese Automation Congress (CAC)*. 2020, s. 7084-7088. ISSN 2688-0938. Dostupné z: <https://doi.org/10.1109/CAC51589.2020.9327333>.
- [60] GOHEL, Vidhi a MEHENDALE, Ninad. Review on electromyography signal acquisition and processing. Online. *Biophysical Reviews*. 2020, roč. 12, č. 6, s. 1361-1367. ISSN 1867-2450. Dostupné z:
<https://doi.org/10.1007/s12551-020-00770-w>.
- [61] BARONA LÓPEZ, Lorena Isabel Barona; VALDIVIESO CARAGUAY, Ángel Leonardo Valdivieso; VIMOS, Victor H.; ZEA, Jonathan A.; VÁSCONEZ, Juan P. et al. An Energy-Based Method for Orientation Correction of EMG Bracelet Sensors in Hand Gesture Recognition Systems. Online. *Sensors*. 2020, roč. 20, č. 21, s. 6327. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s20216327>.
- [62] DU, Yu; JIN, Wenguang; WEI, Wentao; HU, Yu a GENG, Weidong. Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation. Online. *Sensors*. 2017, roč. 17, č. 3, s. 458. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s17030458>.
- [63] *Understanding Loss Function in Deep Learning*. Online. Analytics Vidhya. 2023. Dostupné z:
<https://www.analyticsvidhya.com/blog/2022/06/understanding-loss->

- [function-in-deep-learning/](#). [cit. 2024-02-29].
- [64] *A Comprehensive Guide on Optimizers in Deep Learning*. Online. GUPTA, Ayush. Analytics Vidhya. 2024. Dostupné z: <https://www.analyticsvidhya.com/blog/2021/10/a-comprehensive-guide-on-deep-learning-optimizers/>. [cit. 2024-02-29].
- [65] *Everything you need to know about Adam Optimizer*. Online. NIKHIL, Nishant. Medium. 2017. Dostupné z: <https://medium.com/@nishantnikhil/adam-optimizer-notes-ddac4fd7218>. [cit. 2024-02-29].
- [66] MORALES, L. a CEPEDA, J. Feature Extraction from sEMG of Forearm Muscles, Performance Analysis of Neural Networks and Support Vector Machines for Movement Classification. In: *Proceedings of the 14th International Conference on Informatics in Control, Automation and Robotics - Volume 1: ICINCO*. SciTePress, 2017, s. 254-261. ISBN 978-989-758-263-9. Dostupné z: <https://doi.org/10.5220/0006429402540261>.
- [67] *A000067-datasheet*. Online. Arduino docs. [2024], 17/05/2024. Dostupné z: <https://docs.arduino.cc/resources/datasheets/A000067-datasheet.pdf>. [cit. 2024-05-19].
- [68] *WormFood's AVR Baud Rate Calculator*. Online. WormFood's AVR Baud Rate Calculator Ver. 2.1.1. C2005-2022. Dostupné z: <https://wormfood.net/avrbaudcalc.php>. [cit. 2024-05-19].
- [69] *AnalogRead() [Analog I/O]*. Online. Arduino. C2024. Dostupné z: <https://www.arduino.cc/reference/en/language/functions/analog-io/analogread/>. [cit. 2024-04-21].

