

Ing. Tomáš Závodník

**Snímanie a spracovanie elektrických signálov zo senzorických
systémov**

Autoreferát dizertačnej práce

na získanie vedecko-akademickej hodnosti philosophiae doctor

v doktorandskom študijnom programe: elektronika a fotonika

Miesto a dátum: Bratislava, August 2023

Slovenská Technická Univerzita v Bratislave
Fakulta Elektrotechniky a Informatiky
Ústav Elektroniky a fotoniky

Ing. Tomáš Závodník

**Snímanie a spracovanie elektrických signálov zo senzorických
systémov**

Autoreferát dizertačnej práce

na získanie vedecko-akademickej hodnosti philosophiae doctor

v doktorandskom študijnom programe: elektronika a fotonika

Miesto a dátum: Bratislava, August 2023

Dizertačná práca bola vypracovaná na:

Ústave Elektroniky a fotoniky, FEI STU v Bratislave

Predkladateľ: Ing. Tomáš Závodník
Ústav elektroniky a fotoniky,
Fakulta elektrotechniky a informatiky,
Slovenská technická univerzita v Bratislave,
Ilkovičova 3, 812 19 Bratislava

Školiteľ: prof. Ing. Daniel Donoval, DrSc.
Ústav elektroniky a fotoniky FEI STU v Bratislave

Oponenti: RNDr. Anton Mateasik, PhD.
Medzinárodné Laserové Centrum,
Ilkovičova 3, Bratislava

doc. RNDr. Pavol Vítovič, PhD.
Ústav simulačného a virtuálneho medicínskeho
vzdelávania, Lekárska fakulta, Univerzita
Komenského, Sasinkova 4, Bratislava

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa koná dňa 28.9. ,o 9 hod. na Fakulte
Elektrotechniky a Informatiky, Slovenskej Technickej Univerzity
v Bratislave, Ilkovičova 3, 812 19 Bratislava.

Obsah

1.	Úvod	5
2.	Tézy dizertačnej práce	8
3.	Teoretický úvod	9
3.1	EKG analýza, HRV	10
	Výpočet IBI	11
4.	Dosiahnuté výsledky	12
4.1	Základný modul	14
4.2	EKG AFE (Analogový frontend)	18
4.3	Datasety	20
4.4	Trénovanie modelov	22
4.5	Experiment #1	23
4.6	Experiment #2	26
4.7	Experiment #3	28
4.8	Experiment #4	30
4.9	Experiment #5	33
4.10	Experiment #6	35
4.11	Experiment #7	37
4.12	Experiment #8	39
4.13	Experiment #9	41
4.14	Experiment #10	43
4.15	Postup vnorenej implementácií	45
4.16	Testovanie vnorenej implementácie a výsledky	47
5.	Záver	50
6.	Zhrnutie dizertačnej práce	56
7.	Summary	58
8.	Zoznam použitej literatúry	59
9.	Zoznam publikácií:	68

1. Úvod

Jeden z najväčších výdavkov v rozvinutých krajinách je zdravotníctvo. Podľa štúdie OECD z roku 2018 priemerne vynakladajú rozvinuté štáty na chod svojich zdravotníckych systémov 9.3% HDP daného štátu [1]. Podľa predpovedí organizácie OECD [2] bude v horizonte niekoľkých rokov značne pribúdať starších ľudí kým časť populácie v mladšom veku bude stagnovať alebo ubúdať. S vyšším vekom sa aj fyzické zdravie populácie bude zhoršovať čo bude mať za následok prudké zvyšovanie nákladov na chod zdravotníctva. Aj bez dôkladnej znalosti ekonomiky môžeme predvídať že tlak na verejné financie bude obrovský. Technologicky sektor odpovedá na tieto tlaky novými technológiami ktoré sa čoraz viac dostávajú do popredia. Technológiami ako IoT, telemedicína, automatické spracovanie výsledkovú pomocou ML/AI algoritmov a medicínskou robotikou.

V tejto práci sa chcem zaoberať možnosťou spojenia týchto postupov a navrhnuť vnorené riešenie problému s využitím najnovších poznatkov v oblasti IoT a ML. Cieľom práce bude navrhnutie EKG multisenzorickej platformy ktorá ma kontinuálne spojenie s internetom a je schopná obsluhovať veľké množstvo senzorov. Okrem platformy bude v práci navrhnutá základná štruktúra systému na vyzbieranie, kontrolovanie, riadenie a čistenie získaných dát a zariadení. Pomocou tohoto systému vyzbierať dáta so senzorickej platformy ktoré budú následne skontrolované, označené a filtrované. Následne vybrať adekvátnu knižnicu na tréovanie ML, pomocou tejto knižnice natréovať neurónovú sieť ktorá bude schopná na základe zozbieraných dát správne vyhodnotiť aktuálny zdravotný stav pacienta.

Správne zvolenie neurónovej siete bude vyžadovať veľké množstvo dát, a veľký počet iterácií. Kde pri každej iterácii bude nutné

vyhodnotiť energetickú náročnosť, keďže konečné riešenie vyžaduje implementáciu neurónovej siete do vnoreného zariadenia kde sú výpočtové zdroje značne obmedzené.

Následne zistiť či takéto vytvorené komplexne riešenie je schopne identifikovať jednotlivca len s EKG meraním, určiť či je možné použiť takto doladenú neurónovú sieť na identifikáciu potencionálnych anomálií v EKG signále.

Témou tejto práce je oboznámenie sa s technikami použitými v HRV analýze, za účelom navrhnutia systému na vnorenú analýzu EKG signálu, s využitím strojového učenia a neurónových sietí. Výsledkom práce je zariadenie, ktoré je schopné dlhodobo monitorovať srdcovú činnosť človeka a v reálnom čase vyhodnotiť výsledky EKG signálu. V prípade neštandardných výsledkov odoslať dáta na podrobnú analýzu. Aktuálne systémy v oblasti HRV analýzy neurónovou sieťou, sa sústreďia na analyzovanie dát na serveroch, ktoré majú k dispozícii obrovský výpočtový výkon.

Systém navrhovaný v tejto práci funguje ako batériou napájaný EKG holter, ktorého úlohou je klasifikovať dáta pacienta. V prípade zisteného problému v zdravotnom stave kontaktovať obsluhu. Do tohto vnoreného zariadenia bude implementovaná neurónová sieť, ktorá musí byť dostatočne výpočtovo efektívna, aby bola použiteľná s obmedzeným výpočtovým výkonom mikrokontroléra. Pomocou HRV analýzy nájsť a vytvoriť vhodný diagnostický vstup relevantných hodnôt, ktoré poskytnú neurónovej sieti obraz o zdravotnom stave. Výhoda neurónovej siete oproti statickým algoritmom je v schopnosti jednoducho prispôbiť vyhodnocovaný model priamo konkrétnemu pacientovi. Neurónová sieť sa natrénuje na všeobecných dátach, a potom prispôbí konkrétnemu pacientovi na základe niekoľkých krátkych meraní.

Je mnoho výhod analýzy priamo na doske (on-board). Ak predpokladáme nasadenie v odľahlejších oblastiach, kde pokrytie internetom nie je dostatočné na prenos nespracovaného EKG signálu,

tak je vnorená analýza jediné akceptovateľné riešenie. Vďaka malému množstvu dát, ktoré je potrebné preniesť cez sieť pripadajú v úvahu aj IoT siete, ktoré majú veľké pokrytie, ale povoľujú malý dátový tok.

2. Tézý dizertačnej práce

Na základe doteraz nadobudnutých znalostí o problematike HRV analýzy a neurónových sietí je možné tézy dizertačnej práce sformulovať nasledovne:


1. Preskúmať aktuálnu literatúru na nadobudnutie ďalších znalostí v oblasti HRV analýzy, spracovania EKG signálov a tréningovania neurónových sietí.
2. Navrhnuť firmware pre EKG holter.
3. Výrazne rozšíriť dátové zdroje pre vytvorený dataset, pokračovať v zbere a kategorizácii dát EKG meraní pomocou EKG holtera.
4. Vytvoriť viaceré verzie natrénovaných neurónových sietí. Na základe testov neurónových sietí vybrať najúspešnejšiu verziu neurónovej siete pre vnorenú implementáciu.
5. Implementovať a verifikovať implementáciu natrénovanej neurónovej siete do vnoreného zariadenia pre jeho validáciu pre prax.

3. Teoretický úvod

Elektrokardiografia je neinvazívny proces sledovania elektrickej aktivity ľudského srdca. Záznam takejto aktivity sa nazýva elektrokardiogram a označuje sa skratkou EKG. Slovo elektrokardiografia pochádza z nemeckého jazyka „*elektrokardiographie*“. Proces bol prvýkrát zdokumentovaný holandským doktorom Einthovanom v roku 1902. Trvalo asi 10 rokov kým EKG a jeho výhody začali byť využívané v medicíne všeobecne [3].

Základná jednotka EKG záznamu je PQRST komplex, vid obr. 1. Komplex pozostáva z niekoľkých častí, ktoré sú priamym dôsledkom procesu polarizácie a repolarizácie srdca.

- P-vlna – Reprezentuje elektrickú aktivitu medzi sinoatriálnym uzlom cez srdcové átria, ktorých výsledok je stiahnutie átrií, čo vypumpuje krv do srdcových komôr.
- QRS komplex – Spôsobený ventrikulárnou repolarizáciou, normálny QRS komplex má trvanie pod 120 ms [4]. Príliš dlhý alebo príliš krátky QRS komplex môže znamenať poruchu na srdci.
- T- vlna – Je vytvorená neutralizáciou elektrickej aktivity predsieni srdca.



Obrázok 1: Základný segment EKG analýzy. Sú vyznačene P, Q, R, S a T komplexy [5].

3.1 EKG analýza, HRV

Biologické systémy vykazujú veľmi veľkú úroveň variability, túto variabilitu je možné aproximovať pomocou matematických funkcií. HRV analýza, kde HRV je skratka anglického výrazu “*heart-rate variability*“ v preklade variability srdcovej činnosti. Je to označenie pre veľké množstvo matematických funkcií charakterizujúcich tieto systémy. Všetky tieto matematické funkcie pracujú so zmenami v časových intervaloch po sebe idúcich úderov srdca. Časový interval medzi údermi srdca sa odborné nazýva skratkou IBI, “*inter beat interval*“, v preklade čas medzi údermi. Zdravé srdce nemá pravidelný rytmus úderov. Za normálnych okolností je značná variabilita medzi jednotlivými IBI. Variabilita umožňuje kardiovaskulárnemu systému prispôsobovať sa prudkým zmenám vo fyzickej aktivite [6]. Ak sú zmeny príliš prudké alebo veľmi slabé je možné odhadnúť poruchy kardiovaskulárnej sústavy [7]. Okrem stavu kardiovaskulárnej sústavy je možné pomocou HRV analýzy zistiť približný stav autonómneho

nervového systému (ANS). Na základe dlhodobej HRV analýzy je možné odsledovať stav ANS pri fyzickej záťaž, ako aj v pokoji [8].

Na výpočet IBI a následne HRV parametrov sa využíva EKG záznam. Preto je kvalita a dĺžka EKG záznamu veľmi dôležitá pre HRV analýzu.

Matematické funkcie HRV analýzy sa delia na 3 kategórie:

- Časová analýza,
- Frekvenčná analýza,
- Nelineárna analýza.


Odlisujú sa od seba vyžadovanou dĺžkou EKG merania, zložitou výpočtu, nárokmi na výpočtový výkon a informáciami, ktoré je možné získať z výpočtu.

3.2 Výpočet IBI

Prvým krokom v HRV analýze je výpočet IBI. V praxi sa používa veľké množstvo algoritmov, ktoré slúžia na jeho výpočet. Rozdiely sú najmä vo výpočtovej náročnosti a zložitosti implementácie. Jeden z najviac využívaných je Pan-Thomkinsov algoritmus.

4. Dosiahnuté výsledky

Táto časť práce sa zaoberá konkrétnymi krokmi, ktoré boli vykonané aby bolo možné zostrojiť mobilné meracie zariadenie na realizáciu EKG meraní. Ďalej sa práca zaoberá využitím zostrojeného meracieho zariadenia na vykonanie zberu EKG meraní. Tieto merania boli analyzované. Po analýze boli použité na vytvorenie trénovacieho datasetu. Dataset bol použitý na realizáciu poslednej časti práce a to trénovanie neurónových sietí. Bolo vytvorených viacero verzií neurónových sietí. Po ich vyhodnotení bola najlepšia verzia implementovaná do skonštruovaného zariadenia. Posledná časť práce zhŕňa vykonané experimenty s touto neurónovou sieťou.




