

Ing. Krisztián Gašparek

**VÝSKUM A IMPLEMENTÁCIA STROJOVÉHO UČENIA VO VNORENÝCH
SYSTEMOCH**

RESEARCH AND IMPLEMENTATION OF MACHINE LEARNING IN
EMBEDDED SYSTEMS

Autoreferát dizertačnej práce

na získanie vedecko-akademickej hodnosti philosophiae doctor

v doktorandskom študijnom programe: elektronika a fotonika

Miesto a dátum: Bratislava, apríl 2024

Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky
Ústav elektroniky a fotoniky

Ing. Krisztián Gašparek

**VÝSKUM A IMPLEMENTÁCIA STROJOVÉHO UČENIA VO VNORENÝCH
SYSTÉMOCH**

RESEARCH AND IMPLEMENTATION OF MACHINE LEARNING IN
EMBEDDED SYSTEMS

Autoreferát dizertačnej práce

na získanie vedecko-akademickej hodnosti philosophiae doctor

v doktorandskom študijnom programe: elektronika a fotonika

Miesto a dátum: Bratislava, apríl 2024

Dizertačná práca bola vypracovaná na:

Ústave elektroniky a fotoniky FEI STU v Bratislave

Predkladateľ: Ing. Krisztián Gašparek
Ústav elektroniky a fotoniky,
Fakulta elektrotechniky a informatiky,
Slovenská technická univerzita v Bratislave,
Ilkovičova 3, 841 04 Bratislava

Školiteľ: doc. Ing. Martin Donoval, PhD.
Ústav elektroniky a fotoniky FEI STU v Bratislave
Ilkovičova 3, 841 04 Bratislava

Oponenti: prof. Ing. František Duchoň, PhD.
Ústav robotiky a kybernetiky FEI STU v Bratislave ,
Ilkovičova 3, 841 04 Bratislava

doc. RNDr. Pavol Vitovič, PhD.
Ústav medicínskeho vzdelávania a simulácií LF UK,
Sasinkova 4, 813 72 Bratislava

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa koná dňa 07.05.2024, o 9.00 hod. na
Fakulte Elektrotechniky a Informatiky, Slovenskej Technickej Univerzity
v Bratislave, Ilkovičova 3, 812 19 Bratislava.

prof. Ing. Vladimír Kutiš, PhD.
Dekan FEI STU

Obsah

1	Úvod.....	5
2	Tézy dizertačnej práce	6
3	Teoretický úvod.....	7
3.1	Fotopletyzmozgrafia (PPG)	8
3.2	Krvný tlak (BP)	12
4	Dosiahnuté výsledky	16
4.1	Testovacie zariadenie na meranie PPG	16
4.2	Zber a spracovanie dát	21
4.3	Trénovanie modelov strojového učenia.....	28
1.1	Zhrnutie výsledkov	42
4.4	Implementácia modelu do vnoreného systému	43
5	Záver	47
6	Zhrnutie.....	52
7	Summary	54
8	Zoznam použitej literatúry	56
9	Zoznam publikácií autora.....	63

1 Úvod

Dlhodobó pretrvávajúci vysoký krvný tlak môže viesť k chronickému zlyhaniu životne dôležitých orgánov, ako sú srdce, obličky alebo mozog. V roku 2019 malo 22 percent obyvateľov EÚ vo veku 15 rokov a viac diagnostikovaný vysoký krvný tlak. Slovensko sa nachádza na šiestom najhoršom mieste tejto štatistiky. Podľa odhadov WHO celkovo 46 % plnoletých osôb si nie je vedomých, že má vysoký krvný tlak, a iba 42 % dospelých osôb s hypertenziou je diagnostikovaných a liečených. Len 21 % plnoletých osôb s vysokým krvným tlakom má svoj krvný tlak pod kontrolou [1], [2], [3]. Rastom a starnutím populácie prudko stúpajú náklady na zdravotnú starostlivosť. Najmä vyspelé krajiny zaznamenávajú prudký nárast počtu ľudí, ktorí sú starší ako 60 rokov. Práve tento segment populácie najviac zaťažuje zdravotnícky systém, a preto je nutné využívať nové technológie na zvýšenie komfortu pacientov a zníženie výdavkov na poskytovanie zdravotnej starostlivosti [4]. Moderné nositeľné zariadenia, využívajúce umelú inteligenciu na nepretržité monitorovanie fyziologických parametrov ľudí, by mohli znížiť počet nediagnostikovaných pacientov, vyťaženie lekárov a pomocou diaľkového monitoringu zvýšiť komfort pacientov. Problémom je, že v súčasnosti na trhu nie je k dispozícii spoľahlivé zariadenie na nepretržité a súčasne neinvazívne monitorovanie krvného tlaku. Z daného dôvodu sme sa rozhodli navrhnuť vlastné pilotné zariadenie.

2 Tézy dizertačnej práce

Tézy dizertačnej práce sú definované nasledovne:

- Preskúmať aktuálnu literatúru a nadobudnúť širšie znalosti v téme strojového učenia, spracovaní fotopletyzomografických signálov a následného merania krvného tlaku neinvazívnymi metódami.
- Nazbierať dostatočný počet anotovaných dát, vhodných pre tvorbu modelov strojového učenia.
- Na základe poznatkov, získaných nadobudnutím vedomostnej bázy zvoliť najvhodnejšie metódy strojového učenia pre implementáciu do vnoreného systému.
- Navrhnuť model strojového učenia na výpočet krvného tlaku pomocou fotopletyzomografického signálu.
- Optimalizovať navrhnutý algoritmus na meranie krvného tlaku pre použitie vo vnorenom systéme za účelom zníženia výpočtových a prenosových nárokov.