SEZNAM SYMBOLŮ A ZKRATEK

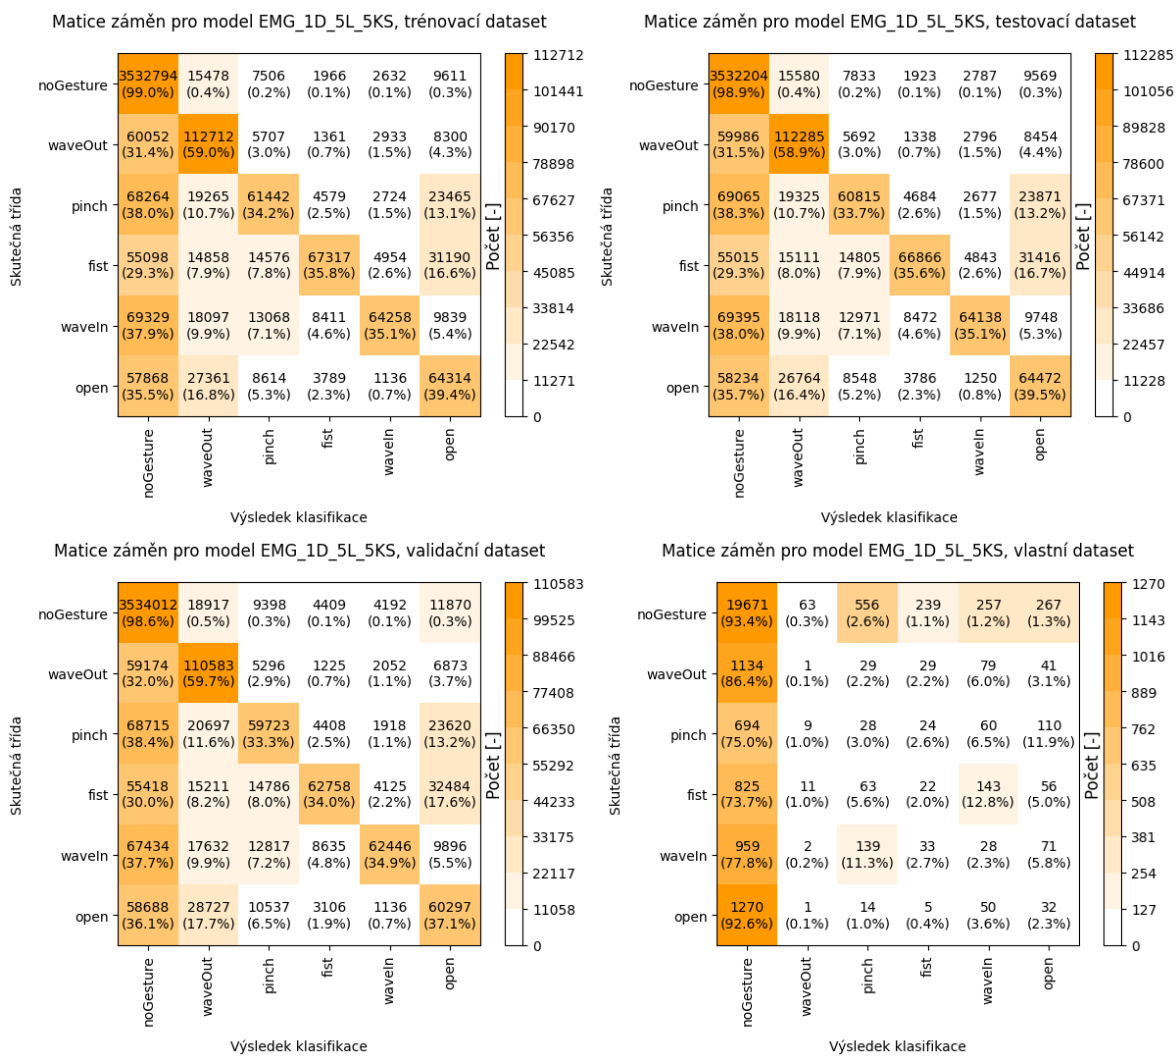
Zkratky:

EMG	elektromyografie
sEMG	povrchová elektromyografie
EKG	elektrokardiografie
BT	Bluetooth
DC	stejnsměrný proud (Direct Current)
SVM	metoda podpůrných vektorů (Support Vector Machine)
kNN	k-nejbližších sousedů (k-Nearest Neighbours)
ANN	umělá neuronová síť (Artificial Neural Network)
CNN	konvoluční neuronová síť (Convolutional Neural Network)
LSTM	síť s dlouhou krátkodobou pamětí (Long Short-term Memory)
RNN	rekurentní neuronová síť (Recurrent Neural Network)
FFNN (FFANN)	dopředná neuronová síť (Feedforward (Artificial) Neural Network)
FWA	přesnost podle okna (Frame-wise Accuracy)
DA	přesnost detekce (Detection Accuracy)
DQN	Deep Q-learning
RMS	střední kvadratický průměr (Root Mean Square)
MSE	střední kvadratická odchylka (Mean Square Error)
FPGA	programovatelné hradlové pole (Field Programmable Gate Array)
ReLU	funkce usměrňovač (Rectified Linear Unit)
JSON	JavaScriptový objektový zápis (JavaScript Object Notation)
CSV	hodnoty oddělené čárkami (Comma Separated Values)
ROC	operační charakteristika přepínače (Receiver Operating Characteristic)
ROC AUC	plocha pod křivkou ROC
CUDA	Compute Unified Device Architecture
cuDNN	Nvidia CUDA Deep Neural Network Library
GPU	grafický procesor (Graphics Processing Unit)
IDE	vývojové prostředí (Integrated Development Environment)
RAM	operační paměť (Random Access Memory)
VRAM	video paměť (Video RAM)

