



Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky

Teze přednášek ke jmenování profesorem

Kyberneticko-informatické systémy
v analýze biomedicínských dat

Cybernetic-Informatic Systems in Biomedical Data
Analysis

Autor: **doc. Ing. Jan Mareš, Ph.D.**
Obor: **Řízení strojů a procesů**

Zlín, prosinec 2023

© Jan Mareš

Vydala **Univerzita Tomáše Bati ve Zlíně** v edici **Qualifying Lectures for Professorship**.

Publikace byla vydána v roce 2023

Klíčová slova: *zpracování signálů a obrazů, hluboké učení, medicínské aplikace*

Key words: *signal and image processing, deep learning, medical applications*

Práce je dostupná v Knihovně UTB ve Zlíně.

ISBN 978-80-7678-212-9

ABSTRAKT

Tato práce se zabývá metodologií zpracování signálů a obrazů a aplikacemi metod pro analýzu vícekanálových signálů získaných v oblasti biomedicíny. Prezentuje autorův nedávný výzkum, který lze rozdělit do dvou částí.

Výzkum věkově závislé změny v parametru barevného šumu v EEG záznamech, kde subjekty byly podrobeny neurologickému a neuropsychologickému vyšetření. Výzkum analyzuje, zda snížení hodnoty parametru λ v souvislosti s mocninným rozložením může být způsoben ztrátou synapsí a sníženou konektivitou neuronové sítě mozku u starších jedinců.

Druhá část výzkumu se zaměřuje na detekci pohybujících se objektů (mimiky a chůze) pomocí videokamery nebo systému KINECT. Byly použity matematické metody k lokalizaci složek obrazu pro zpracování každého pozorovaného obrázku. Výsledkem je hardwarová robotická platforma, která provádí autonomní měření chůze a mění své chování v různých scénářích. Tyto data se dále analyzují a slouží k diagnostice stavu pacienta pomocí klasických statistických algoritmů a metod umělé inteligence.

ABSTRACT

This work focuses on the methodology of signal and image processing and the applications of methods for the analysis of multi-channel signals obtained in the field of biomedicine. It presents the author's recent research, which can be divided into the following parts:

Research on age-related changes in the parameter of color noise in EEG recordings, where subjects underwent neurological and neuropsychological examinations. The research investigates whether the reduction in the parameter λ in connection with the power-law distribution may be caused by the loss of synapses and decreased connectivity of the brain's neural network in older individuals.

The second part of the research is centered on the detection of moving objects (facial expressions and walking) using a video camera or the KINECT system. Mathematical methods were employed to localize components of the image for the processing of each observed image. The result is a hardware robotic platform that autonomously measures walking and adjusts its behavior in different scenarios. These data are further analyzed and used for diagnosing the patient's condition through traditional statistical algorithms and artificial intelligence methods.

OBSAH

1.	ÚVOD.....	7
1.1	CÍLE VÝZKUMU	8
2.	ANALÝZA BIOSIGNÁLŮ	9
2.1	BIOSIGNÁLY	9
3.	ANALÝZA EEG SIGNÁLŮ	11
3.1	VÝSLEDKY VÝZKUMU V ANALÝZE EEG DAT	12
4.	SLEDOVÁNÍ MIMIKY A CHŮZE	14
4.1	BIOMEDICÍNSKÉ POZADÍ.....	15
4.1.1	<i>Poruchy lícního nervu.....</i>	<i>15</i>
4.1.2	<i>Poruchy rovnováhy.....</i>	<i>16</i>
4.2	SLEDOVÁNÍ MIMIKY PACIENTA.....	18
4.3	SLEDOVÁNÍ CHŮZE PACIENTA	18
4.3.1	<i>Autonomní robot pro sběr dat.....</i>	<i>19</i>
5.	ANALÝZA MIMIKY	24
5.1	DATOVÝ SOUBOR	24
5.2	METODIKA	24
5.2.1	<i>Předzpracování dat.....</i>	<i>25</i>
5.2.2	<i>Výpočet skóre zdraví.....</i>	<i>26</i>
5.2.3	<i>Klasifikace dat</i>	<i>28</i>
5.2.4	<i>Trojcestná neuronová síť.....</i>	<i>31</i>
6.	ANALÝZA CHŮZE	34
6.1	DATOVÝ SOUBOR	34
6.2	PŘEDZPRACOVÁNÍ DAT.....	34
6.3	KLASIFIKACE DAT	35
7.	VÝSLEDKY A BUDOUCÍ PRÁCE	37
8.	ZÁVĚR	39
9.	LITERATURA.....	40
10.	PROFESNÍ ŽIVOTOPIS AUTORA.....	45

1. ÚVOD

Práce se zabývá tématem zpracování signálů a obrazů v oblasti inženýrství a biomedicíny. Tyto metody a algoritmy tvoří základ pro všechna témata spojená s měřením, řízením, modelováním, ale i informatikou v biomedicině. Cílem práce je proto ukázat využití zpracování signálů ve všech zmíněných oblastech, a to od sběru dat, přes jejich zpracování až po výslednou evaluaci daného (medicínského) problému.

Přednáška popisuje pokroky v oblasti vlastního výzkumu autora v průběhu posledních deseti let. Zabývá se zpracováním signálů (obraz lze považovat za multidimenzionální signál) v biomedicině, což je moderní oblast s mnoha možnostmi a příležitostmi pro výzkum. Signál EEG je základem pro neurology, signál EKG pro kardiology, CT a NMR jsou základem pro radiology. Bohužel se signály a obrazy často zpracovávají pouze vizuálně odborníkem a téměř neexistují žádná objektivní kritéria. Proto existuje šance zlepšit standardy pomocí poloautomatických nebo plně automatických nástrojů pro zpracování takových signálů a obrazů. Výzkum se proto opírá o spolupráce s předními českými medicínskými pracovišti, Fakultní nemocnicí v Hradci Králové, Klinikou neurologie a Fakultní nemocnicí Královské Vinohrady v Praze, Klinikou ORL

V následujících kapitolách jsou představeny různé výzkumné projekty, na kterých se autor podílel a které ukazují, že zpracování signálů je nezbytným a užitečným nástrojem v mnoha odvětvích biomedicíny. Každý z těchto projektů představuje samostatné výzkumné téma, ve kterém lze nalézt zásadní pokrok nebo novinky. Nejdůležitějšími z nich jsou: (i) potvrzení hypotézy, že počet receptorů a tím i počet spojení mezi neurony v mozku klesá s věkem (tato analýza byla první, která byla aplikována na signál EEG), (ii) vývoj systému pro sledování chůze a analýzu poruch chůze a (iii) vývoj systému pro sledování a analýzu mimiky a jejích poruch.

1.1 Cíle výzkumu

Matematické metody pro analýzu signálů a obrazů hrají klíčovou roli ve všech těchto oblastech. Spektrální analýza a transformace, jako například Fourierova nebo Wavelet transformace, jsou základními nástroji pro filtrování, analýzu a diagnostiku signálů či pro potlačení nežádoucího šumu. Detekce hran a zpracování obrazu jsou nezbytné pro analýzu videa a zpracování CT snímků. Kromě toho jsou matematické metody optimalizace a statistické analýzy zahrnuty do všech těchto témat.

První část práce se zaměřuje na analýzu věkově závislých změn v parametru barevného šumu v EEG záznamech, které byly získány od největšího zaznamenaného počtu zdravých jedinců. Všichni účastníci absolvovali důkladné neurologické a neuropsychologické vyšetření, které bylo provedeno s cílem minimalizovat vliv možného neurologického onemocnění na výsledky analýzy. Na základě předešlého výzkumu, který naznačuje, že počet neuronů se s věkem významně nesníží, se zdá být nejpravděpodobnější příčinou poklesu hodnoty parametru α vztahujícího se k mocninovému rozdělení $1/f^\alpha$ ztráta synapsí a tím i snížení konektivity neuronové sítě v mozku.

Druhou částí práce je identifikace obličeje a mimiky pomocí stereovizní kamery. Následně použité matematické postupy identifikují konkrétní pohybová data, ze kterých lze identifikovat poruchy hybnosti mimiky daného subjektu.

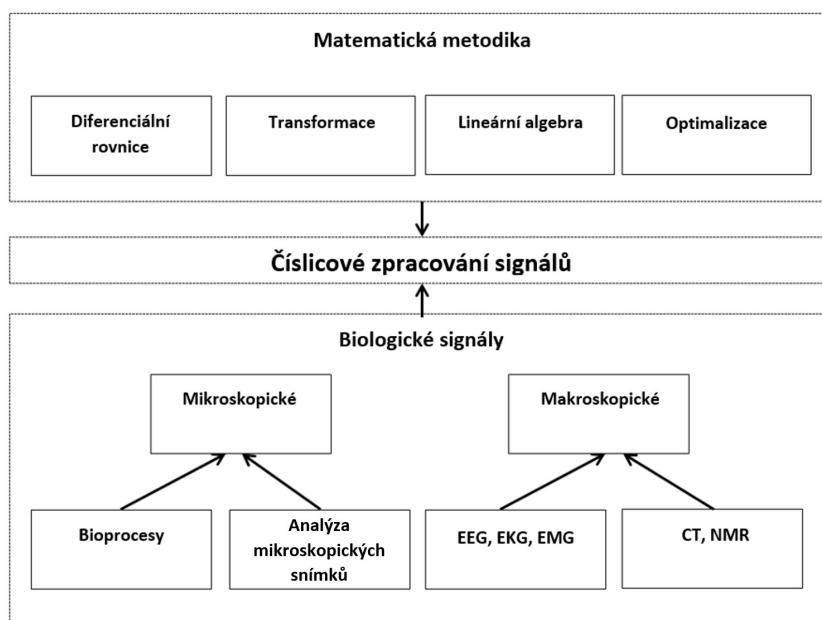
Třetí část práce se poté zaměřuje na principy spojené s identifikací pohybů prostřednictvím videokamerového systému. Následně jsou použity specifické matematické postupy pro lokalizaci obrazových prvků při analýze každého pozorovaného obrazu. Hlavním cílem je zkoumání využití systému MS Kinect a dalších stereovizních kamer k získávání pohybových dat, identifikaci charakteristických znaků chůze a analýze odchylek v chůzi s použitím vybraných metod digitálního zpracování signálů a obrazů.