Obrázok 2: Abstrakcia funkcie vytvoreného systému.

Schéma navrhnutého systému je na obrázku 2, kde sú vyobrazené jednotlivé časti systému. Opis riešenia je rozdelený do niekoľkých častí:

- Fyzické zariadenie - Riadi zber dát. Zber je realizovaný pomocou senzorov snímajúcich informácie o pacientovi a jeho aktivite, primárne EKG,
- Firmware zariadenia – Skladá sa z firmvéru procesora na zber dát a firmvéru procesora, ktorý dane dáta spracováva.
- Algoritmy strojového učenia - Tieto algoritmy majú za úlohu spracovať merané dáta do užitočnej formy, na úrovni vnoreného zariadenia,
- Serverová časť - Zabezpečuje zber dát a komunikáciu so zariadeniami,
- Databázový systém - Umožňujúci ukladanie a spracovávanie dát,
- Webové užívateľské rozhranie - Ktoré umožňuje kontrolovať a nastavovať zariadenia,
- Analytická časť - Ktorá sa zaoberá tvorbou algoritmov na vnorené spracovanie EKG signálu,
- Experimentálna časť - Kde sú popísané vytvorené neurónové siete a ich testovanie na dobrovoľníkoch.

Vytvorená hardvérová platforma bola rozdelená do dvoch častí. Každá časť má samostatné MCU zodpovedné za riadenie senzorov, ku ktorým je pripojené. Komunikácia medzi nimi je realizovaná pomocou RS485 zbernice. Fyzická realizácia zariadenia je vyobrazená na obrázku 3. Na obrázku sú označené jednotlivé časti zariadenia. Zariadenie sa skladá z týchto častí:

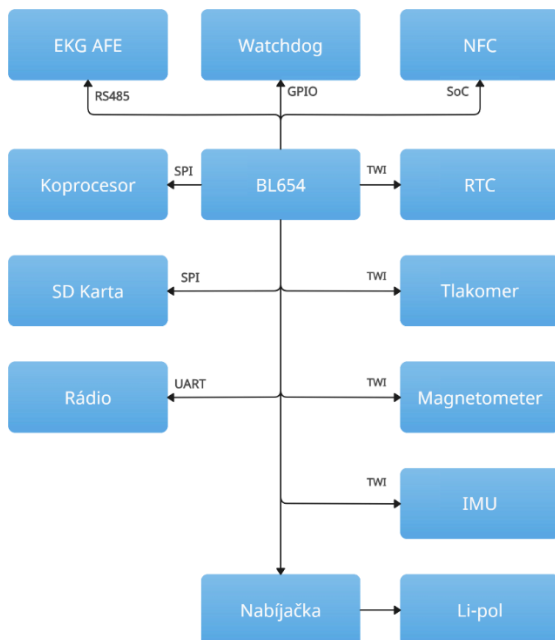
- Základný modul
- Vymeniteľný merací modul (EKG AFE)



Obrázok 3: Vizualizácia hardvérového vyhotovenia meracieho zariadenia.

4.1. Základný modul

Je to najzložitejšia časť zariadenia. Obsahuje batériu a komunikačný modul. Tak isto obsahuje aj všetky potrebné komponenty pre komunikáciu so serverom a pre realizáciu potrebných výpočtov na analýzu signálu. Jednotlivé časti systému sú schematicky zobrazené na obrázku 4.



Obrázok 4: Bloková schéma hlavnej jednotky navrhnutého zariadenia EKG.

Hlavné MCU/BL654 - Zabezpečuje prácu s perifériami a komunikáciu cez bezdrôtové rozhranie. Vybraný procesor vyrábaný spoločnosťou Laird je *NRF52840* vo formáte BL654. Laird zabezpečuje certifikáciu pre komunikačnú perifériu a zároveň poskytuje PCB anténu pre 2,4 GHz perifériu. Tento procesor má dostatočný výkon pre väčšinu použitia. Taktiež zabezpečuje komunikáciu s meracou časťou a preposielanie cez 4G/2G modul na server. Na tomto MCU tak isto prebieha kontrola meraného signálu či obsahuje EKG meranie. Táto kontrola je realizovaná navrhnutým algoritmom.

Koprocessor – Výkonné MCU špecializovane na spracovanie EKG dát. Zvolený procesor je STM32H7, ktorý má oproti hlavnému MCU podstatne vyšší výpočtový výkon. Komunikácia s hlavným MCU je realizovaná cez zbernicu SPI. Hlavné MCU preposiela cez SPI dáta do koprocessora. Ten dáta spracuje a následne je výsledok cez tú istú zbernicu zaslaný späť do hlavného MCU. Hlavné MCU to pomocou komunikačného modulu prepošle na server kde sú dáta verifikovane a uložené.

EKG AFE (Analog front-end) – EKG merací obvod je na oddelenej doske spoločne so svojim vlastným MCU. Tento koncept oddelenia umožňuje pripojiť k platforme viacero typov EKG analógových meracích obvodov. Hlavne viac-zvodových obvodov a to za účelom získavania dát z viacerých elektród. Viac-zvodové merania sa používajú na dôkladnejšiu analýzu zdravotného stavu. Nie vždy je však potrebné použiť vyššie počty elektród. Preto bol zvolený koncept odpojiteľnej časti, aby bolo možné prispôbiť zariadenie danej situácii.

Pridávne senzory – Sem patria senzory magnetometer, akcelerometer a senzor atmosférického tlaku. Senzory, ktoré sú určené na získavanie prídavných dát pre spracovanie, prípadne pre ďalší výskum. Jedna zo sľubných oblastí výskumu s využitím týchto dát je napríklad seizmokardiografia [158]. Tak isto ako EKG merania sú dáta vyzbierané hlavným MCU a sú odosielane na server. Na servery sú ukladane do databázy. Jedným s možným využitím dát z IMU je filtrácia signálu na základe pohybu s použitím napríklad adaptívneho filtrovacieho algoritmu.

Externý watchdog - Zabezpečuje kontrolu senzora pred zlyhaním a zaseknutím programu. Pokiaľ tento modul nie je obnovovaný každých 20 sekúnd, vykoná reset procesora. Reset je vykonaný pomocou reset pinu integrovaného do MCU. Hlavne MCU musí zaslať toto obnovenie vo forme impulzu na GPIO pine.

Samozrejme hlavný mikroprocesor ma vlastný softvérovo nezávislý watchdog, ktorý reštartuje MCU pokiaľ nie je dopytovaný cez vymazanie registra. Ale na základe skúsenosti bolo zistené, že meracie prístroje by mali mať viac záruk spoľahlivosti.

Batéria - 900 mAh batéria, ktorá zabezpečuje napájanie zariadenia. Kapacita batérie bola zvolená na základe požiadaviek komunikačného modulu, ktorý môže mať impulzovo veľkú spotrebu. Hlavnou požiadavkou bola vydrž niekoľko dní pri zápise na SD kartu a niekoľko hodín pri živom režime. Hlavné kritérium pri výbere bola schopnosť baterky dodať v krátkom okamihu dostatok prúdu pre operáciu 4G/2G modemu.

SD karta - Zabezpečuje dátové úložisko pre merane dáta. V živom režime, pokiaľ nie je možné odoslať dáta na server, sa dáta zapíšu na SD kartu. V „offline“ režime sa na kartu zapisujú všetky merane dáta. EKG sa zapisuje v EDF formáte a prídavné senzory sa zapisujú ako CSV. SD karta a koprocessor sú na spoločnej SPI linke pre šetrenie GPIO pinov na hlavnom MCU. Keď chce koprocessor používať SD kartu tak sa musí hlavný MCU odpojiť.

RTC – “Real time clock“ (RTC). Obvod, ktorý zabezpečuje presne meranie času. EKG holter vybavený komunikačným modulom je schopný pomocou internetového pripojenia nastavovať a korigovať čas. Ak by nastal prípad, že internet je nedostupný a zariadenie je prepnuté do zapisovacieho režimu, je pre správnosť merania absolútne nevyhnutné vedieť aktuálny čas.


NFC - Hlavne MCU je vybavené NFC perifériou, ktorá slúži na rýchle sparovanie s ďalšími meracími zariadeniami. Tieto zariadenia môžu použiť komunikačný modul EKG holtera pre odosielanie dát na server. Ďalšie využitie je na rýchlu kontrolu identity zariadenia.

Komunikačný modul – Hlavná súčiastka, ktorá zabezpečuje komunikáciu s internetom. Na trhu je dostupných veľa modelov komunikačných modulov. Preto bolo nutné zostaviť zoznam kritérií, na základe ktorých sa vyberal tento modul. Parametre výberu komunikačného modulu boli veľkosť na doske plošného spoja, maximálna rýchlosť prenosu, využívané prenosové pásma a cena. Ako jeden z najlepších vyšiel modul *EG912Y* [101].

4.2. EKG AFE (Analogový frontend)

Tento modul bol vytvorené ako samostatný odpojiteľný merací modul. Dôvod prečo bol merací obvod navrhnutý ako úplne odpojiteľný obvod je možnosť výmeny meracieho EKG obvodu. Napríklad testovací modul je 3-kanálový ale zariadenie je schopné obslúžiť aj 12 zvodový EKG merací frontend. Táto flexibilita umožňuje prispôbiť sa požiadavkám zdravotníkov. Okrem flexibility je ďalšou výhodou oddelenia meracieho frontendu od zvyšku zariadenia, odľahčenie hlavného MCU od obsluhovania EKG meracej periférie. Táto periféria vyžaduje presné časovanie aby sa pri vyšších frekvenciách nestrácali body EKG signálu. To je kritická časť navrhnutého systému, preto je vhodné použiť na jej realizáciu samostatné MCU.

Na obrázku 5 je schematický opis vytvoreného obvodu aj s vyobrazením komunikačných periférií.



Obrázok 5: Bloková schéma navrhnutého AFE.

BL654 – Blok predstavuje prípojku pre RS485 zbernica pomocou, ktorej sa pripája frontend do hlavnej časti zariadenia.

STM32 – Procesor na obsluhu meracieho frontendu a komunikáciu s hlavnou časťou zariadenia. Oproti hlavnému MCU a koprocesoru ma veľmi nízky výkon. Požiadavky na jeho výpočtové kapacity boli skromné.

LED – Signalizačná dióda, ktorá užívateľovi dáva informáciu o správnej funkčnosti modulu.

EKG AFE – Komerčný merací EKG obvod. V prípade zariadenia, ktoré bolo vytvorené ako časť tejto práce ide o 3 zvodový EKG merací obvod *ADS1292r*. Tento obvod je okrem EKG merania schopný merať aj dýchanie. V prípade komerčného nasadenia bude zariadenie ponúkané aj v 12 zvodovej konfigurácii.

4.3. Datasetsy

Boli vytvorené 2 rozdielne datasetsy pre tréovanie neurónových sietí. Prvý dataset bol menší a bol vytvorený ako prvý “*proof-of-concept*”. Prvý dataset bol využitý kým sa nenazbieralo dost’ dát na väčší dataset.

Druhý dataset bol vytvorený s dátami, ktoré sú využívané pri tvorbe zložitejších neurónových sietí. Získanie prístupu k týmto datasetom trvalo nejaký čas a dovtedy sa využíval menší dataset. Po získaní prístupu sa dáta prekopírovali do druhého datasetu a rozšírili o merania vykonané hardvérovou platformou.

Jedným z hlavných parametrov, ktorý ovplyvňuje tvorbu algoritmov je veľkosť datasetu. Tá môže byť vyjadrená ako počet meraní v celkových nameraných hodinách, počte vzoriek alebo počte meraných ľudí s nejakou minimálnou dĺžkou merania. Na posudzovanie meraní vytvorených pre potreby tejto práce sa ako primárne meradlo vybralo počet meraných ľudí.

Oba datasetsy sa skladajú z dvoch častí, prvá časť sú merania, ktoré boli prebrané s physio.org databázy. Táto časť je najrozsiahljšia a obsahuje veľké množstvo dát z viacerých nemocníc. Zároveň obsahuje merania ľudí, ktorých EKG signál nemá anomálie a aj také merania, ktoré obsahujú deformácie signálu spôsobené zdravotnou poruchou.

Druhá časť datasetu obsahuje merania, ktoré boli vytvorené s využitím vyvíjaného EKG holtera. Tieto merania sú vykonané na osobách bez diagnostikovaných srdcových porúch. Táto časť datasetu je podstatne menšia ale je potrebná pre správne natréovanie neurónových sietí.