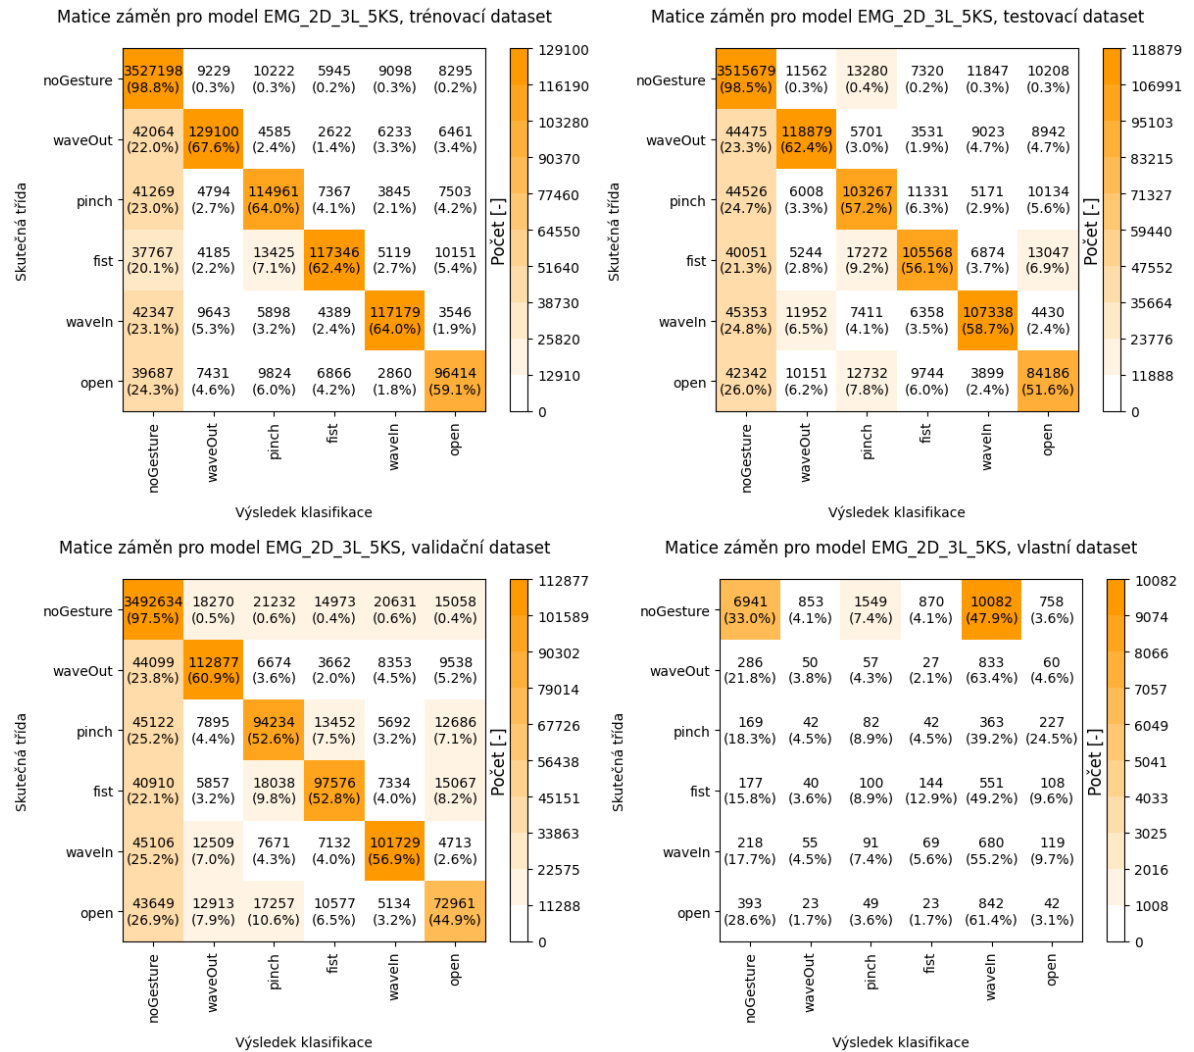
SEZNAM PŘÍLOH

PŘÍLOHA A - NAMĚŘENÉ HODNOTY.....	48
PŘÍLOHA B - OBSAH ELEKTRONICKÉ PŘÍLOHY.....	57

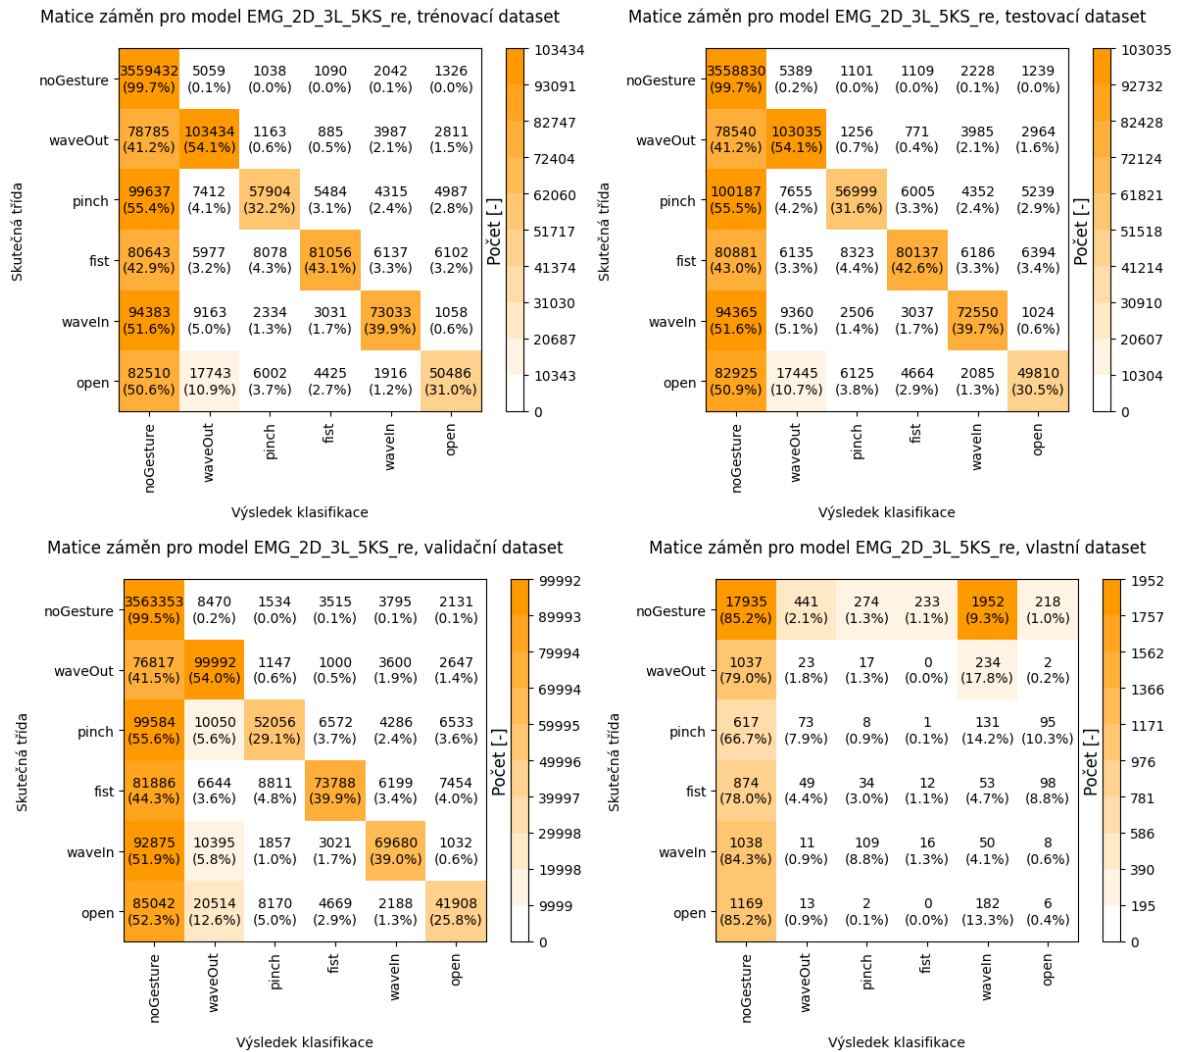
Příloha A - Naměřené hodnoty



Obrázek 16 Matice záměn pro hodnocení datasetů modelem „EMG_1D_5L_5KS“




Obrázek 17 Matrice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS“




Obrázek 18 Matrice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS_re“