3 Teoretický úvod

Neustály rozvoj ľudstva a technologických prostriedkov odzrkadľuje snahu lekárov, vedcov a iných ľudí udržiavať a zlepšovať zdravotnú starostlivosť, aby sme mohli predchádzať chorobám. Neustále vznikajú nové a zdokonaľujú sa existujúce diagnostické metódy na monitorovanie zdravotného stavu, kontinuálne a v reálnom čase. Včasná a presná diagnóza je kľúčom k udržaniu vysokej kvality života [5], [6]. Staršie metódy založené na invazívnom odbere vzoriek použitím veľkých a zložitých prístrojov sa postupne transformujú na neinvazívne metódy, ktoré nevyžadujú náročnú manipuláciu a navyše sú komfortnejšie pre pacienta [7]. S pokrokom technológií, s vývojom pokročilých materiálov a príchodom internetu vecí sa nositeľná elektronika dostáva do popredia [6]. Vzhľadom na to, že zdravotná starostlivosť smeruje viac k personalizovanej medicíne, sa predpokladá, že trh nositeľnej medicíny celosvetovo vzrastie o približne 26,4 % na 195,57 miliardy USD v rokoch 2020 až 2027 [8]. Príchod inteligentných a bezdrôtovo prepojených nositeľných monitorovacích zariadení prináša revolúciu v zdravotníctve. Tento trend začal jednoduchými fitness náramkami a rýchlo sa rozvinul do formy inteligentných hodínok, inteligentného oblečenia, okuliarov, kontaktných šošoviek a rôznych telových implantátov [9], [10]. Tieto zariadenia dokážu pozorne sledovať životné funkcie, zdravie človeka a dlhodobo hlásiť zmenu zdravotných indikátorov pacienta. Ideálne nositeľné senzory musia

byť neinvazívne, kompaktné, ľahko prenosné, nízkonákladové a ľahké na výrobu [11], [12], [13]. Monitorovanie ľudského zdravia nositeľnou elektronikou má však aj svoje nevýhody a senzorkové princípy sa často výrazne líšia od bežných laboratórnych meraní. Stovky týchto princípov boli popísané v mnohých publikáciách [12], [13], [14], no pri mnohých príležitostiach neuvažujú o ich použití v reálnom živote.

3.1 Fotopletyzmozgrafia (PPG)


Fotopletyzmozgrafia (PPG) je v zdravotníctve široko používaná optická snímacia metóda, ktorá slúži na monitorovanie prietoku krvi v reálnom čase [15]. Používa sa na stanovenie fyziologických parametrov, ako je saturácia krvi kyslíkom, krvný tlak, srdcový výdaj, dýchanie, ale aj na hodnotenie autonómnych funkcií, hĺbky anestézie a taktiež aj na zistenie periférnych cievnych ochorení [16]. Táto metóda v skratke umožňuje merať zmeny objemu v celom tele. Meria množstvo svetla, ktoré je absorbované, alebo odrazené krvnými cievami v podkožnom tkanive. Ako prúdi krv, kardiovaskulárna pulzná vlna vychádza zo srdca a šíri sa telom, pričom periodicky rozťahuje tepny a vlásoknice v podkožnom tkanive. Keďže krv v tkanive absorbuje viac svetla ako okolité tkanivo, zníženie množstva krvi vyvolá zmeny intenzity svetla na fotodetektore, ktoré vo všeobecnosti pozostáva z pulzujúcej a nepulzujúcej zložky objemu krvi [17]. Pulzujúca zložka súvisí so zmenami objemu arteriálnej krvi a je synchronná so srdcovým

rytmom, zatiaľ čo nepulzujúca zložka je funkciou základného objemu krvi, dýchania, aktivity nervového systému a termoregulácie [18]. Svetlo v spektre od viditeľného až po blízke infračervené svetlo je schopné sa dostať do ľudského tkaniva len niekoľko milimetrov, nakoľko je jeho penetrácia obmedzená v dôsledku absorpcie svetla krvou, melanínom, tukom, vodou a rozptylom svetla v tkanive. Skutočná absorpcia svetla závisí nielen od zloženia tkaniva, ale aj od vlnovej dĺžky svetla. Tieto rozdiely umožňujú získavanie rôznych informácií zo signálu PPG. Napríklad zelené svetlo je telom okamžite pohlcované, preto je vhodné len na meranie na miestach, kde je v tkanive veľa krvi, a zároveň je menej ovplyvnené rušením okolitého svetla. Naopak, červené a blízke infračervené svetlo prenikajú hlbšie do ľudského tela a poskytujú tak širší rozsah informácií o fyziologickom signáli [19], [20]. Tento jav súvisí so zložením kože a evolučným vývojom, keďže epiderma plní ochrannú funkciu spodného mäkkého tkaniva pred škodlivým UV žiarením. Kožný pigment absorbuje kratšie vlnové dĺžky, UV a do určitej miery aj viditeľné svetlo. Voda v tkanivách, naopak, absorbuje svetlo v oblastiach s dlhými vlnovými dĺžkami. V literatúre sa uvádza aj „optické okno“ pre vlnové dĺžky 600 až 1 300 nm [21], [22].

V závislosti od umiestnenia zdroja svetla a fotodetektora poznáme dve rôzne konfigurácie merania PPG signálu - transmisnú a reflexnú konfiguráciu. V transmisnej konfigurácii sú zdroj svetla a senzor umiestené na opačnej strane snímanej tkaniny. Táto konfigurácia je najvhodnejšia pre oblasti s vysokou hustotou kapilár,

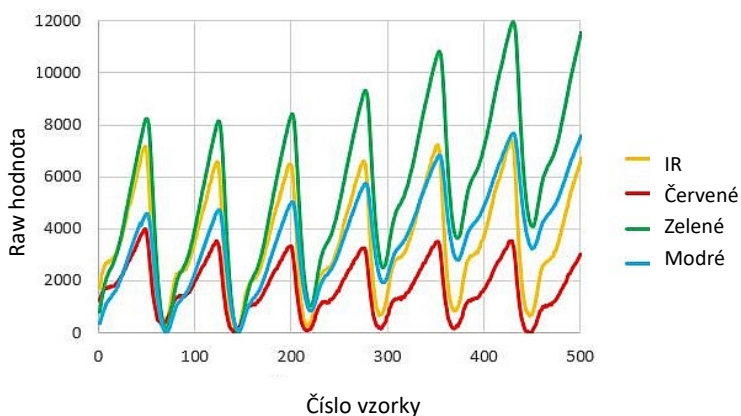
ako sú prsty alebo ušný lalôčik. Zvyčajne sa používa červené (680 nm) alebo blízke infračervené (810 nm) svetlo, keďže sa vyžaduje hlboký prienik do tkaniva [23], [24]. Takéto merania sú stabilnejšie, opakovateľné a sú menej citlivé na zmeny polohy.