2. ANALÝZA BIOSIGNÁLŮ

2.1 Biosignály

Biologické signály, známé také jako biosignály, jsou elektrické nebo magnetické signály, které vznikají v důsledku různých biologických aktivit. Tyto biosignály mají různorodý původ, například elektrokardiogram (EKG) je generován srdcem a elektroencefalogram (EEG) je produktem mozkové činnosti. Avšak lze se také zaměřit na mikroskopické biologické signály, které souvisejí s aktivitou mikroorganismů, buněk, nebo bakterií atd. Proto můžeme biologické procesy rozdělit do dvou hlavních kategorií: (i) makroskopické biosignály, jako jsou EKG a EEG, a (ii) mikroskopické biosignály, například respirační kvocient (svalových) buněk.

Analyzování biosignálů hraje klíčovou roli při snaze pochopit libovolné biologické procesy. Z makroskopického hlediska to zahrnuje analýzu srdeční nebo mozkové aktivity jedince specialistou, který je schopen posoudit zdravotní stav daného orgánu či jedince. Z mikroskopického hlediska zpracování biologických signálů zahrnuje analýzu souboru proměnných, které poskytují informace o podmínkách, výživě, dýchání a produkci hmoty. Tímto způsobem může specialisté určit zdravotní stav buněčných souborů.



Obrázek 1. Schéma analýzy biologických signálů

Dalším potenciálním tématem může být analýza biologických obrazů. Obraz, jak jsme již dříve objasnili, můžeme chápat jako multidimenzionální signál a obvykle slouží k posouzení aktuálního stavu zkoumaného subjektu. V makroskopickém světě může biologický obraz být získán pomocí výpočetní tomografie nebo magnetické rezonance, což umožňuje vizualizaci určitých patologických nálezů. Naopak v mikroskopickém měřítku můžeme biologický obraz získat z mikroskopického záznamu, což umožňuje zkoumat velikost buněk nebo tloušťku buněčných stěn.

Zvláštní a relativně novou oblastí v kapitole biologických obrazů v makroskopickém měřítku jsou signály pocházející z biosenzorů. Biosenzory obvykle umožňují neinvazivní monitorování biologické aktivity subjektu, jako jsou například pohyby či poruchy chůze. Signály z těchto senzorů poskytují nové informace o zdravotním stavu zkoumaného subjektu a mohou být cennými nástroji pro diagnostiku.

V následujících kapitolách budou popsány některé z výzkumných projektů, na kterých se autor podílel, a v nichž tyto myšlenky budou dále rozvedeny.

3. ANALÝZA EEG SIGNÁLŮ

Tato kapitola popisuje analýzu jednoho druhu makroskopických biologických signálů, elektroencefalogramu (EEG), který je generován mozkiem a hraje zásadní roli při diagnóze neurologických poruch. Výzkum analýzy signálů EEG pochází ze spolupráce autora s Klinikou neurologie Fakultní nemocnice v Hradci Králové.

Cílem práce je získat důležité informace týkající se samoorganizace elektrické aktivity mozku. V této souvislosti se ukazuje, že mnoho složitých biologických sítí vykazuje tzv. "topologii bez škály"[1-3]. Prvním teoretickým modelem, který se pokouší vysvětlit vznik této topologie, je Simonův model založený na procesu "bohatí bohatnou". Druhý přístup, prezentovaný Perem Bakem a jeho spolupracovníky, se nazývá model samoorganizované kritičnosti [4,5]. Tyto modely popisují, že rozsáhlé struktury v biologických systémech jsou vytvářeny prostřednictvím periodické aktivity, která vychází z malého vnějšího podněcování v systémech s vnitřní pamětí. Třetím modelem, známým jako "sloučení a vytvoření", využívá konceptu bezškálových sítí, které se vyvíjejí prostřednictvím procesů sjednocování.

Výzkum se soustředí na vztah mezi aktivitou EEG a organizační strukturou mozku. Nové poznatky naznačují, že biologické neuronové sítě mohou operovat v blízkosti tzv. kritického bodu, což zahrnuje fluktuaci mezi fázemi rychlého ukončení aktivity a fázemi nárůstu aktivity v čase.

Tento vývoj má značný význam, protože mnohé simulace ukazují, že zpracování informací je nejefektivnější v kritickém bodě. Koncept samoorganizované kritičnosti popisuje vznik kritické dynamiky v komplexních systémech, které vznikají z vnitřních interakcí mezi složkami systému.

Výkonové spektrum EEG je obvykle charakterizováno funkcí $1/f^\lambda$. Kritická dynamika umožňuje rychlou reorganizaci neuronových sítí v mozku. Toto ale také umožňuje zkoumat vztah mezi hodnotou koeficientu λ a věkem pacienta, což může být spojeno s proměnami v samoorganizaci mozkové aktivity.

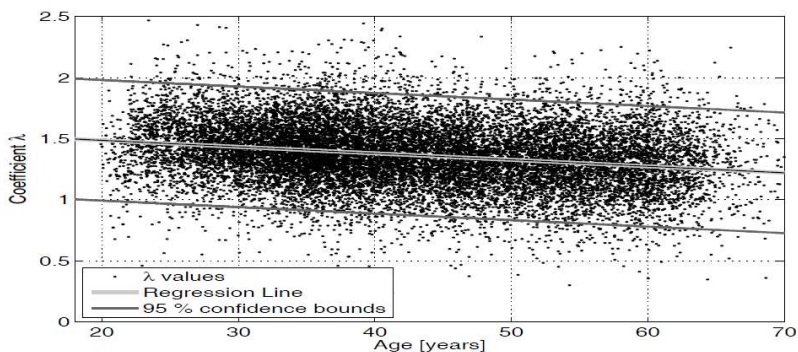
Pro určení koeficientu λ se využívá výkonová spektrální hustota (PSD) signálu, která popisuje výkon signálu v závislosti na relevantní frekvenci, což

umožňuje určit hodnotu λ . Pokud nejsou identifikovány žádné závislosti, bude λ konstantní v celém frekvenčním rozsahu, což se označuje jako "bílý šum". Naopak, pokud λ nabývá hodnoty dvě, hovoříme o "hnědém šumu". Mezi těmito dvěma krajními situacemi má λ hodnotu jedna a popisuje se jako "fialový šum".

Celý nový algoritmus pro výpočet koeficientu λ lze stručně popsat následovně:

1. Výpočet výkonové spektrální hustoty signálu.
2. Logaritmus výkonu versus logaritmus frekvence.
3. Aproximace výsledků přímkou v konkrétních frekvenčních pásmech.


Hodnoty koeficientu λ spojené s definovanou elektrodou pro všechny jedince jsou prezentovány na Obr. 2 spolu s příslušnou regresní přímkou a intervaly spolehlivosti. Celá teorie, nový algoritmus pro analýzu a všechny výsledky, které potvrzují hypotézu, jsou popsány v [6].



Obrázek 2 - Vývoj hodnoty koeficientu λ pro všechny kanály v závislosti na věku.

3.1 Výsledky výzkumu v analýze EEG dat

Na základě provedené analýzy lze potvrdit, že změnu koeficientu λ s věkem lze nalézt u 89,5 % všech frekvenčních kanálů. Pro pásma BETA a DELTA je výsledek potvrzen ve 100 % kanálů a opačně, pro 11 z 19 elektrod je výsledek potvrzen na 100 %.



Obrázek 3 - Vývoj hodnoty koeficientu λ pro všechny kanály v závislosti na věku.

Tato výzkumná práce byla realizována v úzké spolupráci s Klinikou neurologie Fakultní nemocnice v Hradci Králové. Klíčovou inovací v rámci výzkumu bylo formulování a následné potvrzení hypotézy, která se týká poklesu počtu receptorů a tím i počtu synaptických spojení mezi neurony v průběhu stárnutí. Tato analýza měla zvláštní význam, neboť šlo o první aplikaci tohoto přístupu na EEG signály. Práce pokračovala v ověřování různých hypotéz o počtu receptorů a synaptických spojení mezi neurony u pacientů postižených různými neurodegenerativními onemocněními, jako jsou Alzheimerova choroba nebo demence.

Výsledky výzkumu byly zveřejněny v několika odborných publikacích, konkrétně v pracích [6], [7], [8] a [9]. Tyto publikace představují důležitý příspěvek k pochopení dynamiky neuronových spojení a jejich vztahu k stárnutí a neurodegenerativním onemocněním.

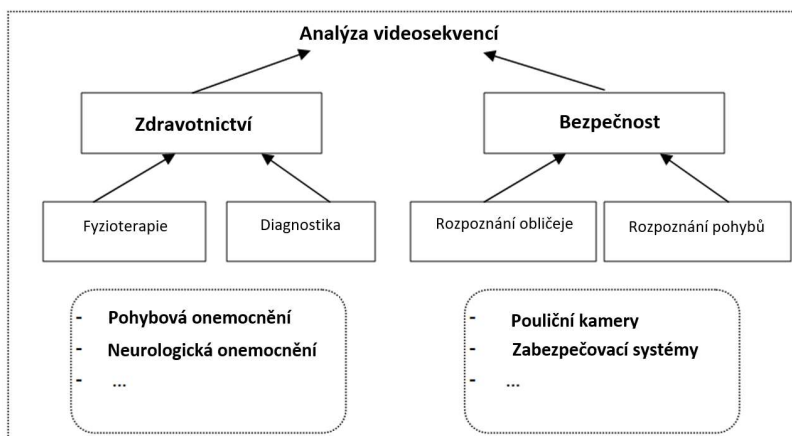
4. SLEDOVÁNÍ MIMIKY A CHŮZE

Tato kapitola se zaměřuje na odlišné možnosti využití digitálního zpracování signálů, konkrétně na využití digitálních kamer jako senzorů, což představuje velmi atraktivní výzkumné téma, na němž autor aktivně spolupracoval se svými doktorandy a diplomanty.