Matice záměn pro model EMG_2D_3L_5KS_abs, trénovací dataset




Matice záměn pro model EMG_2D_3L_5KS_abs, testovací dataset



Matice záměn pro model EMG_2D_3L_5KS_abs, validační dataset




Matice záměn pro model EMG_2D_3L_5KS_abs, vlastní dataset




Obrázek 19 Matice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS_abs“


Matice záměn pro model EMG_2D_3L_5KS_posneg, trénovací dataset



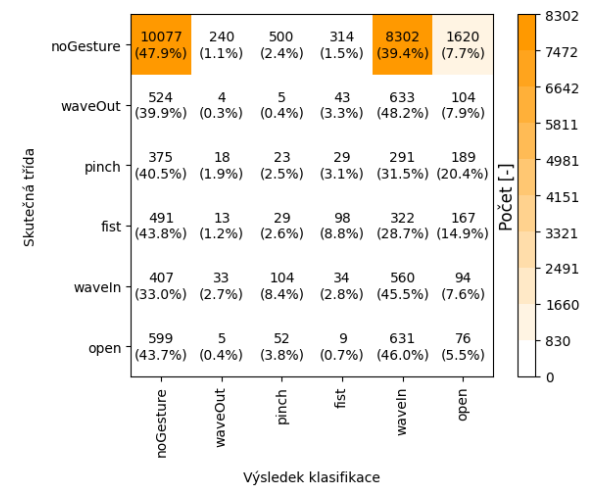
Matice záměn pro model EMG_2D_3L_5KS_posneg, testovací dataset