Pri reflexnom usporiadaní sú zdroj svetla a senzor umiestnené na tej istej strane snímanej tkaniny a využíva sa odraz od vnútorných štruktúr pokožky [25], [26]. Táto konfigurácia má nižšiu kvalitu signálu, ale je vhodnejšia pre nepretržité nosenie. Keďže maximálna pulzujúcej zložky odrazeného svetla sa vyskytujú v rozsahu medzi 510 a 590 nm [27], používa sa zvyčajne zelené (565 nm) alebo žlté (590 nm) svetlo [28]. Meranie je možné uskutočniť aj na iných miestach ľudského tela, za predpokladu dostatočnej dostupnosti krvných ciev. Štandardne sa na PPG meranie ešte používajú: čelo, vonkajší ušný lalok, oblasti okolo bicepsu a lýtkových svalov, alebo oblasti okolo zápästia [29], [30], [31]. Na Obrázok 1 môžeme vidieť dve rozdielne metódy merania PPG signálu.



Obrázok 1 - Metódy merania PPG (a) transmisná, (b) reflexná [32]

Odrazené a absorbované svetlo je modulované pulzovaním množstva arteriálnej krvi, pričom absorpcia iných častí tkanív je konštantná. Pre jednoduchosť sa dá povedať, že AC zložka nameraného signálu je synchronná a proporcionálna k pletyzmografickému signálu meraného subjektu a DC zložka je konštantná absorpcia ľudského tkaniva v optickej ceste závislá na použitej vlnovej dĺžke a intenzite žiarenia. Na obrázku 2 sú zobrazené 4 priebehy digitalizovaného PPG signálu, ktoré sú namerané pri osvetlení so štyrmi rôznymi vlnovými dĺžkami svetla. Na osi X je zobrazené poradové číslo balíka z AD prevodníka, na osi Y sú jednotlivé raw hodnoty PPG kriviek získané pomocou fotodiódy pri osvetlení so svetlom rôznych vlnových dĺžok [33].



Obrázok 2 - Priebeh PPG signálu meraného rôznymi vlnovými dĺžkami [33]

Svetlo s rôznymi vlnovými dĺžkami je absorbované ľudským telom rôzne. Veľa PPG zariadení disponuje jednou, alebo viacerými zelenými LED diódami. Zelené svetlo je okamžite absorbované ľudským telom. Meranie použitím zeleného svetla je menej ovplyvnené rušením okolitého svetla. Avšak kvôli silnej absorpcii je tiež limitovaná hĺbka penetrácie. Zelená farba je teda vhodná len na meranie na miestach, kde sa nachádza veľa krvi v tkanive. Hemoglobín takisto silno absorbuje zelené svetlo, čo tiež sťažuje hĺbkové vniknutie svetla do tkanív. V zdravotníctve sa na pulzoxymetriu používajú najmä blízke infračervené svetelné zdroje. Červené svetlo vniká hlboko do ľudského tela a preto poskytuje široký rozsah informácií o fyziologickom signáli [34]. Zo spomenutých vlastností vyplýva, že zelené svetlo je viac vhodné na meranie reflexným princípom a naopak červená a blízka infračervená je vhodnejšia na meranie transmisným princípom.

3.2 Krvný tlak (BP)

Vysoký krvný tlak, hypertenzia, je hlavným rizikovým faktorom kardiovaskulárnych chorôb. Riziko je minimalizovateľné s diagnostikou choroby. Podcenenie dôležitosti merania krvného tlaku je bežné a necháva mnohých jedincov s hypertenziou nediagnostikovaných alebo s neadekvátne kontrolovaným krvným tlakom [35].

Pri meraní krvného tlaku rozlišujeme dve rôzne merané hodnoty. Sú to systolický a diastolický tlak. Systolický tlak je tlak krvi v tepnách

počas systoly. Pri systole dochádza ku stiahnutiu srdca, čo je predstavuje úder srdca, pri ktorom je vypustená krv do krvného obehu. Po systole nastáva vždy diastola, pokojový stav srdca medzi dvoma sťahmi. Diastolický tlak je tlak krvi počas diastoly. Počas diastoly je srdcový sval uvoľnený a plní sa krvou. Srdce sa pripravuje na stiahnutie, ktorým sa krv znova vypumpuje do obehu. Hodnota systolického tlaku je vždy vyjadrená ako prvé číslo pred lomkou na tlakomeri, druhé číslo za lomkou je hodnota diastolického tlaku krvi [36].

Krvný tlak sa podľa jeho hodnôt zaraďuje do troch skupín. Sú to: hypotenzia, normotenzia a hypertenzia. Hypotenzia je odborný názov pre nízky krvný tlak. O hypotenzii hovoríme, ak hodnota krvného tlaku je menšia ako 90/60 mmHg. Pri nízkom krvnom tlaku môžu byť nedostatočne zásobené krvou niektoré dôležité orgány, napríklad mozog alebo obličky. Normotenzia je odborný názov pre normálny krvný tlak. Hodnota normálneho krvného tlaku je v rozmedzí nad 90/60 mmHg a pod 120/80 mmHg. Hypertenzia je odborný názov pre vysoký krvný tlak. O hypertenzii hovoríme, ak hodnota tlaku je nad 140/90 mmHg. Hypertenzia môže viesť k infarktu srdca alebo cievnej mozgovej príhode, srdcovému zlyhávaniu, poškodeniu zraku, alebo problémom s pamäťou [36].

Priemerná hodnota krvného tlaku dospelých je prakticky konštantná počas celého života, ale v niektorých obdobiach sa môže prudko zmeniť pod vplyvom rôznych faktorov, napríklad pod vplyvom psychického a fyzického stresu, dýchania, okolia či zmeny teploty.

Tabuľka 1 - Kategória krvného tlaku [37]

Kategória krvného tlaku	Systolický krvný tlak (mmHg)	Diastolický krvný tlak (mmHg)
Normálny	menej ako 120	menej ako 80
Zvýšený	120 až 129	menej ako 80
1. stupeň hypertenzie	130 až 139	80 až 89
2. stupeň hypertenzie	140 až 179	90 alebo viac
Hypertenzná kríza	viac ako 180	viac ako 120