Analýza videosekvencí, počítačové vidění a modelování pohybu jsou klíčovými aspekty interdisciplinárního směru digitálního zpracování signálů a obrazů. Tyto techniky umožňují detekci, lokalizaci, identifikaci, a dokonce predikci pohybujících se objektů. Aplikace těchto metod lze nalézt v různých oblastech, včetně inženýrství, biomedicíny či bezpečnosti.

Hlavní vědní obory v oblasti počítačového vidění se soustřeďují na analýzu bezpečnostních videí a aplikace analýzy videa ve zdravotnictví. Zvláštní pozornost je věnována pokrokům v oblasti fyzioterapie, kde počítačový systém může posoudit, zda pacient správně provádí fyzioterapeutická cvičení, a také v oblasti diagnostiky, jak ukazuje Obrázek 4. Využití počítačového vidění v diagnostice představuje zcela nový a interdisciplinární obor, který spojuje zpracování signálů, robotiku a řízení procesů.

Tato kapitola reflektuje rozsáhlý výzkum v těchto oblastech, zahrnující analýzu vzájemného vztahu mezi více ukazateli [10], využití geometrické algebry [11], specifické metody pro extrakci obrazových prvků [12] a určování polohy [13].



Obrázek 4 – Oblasti využití počítačového vidění.

4.1 Biomedicínské pozadí

Výzkum se zaměřuje na velmi specifické onemocnění: nádor vnitřního ucha, tzv. vestibulární schwannom, a na rekonstrukci a analýzu rehabilitace svalů a nervů po chirurgickém zákroku. Pacienti po chirurgickém zákroku téměř vždy trpí (i) poruchou mimiky, způsobenou přerušáním tzv. lícního nervu, a (ii) poruchou rovnováhy, způsobenou náhlou změnou ve vnitřním uchu. Výzkum se zaměřuje jak na získávání dat v klinickém prostředí, tak na pokročilou analýzu těchto dat.

4.1.1 Poruchy lícního nervu

Navzdory pokrokům v lékařství, chirurgii a fyzioterapii zůstává postižení lícního nervu devastujícím klinickým stavem s výrazným psychosociálním a funkčním vlivem na pacienty. Pacienti často trpí asymetrickou polohou obočí a poruchami pohybu, dysfunkcí uzávěru očí, poruchami pohybu úst, což vede k potížím s artikulací, neschopností usmívat se a asymetrií obličeje. Ztráta tonu mimických svalů způsobuje viditelnou asymetrii obličeje, což také komplikuje neverbální komunikaci. Pacienti s dysfunkcí lícního nervu nejsou schopni vyjádřit své emoce prostřednictvím mimických výrazů a jejich emoční stav je často nesprávně interpretován.

Incidenci periferní paralýzy obličejového nervu lze nalézt v intervalu od 20–30 případů na 100 000 lidí za rok. Jedná se o jedno z nejběžnějších onemocnění postihujících lidské lební nervy. Místo zranění může být v lebce, v uchu nebo mimo lebku. Na základě etiologie lze rozlišit traumatickou, zánětlivou, metabolickou, toxickou, iatrogenní, vrozenou a idiopatickou paralýzu obličejového nervu.

Paréza obličejového nervu je dále obecně jednou z nejběžnějších potíží většiny chirurgických zákroků v chirurgii hlavy a krku (chirurgie slinné žlázy a podčelistní žlázy, vyjmutí lymfatických uzlin v krku, chirurgie středního ucha a časové kosti, chirurgie posterolaterální lební báze). U pacientů podstupujících chirurgické zákroky s konkrétním rizikem poškození obličejového nervu se poškození projevuje především narušením funkce mimických svalů. To vede buď k úplné paralýze, nebo v nejlepším případě k

zvýšené únavě obličejových svalů, což má silný vliv na každodenní život pacienta. Změněný pohyb úst způsobuje problémy s artikulací a asymetrie obličeje vede k problémům v neverbální komunikaci.

K obnovení funkce mimických svalů je třeba několik měsíců rehabilitace. Hlavním problémem je, jak nastavit rehabilitaci, tak, aby se daly minimalizovat nežádoucí vedlejší účinky, např. synkineze (představuje nechtěné stahy svalů obličeje během pokusu o pohyb, způsobené chybnou znovuinnervací).

V klinické praxi existuje více přístupů, jak kvantifikovat míru hybnosti mimických svalů. K hodnocení funkce lícního nervu i elektrofyziologických metod se používají klinické testy a klasifikace. Nejběžnějším nástrojem pro hodnocení funkce lícního nervu jsou klinické škály založené na subjektivně-klinickém hodnocení vzhledu obličeje a volní mimické svalové aktivitě. V současné době existuje na dvě desítky různých stupnic pro toto klinické hodnocení. Nejběžněji používanou je šestibodová škála House-Brackmanna (HB). Dr. John W. House a Dr. Derald E. Brackmann, američtí otolaryngologové, HB škálu popsali v roce 1985. HB vykazuje srovnatelné výsledky mezi různými pozorovateli (lékaři) u pacientů s normální nebo jen mírně narušenou funkcí lícního nervu. Ukázalo se však, že variabilita mezi pozorovateli se zvyšuje v závislosti na závažnosti parézy lícního nervu.

HB je přesto pravděpodobně nejrozšířenější a nejpoužívanější škálou pro hodnocení dysfunkce lícního nervu, která se používá ve všech oblastech klinické medicíny. Přes všechny uvedené nedostatky je proto v této práci brána jako referenční.

4.1.2 Poruchy rovnováhy

Lidský systém rovnováhy je multisenzorický a skládá se z komplexní vzájemné koordinace a komunikace několika orgánových systémů, jako je mozek, vestibulární aparát vnitřního ucha, vizuální systém a propiocepce. Poruchy rovnováhy nejen zvyšují riziko pádů s následnými zlomeninami a jinými typy zranění, ale také významně narušují kvalitu života pacienta, který (v závislosti na závažnosti poruchy a jejím vývoji) nemusí být schopen pracovat, sportovat a plnit běžné fyzické úkoly, jako jsou domácí práce nebo

hygienické návyky. Diagnózy narušující stabilitu pacienta zahrnují více oborů (např. otorhinolaryngologii, neurologii, ortopedii a fyzioterapii) a vyžadují úzkou spolupráci těchto oborů.

S moderními diagnostickými metodami jsou specialisté z různých oborů schopni charakterizovat typ patologie zodpovědné za poruchu rovnováhy (např. nekompenzovanou vestibulární lézi) a kvantifikovat závažnost konkrétního postižení orgánu. Tyto metody jsou schopny objektivně hodnotit pouze statickou část rovnováhy (stabilometrie, posturografie). Dotazníky nebo klinické testy (např. test Timed Up and Go nebo Šestimínutový test chůze) jsou v současnosti používány k hodnocení dynamické stability. Nicméně mají omezenou užitečnost při kvantifikaci chůze a pohybové stability v normálním životě pacienta. Navíc tyto metody nelze zpracovávat kvantitativně a jsou omezeny určitou mírou subjektivity vyšetřovatele. V klinické praxi zatím neexistuje zkouška, která by objektivně hodnotila dynamickou složku stability jako celek.

Během kompenzace poruchy rovnováhy je zpočátku důležitá farmakologická léčba, ale po jejím relativně krátkém období aplikace je nejdůležitější cílená rehabilitace rovnováhy. V případě nerovnováhy spojené s periferními vestibulárními poruchami jde o trénink pomalých a později také rychlých pohybů hlavy a stabilizaci obrazu. Tyto jednotlivé fáze probíhají u každého pacienta různou rychlostí, proto pacient s novou lézí vestibulárního systému zpočátku nezvládne všechny části rehabilitace.

Je proto nezbytný vývoj objektivního testu pro kvantifikaci rovnováhy při chůzi, stanovení vhodné rehabilitační procedury a standardizaci doporučených cviků s cílem individualizovat péči o každého pacienta. Navíc hodnocení pomocí dosavadních klinických testů závisí na pozorovateli a nedovoluje sledovat vývoj v průběhu času. Z těchto důvodů byla do klinické praxe zavedena dynamická počítačová posturografie, k umožnění objektivního hodnocení posturální stability ve stoje. Proto je v klinické praxi vynakládáno značné úsilí na vývoj systémů, které by umožnily hodnocení stability při pohybu, zejména při chůzi, což je jedním z nejcharakterističtějších lidských pohybů.

4.2 Sledování mimiky pacienta

Jako nástroj pro sběr mimických dat lze použít jakoukoliv stereovizní kameru, v našem případě byl vybrán senzor Kinect for Windows v2 z několika důvodů: detekuje body obličeje pomocí softwaru (není potřeba žádných fyzických značek), výrobcem je poskytováno API (rozhraní pro programování aplikací), které umožňuje jednoduchý přístup k datům, navíc je to efektivní řešení.

Senzor Kinect v2 obsahuje RGB kameru, infračervený senzor a směrový mikrofon. Hloubková data jsou získávána z infračerveného senzoru. Výhodou tohoto přístupu je, že výsledný obraz je nezávislý na osvětlení místnosti. Na druhou stranu během měření nesmí být přítomny žádné jiné zdroje infračerveného záření kvůli silnému rušení. Obličejové rysy jsou pak extrahovány algoritmem Microsoft Kinect Face, který je založen na modelu aktivního vzhledu (Active Appearance Model).