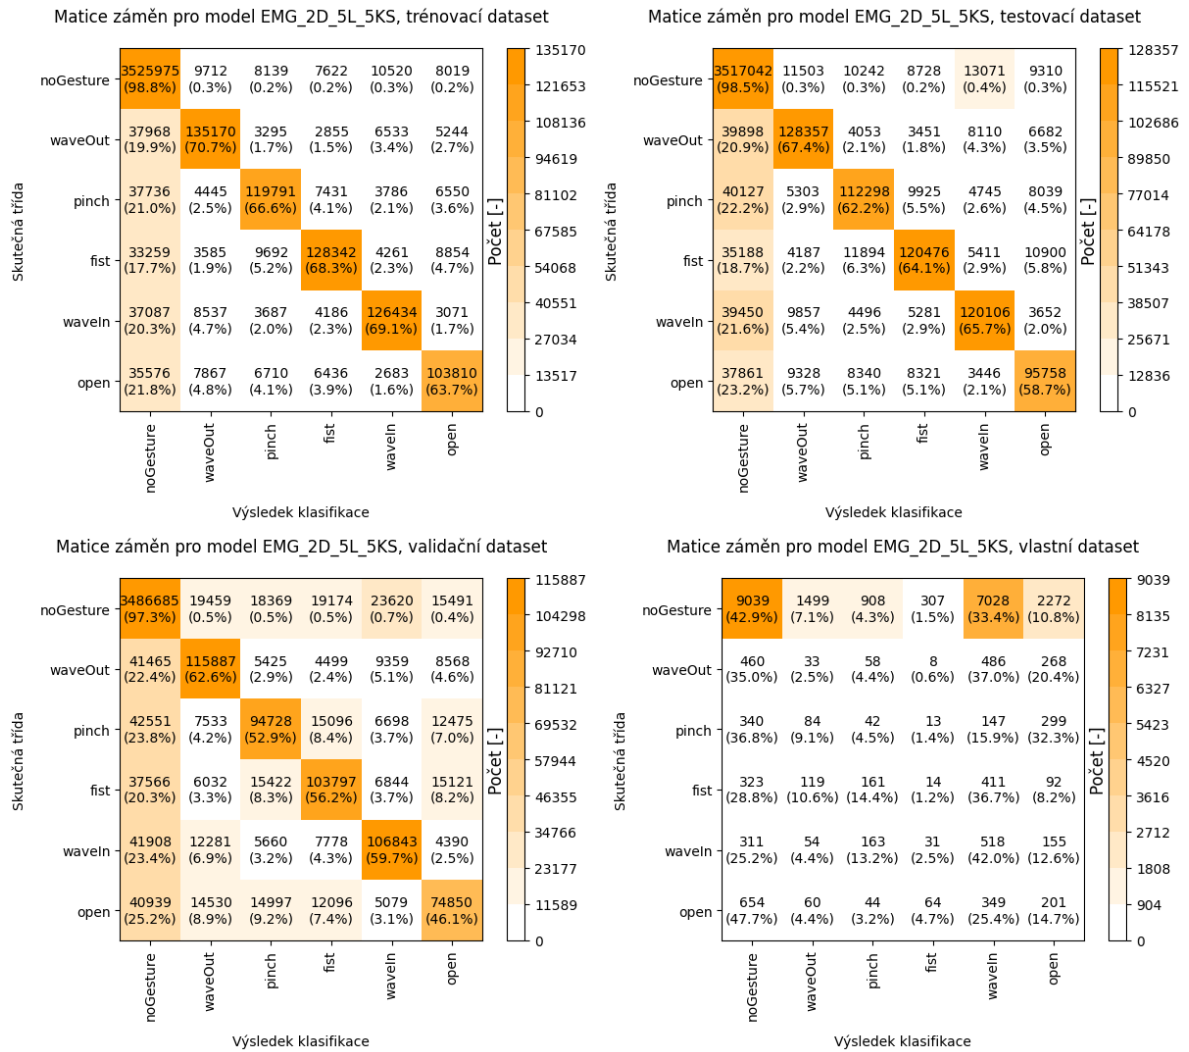
Matice záměn pro model EMG_2D_3L_5KS_posneg, validační dataset