Presné hodnoty krvného tlaku je možné získať priamym intraarteriálnym meraním krvného tlaku. Táto technika ale nie je praktická a uplatňuje sa najmä pri vyšetrení klinickým lekárom. V súčasnosti sa používa nepriama auskultačná (Korotkoffova) metóda merania krvného tlaku. Pri Korotkoffovej metóde sa tlak určuje pomocou meracieho zariadenia nazývaného sfgymomanometer. Manžeta použitá na meranie sa v tomto prípade nafúkne na úroveň vyššiu, ako je arteriálny tlak. Potom sa manžeta postupne vypustí a zaznamená sa tlak, pri ktorom sa objavia zvuky produkované arteriálnymi pulzovými vlnami (Korotkoffove zvuky), ktoré sa znova stratia pri obnovení toku krvi v tepne. Táto nepriama metóda merania je na lekárske diagnostické účely dostatočne presná. Väčšina

automatických prístrojov používaných na meranie krvného tlaku však používa oscilometrickú metódu. V tomto prípade sa manžeta obvykle ovinie okolo zápästia (niekedy prsta). Oscilometrická metóda spočíva v zachytení zmien v tepnách pri prúdení krvi. Pri každom sťahu vypudí srdce okysličenú krv do obehu. Tá prechádza cievami a spôsobuje ich vlnenie. Oscilometrická metóda nemeria systolický a diastolický tlak, ale strednú hodnotu arteriálneho tlaku. Obe zvyšné hodnoty sa dopočítavajú a sú zvyčajne empiricky kalibrované proti auskultačnej metóde. Nepriame metódy merania krvného tlaku zvyčajne vyžadujú, aby pacient nebol fyzicky aktívny počas merania, inak nastanú významné chyby pri meraniach. Navyše, nepriame merania nie je možné dlhodobo vykonávať nepretržite. Vhodné je opakovať ich iba v určitých časových intervaloch [38].

4 Dosaiahnuté výsledky

Práca sa skladá z viacerých častí, zahŕňajúc návrh meracieho zariadenia, proces zberu a spracovania dát, tréning modelov strojového učenia a implementáciu vybraného algoritmu do zariadenia. Tento projekt vyžaduje komplexný prístup, tieto časti sú zhrnuté v nasledujúcich podkapitolách.


4.1 Testovacie zariadenie na meranie PPG

Napriek tomu, že na trhu existuje množstvo štandardných komerčne dostupných systémov, sme museli zavrhnúť možnosť ich použitia, keďže tieto zariadenia sú úzko špecifické a nie je ich možné použiť na ľubovoľnej časti tela. Každá časť tela má odlišné prekrvenie, množstvo tuku a krvné riečište sa nachádza v rôznych hĺbkach kože. Preto pre účely vykonania našich meraní je potrebné, aby zariadenie disponovalo možnosťou konfigurovania výkonu a umiestnenia LED zdrojov a fotodetektorov.

Väčšina dostupných zariadení neposkytuje prístup k čistým (raw) dátam, neumožňuje regulovať výkon LED ani meniť vzorkovaciu frekvenciu. Preto sme sa rozhodli vyvinúť vlastné voľne konfigurovateľné zariadenie s raw výstupom dát a univerzálnou konštrukciou, ktorá sa dá upevniť na ruku, nohu, čelo alebo hrud'. Na základe tejto špecifikácie bolo nutné navrhnuť univerzálny snímač schopný snímať na rôznych miestach tela.

Pre takýto snímač neexistovalo vhodné jedno rozloženie LED a senzorov. Výsledkom bolo špeciálne rozloženie viacerých dvojíc LED

a senzorov (PPG snímačov) s možnosťou softvérovej konfigurácie, čo umožnilo zjednodušenie celého procesu testovania a zbierania dát. Po vyhodnotení mnohých konfigurácií snímačov sme vybrali konkrétnu konfiguráciu, ktorá je zobrazená na obrázku 3, kde D1 až D15 sú viacfarebné zdroje svetla a U8 a D16 sú senzory odrazeného svetla. Vďaka tejto konštrukcii sme schopní vykonať podrobné mapovanie ľudského tela, optimalizovať geometriu (ich vzájomné vzdialenosti, umiestnenie a potrebný počet) snímačov na nasadenie na konkrétnu časť ľudského tela.

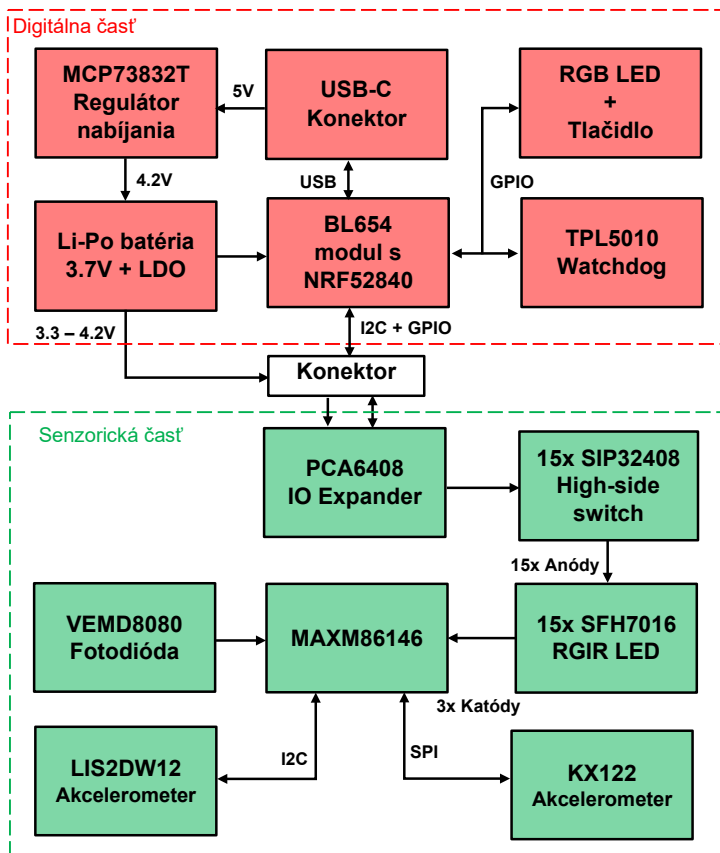


Obrázok 3 - Rozloženie LED a snímačov

Po konečnom návrhu rozloženia komponentov na senzorickej doske bolo prístupné k návrhu schémy zariadenia. Pre návrh zariadenia bol použitý program Altium Designer. Ďalej nasledoval výber hlavných komponentov, pri ktorom bol kladený dôraz hlavne na kompaktnosť výsledného zariadenia. Pred samotným návrhom boli skúmané integrované analógové snímacie obvody so zabudovanými LED a fotodiódami. Po overení viacerých