4.3 Sledování chůze pacienta

Existuje několik způsobů, jak monitorovat pohyby a chůzi pacientů, které jsou detailně popsány v literatuře [14-16]. Z pohledu neurologie je důležité si uvědomit, že chůze na běžeckém trenažéru nebo s připojeným speciálním zařízením, které je připevněno k tělu pacienta, se od přirozené chůze výrazně liší. To je způsobeno tím, že při chůzi na běžeckém trenažéru dochází k rozdílnému zpracování pohybových informací vnitřním uchem. Chůze na běžeckém trenažéru způsobuje, že vnitřní ucho posílá signály indikující minimální pohyb těla, přestože nohy provádí chůzi.

Nástrojem pro sběr pohybových dat je tedy opět systém MS Kinect. Navrhovaná metodologie se zabývá tím, jak ho lze využít k získávání sekvencí videonahrávek, které umožňují přímou interakci mezi člověkem a technologií.

Výzkum se zaměřuje na potvrzení možného způsobu, jak překonat reálná omezení systému pro sběr dat. Konkrétně se sledování chůze pacientů provádí z mobilní robotické platformy, jak je znázorněno na Obrázcích 5, 6 a 7. Tato platforma byla vyvinuta s cílem eliminovat hlavní nedostatky statického systému Kinect a byla navržena tak, aby zachytila pohyby celého těla během přirozené chůze.


4.3.1 Autonomní robot pro sběr dat

V této kapitole je popsána především konstrukce autonomního robota, jehož vývoj vzešel z pokračující spolupráce s Fakultní nemocnicí Hradec Králové. Jeho "produkční verze" byla dokončena až ve spolupráci s Otorinolaryngologickou klinikou Fakultní nemocnice Královské Vinohrady (ORL FNKV).

Základním problémem, který vedl k vývoji tohoto robota a následným skriptům pro vyhodnocování, byla nekonzistence mezi různými způsoby hodnocení pacientů v různých škálovacích systémech. Tato nekonzistence v hodnoceních je známá a sami lékaři jsou si jí vědomi. Proto se nyní v mnoha případech požaduje alespoň dvě nezávislá hodnocení od různých lékařů. Nicméně dlouhodobě se ukazuje, že ani tento proces není zcela dokonalý a konzistentní.

S nástupem senzorů schopných sledovat lidský pohyb se objevil požadavek na vytvoření systému, který bude schopen opakovaně zařazovat pacienty s podobnými projevy do stejných kategorií, bez ohledu na subjektivní hodnocení odborníkem.

Proto bylo logickým krokem spojit vyvíjenou robotickou platformu s tehdy testovaným senzorem Kinect. To bylo zvláště důležité, protože mnohé kliniky odmítaly jakékoli stavební zásahy a posílání pacientů do dalších specializovaných laboratoří.



Obrázek 5 – Mobilní robot verze 0.

Mobilní robot verze 0 je prototyp systému s velmi omezenou funkcí. Jedná se o šestikolového robota vybaveného systémem ultrazvukových senzorů pro orientaci v prostoru.

Základní parametry a funkce:

- Jízda vpřed a vzad, zatáčení
- Ovládán systémem RaspberryPi
- Automatická detekce překážek
- Komunikace s řídicím PC pomocí wifi modulu



Obrázek 6 – Mobilní robot verze I.

Mobilní robot verze I je první funkční prototyp tohoto systému. Jedná se o čtyřkolového robota vybaveného systémem Kinect pro sběr pohybových dat.

Základní funkce:

- Jízda vpřed a vzad, zatáčení
- Vybaven systémem Kinect a notebookem pro sběr dat
- Následuje, resp. ujíždí před pacientem (vzdálenost od pacienta je řízena automaticky na základě dat z Kinectu)
- Na zadní straně robota je umístěna kamera pro zlepšení orientace v prostoru
- Pomocí kamery a sady ultrazvukových senzorů udržuje přímý směr nemocniční chodbou



Obrázek 7 – Mobilní robot verze II.

Mobilní robot verze II je druhý prototyp tohoto systému. Jedná se opět o čtyřkolového robota vybaveného systémem Orbec Astra pro sběr pohybových dat.

Základní parametry a funkce:

- Funkčnost velmi podobná verzi I
- Kinect nahrazen systémem Orbec Astra (do budoucna možno nahradit jakoukoliv setereovizní kamerou, např. i tabletem nebo telefonem)
- Notebook nahrazen počítačem s dotykovou obrazovkou
- Možnost ovládání pohybu aplikací

Pro analýzu vzoru chůze je nezbytné provádět měření, extrahovat důležité charakteristiky a interpretovat výsledky s cílem udělat závěry ohledně zdravotního stavu subjektu. Existuje několik technik pro pozorování vzoru chůze, a hlavní kategorie rysů, které je třeba sledovat během tohoto procesu, jsou temporální a prostorová měření.

Náš přístup ke sledování vzoru chůze využívá senzor MS Kinect, který dokáže sledovat kostru subjektu. Tato funkce sledování kostry umožňuje určit polohu 25 hlavních kloubů těla na základě hloubkového obrazu. I když senzor Kinect má omezené zorné pole, což umožňuje spolehlivé sledování pouze v určité vzdálenosti, kombinace tohoto cenově dostupného senzoru s mobilní robotickou platformou otevírá nové možnosti pro sledování vzoru chůze.

Výsledky výzkumu v oblasti sledování chůze pacienta (zaměřené hlavně na vývoj robotické platformy) jsou shrnuty např. v publikacích [17-22].

5. ANALÝZA MIMIKY

5.1 Datový soubor

Sledovaný datový soubor obsahuje celkem 127 pacientů a 236 sezení. Časový rozsah a počet měření jednotlivých pacientů ukazuje následující tabulka.

Tabulka 1 -Datový soubor pro analýzu mimiky


	Analýza mimiky
Sběr dat od	22. ledna 2019
Sběr dat od	současnost
Počet pacientů	127
Počet sezení	236
Počet mužů	71
Počet žen	56
Průměrný věk	58

5.2 Metodika


Během diagnostiky lékaři hodnotí závažnost ochrnutí obličeje, když pacienti provádějí několik standardních obličejových pohybů. Soustředí se také na asymetrii, která se vyskytuje kolem konkrétních obličejových oblastí. Na základě obličejového pohybu pacienta se změny asymetrie textury a tvaru obličeje měří na celém obličeji, a největší asymetrie změn se objevuje kolem určité obličejové oblasti. Například největší asymetrie změn se objevuje kolem úst, když pacient stažení rty nebo odhalí zuby.

5.2.1 Předzpracování dat

Rizikem je, že každý pacient provádí cvičení v různých časech a rychlostech. Pro další analýzu je potřeba provést zarovnání těchto dat. Obrázky 8 a 9 znázorňují původní data a požadované zarovnání na příkladu vzdálenosti mezi očními koutky a obočím pro tři různé pacienty při provádění cviku zvedání obočí.



Obrázek 8 – Data před zarovnáním



Obrázek 9 – Data po zarovnání.

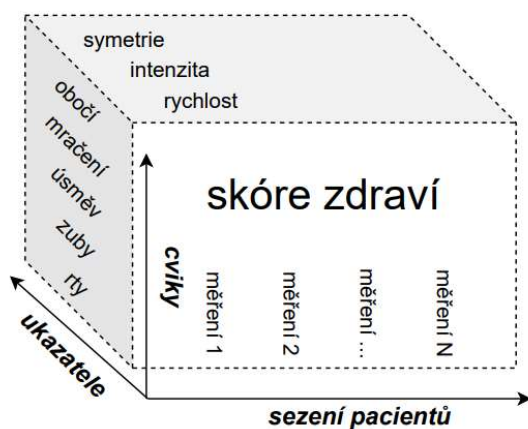
Body zájmu pro zarovnání lze samozřejmě identifikovat manuálně, ale protože v budoucnosti lze očekávat více dat, je nezbytná automatická identifikace bodů. Křivky jsou normalizovány a zarovnány s referenční křivkou pomocí tzv. dynamického borcení času (DTW) s cílem identifikovat začátky a konce každé opakování cvičení. Data ukazují, že pacienti ne vždy provádějí cvičení tak, jak je požadováno, tedy DTW se používá také k automatickému určení počtu opakování. K tomu účelu se vypočítá vzdálenost mezi každou křivkou a referenčními křivkami pro 2, 3 nebo 4 opakování a vyberou se ta, která mají minimální průměrnou vzdálenost.

Kvůli různému počtu opakování cvičení jednotlivými pacienty bylo rozhodnuto vybrat jednu realizaci cvičení pro každého pacienta (každé měření). Protože první a poslední opakování jsou někdy chybně identifikována (šum na začátku nebo na konci cvičení), bylo vybráno druhé opakování pro každého pacienta. Toto rozhodnutí také umožňuje zohlednit možnou únavu při opakování cvičení.

Třídy HB 4 a 5 mají velmi nízké frekvence (ve srovnání s ostatními), jsou poměrně umělé a používají se k klinické praxi velmi zřídka. HB4 je velmi podobná HB3, zatímco HB5 je podobná HB6. Pro zvýšení spolehlivosti modelovacího procesu byla změněna klasifikace všech vzorků s HB4 na HB3 a vzorky s HB5 byly překlasifikovány na HB6.


5.2.2 Výpočet skóre zdraví

Následujícím krokem v klasifikaci dat ve výpočet tzv. skóre zdraví (HS), bezrozměrné číslo, odpovídající míře postižení pacienta. Pro jeho výpočet byla na časové křivky aplikována funkcionální logistická regrese (FLR). a to pro ukazatele: (i) symetrie obličeje, (ii) intenzita cviku, (iii) rychlost cviku a pro každý cvik: (i) zvedání obočí, (ii) mračení, (iii) úsměv, (iv) cenění zubů, (v) špulení rtů. Pomocí FLR se všechny křivky transformovaly na skóre HS s hodnotou mezi 0 a 1, obrázek 10.