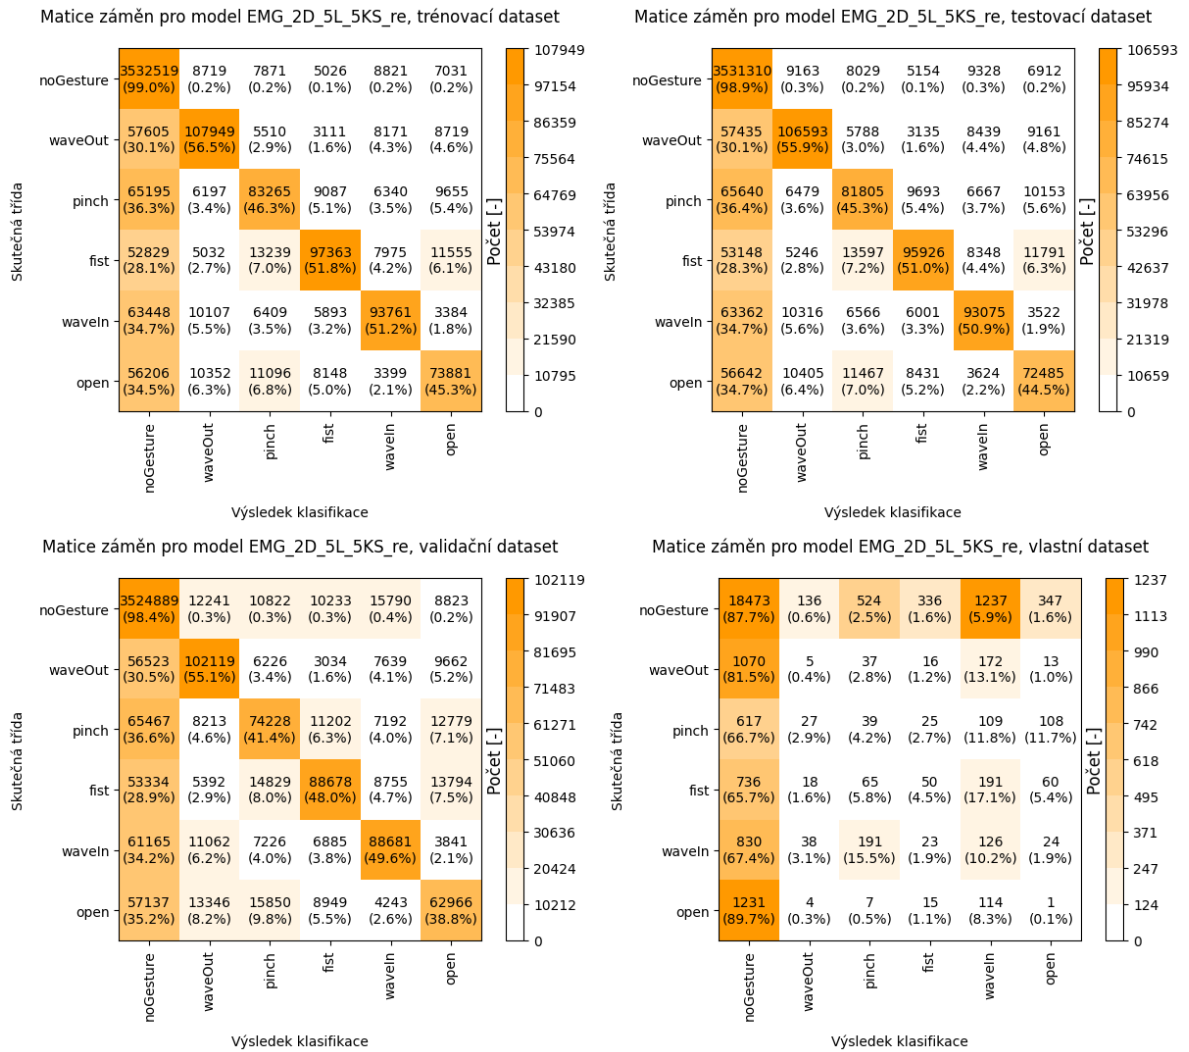
Matice záměn pro model EMG_2D_3L_5KS_posneg, vlastní dataset