integrovaných obvodov bolo zistené, že nespĺňajú požadovanú univerzálnosť a predpokladané nároky na presnosť merania. Tým pádom bolo nutné preskúmať ďalšiu možnosť snímania, pričom by bol použitý integrovaný obvod s možnosťou ovládania jasú externej trojfarebnej LED a so schopnosťou zberu signálu externých fotodetektorov. Z relevantných produktov najlepšie našim parametrom a požiadavkám vyhovovali len dve, a to AFE4403 [39] od firmy Texas Instruments a MAX86140/MAX86141 [40], [41] od firmy Analog Devices, ktoré mali parametre veľmi blízke, s tým rozdielom, že MAX86141 verzia integrovaného obvodu od Analog Devices disponuje dvoma vstupmi pre fotosnímače a umožňuje jednoduchšie pripojenie troch rôznych LED. V neposlednom rade dostupnosť k integrovaným obvodom od firmy Analog Devices v čase návrhu bola oveľa lepšia ako dostupnosť produktov od konkurenčnej firmy. Na základe dostupnosti elektronických obvodov a vytýčených parametrov boli vybrané integrované obvody MAX86141 a MAXM86146. Hlavným rozdielom týchto dvoch obvodov je, že MAX86141 je samostatný integrovaný analógový frontend umožňujúci merať dva fotodetektory a budiť trojfarebný zdroj svetla, zatiaľ čo MAXM86146 je hotové integrované riešenie obsahujúce aj dve fotodiódy. Obvod MAXM86146 v sebe ďalej spája nielen analógový front end MAX86141 a fotodiódy, ale aj programovateľný mikrokontrolér s jadrom ARM Cortex MAX32664. Prvotný návrh bol plánovaný s obvodom MAX86141, ktorý je však vyrábaný len v puzdre 20 WLP s rozmermi 2,05 mm x 1,85 mm. Táto skutočnosť

nevyhovovala pre návrh DPS, kde bolo nutné použiť technológiu „in-pad via“, a tým pádom bol použitý obvod MAXM86146 s puzdrom 38-PIN OLGA o rozmere 4,5 mm x 4,1 mm, ktorý je možné použiť pre štandardný návrh a výrobu DPS. Po výbere komponentu analógového frontendu nasledoval výber LED a fotodiód. Pri výbere týchto komponentov boli použité odporúčania od výrobcu frontendu a po prieskume boli vybrané LED od výrobcu Osram s názvom SFH7013, ktoré sú priamo určené pre aplikácie v zdravotníckom priemysle pre snímanie PPG signálu. Ako externá fotodióda bola vybraná VEMD8080 PIN dióda od firmy Vishay, ktorá disponovala dobrými parametrami pre viditeľné aj IR žiarenie. Zvyšné komponenty boli vybrané na základe dostupnosti a katalógových parametrov. Po výbere všetkých komponentov a návrhu schémy bolo zariadenie rozdelené na dve časti, a to na senzorickú a digitálnu časť. Na senzorickej časti sa nachádzajú všetky komponenty nevyhnutné ku snímaniu PPG signálu a na digitálnej časti sa nachádzajú číslicové obvody spracovania signálu. Rozdelenie zariadenia do dvoch častí ovplyvnilo viacero faktorov. Hlavnými dôvodmi sú dosiahnutie kompaktných rozmerov zariadenia a možnosť jednoduchej výmeny a servisovania senzorickej časti zariadenia, čo nám zrýchli vývoj nových telemedicínskych zariadení. Digitálna časť zostáva nezmenená, čo umožňuje modularitu zariadenia podobnú princípu základnej dosky počítača. Rozdelenie zariadenia do dvoch častí tiež umožňuje umiestnenie Li-PO batérie medzi tieto časti, čo zabezpečí jej ochranu pred mechanickými poškodeniami.



Obrázok 4 - Bloková schéma zariadenia

4.2 Zber a spracovanie dát

Po identifikácii užitočných dát pre zber je mimoriadne dôležité si určiť presný proces a pravidlá zberu dát, aby bola zachovaná kvalita a konzistentnosť nazbieraných údajov. Prvým dôležitým krokom je určiť si vzorkovaciu frekvenciu PPG signálu. Vo všeobecnosti má PPG signál frekvenčný rozsah od 0,5 Hz do 10 Hz. Najdôležitejšou frekvenčnou zložkou PPG signálu je srdcová frekvencia, ktorá zvyčajne spadá do rozsahu od 0,8 Hz do 4 Hz. Ostatné frekvenčné zložky PPG signálu predstavujú šum a artefakty, ktoré je potrebné odfiltrovať, aby sa získali informácie o srdcovej frekvencii [42]. Výber vzorkovacej frekvencie by mal byť založený na Nyquist-Shannonovej vzorkovacej vete, ktorá hovorí, že vzorkovacia frekvencia by mala byť aspoň dvojnásobkom najvyššej frekvenčnej zložky signálu, ktorý je predmetom záujmu. V prípade PPG signálov sa zvyčajne používa vzorkovacia frekvencia 25 Hz alebo vyššia, aby sa zachytili dôležité frekvenčné zložky [43]. Po zvolení vhodných údajov a vzorkovacej frekvencie sa môže začať proces zberu údajov. Údaje sa zbierajú pomocou skonštruovaného meracieho zariadenia PPG, ktoré sa pripevní na hrudník meranej osoby. Zariadenie sa nalepuje 2 cm pod začiatkom hrudnej kosti pomocou obojstrannej biokompatibilnej lepiacej pásky. Meracie zariadenie meria 50 Hz vzorkovacou frekvenciou. Zariadenie PPG meria zmeny objemu krvi v mikrovaskulárnom lôžku tkaniva, ktoré sa nachádza pod kožou. Senzor PPG zisťuje zmeny v množstve svetla, ktoré absorbuje krv pri


jej prúdení cievami. Keďže rôzne vlnové dĺžky svetla sa absorbujú v iných hĺbkach tkaniva, zariadenie meria a zbiera PPG krivky pomocou troch rôznych vlnových dĺžok. Kvôli zabezpečeniu redundancií sa zbierajú dáta všetkých troch farieb pomocou dvoch rôznych senzorických prvkov, takže dokopy sa zbiera 6 rôznych kriviek PPG signálu. Zariadenie naďalej zbiera údaje z akcelerometra a údaje teploty kože. Namerané údaje sa potom prenášajú na server prostredníctvom bezdrôtovej komunikácie a ukladajú sa do databázy PostgreSQL. Prenos je zabezpečený pomocou vytvorenej brány, ktorá slúži ako prekladač medzi rádiovým signálom krátkeho a dlhého dosahu. Na komunikáciu medzi bránou a zariadením je použitá 2,4 GHz komunikácia založená na vlastnom komunikačnom protokole. Na komunikáciu so serverom je možné použiť WiFi alebo mobilné internetové prepojenie pomocou LTE pripojenia. Zozbierané údaje sa potom predspracujú, aby sa odstránil akýkoľvek šum alebo artefakty, ktoré sa mohli vyskytnúť počas procesu zberu údajov. Údaje získané z akcelerometra sa využívajú na odstránenie artefaktov zo signálu.