Obrázek 10 – Skóre zdraví.

Obrázek 11 ukazuje hodnoty vypočteného HS. Nízké skóre zdraví (modrá barva) značí významnou poruchu pohyblivosti obličejových svalů v dané oblasti definované pomocí ukazatelů, naopak vysoké hodnoty (červená barva) označuje vysokou míru uzdravení.



Obrázek 11 – Vypočtené hodnoty skóre zdraví.

Pro posouzení vztahu mezi skórem zdraví a stupni HB (které poskytl lékař) byly vypočteny odpovídající párové Spearmanovy korelační koeficienty včetně p-hodnot, což je ukázáno v Tab. 2 (zeleně jsou označeny ukazatele vybrané do modelů). U několika ukazatelů je mírně negativní korelace (pod $-0,2$) s významnou hodnotou ($p < 0,05$). To naznačuje, že HS může sloužit jako užitečný prediktor pro klasifikaci HB. Nejsilnější korelace je dosaženo u úsměvu a cenění zubů. Důvodem je, že dysfunkce lícního nervu je v této oblasti nejzřetelnější, a to jak pro lékaře, tak pro model.

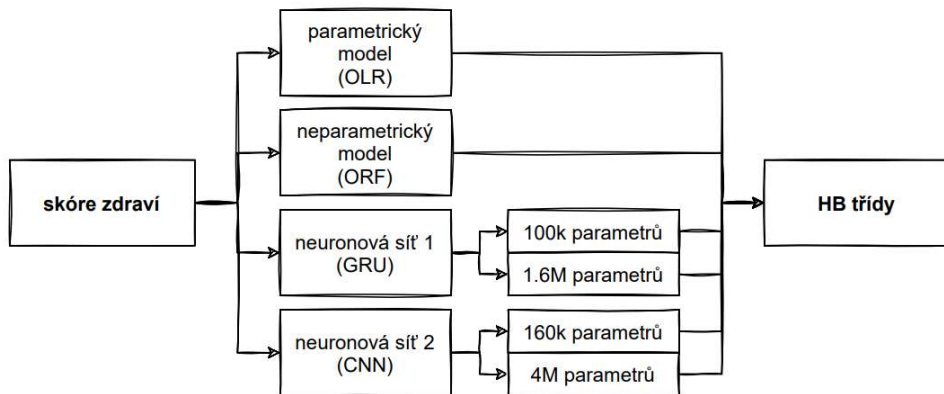
Tabulka 2 – Vztah mezi HS a HB

	ukazatel	korelační koeficient	p-hodnota
01	$I_{SI,úsměv}(t)$	-0,50	0,00
02	$I_{SI,zuby}(t)$	-0,47	0,00
03	$I_{I,rtý}(t)$	-0,40	0,00
04	$I_{I,mračení}(t)$	-0,29	0,00
05	$I_{SI,obočí}(t)$	-0,26	0,00
06	$I_{S,rtý}(t)$	-0,22	0,01
07	$I_{S,obočí}(t)$	-0,21	0,02
08	$I_{I,obočí}(t)$	-0,18	0,04
09	$I_{I,úsměv}(t)$	-0,18	0,04
10	$I_{S,mračení}(t)$	-0,17	0,06
11	$I_{I,zuby}(t)$	-0,12	0,18
12	$I_{S,úsměv}(t)$	-0,11	0,21
13	$I_{S,zuby}(t)$	-0,09	0,32
14	$I_{SI,mračení}(t)$	-0,08	0,37

5.2.3 Klasifikace dat

V této kapitole jsou představeny výsledky verifikace skóre zdraví pomocí jeho klasifikace do stupňů HB různými modely. Nejprve se použije parametrický model založený na ordinální logistické regresi (OLR). Dále jsou ukázány výsledky neparametrického modelu, který byl založený na ordinálních náhodných lesech (ORF). A konečně jsou ukázány i výsledky čtyř modelů založených na neuronových sítích, a to konkrétně dvou založených na

síť s uzavřenými rekurentními jednotkami a dvou na síť s konvolučními vrstvami, obrázek 12 [23-25].



Obrázek 12–Klasifikační algoritmy pro výpočet HB.

Porovnání celkové přesnosti na testovací sadě s přesností na tréninkových datových sadách ukazují následující výsledky:

- model OLR poskytuje výsledky bez přeučení (přesnosti klasifikace na trénovacích sadách se pohybují kolem 60 %);
- model ORF vykazuje silné přeučení (přesnosti klasifikace na trénovacích sadách dosahují 100 %)
- GRU vykazuje tendenci k přeučení (některé přesnosti klasifikace na trénovacích sadách dosahují 100 %);
- CNN vykazuje velmi silnou tendenci k přeučení (prakticky na všech trénovacích sadách dosahuje přesnosti 100 %), ačkoli na testovacích sadách dosahuje nejlepšího výsledku (64 %);

Neparametrické metody obvykle vyžadují (ze své podstaty) velkou trénovací množinu, aby se naučily systematické vzorce a odfiltrovaly šum. Jak se dalo očekávat, modely neuronových sítí vykazují silné přeučení na trénovací množině z podobných důvodů jako neparametrický model ORF. Díky předčasnému ukončení učení však stále mohou dosáhnout přesnosti klasifikace testovací množiny srovnatelné s OLR, viz tabulky 3, 4 a 5

Tabulka 3 – Přesnost klasifikace na trénovací sadě

sada	OLR	ORF	GRU-tp100k	GRU-tp1.6M	CNN-tp160k	CNN-tp4M
trénovací 1	55 %	98 %	94 %	43 %	99 %	99 %
trénovací 2	63 %	100 %	100 %	100 %	100 %	100 %
trénovací 3	50 %	99 %	100 %	96 %	100 %	100 %
trénovací 4	60 %	98 %	100 %	97 %	100 %	100 %
trénovací 5	62 %	100 %	98 %	69 %	100 %	100 %
testovací	57 %	52 %	51 %	46 %	59 %	64 %


Tabulka 4 – Přesnost klasifikace na testovací sadě (přesná klasifikace)

HB lékaře	OLR	ORF	GRU-tp100k	GRU-tp1.6M	CNN-tp160k	CNN-tp4M
1	48 %	83 %	66 %	64 %	74 %	74 %
2	62 %	10 %	33 %	52 %	29 %	43 %
3	65 %	35 %	39 %	22 %	52 %	52 %
6	70 %	25 %	40 %	15 %	55 %	70 %
celkově	57 %	52 %	51 %	46 %	59 %	64 %

Tabulka 5 – Přesnost klasifikace na testovací sadě (přibližná klasifikace)

HB lékařem	OLR	ORF	GRU-tp100k	GRU-tp1.6M	CNN-tp160k	CNN-tp4M
1	78 %	84 %	78 %	76 %	76 %	81 %
2	100 %	100 %	86 %	90 %	86 %	100 %
3	78 %	39 %	48 %	39 %	70 %	61 %
6	70 %	25 %	40 %	15 %	55 %	70 %
celkově	80 %	69 %	67 %	61 %	73 %	79 %

Výsledky klasifikací výše popsaných algoritmů jsou shrnuty v obrázku 13. Zelený sloupec reprezentuje přesnou klasifikaci, modrý sloupec přibližnou klasifikaci (tedy daná třída HB plus nebo minus 1).

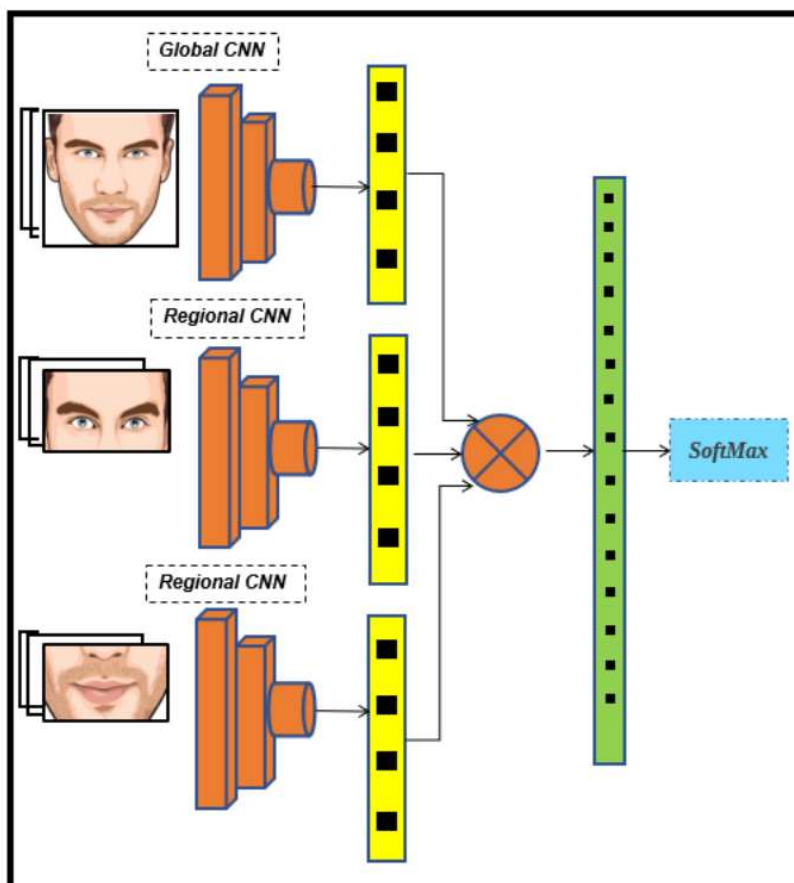


Obrázek 13 – Výsledky klasifikací.