Obrázek 20 Matice záměn pro hodnocení datasetů modelem „EMG_2D_3L_5KS_posneg“




Obrázek 21 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS“




Obrázek 22 Matrice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS_re“


Matice záměn pro model EMG_2D_5L_5KS_abs, trénovací dataset




Matice záměn pro model EMG_2D_5L_5KS_abs, testovací dataset



Matice záměn pro model EMG_2D_5L_5KS_abs, validační dataset




Matice záměn pro model EMG_2D_5L_5KS_abs, vlastní dataset




Obrázek 23 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS_abs“


Matice záměn pro model EMG_2D_5L_5KS_posneg, trénovací dataset




Matice záměn pro model EMG_2D_5L_5KS_posneg, testovací dataset



Matice záměn pro model EMG_2D_5L_5KS_posneg, validační dataset



Matice záměn pro model EMG_2D_5L_5KS_posneg, vlastní dataset



Obrázek 24 Matice záměn pro hodnocení datasetů modelem „EMG_2D_5L_5KS_posneg“

Příloha B - Obsah elektronické přílohy

Elektronická příloha této práce obsahuje všech 9 naučených modelů (CNN_models.zip), celou sadu vlastních nasnímaných EMG dat (CUSTOM_DATASET.zip), Arduino zdrojový kód pro snímání EMG (Arduino_sampler_V2.ino), Jupyter notebook s veškerými použitými algoritmy při práci (thesis_code.ipynb) a readme soubor.

V příloze nejsou obsaženy trénovací, testovací a validační datasey, z důvodu své velikosti – s pomocí python kódu v thesis_code.ipynb je lze rekonstruovat, po stažení z: <https://zenodo.org/records/4421500>

Jednotlivé sítě byly učeny za pomoci knihovny Pytorch v2.2.1 postavené na CUDA architektuře verze 12.1v kombinaci s cuDNN v8.9.5.29, běžící v jazyce Python verze 3.11.5. Po hardwarové stránce se jednalo výlučně o notebookovou verzi Nvidia Geforce RTX 4070 (8 GB VRAM, 105 W), Intel Core i7-13700H, 32 GB GDDR5 RAM.

Nakonec je vhodné uvést, že v této práci bylo využíváno nástroje ChatGPT od OpenAI, konkrétně modelů GPT-4 (později GPT-4 Turbo) a GPT-4o, verzí odpovídajícím období mezi říjnem 2023 a květnem 2024.

```
/.....kořenový adresář přiloženého archivu
├── CUSTOM_DATASET.zip.....vlastní naměřená EMG data
│   ├── user10_double_tap_1.csv
│   ├── user10_double_tap_2.csv
│   ├── ...
│   ├── user1_wave_out_4.csv
│   └── user1_wave_out_5.csv
├── CNN_models.zip.....naučené konvoluční sítě
│   ├── EMG_1D_5L_5KS.pth
│   ├── EMG_2D_3L_5KS.pth
│   ├── EMG_2D_3L_5KS_abs.pth
│   ├── EMG_2D_3L_5KS_posneg.pth
│   ├── EMG_2D_3L_5KS_re.pth
│   ├── EMG_2D_5L_5KS.pth
│   ├── EMG_2D_5L_5KS_abs.pth
│   ├── EMG_2D_5L_5KS_posneg.pth
│   └── EMG_2D_5L_5KS_re.pth
├── thesis_code.ipynb.....hlavní soubor s veškerými algoritmy
├── readme.md.....soubor s popisem obsahu adresáře
└── Arduino_sampler_V2.ino.....Arduino zdrojový kód pro vzorkování EMG
```