Dátový súbor

Referenčné údaje o diastolickom a systolickom krvnom tlaku sa zbierajú každú minútu neinvazívnou metódou pomocou manžetového tlakomera, ktorý vykonáva merania v minútových intervaloch. Následne sa tieto údaje ukladajú do databázy. Zbierajú sa pomocou monitorovacieho zariadenia „CARESCAPE B650 Monitor“ s pripojeným meracím modulom „CARESCAPE Patient Data Module“, ktoré sa používa na jednotkách intenzívnej starostlivosti a zaručuje vysokú presnosť merania [44]. Zber referenčných dát z monitorovacieho zariadenia sa realizuje pomocou pripojeného počítača, na ktorom beží obslužný softvér zariadenia. Keďže softvér neumožňuje priame exportovanie nameraných údajov, tento proces sa uskutočňuje pomocou rozpoznávania textu zobrazeného na obrazovke obslužného počítača. Rozpoznávanie obrazu je realizované pomocou druhého počítača, ktorý je prepojený na obslužný počítač prostredníctvom siete a prenáša obraz cez RDP protokol. Použitie druhého počítača bolo nevyhnutné, pretože obslužný počítač nedisponuje dostatočným výkonom na vykonávanie ďalších úloh, a inštalácia obslužného softvéru na ďalší výkonnejší počítač nebola možná. Z obrazovky obslužného počítača sa odčítavajú údaje každú sekundu. Okrem systolického a diastolického tlaku sa zbierajú aj hodnoty okysličenia krvi a pulzu. Odčítavanie je realizované pomocou algoritmu, ktorý najprv vytvorí obrázok z obrazovky počítača. Tento obrázok sa následne analyzuje pomocou

algoritmu na rozpoznávanie obrazu a rozpoznané číslice sa následne zasielajú do PostgreSQL databázy.

Každé meranie bolo uskutočnené na testovacích subjektoch , ktoré boli buď v ležiacej, alebo sediacej polohe. Minimálna dĺžka merania jednej osoby bola stanovená na 1 h. Celkovo bolo vykonaných 219 meraní na 81 unikátnych osobách, z čoho 25 bolo ženského pohlavia a 56 mužského pohlavia. Duplicitné merania niektorých osôb nám umožňuje verifikovať správnosť výpočtu. Veková skladba meraných osôb je znázornená na obrázku 5. Najväčší podiel nášho dátového súboru reprezentujú mladší ľudia, čo je vysvetliteľné, keďže merania prebiehali na dobrovoľnej báze a najviac dobrovoľníkov sme našli medzi kolegami a ich známymi. Celkovo dátový súbor obsahuje 389 hodín merania, čo zodpovedá 23 340 vzorkám krvného tlaku z referenčného prístroja, a 70 020 000 nameraným vzorkám PPG signálu. Celkový dátový súbor zodpovedá približne 5 GB dátovému súboru v *.csv formáte.




Obrázok 5 - Veková skladba meraných osôb

Dátový súbor obsahuje údaje z celkovo 10 senzorov, ktoré budú použité na tréningovanie modelu. Tieto údaje budú slúžiť na výpočet krvného tlaku, buď ako referenčné údaje, alebo ako východiskové dáta pre výpočet krvného tlaku. V rámci dátového súboru máme aj údaje z dvoch akcelerometrov, ktoré slúžia na overenie správnosti údajov. Jeden akcelerometer je v našom PPG zariadení, a druhý je prilepený na snímač PPG signálu referenčného zariadenia. Z referenčného meracieho zariadenia sa ukladajú každú sekundu hodnoty systolického krvného tlaku, diastolického krvného tlaku, okysličenia krvi a pulzu. Navrhnuté zariadenie vzorkuje PPG signál na troch rôznych vlnových dĺžkach pomocou dvoch fotosnímačov, a celkovo sa ukladá 6 kriviek PPG signálu so vzorkovacou frekvenciou 50 Hz. Údaje z oboch akcelerometrov sú tiež vzorkované s frekvenciou 50 Hz. Z oboch akcelerometrov sú k dispozícii 3 osi signálu zrýchlenia, ktoré sa dajú použiť na identifikáciu ľudskej aktivity a polohy [45]. V našom prípade sa tieto údaje používajú na overenie a validáciu signálu.

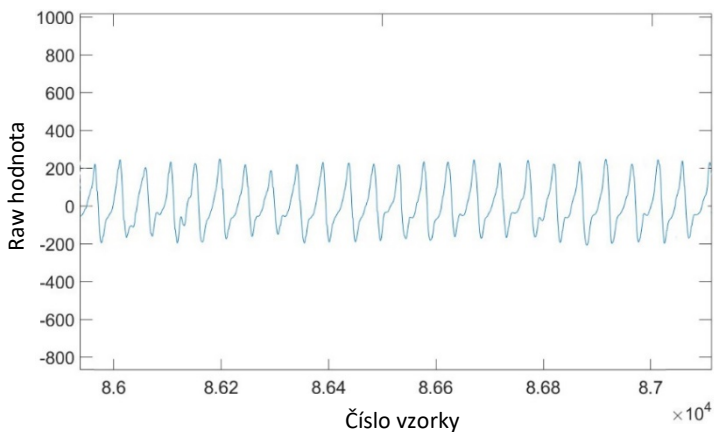
Predspracovanie a filtrovanie nameraných dát

Po nazbieraní dát pre tréovanie modelov strojového učenia je potrebné nazbierané údaje vyfiltrovať od nežiaduceho šumu a odstrániť artefakty z nameraného signálu. Proces filtrovania signálu sa skladá z niekoľkých krokov. Prvým krokom je použitie digitálneho filtra na odstránenie nežiaducich frekvenčných zložiek signálu a ponechanie len užitočného PPG signálu. Ako už bolo spomenuté, najdôležitejšou frekvenčnou zložkou PPG signálu je frekvencia srdcovej činnosti, ktorá zvyčajne spadá do rozsahu od 0,8 Hz do 4 Hz. Na obrázku 6 môžeme vidieť raw PPG signál.