5.2.4 Trojcestná neuronová síť

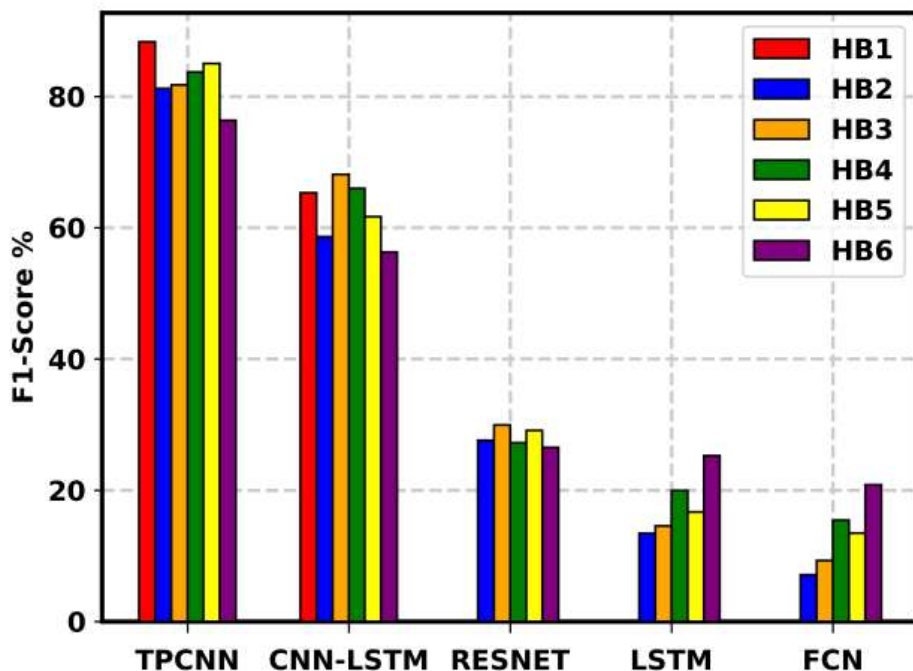
Na základě nedostatečné přesnosti klasifikačních algoritmů popsaných výše byla dále navržena tzv. trojcestná konvoluční neuronová síť (TPCNN) pro hodnocení vysokoúrovňových pohybových rysů obličejových svalů na

základě diagnostických obličejových pohybů. TPCNN používá jednu konvoluční sub-síť k hodnocení globálních pohybových rysů na celém obličejí a další dvě sub-sítě k hodnocení lokálních pohybových rysů z relevantních obličejových oblastí. Extrahované rysy TPCNN jsou sloučeny pro konečné hodnocení. Používají se dva typy sub-sítí pro globální a regionální oblasti: sub-síť pro celý obličej a dvě sub-sítě pro oblasti očí a úst. Obrázek 14 ilustruje rámec navrhované TPCNN.



Obrázek 14 – Navržená trojcestná konvoluční neuronová síť.

K ověření klasifikačních schopností byla navržená metoda porovnána s dalšími standardními klasifikačními metodami, které lze nalézt v literatuře (CNN-LSTM, ResNet a FCN). Výsledky jsou zřetelné z obrázku 15. Hodnota F1-skóre dosahuje v našem případě více než 80%.



Obrázek 15 – Porovnání klasifikace TPCNN se standardními metodami.

Výsledky výzkumu v oblasti analýzy mimiky a klasifikace do škály dle House a Brackmanna jsou shrnuty především v publikacích [26-31].

6. ANALÝZA CHŮZE

6.1 Datový soubor

Datový soubor zahrnuje celkem 84 úspěšných rehabilitačních cvičení provedených u 37 pacientů. Všichni pacienti, mezi nimiž bylo 23 mužů a 14 žen ve věku od 21 do 77 let, podstoupili operaci vestibulárního schwannomu. Z těchto pacientů mělo 24 nádorů na levé straně a 13 na pravé straně. Tyto nádory byly rozděleny podle Koosovy klasifikace. Časový rozsah a počet měření jednotlivých pacientů ukazuje následující tabulka.


Tabulka 6 -Datový soubor pro analýzu chůze

	Analýza chůze
Sběr dat od	16. ledna 2018
Sběr dat od	současnost
Počet pacientů	37
Počet sezení	84
Počet mužů	23
Počet žen	14
Průměrný věk	57

47 vzorků vykazovalo mírný nerovnovážený stav před operací (tzv. třída 1), 19 vzorků vykazovalo silný nerovnovážený stav před operací (tzv. třída 2) a 18 vzorků nevykazovalo žádný nerovnovážený stav před operací (tzv. třída 3).

6.2 Předzpracování dat

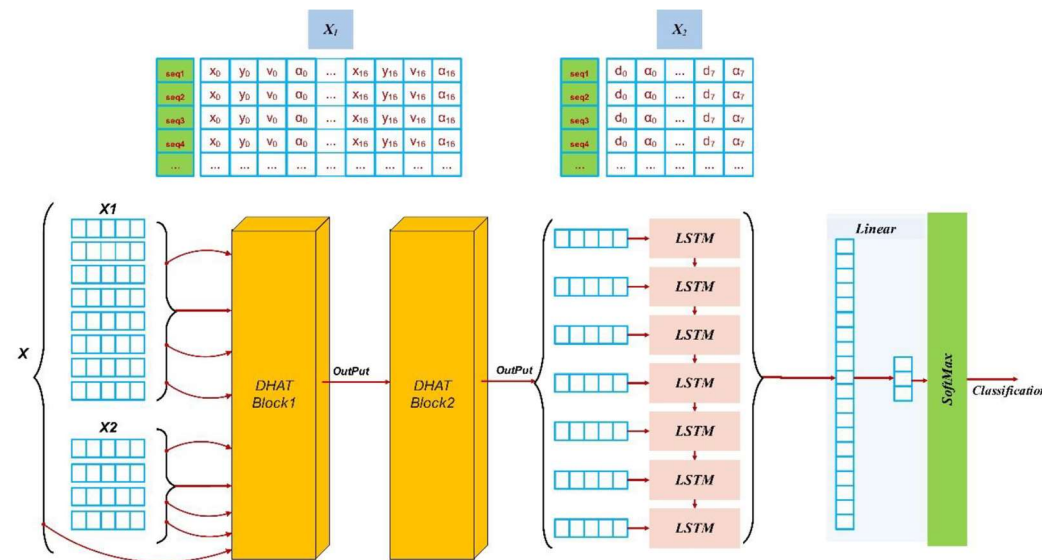
Obrázek 16 ukazuje architekturu navrhovaného předzpracování dat. Tento krok používá obrazové filtry pro získání kvalitnějších obrazů (EqualHist, GaussianBlur a applyColorMap z knihovny OpenCV). Filtrovaný obrázek je poté použit jako vstup pro detekci klíčových bodů k extrakci klíčových bodů kostry a následně je použit Kalmanův filtr k identifikaci chybějících bodů.



Obrázek 16 – Architektura předzpracování dat.

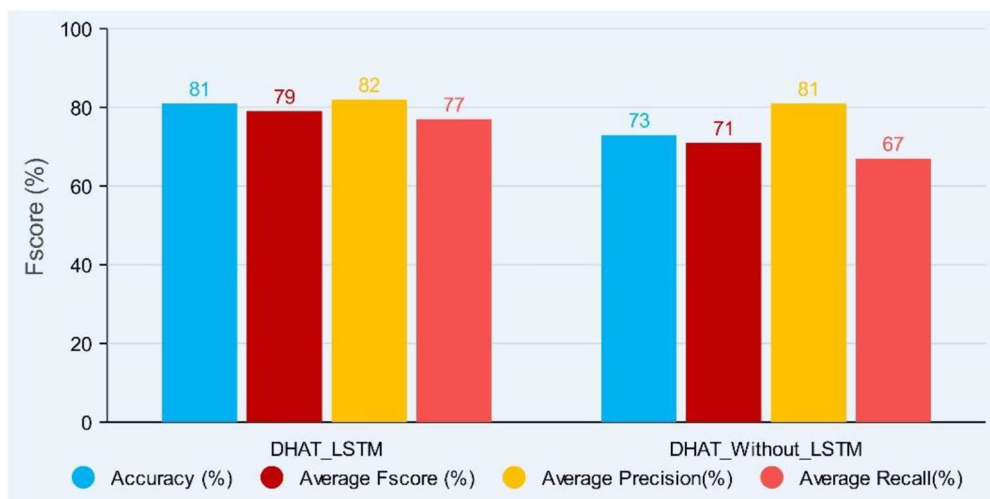
6.3 Klasifikace dat

Klasifikační algoritmus se skládá z bloků dual self-attention transformer (DHAT), které jsou aplikovány na sekvenci extrahovaných klíčových bodů. Tyto vrstvy jsou zařazeny dvě. Obrázek 17 vysvětluje rámec navrženého DHAT-LSTM [32-34].



Obrázek 17 – Klasifikační algoritmus.

Obrázek 18 ukazuje výsledky modelu DHAT s a bez modulu LSTM. Vzhledem k tomu, že DHAT-LSTM přidává LSTM pro zlepšení analýzy lokální informace, jeho výsledek klasifikace je značně lepší než u samotné DHAT. Navržený model přinesl zlepšení klasifikačního výsledku z 73 % na 81 %.



Obrázek 18 – Výsledky modelu DHAT.

Výsledky výzkumu v oblasti analýzy chůze jsou shrnuty především v publikacích [35-37].

7. VÝSLEDKY A BUDOUCÍ PRÁCE

Výzkum autora se zabývá tématem zpracování signálů a obrazů v oblasti biomedicíny. Zpracování signálů je základem pro všechny oblasti spojené s měřením, řízením, modelováním a informatikou v biomedicině. Cílem je proto ukázat možné využití moderních metod zpracování signálů jako užitečného nástroje v těchto oblastech.

Přednáška prezentuje výzkum, na kterém autor pracoval v posledních několika letech. Vše se zaměřuje na digitální zpracování signálů a lze rozdělit do těchto částí.