Väčší dataset bol vytvorený neskôr a pozostáva z dát, ktoré boli v prvom datasete a následne rozšírené o merania s datasetu PTB-XL. Dataset obsahuje 21799 12-zvodových EKG meraní 10 sekundovej dĺžky. Zhruba polovica meraní patrí mužom a polovica

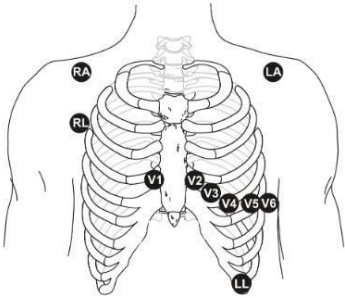
ženám. Veková distribúcia v datasete je od 0 po 95. Vekový medián je 41. Tieto parametre boli zachované pri preberaní dát do tréningového datasetu. Vzorkovacia frekvencia je buď 500 Hz alebo 100 Hz. Pre potreby tréningu je vzorkovacia frekvencia upravovaná pri tréningu pre neurónovú sieť. V tabuľke 1 je vidno rozdelenie jednotlivých meraní podľa porúch.

Počet záznamov	Trieda	Popis
9514	NORM	Normálne EKG
5469	MI	Infarktové
5235	STTC	ST poruchy
4898	CD	Vodivostná chyba
2649	HYP	Hypertrophia

Tabuľka 1: Tabuľka rozdelenia jednotlivých meraní.

Do datasetu bolo z PTB-XL zobrazených 800 meraní s každej poruchy a 1800 meraní normálneho EKG. Druhá časť datasetu je rozšírená o merania ktoré sú robené vytvoreným EKG holterom. Tieto merania sú 2 kanálové a sú urobené zväčša na zdravých ľuďoch. Keďže boli merania vykonávané na dobrovoľníkoch nie je možné garantovať, že boli osoby zdravé. Dobrovoľníci, ktorí vedeli, že majú nejakú srdcovú poruchu to povedali dopredu a ich signál bol označený s danou poruchou.

Mason-Likar 12-zvodové umiestnenie EKG elektród

Miesto	Názov	Farba elektródy	Mason-Likar a Cabrera 12-zvodové umiestnenie EKG elektród
V1	V1	Červená	
V2	V2	Žltá	
V3	V3	Zelená	
V4	V4	Modrá	
V5	V5	Oranžová	
V6	V6	Fialová	
RA	RA	Biela	
LA	LA	Čierna	
LL	LL	Červená	
RL	RL	Zelená	

Obrázok 6: Umiestnenie elektród pri 12-zvodovom meraní. 12-zvodové meranie bolo využité v PTB-XL datasete [156].

Celková veľkosť tohto datasetu je 5520. Pomer nameraných dát k prebraným dátam je 10%. Prevzatý dataset má záznamy vykonané pomocou 12-zvodového EKG, čo je prehnané pre potreby tejto práce. Preto boli dodatočné signály odstránené. Bol ponechaný len jeden kanál aby boli merania porovnateľné s meraniami ktoré boli urobené pomocou vytvoreného EKG holtera. Spôsob umiestnenia meracích elektród pri 12-zvodovom meraní je na obrázku 6.

4.4. Tréningovanie modelov

V tejto časti práce sú zdokumentované výsledky tréningovania neurónových sietí, ktoré boli dosiahnuté pomocou navrhnutého zariadenia, vytvoreného datasetu a vybraných algoritmov.

Podstatou tejto časti je natréňovanie neurónovej siete, ktorá je schopná identifikovať jednotlivé segmenty EKG signálu a ako segmenty prislúchajú meranej osobe. Výhoda oproti klasifikácií jednotlivých porúch je vo fakte, že navrhovaný spôsob neidentifikuje choroby a poruchy, o ktorých pacient už vie. V prípade že nastane zmena v zdravotnom stave, či už zlepšenie alebo zhoršenie, navrhovaný systém by mal zmenu identifikovať a oznámiť to na obsluhujúci server. Pri tréňovaní je to realizované tak, že v jednej triede sú EKG segmenty, ktoré prislúchajú jednej osobe. V druhej triede sú všetky EKG segmenty, ktoré nie sú namerané na osobe z triedy 1. Keďže EKG dataset, ktorý bol použitý obsahuje krátke merania veľkého množstva ľudí, sú merania v 1 triede vždy z vytvoreného EKG holtera.


Vstupný signál je filtrovaný pásmovo priepustným FIR filtrom, s frekvenciou 2-32 Hz. Každý experimentálny návrh neurónovej siete je zdokumentovaný samostatne v nasledujúcej časti práce. Každá časť obsahuje popis neurónovej siete, popis vstupu, ilustračný obrázok štruktúry siete, počet natréňovaní s dosiahnutou úspešnosťou, pravdivostnou tabuľkou pre najlepšiu iteráciu a záverečné vyhodnotenie.

4.5. Experiment #1

Popis: Pokus o natréňovanie “*proof-of-concept*” siete, s využitím nastavení, ktoré sa osvedčili pri biometrickej identifikácii. Sieť bola tréňovaná na menšom datasete. Štruktúra bola vybraná na základe rešerše aktuálneho výskumu, ktorý je v tabuľke 1. Konkrétnou inšpiráciou bola práca Mai a kolektívu [9].

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je podvzorkovaný na 500 Hz. Počet vstupných neurónov je 500.

Priemerná dĺžka vyhodnocovaného merania bola 10 sekúnd. Zámerné boli na experiment vybrané dáta, ktoré boli stabilné, málo zašumené a dostatočne dlhé.



Obrázok 7: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 neurón na obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	FFNN	-
Úprava vstupného signálu	Segmentácia	
Vstupné neuróny	500	-
Výstupné n	1	-
Stratová funkcia	Binary cross entropy	-
Dataset	Menší dataset	-
Optimalizátor	Adam	Learning r: 0.01 %
Dropout	0	-

Skryté vrstvy	Plné spojenie 2	Každá 350 n
Počet natrénovaní	3	-
Zastavenie	Chyba na tréningovacom sete < 20 %, max epoch 200000, zmena na testovacom sete < 2 % pri 50 epochach	-

Tabuľka 2: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	60 %	90 %	-
#2	59 %	92 %	-
#3	62 %	98 %	-

Tabuľka 3: Tabuľka natrénovaní.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	62 %	15 %
Chybné PQRST	13 %	10 %

Tabuľka 4: Výsledky klasifikačného testu najlepšej siete. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.


Vyhodnotenie: Z výsledkov možno usúdiť, že neurónová sieť identifikovala viac poruchových segmentov v meraniach, ktoré pochádzali od ľudí s diagnostikovanou srdcovou vadou. U zdravých ľudí bolí nájdené poruchy v dôsledku niekoľkých faktorov. Relatívne krátka doba tréningovania mohla zapríčiniť, že neurónová sieť počas

optimalizácie uviazla v lokálnom minime a nie v globálnom minime. Nedostatočné odfiltrovanie šumu mohlo spôsobiť narušenie QRS komplexov, ktoré vyzeralo podobne ako srdcová porucha. Sieť sa mohla počas tréningu naučiť identifikovať nesprávne elementy ktoré následne našla v testovacích dátach zdravých pacientov.

4.6. Experiment #2

Popis: Na základe úspechu pri prvom pokuse tréningu siete sa vykonal experiment s rovnakým typom neurónovej siete. Sieť bola trénovaná na druhom, hlavnom vytvorenom datasete. Keďže hlboká FFNN sieť sa ukázala ako vhodná pri predchádzajúcom teste, bolo rozumné predpokladať že zväčšená sieť bude fungovať dobre pri väčšom datasete.

Vstup siete: Rovnako ako pri experimente 1, vstup tvorila jedna sekunda signálu navzorkovaná na 500 Hz. Podvzorkovanie bolo zvolené na základe rešerše dostupnej literatúry.



Obrázok 8: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 neurón na obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	FFNN	-
Vstupné n.	500	-
Výstupné n.	1	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03 %
Dropout	0.3	-
Skryté vrstvy	Plné spojenie 3	Každá 400 neurónov
Počet natrénovaní	2	-
Zastavenie	Chyba na tréningovom sete < 20 %, max epoch 500000, zmena na testovacom sete < 2 % pri 50 epochach	-

Tabuľka 5: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	71 %	90 %	-
#2	63 %	92 %	-

Tabuľka 6: Tabuľka natrénovaných verzií.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	71 %	9 %
Chybné PQRST	6 %	14 %


Tabuľka 7: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných z merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Rovnaký úspech ako pri prvom pokuse bol dosiahnutý aj pri druhom pokuse. Väčšia sieť sa bola schopná naučiť identifikovať signál špecifického pacienta s celého datasetu. Dosiahla lepšie výsledky aj napriek väčšiemu množstvu dát.

4.7. Experiment #3

Popis: Väčšina analyzovaných neurónových sietí využíva grafické spracovanie dát pre CNN. CNN je výpočtovo menej náročná ako RNN sieť a náročnejšia ako FFNN ale vstup pre CNN vyžaduje zložitejšie spracovanie. Táto sieť bola navrhnutá ako test pre porovnanie s plánovanými RNN sieťami. Štruktúra je vytvorená na základe viacerých publikácií [10] [11][12]. Zložitosť CNN pre vnorené využitie bola čiastočne adresovaná využitím 1D konvolúciu nie klasickou 2D. Vstup siete predstavuje výpočet PSD Weltchovou metódou. Na základe preštudovanej literatúry prekryvanie okien pri Weltchovej je dosahuje lepšie výsledky ako Bartletová metóda. Parametrický výpočet PSD v tomto prípade je nerealizovateľný pre komplexitu biologických systémov. Preto bolo zvolená neparаметrická Weltchová metóda.

Vstup siete: Vstup tvoria hodnoty PSD vypočítané pomocou neparаметrickej Weltchovej metódy. Vstup je vypočítaný s 10 sekúnd záznamu. Frekvencia je 500 Hz čo je meracia frekvencia pre PTB-XL dataset a podvzorkovaný signál pre merania vytvorené EKG holterom.



Obrázok 9: Štruktúra neurónovej siete.

Parametre	Hodnota	Poznámka
Typ	CNN/1dconv	-
Vstupné n.	128	-
Výstupné n.	1	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03%
Dropout	0	-
Skryté vrstvy	2 Konvolucne vrstvy 2 max pool vrstvy	Každá 200 neurónov
Počet natren.	3	-
Zastavenie	Chyba na trénoacom sete < 20 %, max epoch 500000, zmena na testovacom sete < 2 % pri 50 epochách	-

Tabuľka 8: Základné parametre neurónovej siete.

Poradie	Testovací s.	Trénovací s.	Poznámka
#1	39 %	91 %	-
#2	43 %	92 %	-
#3	41 %	92 %	-

Tabuľka 9: Tabuľka natrénovaných verzií.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	43 %	21 %
Chybné PQRST	19 %	17 %

Tabuľka 10: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných z merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.


Vyhodnotenie: Výsledky natrénovania tejto siete boli podstatne horšie ako pri pokusoch ktoré používali architektúru FFNN. Pravdepodobná príčina je v spôsobe prípravy dát pre neurónovú sieť. Je možné že výpočet PSD odstránil zo signálu informácie ktoré boli potrebné na identifikáciu segmentov. Dosiahnutý výsledok 43% naznačuje že sieť sa dokázala naučiť niečo s trénovacích informácií.

4.8. Experiment #4

Popis: Druhý pokus o natrénovanie CNN siete s použitím 1 rozmernej konvolúcie. Tak ako pri predchádzajúcej iterácii je štruktúra postavená na prácach výskumníkov. Keďže prechádzajúci pokus nebol úplne úspešný, v tomto pokuse bol ako vstup siete zvolený priamo signál EKG. Sieť bola zväčšená aby sa bola schopná prispôbiť dátam s vyššou zložitosťou. Dáta sa považujú za

zložitejšie pretože nie sú spracované a sieť sa teda musí naučiť zložitejšiu identifikáciu.

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je nevzorkovaný na 500 Hz. Čo je meracia frekvencia preberaného datasetu a pre merania s EKG holtera podvzorkované na 500 Hz s meracej frekvencie 1000 Hz.



Obrázok 10: Štruktúra neurónovej siete.

Parametre	Hodnota	Poznámka
Typ	CNN	-
Vstupné neuróny	500	-
Výstupné neuróny	2	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03 %
Dropout	0	-
Skryté vrstvy	Plné spojenie 2	Každá 120 neurónov
Počet natrénovaní	6	-
Zastavenie	Chyba na tréningovom sete <	-

	20 %, max epoch 20000, zmena na testovacom sete < 2 % pri 50 epochach	
--	--	--

Tabuľka 11: Základné parametre neurónovej siete.