Obrázok 6 – Raw PPG signál

Je potrebné aplikovať filter, ktorý odfiltruje nežiadané frekvenčné zložky signálu, preto sme sa rozhodli použiť FIR filtre. Použili sme hornopriepustný filter 25. rádu s medznou frekvenciou 0,8 Hz a dolnopriepustný filter 6. rádu s medznou frekvenciou 5 Hz. Odfiltrovaný signál môžeme vidieť na obrázku 7.



Obrázok 7 – Filtrovaný priebeh PPG signálu

Údaje obsahujúce nadmerné pohybové artefakty boli odstránené a nahradené syntetickými údajmi vypočítanými z priemeru predchádzajúceho signálu. Poškodenie údajov sa určovalo pomocou akcelerometra. Jednotlivé osi akcelerometra boli vynásobené pomocou karteziánskeho súčinu a keď hodnota prekročila prahovú hodnotu, boli považované za poškodené úseky dát okolo konkrétneho obdobia.

4.3 Trénovanie modelov strojového učenia

Na návrh a tréovanie modelov sme sa rozhodli použiť TensorFlow s kombináciou Keras a Pandas. TensorFlow je platforma s otvoreným zdrojovým kódom vyvinutá a udržiavaná spoločnosťou Google a patrí medzi najpopulárnejšie frameworky pre strojové učenie [46]. Táto popularita znamená silnú komunitu, aktívnu podporu a neustále inovácie. Keras, ako vysokoúrovňové API pre TensorFlow, nám poskytuje jednoduchú možnosť vytvárania a experimentovania s modelmi neurónových sietí. Pandas je štandardom pre manipuláciu s dátami v jazyku Python [47]. Jeho dátové štruktúry a nástroje na analýzu dát uľahčujú predspracovanie a prípravu dát pred ich použitím v modeloch. Táto kombinácia nástrojov nám ponúka univerzálny prístup k problémom strojového učenia a zároveň poskytuje bohatý súbor funkcií pre manipuláciu s dátami. Okrem toho existuje bohatá dokumentácia, množstvo tutoriálov a príkladov pre TensorFlow, Keras a Pandas, čo výrazne uľahčuje učenie, vývoj a riešenie problémov v tejto oblasti.

Pre dosiahnutie čo najlepších výsledkov je mimoriadne dôležitý správny výber modelu strojového učenia. Pre našu aplikáciu sme sa rozhodli pre použitie umelých neurónových sietí. V tejto podkapitole bude overených a otestovaných viacero modelov strojového učenia, od jednoduchších až po zložitejšie modely.

Ako výstup neurónových sietí sme zvolili zoradenie krvného tlaku do jednej z tried Tieto triedy sú zobrazené v kapitole 3.2 v tabuľke 1.

Neurónová sieť číslo 1

Tento model, založený len na dvoch LSTM vrstvách je jeden z najjednoduchších nami overovaných modelov. Neurónová sieť číslo 1 bude slúžiť ako referencia pre porovnanie so zložitejšími štruktúrami.


Vstupom siete je sekvencia o dĺžke 150 vzoriek, čo zodpovedá približne jednej sekunde merania. Tieto dáta sú rozdelené na tri časti po 50 vzoriek. Každý balík so 150 vzorkami sa prekrýva s nasledujúcim balíkom 150 vzoriek o 30%. Sieť sa skladá z dvoch LSTM vrstiev s hyperbolickým tangensom (TanH) ako aktivačnou funkciou. Obe vrstvy sa skladajú z 80 LSTM modulov a výstupnej, plne-prepojenej vrstvy s piatimi neurónmi so SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 8.



Obrázok 8 – Štruktúra neurónovej siete 1

Celkový dátový súbor bol rozdelený na dva súbory: trénovací a testovací. 20 % dátového súboru slúžilo na testovanie a zvyšok na trénovanie siete. Pri trénovaní bol použitý optimalizátor Adam (Adaptive Moment Estimation) s chybovou funkciou krížová entropia. Veľkosť dávky (angl. batch size) bola 32 a celkovo bolo vykonaných 19 000 trénovacích iterácií. Trénovanie bolo ukončené po dosiahnutí 90 % úspešnosti klasifikácie na trénovacom súbore. Úspešnosť

neurónovej siete po trénovaní na testovacom súbore dosiahla len 65 % úspešnosti. Sieť je príliš jednoduchá a nie je schopná dostatočne generalizovať údaje. Dosiahnuté výsledky nie sú zlé, ale zároveň nie sú dostatočné pre nasadenie do reálneho sveta. Na obrázku 9 je zobrazený graf trénovanie modelu.



Obrázok 9 – Graf vývoja presnosti modelu počas trénovanie neurónovej siete 1

Neurónová sieť číslo 2

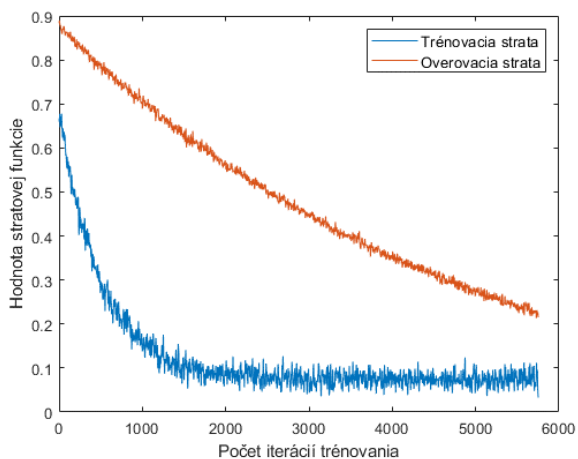
Pri tomto modeli vstup a výstup siete sú rovnaké ako pri predošlom modeli. Rozdiel oproti štruktúre predošlého modelu je, že LSTM vrstvy boli nahradené obojsmernými BiLSTM vrstvami. Sieť sa skladá zo vstupnej vrstvy a z dvoch skrytých BiLSTM vrstiev, každá s TanH aktivačnou funkciou. Obe skryté vrstvy sa skladajú z 80 BiLSTM modulov. Výstupnú vrstvu tvorí plne-prepojená vrstva s piatimi

neurónmi a so SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 10.