První část představuje věkově závislé změny v parametru barevného šumu v EEG záznamech. Všechny subjekty podstoupily podrobné neurologické a neuropsychologické vyšetření, které minimalizovalo vliv možného onemocnění mozku na prezentované výsledky. Vzhledem k tomu, že počet neuronů se s věkem podle nedávných výzkumů významně snižuje, je nejpravděpodobnější příčinou snížení hodnoty parametru λ v souvislosti s mocninným rozložením $1/f^\alpha$ ztráta synapsí, a tím snížená konektivita neuronové sítě mozku. Výsledky této části výzkumu byly publikovány především v [6], [7], [8] a [9].

Výzkum zpracování signálů EEG pokračuje formulací a potvrzením různých hypotéz o počtu receptorů a počtu spojení mezi neurony u pacientů s různými onemocněními (Alzheimerova choroba, demence, ...)

Druhá část výzkumu představuje principy detekce pohybujících se objektů (mimiky a chůze) pomocí videokamery nebo systému KINECT. Následně jsou použity specifické matematické metody pro lokalizaci složek obrazu pro zpracování každého pozorovaného obrázku.

Výsledkem práce je hardwarové řešení robotické platformy. Tato platforma může provádět autonomní měření, která se používají pro analýzu chůze. Platforma může měnit chování v různých scénářích, aby se zabránilo možným problémům během měření.

Součástí výzkumu v této oblasti je i analýza těchto dat a následná diagnostika, resp. objektivní posouzení stavu daného pacienta. Pro klasifikaci

byly využity algoritmy klasické statistiky (ordinální logistická regrese či náhodné lesy) i metody umělé inteligence.

Výsledky této části byly publikovány především v [36-31] a [35-37]. Výzkum v současnosti pokračuje ve dvou základních směrech: (i) sběr dat s využitím tabletů a telefonů (vývoj multiplatformní mobilní aplikace), (ii) pokročilá analýza dat „bez učitele“.

8. ZÁVĚR

Přednáška se věnuje problematice zpracování signálů a obrazů v kontextu inženýrství a biomedicíny. Metody a algoritmy zpracování signálů tvoří základní stavební kámen pro všechny disciplíny spojené s měřením, řízením, modelováním a informatikou v oblasti biomedicíny. Cílem přednášky je ilustrovat využití zpracování signálů v těchto různých oblastech, a to od sběru dat přes jejich zpracování až po objektivní hodnocení příslušného (medicínského) problému.

Přednáška prezentuje klíčové pokroky v rámci vlastního výzkumu autora během uplynulých deseti let. Zabývá se zpracováním signálů, včetně obrazů, v oblasti biomedicíny, což představuje moderní obor s rozsáhlými možnostmi pro výzkum i aplikace. Výzkum je realizován ve spolupráci s předními českými medicínskými institucemi, včetně Fakultní nemocnice v Hradci Králové, Kliniky neurologie a Fakultní nemocnice Královské Vinohrady v Praze, Kliniky ORL

V předchozím textu byly představeny různé výzkumné projekty, na kterých se autor podílel, a které demonstrují, že zpracování signálů je nezbytným a užitečným nástrojem v mnoha oblastech biomedicíny. Každý z těchto projektů představuje samostatnou výzkumnou oblast, kde bylo dosaženo zásadního pokroku a přináší nové poznatky. Mezi nejdůležitější patří: (i) potvrzení hypotézy, že s věkem klesá počet receptorů a tím i počet spojení mezi neurony v mozku (tato analýza byla první, která byla použita na EEG signály), (ii) vývoj systému pro analýzu chůze a detekci poruch chůze a (iii) vývoj systému pro analýzu mimiky a identifikaci jejích poruch.

Všechna zde prezentovaná témata ukazují využití digitálního zpracování signálů a obrazů jako základu mnoha různých oblastí inženýrství a biomedicíny. Všechny výsledky jsou založeny na výzkumné práci autora a jeho týmu a byly publikovány převážně na mezinárodních konferencích nebo v impaktovaných časopisech.

9. LITERATURA

- [1] FALOUTSOS, M.; FALOUTSOS, P.; FALOUTSOS, C. (1999). On Power Law Relationships of the Internet Topology. *Comput. Commun. Rev.* 29: 251.
- [2] BARABÁSI A.L. AND ALBERT R. (1999). Emergence of Scaling in Random Networks, *Science Magazine*, , 286 (5439): 509-512
- [3] BRODER, A.; KUMAR, R.; MAGHOUL, F.; RAGHAVAN, P.; RAJAGOPALAN, S.; STATA, R.; TOMKINS, A.; WIENER, J. (2000). Graph structure in the Web. *Computer Networks* 33 (1-6): 309–20.
- [4] BAK, P.; TANG, C.; AND WISENFELD, K. (1987). Self-organized criticality: An explanation of $1/f$ noise. *Physical Rev. Letters*, 59(4), 381-384.
- [5] BAK, P.; TANG, C.; AND WIESENFELD, K. (1988). Self-organized criticality, *Phys. Rev. A*, 38, 364-374.
- [6] MAREŠ, J. VYŠATA, O. PROCHÁZKA, A., VALIŠ, M. J. Age-dependent complex noise fluctuations in the brain. *Physiological Measurement*. Vol 34, no. 10. 2013. ISSN 0967-3334 (Print), ISSN 1361-6579 (Online). IF: 1.496
- [7] VYŠATA, O., PROCHÁZKA, A., MAREŠ, J., RUSINA, R., PAZDERA, L., VALIŠ, M., KUKAL, J. Change in the Characteristics of EEG Color Noise in Alzheimer's Disease. *Clinical EEG and Neuroscience*.45(3) 2014, ISSN 1550-0594. **IF: 3,157**
- [8] FINKEOVÁ, J., HRNČIŘÍK, P., MAREŠ, J., VOVSÍK, J., HUDEČEK, O., NÁHLÍK, J. A structured mathematical model of PHA biopolymer production process. *Archives of Control Sciences*, vol. 23, no 3, November 2013.
- [9] PROCHÁZKA, A., VASEGHI, S., YADOLLAHI, M., ŤUPA, O., MAREŠ, J., VYŠATA, O.: Remote physiological and GPS data processing in evaluation of physical activities. *Medical & Biological*

Engineering & Computing. 2014. Vol. 52, ISSN: 0140-0118 (print),
ISSN: 1741-0444 (online). **IF: 1,79**

- [10] M. RINGER AND J. LASENBY. Multiple Hypothesis Tracking for Automatic Optical Motion Capture. *Lecture Notes in Computer Science*, 2350, 2002.
- [11] J. LASENBY AND A. STEVENSON. Using Geometric Algebra for Optical Motion Capture. In E. Bayro-Corrochano and G. Sobczyk, editors, *Applied Clifford Algebras in Computer Science and Engineering*. Birkhauser, Boston, U.S.A., 2000.
- [12] M. NIXON AND A. AGUADO. *Feature Extraction & Image Processing*. NewNes Elsevier, 2004.
- [13] M. RINGER, T. DRUMMOND, AND J. LASENBY. Using Occlusions to Aid Position Estimation for Visual Motion Capture. In *Proc Computer Vision and Pattern Recognition (CVPR)*. IEEE USA, 2001.
- [14] BOYD, J.E., GODBOUT, A., THORNTON, C., In Situ Motion Capture of Speed Skating: Escaping the Treadmill, *Computer and Robot Vision*, p.460-467, May 2012. ISBN: 978-1-4673-1271-4
- [15] MACHIDA E., CAO M., MURAO T. AND HASHIMOTO H., Human Motion Tracking of Mobile Robot with Kinect 3D Sensor, *SICE Annual Conference*, p.2207-2211, 2012
- [16] STONE E. E. AND SKUBIC M., UNOBTRUSIVE, Continuous, In-Home Gait Measurement Using the Microsoft Kinect, *IEEE Transactions on Biomedical Engineering*, 60, 2925–2932, 2013
- [17] MAREŠ, J., GRÁFOVÁ, L., PROCHÁZKA, A. On-line sledování pohybuujícího se předmětu s využitím digitální kamery. *Perner's Contact*, vol. 6, no 1, april 2011. Pp. 188 – 195. ISSN 1801-674X.
- [18] MAREŠ, J., PROCHÁZKA, A., DOLEŽEL, P. On-line recognition of autonomous robot position via camera DragonFly. In *Proceedings of the 18th International Conference on Process Control 2011*. June 14 – 17 2011. Bratislava, Tribun EU, 2011. s. 7. ISBN 978-80-227-3517-9.

- [19] CRHA, J., MAREŠ, J. Model of Industrial Robotic Manipulator. *In proceedings of 10th International Conference Process Control 2012*. Pp. C012b-1 - C021b-5. Pardubice 2012. ISBN 978-80-7395-500-7.
- [20] CRHA, J., MAREŠ, J., ŤUPA, O. Robotic Platform for Gait Disorders Monitoring. In *Proceedings of ASR VSB- Technical University Ostrava*, 2015. ISBN 978-80-248-3744-4
- [21] PROCHÁZKA, A., VYŠATA, O., ŤUPA, O., SCHATZ, M., MAREŠ, J., VALIŠ, M., MAŘÍK, V. Motion Tracking and Gait Feature Estimation for Recognising Parkinson's Disease Using MS Kinect. *BioMedical Engineering OnLine*. 2015. Vol. 14, 95. ISSN: 475-925X. IF: 1,43
- [22] CRHA, J., ŤUPA, O., MAREŠ, J., PROCHÁZKA, A. Navigation of robotic platform for gait disorders monitoring. In *Proceedings of conference on Applied Electronics 2016* ", University of West Bohemia, 2016., ISBN: 978-80-261-0601-2
- [23] TUNG, Nai-Yun et al. Numerical prediction for Systolic Blood Pressure in Intradialytic Hypotension Using Time-relevant RNN Models. In: *2021 IEEE 3rd. 2021*, s. 57–59.
- [24] CHEN, Xuhui et al. Cost-Sensitive Deep Active Learning for Epileptic Seizure Detection. In: *ACM-BCB 2018 - Proceedings of the 2018 ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*. Association for Computing Machinery, Inc, 2018, sv. 18, s. 226–235. Isbn 9781450357944.
- [25] KRISHNAN, Surenthiran; MAGALINGAM, Pritheega; IBRAHIM, Roslina. Hybrid deep learning model using recurrent neural network and gated recurrent unit for heart disease prediction. *International Journal of Electrical and Computer Engineering*. 2021, roč. 11, č. 6, s. 5467–5476. issn 2088-8708.
- [26] ČERVENÁ, Lenka; KŘÍŽ, Pavel; KOHOUT, Jan; VEJVAR, Martin; VEREŠPEJOVÁ, Ludmila; ŠTÍCHA, Karel; CRHA, Jan; TRNKOVÁ, Kateřina; CHOVANEC, Martin; MAREŠ, Jan. Advanced Statistical Analysis of 3D Kinect Data: A Comparison of the Classification Methods. *Applied Sciences*. 2021, roč. 11, č. 10. issn 2076-3417.