Poradie	Testovací s.	Trénovací s.	Poznámka
#1	55 %	91 %	-
#2	52 %	92 %	-
#3	53 %	92 %	-

Tabuľka 12: Tabuľka viacerých natrénovaní.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	55 %	14 %
Chybné PQRST	22 %	9 %

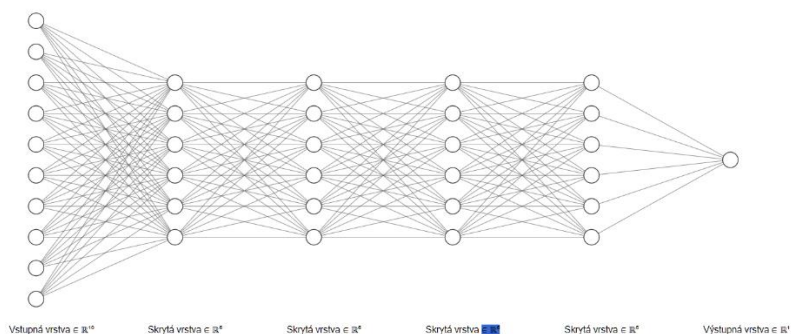
Tabuľka 13: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Použitie väčšej siete, viacej neurónov a dlhšieho tréningového času malo za následok výrazne zlepšenie schopností neurónovej siete klasifikovať PQRST komplexy. Napriek tomu ďalšie zväčšovanie siete by malo príliš veľké nároky na výpočtový výkon zariadenia. Preto sa pristúpilo k testom ďalšej architektúry siete a to RNN.

4.9. Experiment #5

Popis: Prvá RNN sieť. Bola zvolená verzia LSTM, ktorá ma dobré schopnosti modelovať časovo závislé dáta [13]. Sieť bola vytvorená väčšia ako je ideálne pre vnorené použitie za účelom otestovať schopnosti RNN siete prispôbiť sa danému problému.

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, 2 sekundový segment o frekvencií 500 Hz, v prípade dát s EKG holtera bol signál podvzorkovaný. Vstup je 2×500 Hz.



Obrázok 11: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	RNN/LSTM	-
Vstupné neuróny	500	-
Výstupné neuróny	1	-
Stratová funkcia	Binary cross entropy	-

Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03 %
Dropout	0	-
Skryté vrstvy	Plné spojenie 4	Každá 300 neurónov
Počet natren.	3	-
Zastavenie	Chyba na tréningovom sete < 20 %, max epoch 20000, zmena na testovacom sete < 2 % pri 50 epochach	-

Tabuľka 14: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	76 %	95 %	-
#2	74 %	95 %	-
#3	72 %	97 %	-

Tabuľka 15: Tabuľka viacerých tréningov neurónovej siete.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	76 %	7 %
Chybné PQRST	9 %	8 %

Tabuľka 16: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.


Vyhodnotenie: Prvý pokus zo sieťou RNN LSTM dopadol dobre. Podarilo sa natréňovať sieť na výsledok, ktorý bol lepší ako pri FFNN

sieti. Výpočtová náročnosť RNN siete je vyššia ako pri FFNN sieti. Ak sa však podarí získať podstatne lepší výsledok s menšou sieťou bolo by to vhodné na implementáciu do vnoreného zariadenia.

4.10. Experiment #6

Popis: Ďalší pokus so sieťou štruktúry RNN LSTM. Tentokrát bola sieť zmenšená. Zmenšenie sa týkalo vstupnej aj skrytej vrstvy neurónovej siete. Účel zmenšenia bola redukcia nárokov na výpočtový výkon siete. Zmenšenie skrytých vrstiev donútilo sieť viac zovšeobecňovať dáta namiesto memorovania.

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je podvzorkovaný na 250 Hz. Následne je signál nesegmentovaný do 2 okien. Teda vstup tvorí 2x250 bodov.



Obrázok 12: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 neurón na obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	RNN/LSTM	-
Vstupné neuróny	2x250	-

Výstupné neuróny	2	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03 %
Dropout	0	-
Skruté vrstvy	Plné spojenie 3	Každá 200 neurónov
Počet natre.	6	-
Zastavenie	Chyba na tréningovom sete < 20 %, max epoch 20000, zmena na testovacom sete < 2 % pri 50 epochach	-

Tabuľka 17: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	71 %	93 %	-
#2	74 %	92 %	-
#3	72 %	93 %	-

Tabuľka 18: Tabuľka viacerých tréningov neurónovej siete.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	74 %	9 %
Chybné PQRST	9 %	8 %


Tabuľka 19: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných z merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Napriek značnej redukcii vo veľkosti siete, vrátane vstupných informácií, bol dosiahnutý podobný výsledok ako pri experimente č.5. Pokles efektivity o par percent je spôsobený stochastickým charakterom tréningu neurónových sietí.

4.11. Experiment #7

Popis: Pokus o zlepšenie výsledkov a zároveň o čiastočnú redukciu nárokov na výpočtový výkon. Splnenie týchto cieľov stojí na predpoklade, že lepšie predspracovanie údajov umožní neurónovej sieti lepšie zovšeobecnenie údajov aj s menším počtom neurónov. Preto sa vstupné meranie vycentrovalo pomocou R vrcholu PQRST komplexu. R vrchol býva najdominantnejšou časťou PQRST komplexu a preto je využitý. Keďže dominantný, je najmenšia šanca, že ho šum zdeformuje.

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je podvzorkovaný na 250 Hz. Následne je signál nesegmentovaný do 2 okien. Teda vstup tvorí 2×250 bodov. Oproti pokusu 6 je zmena vo využití PT algoritmu na identifikáciu vrcholu v signály. Tento vrchol následne tvorí stred jednotlivých segmentov.



Obrázok 13: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	RNN LSTM	-
Vstupné n.	2x250	-
Výstupné n.	1	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03 %
Dropout	0	-
Skryté vrstvy	Plné spojenie 2	Každá 150 neurónov
Počet natrénovaní	6	-
Zastavenie	Chyba na tréningovom sete < 20 %, max epoch 20000, zmena na testovacom sete < 2 % pri 50 epochach	-

Tabuľka 20: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	85 %	96 %	-
#2	87 %	96 %	
#3	80 %	97 %	

Tabuľka 21: Tabuľka viacerých tréningov neurónovej siete.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	87 %	6 %
Chybné PQRST	6 %	1 %

Tabuľka 22: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania.


Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Podstatné zlepšenie výsledkov neurónovej siete aj napriek zmenšeniu. Zlepšené filtrovanie vstupného signálu ktorý je vycentrovaný s použitím PT algoritmu je schopný podstatne lepšie modelovať problém. Ďalšie zlepšenie by mohlo byť dosiahnuté pridaním HRV parametrov do vstupných dát.

4.12. Experiment #8

Popis: Pokus o podstatné zmenšenie neurónovej siete RNN LSTM. Oproti predošlému pokusu

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je podvzorkovaný na 250 Hz. Následne je signál nesegmentovaný do 2 okien. Teda vstup tvorí 2×250 bodov.



Obrázok 14: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	RNN lstm	-
Vstupné n.	2x250	-
Výstupné n.	1	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.: 0.03 %
Výpadok	0	-
Skryté vrstvy	Plné spojenie 2	Každá 150 neurónov
Počet natrénovaní	3	-
Zastavenie	Chyba na tréningovom sete < 20 %, max epoch 20000, zmena na testovacom sete < 2 % pri 50 epochách	-

Tabuľka 23: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	65 %	92 %	-
#2	62 %	93 %	-
#3	58 %	95 %	-

Tabuľka 24: Tabuľka viacerých tréningov neurónovej siete.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	65 %	20 %
Chybné PQRST	15 %	10 %

Tabuľka 25: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený


počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Odstránenie skrytej vrstvy spôsobilo značnú stratu presnosti. Pravdepodobne ďalšie zmenšovanie siete nie je možné bez zníženia výkonu.

4.13. Experiment #9

Popis: Návrat ku štruktúre z pokusu č.7. Pokus o vylepšenie funkčnosti siete pridaním HRV parametrov, ktoré by mohli umožniť sieti lepšie modelovať veľké časové závislosti bez zväčšenia štruktúry.

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je podvzorkovaný na 250 Hz. Následne je signál nesegmentovaný do 2 okien. Teda vstup tvorí 2×250 bodov. Oproti pokusu 7 je zmena v pridaní 2 vstupných neurónov, ktoré predstavujú HRV parametre. Využitý dataset však obsahuje len 10 sekundové merania. Preto sú tieto HRV parametre vypočítane len z 10 sekundových vzoriek. Pre dáta z veľkého datasetu sú použité 10 minútové vzorky.



Obrázok 15: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 neurón na obrázku 50 reálnych neurónov.

Parametre	Hodnota	Poznámka
Typ	RNN lstm	-
Vstupné n.	2x250	-
Výstupné n.	2	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	Adam	Learning r.:0.03 %
Výpadok	0	-
Skryté vrstvy	Plné spojenie 3	Každá 150 n.
Počet natrénovaní	3	-
Zastavenie	Chyba na tréningovom sete < 20 %, max epoch 20000, zmena na testovacom sete < 2 % pri 50 epochách	-

Tabuľka 26: Základné parametre neurónovej siete.

Poradie	Testovací s.	Tréningový s.	Poznámka
#1	83 %	90 %	-
#2	85 %	90 %	-
#3	81 %	90 %	-

Tabuľka 27: Tabuľka viacerých tréningov neurónovej siete.

Reálna/Správna	Správne PQRST	Chybné PQRST
Správne PQRST	85 %	3 %
Chybné PQRST	5 %	7 %

Tabuľka 28: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania. Počet klasifikovaných ako problémových je percentuálne vyjadrený


počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Zatiaľ najlepší dosiahnutý výsledok pri tréningu neurónových sietí. 93% predstavuje výsledok, ktorý je zhodný s výsledkami dosiahnutými inými výskumníkmi pri analýze EKG signálov využitím algoritmov strojového učenia.

4.14. Experiment #10

Popis: Sieť bola trébovaná za účelom zistiť vplyv pridania dlhšej vstupnej sekvencie dát. Štruktúra siete zostala rovnaká ako pri experimente č.9.

Vstup siete: Vstup siete tvorí EKG signál vybraný z datasetu, ktorý je podvzorkovaný na 250 Hz. Následne je signál nesegmentovaný do 4 okien. Teda vstup tvorí 4x250 bodov.



Obrázok 16: Ilustračná štruktúra neurónovej siete, v skrytej vrstve a vstupnej vrstve reprezentuje 1 neurón na obrázku 50 reálnych neurónov. Sú pridané 2 vstupne neuróny pre HRV parametre.

Parametre	Hodnota	Poznámka
Typ	RNN lstm	-
Vstupné neuróny	4x252	-
Výstupné neuróny	1	-
Stratová funkcia	Binary cross entropy	-
Dataset	Hlavný dataset	-
Optimalizátor	SGD	Learning rate: 0.03 %, Momentum: 0.5
Výpadok	0	-
Skryté vrstvy	Plné spojenie 3	Každá 150 neurónov
Počet natrénovaní	3	-
Zastavenie	Chyba na tréningovej sieti < 20 %, max epoch 20000, zmena na testovacom sieti < 2 % pri 50 epochách	-

Tabuľka 29: Základné parametre neurónovej siete.

Poradie tréningov	Úspešnosť	Úspešnosť na tréningovej sieti	Poznámka
#1	80 %	90 %	-
#2	81 %	90 %	-
#3	84 %	90 %	-

Tabuľka 30: Tabuľka viacerých tréningov neurónovej siete.

Pravdivostná tabuľka	Správne PQRST	Chybné PQRST
Správne PQRST	84 %	3 %
Chybné PQRST	6 %	7 %

Tabuľka 31: Výsledky klasifikačného testu. Počet analyzovaných segmentov je celkový počet segmentov extrahovaných s merania.

Počet klasifikovaných ako problémových je percentuálne vyjadrený počet segmentov, ktoré neurónová sieť vyhodnotila ako podobné segmentu srdcovej poruchy.

Vyhodnotenie: Dosiahnutý výsledok je zhodný s výsledkom pri experimente č. 9. Pridanie viacerých okien do vstupnej sekvencie nemalo prakticky žiaden vplyv na výsledok siete. Reálne sieť zaznamenala pokles o 1%. Stále sa považuje experiment č.9 za najlepší.


4.15. Postup vnorenej implementácií

Vnorená implementácia pozostávala z dvoch častí. Vnorenia algoritmov, ktoré spracovávajú vstupné dáta pre neurónovú sieť a následné vnorenie neurónovej siete.