- [27] KOHOUT, Jan; VEREŠPEJOVÁ, Ludmila; KRÍŽ, Pavel; ČERVENÁ, Lenka; ŠTÍCHA, Karel; CRHA, Jan; TRNKOVÁ, Kateřina; CHOVANEC, Martin; MAREŠ, Jan. Advanced Statistical Analysis of 3D Kinect Data: Mimetic Muscle Rehabilitation Following Head and Neck Surgeries Causing Facial Paresis. *Sensors*. 2020, roč. 21, č. 1, s. 103–122. issn 1424-8220.
- [28] TOMEŠ, Jakub; KOHOUT, Jan; MAREŠ, Jan. 3D Face Capture for Rehabilitation Progress Assessment After Brain Surgery. In: *Advances in Intelligent Systems and Computing*. Springer, 2020, sv. 1294, s. 143–149. Isbn 9783030633219. issn 2194-5365.
- [29] KOHOUT, Jan; MAREŠ, Jan. Human Fatigue Estimate: Usage of Systems from Traffic in Buildings. *Transactions of the VŠB - Technical University of Ostrava, Mechanical Series*. 2018, roč. 64, č. 1, s. 15–18.
- [30] KOHOUT, Jan; CRHA, Jan; TRNKOVÁ, Kateřina; ŠTÍCHA, Karel; MAREŠ, Jan; CHOVANEC, Martin. Robot-based image analysis for evaluating rehabilitation after brain surgery. In: *Mendel. Brno University of Technology*, 2018, sv. 24, s. 159–164. Č. 1. issn 2571-3701.
- [31] SHAYESTEGAN, M.; KOHOUT, J.; ŠTÍCHA, K.; MAREŠ, J. Advanced Analysis of 3D Kinect Data: Supervised Classification of Facial Nerve Function via Parallel Convolutional Neural Networks. *Appl. Sci.* 2022, 12, 5902.
- [32] ULLAH, A., AHMAD, J., MUHAMMAD, K., SAJJAD, M., BAIK, S.W.: Action recognition in video sequences using deep bi-directional LSTM with cnn features. *IEEE Access* 6, 1155–1166 (2017)
- [33] CUI, Z., KE, R., PU, Z., WANG, Y.: Stacked bidirectional and unidirectional LSTM recurrent neural network for forecasting network-wide traf c state with missing values. *Transp. Res. Part C* 118, 102674 (2020)
- [34] HE, K., GKIOXARI, G., DOLLÁR, P., GIRSHICK, R.: Mask R-CNN. In: *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2961–2969 (2017)

- [35] CRHA, J., ŤUPA, O., MAREŠ, J., PROCHÁZKA, A. (2016, September). Navigation of robotic platform for gait disorders monitoring. In 2016 International Conference on Applied Electronics (AE) (pp. 57-60). IEEE.
- [36] SHAYESTEGAN, M., KOHOUT, J., TRNKOVÁ, K., CHOVANEC, M., MAREŠ, J. (2023). Motion Tracking in Diagnosis: Gait Disorders Classification with a Dual-Head Attentional Transformer-LSTM. International Journal of Computational Intelligence Systems, 16(1), 98.
- [37] ŤUPA, O., PROCHÁZKA, A., VYŠATA, O., SCHÄTZ, M., MAREŠ, J., VALIŠ, M., MAŘÍK, V. (2015). Motion tracking and gait feature estimation for recognising Parkinson's disease using MS Kinect. Biomedical engineering online, 14, 1-20.

10. PROFESNÍ ŽIVOTOPIS AUTORA

Osobní údaje

Jméno a příjmení:	Jan Mareš
Adresa:	Vrchotovy Janovice 256, 257 53
Telefonní spojení:	723 046 582
E-mail	jan.mares@vscht.cz
Datum narození:	25. 9 1982

Vzdělání

2002 – 2007	Univerzita Pardubice Fakulta chemicko-technologická Katedra řízení procesů a výpočetní techniky
2007 – 2010	Univerzita Pardubice Fakulta chemicko-technologická doktorský studijní program Technická kybernetika
2017	habilitace na Univerzitě Tomáše Bati ve Zlíně, obor Řízení strojů a procesů

Zahraniční stáže a kurzy

2009	Prediktivní řízení technologických procesů, FChPT, STU, Bratislava (SR)
2010	Modelování, simulace a řízení procesů, University Louvain le Neuve (Belgie)

Praxe

2008 - 2009	externí učitel Fakulty zdravotnických studií
2009 - dosud	asistent, odborný asistent, docent na Ústavu počítačové a řídicí techniky (v roce 2023 přejmenován na Ústav matematiky, informatiky a kybernetiky), FCHI, Vysoká škola chemicko-technologická Praha
2014 – 2022	vedoucí Ústavu počítačové a řídicí techniky (v roce 2023 přejmenován na Ústav matematiky, informatiky a kybernetiky), FCHI, Vysoká škola chemicko-technologická Praha
2018 – 2022	vedoucí Ústavu matematiky, FCHI, Vysoká škola chemicko-technologická Praha
2023 – dosud	vedoucí Ústavu matematiky, informatiky a kybernetiky, FCHI, Vysoká škola chemicko-technologická Praha

Vědecká činnost

- 19 IF publikací, 4 kapitoly v knize, 23 publikací na prestižních mezinárodních konferencích
- kumulativní IF: 39; h-index 6 (Scopus), počet citací 189 (Scopus)

Vědecké zájmy:

- Analýza biomedicínských dat
- Kyberneticko-informatické systémy v biomedicině
- Zpracování obrazů, 3D modelování

Vybrané publikace:

SHAYESTEGAN, M.; KOHOUT, J.; ŠTÍCHA, K.; MAREŠ, J.
Advanced Analysis of 3D Kinect Data: Supervised Classification of
Facial Nerve Function via Parallel Convolutional Neural Networks. *Appl.*
Sci. 2022, 12, 590. IF: 2,679

VRBA, J., MASLEN, CH., MAXOVÁ, J., DURAS, J., ŘEHOŘ, I.,
MAREŠ, J. An Automated Platform for Assembling Light-Powered
Hydrogel Microrobots and their Subsequent Chemical Binding. *Journal of*
Computational Science ISSN: 1877-7503. 2021 IF: 3,976

KRBCOVA, Z., KUKAL J., MAREŠ, J., HABARTOVÁ, L.,
SETNIČKA, V. Variational approach to cancerous tissue identification
from in vivo Raman spectra. *Biomedical signal processing and control.*
2019, 49, 520-527 DOI: 10.1016/j.bspc.2018.12.026. ISSN 1746-8094.
IF: 2,78

HRNČIŘÍK, P., MOUCHA, T., MAREŠ, J. NÁHLÍK, J., JANÁČOVÁ,
D. Software Sensors for Biomass Concentration Estimation in
Filamentous Microorganism Cultivation Process. *Chemical and*
Biochemical Engineering Quarterly. 2019, 33(1), 141-151. ISSN 0352-
9568. doi: 10.15255/CABEQ.2018.1387 IF: 1,383

NÁHLÍK, J., KUKAL, J., KOHOUT, J., MAREŠ, J., HRNČIŘÍK, P.,
VAŘACHA, P. Digital Image Analysis for Morphological State
Characterization of a Culture of Filamentous Microorganisms in
Production of Antibiotics. 2019. *Journal of Biomimetics, Biomaterials*
and Biomedical Engineering. ISSN: 2296-9845. IF: 1,836

Další aktivity

- Člen Oborové rady doktorského studijního programu Technická kybernetika (VŠCHT)
- Člen Oborové rady doktorského studijního programu Měření a zpracování signálů v chemii (VŠCHT)
- Člen Oborové rady doktorského studijního programu Aplikovaná informatika (ČVUT)

- Člen Vědecké rady Fakulty chemicko-inženýrské, VŠCHT Praha
- Člen Vědecké rady Fakulty jaderné a fyzikálně inženýrské, ČVUT Praha
- Člen Vědecké rady Fakulty elektrotechniky a informatiky, Univerzita Pardubice

- Člen hodnotící komise Národního akreditačního úřadu pro oblast Kybernetiky

doc. Ing. Jan Mareš, Ph.D.

**Kyberneticko-informatické systémy v analýze
biomedicínských dat**

Cybernetic-Informatic Systems in Biomedical Data
Analysis

Teze přednášek ke jmenování profesorem

Vydala Univerzita Tomáše Bati ve Zlíně
nám. T. G. Masaryka 5555, 760 01 Zlín.

Náklad: 90 ks

Sazba: Jan Mareš

Publikace neprošla jazykovou ani redakční úpravou.

Pořadí vydání: první

Rok vydání 2023

ISBN 978-80-7678-212-9