Postup zberu dát v zariadení je nasledovný. Dáta sú získané od primárneho *NRF52* MCU, ktoré ich získava z meracieho AFE. Následne sú pomocou SPI zbernice odoslané do sekundárneho *STM32* procesora. V procesore sú spracované ako 1000 bodové merania, kde každé meranie ma 24 bitov. Takéto dáta sú vyčítavané z meracieho AFE.

Komunikácia po zbernici SPI je realizovaná pomocou systému DMA, ktorý vkladá dáta priamo do pamäte MCU bez nutnosti zaťažovať procesor. To umožňuje realizovať výpočty na MCU kým sa nahráva ďalší merací paket. Medzi primárnym a sekundárnym MCU je pridaná DRDY linka pomocou ktorej primárne MCU zisťuje či je sekundárne MCU pripravené prijať ďalší merací paket. Za normálnych okolností je sekundárne MCU schopné spracovať dáta rýchlejšie ako sú namerané. To bolo predmetom optimalizácie, aby čas na vykonanie prechodu neurónovou sieťou aj so

spracovaním signálu zabral menej ako čas merania. Pokiaľ nastane situácia, že primárne MCU chce odoslať správu do sekundárneho ale DRDY pin je vstave obsadenia, tak sa o tom odošle chybová správa na server. Zber chýb je implementovaný aj vo firmvéri vo vnorenej časti aj na servery. Chyby sú pravidelné kontrolované a opravované.



Obrázok 17: Graf fungovania vnorenej implementácie neurónovej siete.

Postup výpočtu dát je znázornený na obrázku 17 a skladá sa z vyzbierania dát od primárneho MCU. Tieto dáta sú následne skontrolované či obsahujú EKG meranie. Ďalej sú segmentované na veľkosť, ktorá je daná veľkosťou vstupnej vrstvy neurónovej siete. Je aplikovaný pásmovo priepustný FIR filter, ktorý prepustí frekvencie od 5-32 Hz. FIR filter je 9 rádu. Následne sa vykoná prvá derivácia signálu. Výsledný signál je umocnený na druhú. Vypočíta sa priemerná hodnota signálu na základe plávajúceho okna o veľkosti 3000 bodov. Priemerná hodnota sa použije ako prahovacia hodnota na identifikáciu R vrcholov PQRST komplexu. Pokiaľ sa v danom okne nenašla hodnota, ktorá je nad prahovou hodnotou, prahová hodnota sa zníži o 10 % a vráti sa o okno dozadu.

Keď sú R vrcholy identifikované, sú zobrazené ich časové značky a signál pred prvou deriváciou po prechode FIR filtrom. Tento signál je segmentovaný časovými značkami R vrcholov na polovicu tak aby bod R vrcholu bol v strede segmentu, ktorý vchádza do neurónovej siete. Následne sú dopyčítané časové HRV parametre, ktoré sú tak isto vložené do neurónovej siete. Je vykonaný prechod neurónovou sieťou.


Pokiaľ výstup neurónovej siete hovorí, že signál obsahuje anomáliu je odoslaný na server na kontrolu. Pokiaľ segment neobsahuje anomálie čaká sa na ďalší segment.

4.16. Testovanie vnorenej implementácie a výsledky

Vybraná neurónová sieť bola v konečnej fáze implementovaná do vnoreného zariadenia. Implementácia prebiehala na základe otestovaných a voľne dostupných zdrojových kódov, ktoré ponúkajú pred-implementované modely jednotlivých neurónových sietí. Jedna z týchto implementácií bola prezvaná, upravená a otestovaná. Následne vnorená do sekundárneho *STM32* mikroprocesora. Štruktúra siete zostáva stabilná a cez vytvorený serverový systém sa do nej vložia natrénované váhy a vnútorné hodnoty neurónov.

Postup testovania:

1. Zariadenie bolo pripojené na pacienta podľa obrázka 18.



Obrázok 18: Schéma zapojenia elektród na hrud' pacienta, boli pripojené elektródy RA,LA,LL [157].

2. Po pripojení na pacienta bolo pomocou vytvoreného serverového systému zapnuté meranie. Server odoslal do sekundárneho procesora natrénovanú neurónovú sieť. Keďže tréning vyžaduje niekoľko hodinové, kvalitné meranie bolo len málo ľudí, na ktorých sa zariadenie mohlo testovať.
3. Počítal sa počet segmentov ktoré boli nameranú a počet segmentov, ktoré boli vnorenou neurónovou sieťou označené za anomálie. V reálnom nasadení by mali byť anomálne segmenty analyzované lekárom.
4. Meranie trvalo 6 hodín a nakoniec sa počet identifikovaných segmentov vydělili celkovým počtom segmentov aby sa získalo celkové percento úspešnosti.
5. Následne sa signál zanalyzoval. Segmenty, ktoré boli označené ako anomálie boli buď skreslené pohybom meraného dobrovoľníka alebo zle identifikované sieťou. Pre potreby tohoto testu bola zanedbaná možnosť, že by dobrovoľníci mali nejakú srdcovú poruchu, o ktorej nevedeli.

6. Opakovalo sa vykonané meranie znova. V tabuľke 31 sú zaznamenané výsledky.

Dobrovoľník	Úspešnosť #1	Úspešnosť #2
Správne PQRST	72 %	13 %
Chybné PQRST	7 %	8 %

Tabuľka 31: Zhrnutie dosiahnutých výsledkov

Prvé meranie malo značnú časť segmentov označenú za anomálie. I keď je predpokladané, že istá časť segmentov bude vždy označená ako anomálna v dôsledku šumu a externých vplyvov. Tak isto časť meraní bude označená za anomáliu v dôsledku komplexnosti biologických systémov. To však nevysvetľovalo tak vysokú mieru anomálií. Predpokladá sa, že sieť nebola dostatočne natrénovaná. Preto bolo vykonané dodatočné dotrénovanie.

Po dotrénovaní dosiahla vnorená sieť podstatne lepšie výsledky. Systém navrhnutý v tejto práci umožňuje kontinuálne prezerat' a upravovat' výstup neurónovej siete. Cieľom je aby sa nakoniec dali reálne pozorovat' zmeny v zdravotnom stave pacienta bez nutnosti manuálne prezerat' celý signál.

Ďalší výskum vo vývoji tohoto systému bude zahrňovat' návrh robustnejších algoritmov na výpočet IBI. PT algoritmus funguje dobre ale pridaním napríklad adaptívnych filtrov, ktoré spracovávajú dáta z akcelerometra by mohlo byť možné získať presnejší výstup.

Zlepšením príznakovej analýzy pred vstupom do neurónovej siete by malo byť možné skrátiť tréningový čas aj množstvo dát potrebné na natrénovanie neurónovej siete.

5. Záver

V tejto práci je popísaný systém na zber, analýzu a filtráciu EKG dát od pacientov. V práci je popísaný vytvorený hardware systému na zber EKG dát, serverová aplikácia na spracovanie EKG dát a riadenie holtera. Webové užívateľské rozhranie ktoré umožňuje prezeranie a nastavovanie zariadenia. Zber dát je realizovaný pomocou navrhnutého EKG holtera ktorého testovania a funkčnosť bol jeden s hlavných bodov tejto práce.

Prvá časť dizertačnej práce je teoretická a objasňujú sa v nej **základné poznatky z oblasti elektrokardiografie**. Sú zhrnuté základné princípy tvorby EKG, jeho prínosu pre sledovanie zdravotného stavu, skrátená história **elektrokardiografie a elektrická realizácia EKG**. V ďalšej sekcii sú zhrnuté základné poznatky o **HRV analýze**. Sú zdokumentované časové, frekvenčné a nelineárne metódy výpočtu HRV parametrov. Sú zhrnuté spôsoby výpočtu jednotlivých parametrov a ich využitie v analýze zdravotného stavu pacienta. Zdokumentované sú rôzne metódy využívané a tréovania neurónových sietí. Vytvorený prehľad najpoužívanejších typov neurónových sietí a ich potenciálne využitie na analýzu biologických signálov. Je vytvorený popis funkčnosti trénovacieho algoritmu pre neurónové siete a niektorých verzii trénovacieho algoritmu pre siete ktoré sú využitie neskôr pri tvorbe daných neurónových sietí. **Tak isto sú zhrnuté nove poznatky z oblasti HRV analýzy a jej využitia v biometrii.**

Je vytvorený prehľad biometrie a aktuálneho stavu EKG biometrie. Využitie biometrie na analýzu EKG signálu a monitorovanie zdravotného stavu človeka. Zahrňuje prehľad dostupných a používaných zdrojov dát pre tréovanie neurónových sietí pri biometrii, tieto dátové zdroje sú analyzované na základe veľkosti a využiteľnosti pre účely tejto práce.

Bol vytvorený rešerš využitia neurónových sietí a strojového učenia v oblasti biometrie a spracovania HRV parametrov. Tento zoznam prác iných výskumníkov bol využitý ako základ pre neurónové siete a spracovanie signálov v tejto práci.

Druhá časť práce je experimentálna a obsahuje popis navrhnutého zariadenia na zber dát. Opisuje jeho fungovanie po hardverovej aj firmwarovej časti. **Vytvorený EKG holter disponuje 2 MCU** jedno ktoré ovláda väčšinu periférií a merania. Druhé ktoré slúži na analýzu meraného signálu. V druhom MCU sú vytvorené vnorené neurónové siete. Vytvorený EKG holter má odpojiteľný EKG AFE. To umožňuje vytvorenému zariadeniu robiť viac kanálové meranie len s jednoduchou výmenou frontendu. Vytvorený EKG AFE je 2 kanálový, vytvorenie 12 kanálového AFE je naplánované pri nasadení do komerčnej prevádzky.

Okrem EKG signálu sú v zariadení integrované aj senzory atmosférického tlaku, akcelerometer a magnetomer. Dáta s týchto senzorov sú zasielané na server spolu s EKG dátami a pracujú rovnako vo všetkých operačných režimoch.

Sú zdokumentované experimenty ktoré boli vykonané za účelom overenia funkčnosti meracieho frontendu. Porovnávanie signálu prebiehalo s využitím komerčného EKG holtera a generátora signálu. Pomocou tohto komerčného holtera boli vykonané kalibračné merania.

Bol vytvorený firmware pre navrhnutý EKG holter ktorý má 4 rozdielne operačné režimy. Režimy boli vytvorené na základe konzultácií s kardiológmi a lekármi ktorý zariadenie testovali. **Prvý režim umožňuje zariadeniu zasielať aktuálne merania na server a v reálnom čase ich zobrazovať na vytvorenom webovom rozhraní.** Tento režim ma časovú odozvu na úrovni 3 sekúnd. Daný režim umožňuje kontrolovať aktuálny signál a nastavenia jednotlivých senzorov.

Druhý implementovaný režim zapisuje namerané dáta na SD kartu, aktivuje sa automaticky keď holter stratí spojenie so serverom alebo keď je zariadenie nastavené do tohto režimu obsluhou. Danom režime zariadenie vydrží niekoľko dní robiť EKG záznam. Rovnako požiadavka na viacdňové EKG meranie prišla od lekárov. Na základe výskumu ktorý bol analyzovaný pre potreby tejto práce vyplynulo že viacdňové merania umožňuje robiť komplexnejšie HRV analýzy a sú schopné zachytiť viac druhou zdravotných porúch s väčšou presnosťou.

Tretí operačný režim zasiela dáta na server vo forme vypočítaných HRV parametrov. Bolo vybraných niekoľko HRV parametrov ktoré dobré odrážajú aktuálny stav pacienta. Hlavne časové parametre ktoré nezaťažujú procesor zbytočným nárokom na výpočtový výkon. Keďže sú zasielané na server len vypočítané dáta šetrí sa šírka prenosového pásma a dané údaje je možné zasielať aj po 2G sieti. Čo umožňuje obsluhu monitorovať zdravotný stav pacienta v reálnom čase aj v oblastiach s horším pripojením do siete.

Posledný, štvrtý operačný režim ukladá namerané dáta na kartu ale signál je analyzovaný sekundárnym výpočtovým procesorom v ktorom je implementovaná vnorená neurónová sieť. **Neurónová sieť vykonáva analýzu a pokiaľ sú dáta vyhodnotené za anomálne sú odoslané na server** aby upozornili operátora zariadenia na potencionálny zdravotný problém. Tento režim je vysoko experimentálny a vyžaduje mať s daného človeka niekoľko hodinové EKG meranie aby bolo možné pretrénovať neurónovú sieť špecificky na daného človeka.

Boli vykonané funkčné testy firmvéru. Testovanie prebiehalo spoločne s testovaním hardveru a testovaním serverovej časti. Počas týchto testov boli zbierané merania rôznych ľudí. **Boli zbierané meranie EKG, dýchanie, magnetického poľa, atmosférického tlaku a akcelerometrické dáta.** Nazbierané dáta boli následne manuálne prekontrolované aby sa zistili prípadne nedostatky alebo

chyby. Následne boli dáta označené a pripravené pre dataset. Počas testovanie navrhnutého zariadenia sa testovala aj možnosť využiť zariadenie na vytvorenie BAN siete. Táto sieť bola vytvorená spoločne s podpazušným teplomerom a PPG senzorom ktorý bol umiestnený na hrud' meraného pacienta. Prídavne zariadenia nedisponovali možnosťou odosielať dáta priamo na server. Preto sa všetky dáta preposielali pomocou 2G/4G modulu navrhnutého zariadenia. Takáto fúzia senzorov bude predmetom ďalšieho skúmania ale s doterajších testov sa ukázalo že navrhnuté zariadenie je schopné efektívne preposielať prídavne dáta. Dodatočné výzvy zostávajú v synchronizácií dát.

Pomocou nakalibrovaného EKG holtera bolo vykonaných 140 jedinečných meraní. Tieto dáta po manuálnej kontrole boli vložené do vytvoreného datasetu ktorý bol vytvorený pre tréning neurónových sietí. Do datasetu boli doložené dáta s veľkého akademického datasetu PTB-XL. Prístup do tohoto datasetu bol dodaný na základe splnených požiadavok na zabezpečenie ochrany osobných údajov a splnenie certifikácie na správu lekárskeho údajov. Konečný dataset má veľkosť 4500 meraní. Väčšina meraní pochádza s datasetu PTB-XL. Menšia časť s nameraných dát.

Na vytvorenom datasete bolo natrénovaných niekoľko desiatok neurónových sietí. Boli vyskúšané rôzne architektúry s rôznymi výsledkami. Cieľom bolo natréovať neurónovú sieť ktorá je schopná rozoznať či daný PQRST komplex EKG signálu patrí meranému človeku. Oproti väčšine zvažovaných prístupov tento spôsob analýzy EKG signálu umožňuje používať EKG holter na ľuďoch ktorý majú známu poruchu na srdci bez toho aby daná porucha spôsobovala zbytočné označovanie. **Takto natrénovaná neurónová sieť je následne využívaná v štvrtom operačnom režime na to aby sa zasielali na server len dátové segmenty ktoré sú nezvyčajné alebo obsahujú nejaké anomálie.** Takýto prístup šetrí čas lekára, udržuje lekára informovaného o aktuálnom stave pacienta a šetrí prenosové pásmo EKG zariadenia.

Najlepšie výsledky dosiahla neurónová sieť typu RNN LSTM ktorá spĺňala kritéria výpočtového výkonu aj dobrej úspešnosti. **Pred optimalizáciou a vnorením neurónová sieť mala úspešnosť 93% na vytvorenom datasete.** Vstup do neurónovej siete boli 4*2 sekundové EKG meranie s 30% prekryvaním. Spoločne s filtrovaným signálom boli zasielané do neurónovej siete aj HRV parametre AVNN a SDNN. Pridanie týchto parametrov malo malý vplyv na výpočtové nároky neurónovej siete ale zvýšilo to úspešnosť identifikácie.

Následne prebiehalo vnorenie neurónovej siete do zvoleného stm32 mikrokontrolera. Optimalizácia neurónovej siete bola vykonaná pomocou niekoľkých optimalizačných stratégií. Išlo o riešenie spojení, kvantizácia váh a posunov vo vnútri neurónov a obmedzenie výkonu. Po optimalizácii sa podarilo znížiť výpočtové nároky neurónovej siete o 40% za cenu zníženia efektivity identifikácie o 10% na 83%.

Testovanie funkčnosti neurónovej siete prebiehalo podobne ako testovanie celkového zariadenia pri zbere dát. Zariadenie bolo pripojené na pacienta. Pomocou vytvoreného systému boli do sekundárneho procesora nahraté parametre neurónovej siete ktorá bola natrénovaná monitorovať daného človeka. EKG holter bol prepnutý do monitorovacieho režimu. V testovacom režime bol na server odosielaný celý výstup neurónovej siete aby sa dali diagnostikovať chyby. **Proces bol zopakovaný na 4 ľudoch s priemernou úspešnosťou identifikácie 72%.** Bolo zistené že na úspešné natrénovanie neurónovej siete je potrebný aspoň 20 hodinový záznam aby vedela neurónová sieť úspešne monitorovať zmeny v signály.

Dosiahnuté výsledky sú porovnateľné s výsledkami dosiahnutými inými výskumníkmi ktoré práce boli analyzované. Lepšie výsledky by mohli byť dosiahnuté zmenou hardveru navrhnutého zariadenia ak by bol pridaný výpočtový akcelerátor. Inou možnosťou by mohlo byť prídanie výkonnejšieho MCU na spracovávanie neurónovej siete. Prídanim analýzy integrovaných senzorov by sa tak isto mohlo zlepšiť

celková úspešnosť systému. Využitie adaptívneho filtrovania dát alebo zakomponovanie príznakovej analýzy pre akcelerometer do neurónovej siete by mohlo zlepšiť výsledky.

Okrem zmien za účelom zlepšenia úspešnosti detekcie by sa ďalší výskum mohol uberať smerom sensorovej fúzie kde by sa k EKG signálu pridal PPG signál ktorý je získavaný oddelenými zariadeniami a kombinoval s EKG. Experimenty ktoré boli vykonané naznačujú že by bolo možné kombinovať EKG signál s PPG signálom za účelom výpočtu tlaku.

6. Zhrnutie dizertačnej práce

Hlavné ciele dosiahnuté v tejto práci sú:

- Boli analyzované a popísané najnovšie postupy v oblasti HRV analýzy, biometrie a využitia neurónových sietí na klasifikáciu EKG signálu
- Bol vytvorený EKG holter ktorý slúži na zber dát a následne bol vytvorený dataset EKG meraní pre analýzu v ďalšej časti práci
- Pomocou generátora signálu a komerčného EKG holtera sa overila funkčnosť daného zariadenia
- Bol vytvorený systém ktorý umožňuje zbieranie EKG meraní s veľkého množstva EKG holterov, umožňuje ukladanie, čistenie a hodnotenie EKG záznamov
- Bola vytvorená možnosť ovládať EKG holter cez web
- Nameraný dataset bol rozšírený o existujúce datasety ktoré sú dostupné na akademické použitie
- Vytvorené zariadenia je možné využiť na vytvorenie BAN siete, táto možnosť bola zanalyzovaná a prvé výsledky zdokumentované
- Boli vytvorené neurónové siete ktoré sa pomocou iterácií natrénovali do stavu kde by sú schopné identifikovať zdravotné poruchy na pacientoch
- Vybraná neurónová sieť typu RNN LSTM mala 93% úspešnosť pri identifikovaní segmentov
- Najlepšia neurónová sieť bola optimalizovaná a implementovaná do vnoreného zariadenia
- Optimalizácia prebiehala odstraňovaním nadbytočných spojení medzi neurónmi, kvantizáciou neurónovej siete a optimalizáciou štruktúry

- Vnorenie bolo vykonané priamou implementáciou neurónovej siete do stm32 MCU kde bola jej funkčnosť overená na dobrovoľníkoch
- Po optimalizácií mala neurónová sieť úspešnosť 78% na testovacom datasete
- Boli vykonané testy vnorenej neurónovej siete, niekoľko hodinové meranie na 4 ľuďoch 83% PQRST komplexov bolo vyhodnotených ako normálnych

7. Summary

Main aims of this thesis have been accomplished. They are:

1. Analysis of current trends in HRV, biometrics and embedded neural network training.
2. An EKG holter has been constructed that was used to create an EKG dataset to be used in the later part of the thesis.
3. Using a signal generator and a commercial EKG holter the functioning of the designed holter has been verified.
4. A system has been designed to facilitate collection, analysis, cleaning and viewing of measured EKG samples.
5. A system has been designed to allow control of EKG hollers from a web interface.
6. The created dataset has been increased by commonly used academic EKG datasets.
7. Demonstration of usage of the EKG holer as a BAN router has been documented.
8. Several neural networks have been trained to the point that they can identify health problems on patients.
9. Best neural network uses LSTM RNN architecture and has a success rate of 85%.
10. The best neural network has been embedded into the created EKG holter.
11. The embedded neural network has been optimized using pruning, quantization and structure optimization.
12. The functioning of the neural network has been verified by performing measurements on 4 volunteers. Success rate of PQRST complex identification has been 72%.

8. Zoznam použitej literatúry

ADC Vedecké práce v zahraničných karentovaných časopisoch

- ADC01 VAVRINSKÝ, Erik [23 %] - ZÁVODNÍK, Tomáš [10 %] - DEBNÁR, Tomáš [7 %] - ČERNAJ, Ľuboš [7 %] - KOZÁRIK, Jozef [7 %] - MIĚJAN, Michal [8 %] - NEVŘELA, Juraj [8 %] - DONOVAL, Martin [7 %] - KOPÁNI, Martin [5 %] - KOSNÁĚOVÁ, Helena [18 %]. Research and development of a COVID-19 tracking system in order to implement analytical tools to reduce the infection risk. In *Sensors*. Vol. 22, iss. 2 (2022), Art. no. 526 [21] s. ISSN 1424-8220 (2022: 3.900 - IF, Q2 - JCR Best Q, 0.764 - SJR, Q1 - SJR Best Q). V databáze: CC: 000747723100001 ; WOS: 000747723100001 ; SCOPUS: 2-s2.0-85123510137 ; DOI: 10.3390/s22020526.
Typ výstupu: článok; Výstup: zahraničný; Kategória publikácie od 2022: V3

ADM Vedecké práce v zahraničných časopisoch registrovaných v databázach Web of Science alebo SCOPUS

- ADM01 VAVRINSKÝ, Erik [30 %] - KOTRADYOVÁ, Veronika [20 %] - SVOBODOVÁ, Helena [20 %] - KOPÁNI, Martin [10 %] - DONOVAL, Martin [5 %] - SEDLÁK, Samuel [5 %] - ŠUBJAK, Ján [5 %] - ZÁVODNÍK, Tomáš [5 %]. Advanced wireless sensors used to monitor the impact of environment design on human physiology. In *Advances in Electrical and Electronic Engineering*. Vol. 17, No. 3 (2019), s. 320-329. ISSN 1336-1376 (2019: 0.205 - SJR, Q3 - SJR Best Q). V databáze: DOI: 10.15598/aeec.v17i3.3310 ; WOS: 000488257400011 ; SCOPUS: 2-s2.0-85073506187.
Kategória publikácie od 2022: V3
- ADM02 VAVRINSKÝ, Erik [50 %] - ŠUBJAK, Ján [10 %] - DONOVAL, Martin [5 %] - WAGNER, Alexandra [5 %] - ZÁVODNÍK, Tomáš [5 %] - SVOBODOVÁ, Helena [25 %]. Application of modern multi-sensor holter in diagnosis and treatment. In *Sensors*. Vol. 20, Iss. 9 (2020), Art. no. 2663 [21] s. ISSN 1424-8220 (2020: 3.576 - IF, Q1 - JCR Best Q, 0.636 - SJR, Q2 - SJR Best Q). V databáze: DOI: 10.3390/s20092663 ; WOS: 000537106200227 ; SCOPUS: 2-s2.0-85084373704.
Kategória publikácie od 2022: V3

BEF Odborné práce v domácich zborníkoch (konferenčných aj nekonferenčných)

- BEF01 KOSNÁČOVÁ, Helena [35 %] - VIŤAZKOVÁ, Diana [20 %] - ZÁVODNÍK, Tomáš [15 %] - BARTOŠ, Patrik [5 %] - KASZNÁR, Martin [5 %] - VAVRINSKÝ, Erik [20 %]. Nositeľný EOG systém pre ľudí s amyotrofičkou laterálnou sklerózou. In *44. Dni lekárskej biofyziky : Zborník abstraktov. Stará Lesná, Slovakia. 31.05.-02.06.2023*. Bratislava : Univerzita Komenského v Bratislave, 2023, S. 48-49.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: O2
- BEF02 VAVRINSKÝ, Erik [20 %] - VIŤAZKOVÁ, Diana [10 %] - KOSNÁČOVÁ, Helena [10 %] - MICĽAN, Michal [10 %] - DONOVAL, Martin [10 %] - ZÁVODNÍK, Tomáš [10 %] - ČERNAJ, Ľuboš [10 %] - JAGELKA, Martin [10 %] - KOZÁRIK, Jozef [10 %]. História dizajnu telemedicínskych zariadení na Ústave elektroniky a fotoniky FEI STU. In *44. Dni lekárskej biofyziky : Zborník abstraktov. Stará Lesná, Slovakia. 31.05.-02.06.2023*. Bratislava : Univerzita Komenského v Bratislave, 2023, S. 78-79.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: O2
- BEF03 VIŤAZKOVÁ, Diana [40 %] - ZÁVODNÍK, Tomáš [20 %] - GAŠPAREK, Krisztián [8 %] - KOSNÁČOVÁ, Helena [7 %] - VAVRINSKÝ, Erik [15 %] - MICĽAN, Michal [10 %]. Aplikácia pokročilého PPG multisenzora v polysomnografických vyšetreniach. In *44. Dni lekárskej biofyziky : Zborník abstraktov. Stará Lesná, Slovakia. 31.05.-02.06.2023*. Bratislava : Univerzita Komenského v Bratislave, 2023, S. 81-82.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: O2

AGJ Autorské osvedčenia, patenty, objavy

- AGJ01 ČERNAJ, Ľuboš [20 %] - NEVØELA, Juraj [10 %] - DONOVAL, Martin [10 %] - MIEĽAN, Michal [10 %] - DEBNÁR, Tomáš [5 %] - GAŠPAREK, Krisztián [10 %] - ZÁVODNÍK, Tomáš [20 %] - KOZÁRIK, Jozef [10 %] - JAGELKA, Martin [5 %]. *Nositeľné biomonitorovacie zariadenie a spôsob monitoringu pacienta : Úžitkový vzor č. 9722, Dátum oznámenia o sprístupnení dokumentu : 29.3.2023, Vestník ÚPV SR č. 6/2023*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2023, 8 s. Dostupné na internete: <<https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/90-2022?csrt=17138102622100521421>>.
Typ výstupu: úžitkový vzor; Výstup: domáci; Kategória publikácie od 2022: D1
- AGJ02 KOZÁRIK, Jozef [25 %] - ČERNAJ, Ľuboš [10 %] - GAŠPAREK, Krisztián [10 %] - DEBNÁR, Tomáš [10 %] - ZÁVODNÍK, Tomáš [25

%] - NEVŘELA, Juraj [5 %] - MAREK, Juraj [5 %] - MÍČJAN, Michal [5 %] - DONOVAL, Martin [5 %]. *Multifunkčný komunikačný bod na implementáciu v telemedicíne : Úžitkový vzor č. 9609, Dátum oznámenia o sprístupnení dokumentu : 12.10.2022, Vestník ÚPV SR č. 19/2022*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2022. 6 s. Dostupné na internete:
<<https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/50085-2021?csrt=17138102622100521421>>.
Typ výstupu: úžitkový vzor; Výstup: domáci; Kategória publikácie od 2022: D1

AGJ03 ZÁVODNÍK, Tomáš [10 %] - ČERNAJ, Ľuboš [5 %] - GAŠPAREK, Krisztián [10 %] - DEBNÁR, Tomáš [10 %] - NEVŘELA, Juraj [5 %] - MIEĽJAN, Michal [5 %] - DONOVAL, Martin [5 %] - KOZÁRIK, Jozef [25 %] - JAGELKA, Martin [25 %]. *Multisenzorická modulárna IoT platforma na meranie environmentálnych parametrov : prihláška úžitkového vzoru č. 9-2023, dátum podania prihlášky: 31.1.2023, dátum zverejnenia prihlášky: 28.6.2023, Vestník ÚPV SR č. 12/2023*. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2023. 7 s. Dostupné na internete:
<<https://wbr.indprop.gov.sk/WebRegistre/UzitkovyVzor/Detail/9-2023?csrt=17138102622100521421>>.
Typ výstupu: prihláška úžitkového vzoru; Výstup: domáci; Kategória publikácie od 2022: D1

AFD Publikované príspevky na domácich vedeckých konferenciách

AFD01 ČERNAJ, Ľuboš [50 %] - CHVÁLA, Aleš [30 %] - MAREK, Juraj [5 %] - DONOVAL, Daniel [5 %] - ZÁVODNÍK, Tomáš [1 %] - KOZÁRIK, Jozef [1 %] - JAGELKA, Martin [4 %] - DONOVAL, Martin [4 %]. *3D electrothermal device/circuit simulation of multifinger power HEMTs. In ELITECH '18 [elektronický zdroj] : 20th Conference of doctoral students. Bratislava, Slovakia. May 23, 2018*. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2018, CD-ROM, [4] p. ISBN 978-80-227-4794-3.
Kategória publikácie od 2022: V2

AFD02 ČERNAJ, Ľuboš [50 %] - CHVÁLA, Aleš [30 %] - MAREK, Juraj [5 %] - DONOVAL, Daniel [5 %] - ZÁVODNÍK, Tomáš [1 %] - KOZÁRIK, Jozef [1 %] - JAGELKA, Martin [4 %] - DONOVAL, Martin [4 %]. *SPICE-like 3D electrothermal simulation of multifinger power HEMTs. In ADEPT 2018 : 6th International conference on advances in electronic and photonic technologies. Tatranská Lomnica, Slovakia. June 18-21, 2018*. 1. vyd. Bratislava : Vydavateľstvo Spektrum STU, 2018, S. 73-76. ISBN 978-80-554-1450-8.
Kategória publikácie od 2022: V2

AFD03 ČERNAJ, Ľuboš [50 %] - CHVÁLA, Aleš [30 %] - MAREK, Juraj [5 %] - DONOVAL, Daniel [5 %] - ZÁVODNÍK, Tomáš [1 %] -

- KOZÁRIK, Jozef [1 %] - JAGELKA, Martin [4 %] - DONOVAL, Martin [4 %]. Direct SPICE-like 3-D electrothermal simulation of power HEMTs. In *ASDAM 2018 : 12th International conference on advanced semiconductor devices and microsystems*. Smolenice, Slovakia. October 21-24, 2018. 1. ed. Danvers : IEEE, 2018, S. 175-178. ISBN 978-1-5386-7488-8. V databáze: IEEE: 8544582 ; WOS: 000468753600039 ; SCOPUS: 2-s2.0-85059987151.
Kategória publikácie od 2022: V2
- AFD04 ČERNAJ, Ľuboš [50 %] - CHVÁLA, Aleš [30 %] - MAREK, Juraj [5 %] - DONOVAL, Daniel [5 %] - KOZÁRIK, Jozef [4 %] - ZÁVODNÍK, Tomáš [3 %] - DONOVAL, Martin [3 %]. Electrothermal spice circuit model of HEMT device. In *ADEPT 2019 : 7th International conference on advances in electronic and photonic technologies*. Štrbské Pleso, Slovakia. June 24-27, 2019. 1. vyd. Žilina : Vydavateľstvo EDIS, 2019, S. 99-102. ISBN 978-80-554-1568-0.
Kategória publikácie od 2022: V2
- AFD05 ČERNAJ, Ľuboš [50 %] - CHVÁLA, Aleš [30 %] - MAREK, Juraj [5 %] - DONOVAL, Daniel [5 %] - KOZÁRIK, Jozef [5 %] - ZÁVODNÍK, Tomáš [5 %]. Modeling of HEMT device using neural network. In *ADEPT 2020 : 8th International conference on advances in electronic and photonic technologies*. Nový Smokovec, Slovakia. September 14-17, 2020. 1. vyd. Žilina : Vydavateľstvo EDIS, 2020, S. 163-166. ISBN 978-80-554-1735-6.
Kategória publikácie od 2022: V2
- AFD06 ČERNAJ, Ľuboš [15 %] - VAVRINSKÝ, Erik [15 %] - ZÁVODNÍK, Tomáš [15 %] - KOZÁRIK, Jozef [15 %] - GAŠPAREK, Krisztián [15 %] - DEBNÁR, Tomáš [15 %] - MIĚJAN, Michal [5 %] - DONOVAL, Martin [5 %]. Wireless temperature sensor for use in healthcare. In *ADEPT 2022 : 10th International conference on advances in electronic and photonic technologies*. Tatranská Lomnica, Slovakia. June 20-24, 2022. 1. vyd. Žilina : Vydavateľstvo EDIS, 2022, S. 218-221. ISBN 978-80-554-1884-1.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD07 ČERNAJ, Ľuboš [20 %] - ZÁVODNÍK, Tomáš [20 %] - KOZÁRIK, Jozef [5 %] - DEBNÁR, Tomáš [5 %] - MIĚJAN, Michal [5 %] - DONOVAL, Martin [5 %] - REŽO, Vratislav [15 %] - VAVRINSKÝ, Erik [15 %] - KOPÁNI, Martin [5 %] - KOSNÁĚOVÁ, Helena [5 %]. Advanced ECG holter with 2.4 GHz communication. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems*. Smolenice, Slovakia. October 23-26, 2022. 1. ed. Danvers : IEEE, 2022, S. 143-146. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966750 ; IEEE: 9966750 ; SCOPUS: 2-s2.0-85144591894.

Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

- AFD08 DEBNÁR, Tomáš [20 %] - GAŠPAREK, Krisztián [20 %] - ŠUBJAK, Ján [20 %] - ZÁVODNÍK, Tomáš [20 %] - DONOVÁL, Martin [20 %]. Introduction to the internet of things (IoT). In *ADEPT 2019 : 7th International conference on advances in electronic and photonic technologies. Štrbské Pleso, Slovakia. June 24-27, 2019*. 1. vyd. Žilina : Vydavateľstvo EDIS, 2019, S. 39-42. ISBN 978-80-554-1568-0. Kategória publikácie od 2022: V2
- AFD09 DEBNÁR, Tomáš [20 %] - ZÁVODNÍK, Tomáš [10 %] - FUNTÍK, Tomáš [10 %] - ČERNAJ, Ľuboš [10 %] - KOZÁRIK, Jozef [10 %] - ERDÉLYI, Ján [10 %] - MAYER, Pavol [10 %] - MICĽAN, Michal [10 %] - NEVŘELA, Juraj [10 %]. Analysis of the movement of employees on the construction site using IoT sensors. In *ADEPT 2022 : 10th International conference on advances in electronic and photonic technologies. Tatranská Lomnica, Slovakia. June 20-24, 2022*. 1. vyd. Žilina : Vydavateľstvo EDIS, 2022, S. 214-217. ISBN 978-80-554-1884-1. Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD10 GAŠPAREK, Krisztián [50 %] - DEBNÁR, Tomáš [25 %] - KOZÁRIK, Jozef [10 %] - ZÁVODNÍK, Tomáš [10 %] - DONOVÁL, Martin [5 %]. Testing and comparison of electrochemical nitrogen dioxide gas sensors for autonomous environmental monitoring systems based on internet of things. In *ADEPT 2020 : 8th International conference on advances in electronic and photonic technologies. Nový Smokovec, Slovakia. September 14-17, 2020*. 1. vyd. Žilina : Vydavateľstvo EDIS, 2020, S. 171-174. ISBN 978-80-554-1735-6. Kategória publikácie od 2022: V2
- AFD11 GAŠPAREK, Krisztián [20 %] - ZÁVODNÍK, Tomáš [20 %] - VAVRINSKÝ, Erik [15 %] - MIĽJAN, Michal [10 %] - DONOVÁL, Martin [10 %] - NEVŘELA, Juraj [5 %] - MATEAŠIK, Anton [5 %] - ZÁBRODSKÝ, Milan [5 %] - ŠÍŠOLÁK, Vladimír [5 %] - KOSNÁĽOVÁ, Helena [5 %]. Design of equipment for advanced PPG research. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 23-26, 2022*. 1. ed. Danvers : IEEE, 2022, S. 135-138. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966768 ; IEEE: 9966768 ; SCOPUS: 2-s2.0-85144593738. Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD12 KOSNÁĽOVÁ, Helena [35 %] - VI• AZKOVÁ, Diana [10 %] - ZÁVODNÍK, Tomáš [20 %] - BARTOŠ, Patrik [5 %] - KASZNÁR, Martin [5 %] - VAVRINSKÝ, Erik [25 %]. EOG headband for

monitoring human health. In *ELITECH '23 [elektronický zdroj] : 25th Conference of Doctoral Students. Bratislava, Slovakia. May 31, 2023*. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2023, [6] s. ISBN 978-80-227-5298-5.

Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

AFD13 KOZÁRIK, Jozef [50 %] - MAREK, Juraj [30 %] - ČERNAJ, Ľuboš [5 %] - CHVÁLA, Aleš [5 %] - ZÁVODNÍK, Tomáš [5 %] - DONOVAL, Daniel [5 %]. Power p-GaN HEMT under short circuit conditions. In *ADEPT 2019 : 7th International conference on advances in electronic and photonic technologies. Štrbské Pleso, Slovakia. June 24-27, 2019*. 1. vyd. Žilina : Vydavateľstvo EDIS, 2019, S. 115--118. ISBN 978-80-554-1568-0.

Kategória publikácie od 2022: V2

AFD14 KOZÁRIK, Jozef [20 %] - ZÁVODNÍK, Tomáš [20 %] - ČERNAJ, Ľuboš [10 %] - DEBNÁR, Tomáš [5 %] - MIĚJAN, Michal [5 %] - DONOVAL, Martin [5 %] - GAŠPAREK, Krisztián [5 %] - VAVRINSKÝ, Erik [15 %] - KOSNÁĚOVÁ, Helena [15 %]. Multifunctional communication gateway for implementation in telemedicine systems. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 23-26, 2022*. 1. ed. Danvers : IEEE, 2022, S. 151-154. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966748 ; IEEE: 9966748 ; SCOPUS: 2-s2.0-85144590555.

Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

AFD15 KOZÁRIK, Jozef [30 %] - GAŠPAREK, Krisztián [25 %] - ZÁVODNÍK, Tomáš [25 %] - ČERNAJ, Ľuboš [10 %] - JAGELKA, Martin [5 %] - DONOVAL, Martin [5 %]. Multi-sensor modular IoT platform for high-density monitoring of environmental parameters. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 23-26, 2022*. 1. ed. Danvers : IEEE, 2022, S. 159-162. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966783 ; IEEE: 9966783 ; SCOPUS: 2-s2.0-85144592432.

Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

AFD16 VAVRINSKÝ, Erik [40 %] - SVOBODOVÁ, Helena [5 %] - MIKOLÁŠEK, Miroslav [10 %] - TVAROŽEK, Vladimír [10 %] - KOVÁČ, Jaroslav jr. [5 %] - ŠUTTA, Pavol [5 %] - MATEJOVIĚ, Martin [5 %] - SEDLÁK, Samuel [5 %] - KOPANI, Martin [5 %] - ZÁVODNÍK, Tomáš [5 %] - DONOVAL, Martin [5 %]. Electro -

- optical monitoring of trisodium citrate applicable in haemodialysis. In *ASDAM 2018 : 12th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 21-24, 2018*. 1. ed. Danvers : IEEE, 2018, S. 109-112. ISBN 978-1-5386-7488-8. V databáze: IEEE: 8544574 ; WOS: 000468753600024 ; SCOPUS: 2-s2.0-85059979548.
Kategória publikácie od 2022: V2
- AFD17 VAVRINSKÝ, Erik [50 %] - KOTRADYOVÁ, Veronika [25 %] - SVOBODOVÁ, Helena [10 %] - ZÁVODNÍK, Tomáš [5 %] - KOPANI, Martin [5 %] - DONOVAL, Martin [5 %]. The use of wireless sensors and advanced technologies in monitoring the interaction between humans and the environment design. In *ASDAM 2018 : 12th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 21-24, 2018*. 1. ed. Danvers : IEEE, 2018, S. 117-120. ISBN 978-1-5386-7488-8. V databáze: IEEE: 8544596 ; WOS: 000468753600026 ; SCOPUS: 2-s2.0-85059983815.
Kategória publikácie od 2022: V2
- AFD18 VAVRINSKÝ, Erik [40 %] - STOPJAKOVÁ, Viera [15 %] - KOPÁNI, Martin [5 %] - MÍČJAN, Michal [5 %] - ZÁVODNÍK, Tomáš [5 %] - KOSNÁČOVÁ, Helena [30 %]. Concept of modern stress-meter. In *ADEPT 2021 : 9th International conference on advances in electronic and photonic technologies. Podbanské, Slovakia. September 20-23.2021*. 1. vyd. Žilina : Vydavateľstvo EDIS, 2021, S. 17-20. ISBN 978-80-554-1806-3.
Výstup: domáci; Kategória publikácie od 2022: V2
- AFD19 VAVRINSKÝ, Erik [30 %] - DONOVAL, Martin [5 %] - MÍČJAN, Michal [5 %] - KOPÁNI, Martin [5 %] - STRÉMY, Maximilián [10 %] - ZÁVODNÍK, Tomáš [10 %] - GAŠPAREK, Krisztián [5 %] - VÍTAZKOVÁ, Diana [10 %] - KOSNÁČOVÁ, Helena [20 %]. Combination of electro/impedance/seismo/phono/cardiography in medicine. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 23-26, 2022*. 1. ed. Danvers : IEEE, 2022, S. 147-150. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966763 ; IEEE: 9966763 ; SCOPUS: 2-s2.0-85144590580.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD20 VAVRINSKÝ, Erik [30 %] - POLÁK, Marek [18 %] - STRÉMY, Maximilián [5 %] - PROKS, Daniel [5 %] - KOPANI, Martin [5 %] - ZÁVODNÍK, Tomáš [5 %] - GAŠPAREK, Krisztián [5 %] - VÍTAZKOVÁ, Diana [10 %] - KOSNÁČOVÁ, Helena [17 %]. Simultaneous electro/mechano/impedance myographic measurement of muscle activity. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice,*

Slovakia. October 23-26, 2022. 1. ed. Danvers : IEEE, 2022, S. 139-142. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966757 ; IEEE: 9966757 ; SCOPUS: 2-s2.0-85144592729.

Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

- AFD21 VAVRINSKÝ, Erik [30 %] - STRÉMY, Maximilián [15 %] - HORVÁTH, Dušan [20 %] - ZÁVODNÍK, Tomáš [5 %] - GAŠPAREK, Krisztián [5 %] - VIŤAZKOVÁ, Diana [10 %] - KOSNÁĎOVÁ, Helena [15 %]. Concept of modern EOG system for BCI. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 23-26, 2022*. 1. ed. Danvers : IEEE, 2022, S. 131-134. ISBN 978-1-6654-6977-7. V databáze: SCOPUS: 2-s2.0-85144591097 ; DOI: 10.1109/ASDAM55965.2022.9966743 ; IEEE: 9966743.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD22 VAVRINSKÝ, Erik [40 %] - ZÁVODNÍK, Tomáš [15 %] - GAŠPAREK, Krisztián [15 %] - DONOVÁL, Martin [10 %] - KOSNÁĎOVÁ, Helena [20 %]. Moderné trendy v oblasti merania ľudskej teploty – review. In *Fotonika 2022 : 17. výročný vedecký seminár Medzinárodného laserového centra CVTI SR. Bratislava, Slovakia. 07. december 2022*. Bratislava : Medzinárodné laserové centrum, 2022, S. 102-106. ISBN 978-80-8240-033-8.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD23 VIŤAZKOVÁ, Diana [29 %] - ZÁVODNÍK, Tomáš [15 %] - GAŠPAREK, Krisztián [8 %] - ČERNAJ, Ľuboš [5 %] - KOSNÁĎOVÁ, Helena [5 %] - VAVRINSKÝ, Erik [10 %] - MIĚJAN, Michal [8 %] - BÁNOVEIN, Peter [10 %] - KOCAN, Ivan [10 %]. Advanced photoplethysmographic multisensor used in polysomnographic examinations. In *ELITECH 23 [elektronický zdroj] : 25th Conference of Doctoral Students. Bratislava, Slovakia. May 31, 2023*. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2023, [6] s. ISBN 978-80-227-5298-5.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2
- AFD24 ZÁVODNÍK, Tomáš [20 %] - JAGELKA, Martin [20 %] - ČERNAJ, Ľuboš [20 %] - KOZÁRIK, Jozef [20 %] - DONOVÁL, Martin [20 %]. Vehicle detection based on magnetic field variations with underground low-power IOT magnetic sensor. In *ASDAM 2018 : 12th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 21-24, 2018*. 1. ed. Danvers : IEEE, 2018,

S. 89-92. ISBN 978-1-5386-7488-8. V databáze: IEEE: 8544717 ;
WOS: 000468753600021 ; SCOPUS: 2-s2.0-85059974137.
Kategória publikácie od 2022: V2

AFD25 ZÁVODNÍK, Tomáš [60 %] - ČERNAJ, Ľuboš [20 %] - GAŠPAREK, Krisztián [5 %] - MÍČJAN, Michal [10 %] - DONOVAL, Martin [5 %].
Biometric identification using shoulder-based PPG sensor. In *ASDAM 2022 : 14th International conference on advanced semiconductor devices and microsystems. Smolenice, Slovakia. October 23-26, 2022*. 1. ed. Danvers : IEEE, 2022, S. 155-158. ISBN 978-1-6654-6977-7. V databáze: DOI: 10.1109/ASDAM55965.2022.9966753 ; IEEE: 9966753 ; SCOPUS: 2-s2.0-85144592522.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

AFD26 ZÁVODNÍK, Tomáš [35 %] - MIÈJAN, Michal [40 %] - DEBNÁR, Tomáš [10 %] - ČERNAJ, Ľuboš [10 %] - KOZÁRIK, Jozef [5 %].
Vývoj systému na monitorovanie možného šírenia ochorenia COVID-19. In *Fotonika 2022 : 17. výročný vedecký seminár Medzinárodného laserového centra CVTI SR. Bratislava, Slovakia. 07. december 2022*. Bratislava : Medzinárodné laserové centrum, 2022, S. 107-110. ISBN 978-80-8240-033-8.
Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie od 2022: V2

9. Zoznam publikácií:

1. World Bank. (2023, April 7). Current health expenditure (% of GDP). [Dataset]. Retrieved from <https://data.worldbank.org/indicator/SH.XPD.CHEX.GD.ZS>
2. OECD. (n.d.). Population projections. [Dataset]. Retrieved from <https://stats.oecd.org/Index.aspx?DataSetCode=POPPROJ>
3. Paul A. Iaizzo 2009. „Handbook of Cardiac Anatomy, Physiology, and Devices“. Humana Press. ISBN 978-1-60327-371-8.
4. Sattar, Y., & Chhabra, L. (2023). Electrocardiogram. StatPearls. <https://www.ncbi.nlm.nih.gov/books/NBK549803/>
5. Madona, P., Basti, R. I., & Zain, M. M. (2021). PQRST wave detection on ECG signals. *Gaceta Sanitaria*, 35, S364–S369. <https://doi.org/10.1016/J.GACETA.2021.10.052>
6. Singh, N., Moneghetti, K. J., Christle, J. W., Hadley, D., Plews, D., & Froelicher, V. (2018). Heart Rate Variability: An Old Metric with New Meaning in the Era of using mHealth Technologies for Health and Exercise Training Guidance. Part One: Physiology and Methods. *Arrhythmia & Electrophysiology Review*, 7(3), 193. <https://doi.org/10.15420/AER.2018.27.2>
7. McCraty R, Shaffer F. Heart Rate Variability: New Perspectives on Physiological Mechanisms, Assessment of Self-regulatory Capacity, and Health risk. *Glob Adv Health Med*. 2015 Jan;4(1):46-61. doi: 10.7453/gahmj.2014.073. PMID: 25694852; PMCID: PMC4311559.
8. Freeman JV, Dewey FE, Hadley DM et al. Autonomic nervous system interaction with the cardiovascular system during exercise. *Prog Cardiovasc Dis*. 2006;48:342–62. doi: 10.1016/j.pcad.2005.11.003.
9. V. Mai, I. Khalil, and C. Meli, “ECG biometric using multilayer perceptron and radial basis function neural networks,” in *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, Aug. 2011, pp. 2745–2748
10. P.-L. Hong, J.-Y. Hsiao, C.-H. Chung, Y.-M. Feng, and S.-C. Wu, “ECG biometric recognition: Template-free approaches based on deep learning,” in *Proc. 41st Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, Jul. 2019, pp. 2633–2636.
11. R. Donida Labati, E. Muñoz, V. Piuri, R. Sassi, and F. Scotti, “Deep-ECG: Convolutional neural networks for ECG biometric recognition,” *Pattern Recognit. Lett.*, vol. 126, pp. 78–85, Sep. 2019
12. J. S. Kim, S. H. Kim, and S. B. Pan, “Personal recognition using convolutional neural network with eeg coupling image,” *J. Ambient Intell. Humanized Comput.*, pp. 1–10, Jul. 2019
13. Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, 99, 650–655. <https://doi.org/10.1016/J.PROCIR.2021.03.088>