Obrázok 10 - Štruktúra neurónovej siete 2

Celkový dátový súbor bol rozdelený na trénovací a testovací. 20 % súboru slúžilo na testovanie. Pri trénovaní bol použitý Adam optimalizátor so stratovou funkciou krížová entropia, batch size bola 32 a celkovo bolo vykonaných 180 000 trénovacích iterácií. Trénovanie bolo ukončené po dosiahnutí 90 % úspešnosti klasifikácie na trénovacej množine. Úspešnosť neurónovej siete po trénovaní bola 80 %. Výsledkom je, že použitie BiLSTM vrstiev namiesto LSTM vrstiev zlepšuje úspešnosť klasifikácie siete, ale nie dostatočne na použitie v praxi a zároveň BiLSTM architektúra je veľmi výpočtovo náročná, takže nie je vhodná pre použitie vo vnorených systémoch. Graf trénovania je zobrazený na obrázku 11.

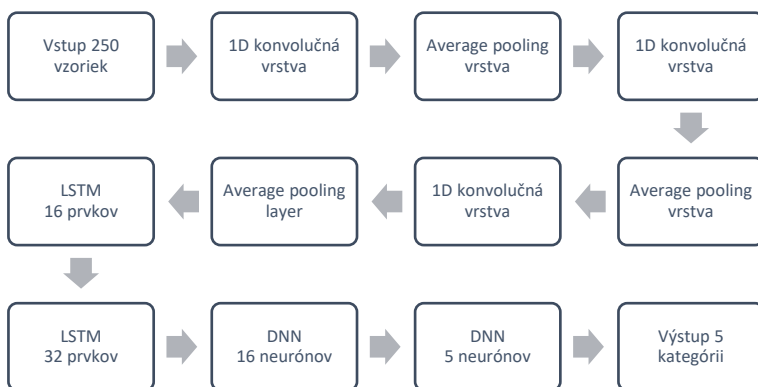


Obrázok 11 - Graf vývoja presnosti modelu počas tréningovania neurónovej siete 2

Neurónová sieť číslo 3

Pri tomto modeli je vstup siete sekvencia o dĺžke 250 vzoriek. Štruktúra siete je pomerne zložitá a je inšpirovaná publikáciou [48], kde štruktúra siete vznikla kombinovaním konvolučných a LSTM vrstiev. Dáta vstupujú do prvej konvolučnej vrstvy, ktorá sa skladá zo 64 konvolučných filtrov s rozmerom okna 25 a s aktivačnou funkciou ReLU. Po konvolučnej vrstve nasleduje zhlukovacia vrstva. Po zhlukovacej vrstve nasleduje ďalšia konvolučná vrstva, ktorá sa skladá z 32 filtrov a rozmerom okna 25 a s aktivačnou funkciou ReLU. Ďalej nasleduje zhlukovacia vrstva. Po zhlukovacej vrstve nasleduje ďalšia konvolučná vrstva, ktorá sa skladá zo 16 filtrov a rozmerom okna 25 a s aktivačnou funkciou ReLU, pričom nasleduje ďalšia zhromažďovacia vrstva. Po zhromažďovacej vrstve nasledujú vrstvy s

LSTM prvkami. Prvá je 16-prvková a druhá je 32-prvková, obe s TanH aktivačnou funkciou. Ďalšia vrstva je plne-prepojená, so 16 neurónmi a s aktivačnou funkciou ReLU. Výstupnú vrstvu tvorí plne-prepojená vrstva s piatimi neurónmi so SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 12.




Obrázok 12 - Štruktúra neurónovej siete 3

Celkový dátový súbor bol rozdelený na tréningový a testovací, kde 20 % celkového súboru slúžilo na testovacie účely. Pri tréningu bol použitý Adam optimalizátor so stratovou funkciou krížová entropia, batch size bola 32 a celkovo bolo vykonaných 200 000 tréningových iterácií. Tréning bolo predčasne ukončené, keďže tréningová úspešnosť po dvoch dňoch tréningu nekonvergovala. Úspešnosť neurónovej siete po tréningu zodpovedala 53 %. K neúspešnosti modelu mohlo viesť viacero dôvodov, ako sú nedostatočné množstvo dát alebo príliš malý rozmer siete na to, aby mohla vykonávať generalizáciu dát. Avšak väčšia štruktúra siete by sa pravdepodobne

nezmesčila do vnoreného zariadenia. Rozdiely vo výsledkoch oproti článku, z ktorého sa vychádzalo [48], mohli byť spôsobené aj kvôli rozdielnemu tvaru PPG signálu na hrudi a na prste.

Neurónová sieť číslo 4


Pri tomto modeli je vstup siete sekvencia 100 vzoriek. Prvá vrstva siete je plne-prepojená so 130 neurónmi a s aktivačnou funkciou ReLU, ďalej nasledujú ďalšie dve plne-prepojené vrstvy s totožnou štruktúrou. Na výstupe sa nachádza plne-prepojená vrstva s piatimi neurónmi so SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 13.



Obrázok 13 - Štruktúra neurónovej siete 4

Celkový dátový súbor bol rozdelený na tréningový a testovací, kde 20 % súboru slúžilo na testovanie. Pri tréningu bol použitý Adam optimalizátor so stratovou funkciou krížová entropia, batch size bola 32 a celkovo bolo vykonaných 10 000 tréningových iterácií, kde tréning bolo ukončené po dosiahnutí 90 % úspešnosti klasifikácie


na trénoacom dátovom súbore. Úspešnosť neurónovej siete po trénoaní bola 65 %. Graf trénoania je zobrazený na obrázku 14.



Obrázok 14 - Graf vývoja presnosti modelu počas trénoania neurónovej siete 4


Neurónová sieť číslo 5

Pri tomto modeli je vstup siete sekvencia 100 vzoriek. Prvá vrstva siete je plne-prepojená vrstva so 130 neurónmi a s aktivačnou funkciou ReLU. Ďalej nasledujú ďalšie štyri plne-prepojené vrstvy s totožnou štruktúrou. Na výstupe sa nachádza plne-prepojená vrstva s piatimi neurónmi so SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 15.



Obrázok 15 - Štruktúra neurónovej siete 5

Celkový dátový súbor bol rozdelený na tréningový a testovací, kde 20 % súboru slúžilo na testovanie. Pri tréningu bol použitý Adam optimalizátor so stratovou funkciou krížová entropia, pričom batch size bola 32. Celkovo bolo vykonaných 40 000 tréningových iterácií. Tréning bolo ukončené po dosiahnutí 90 % úspešnosti klasifikácie. Úspešnosť neurónovej siete bola po tréningu 62 %. Graf tréninga je zobrazený na obrázku 16.

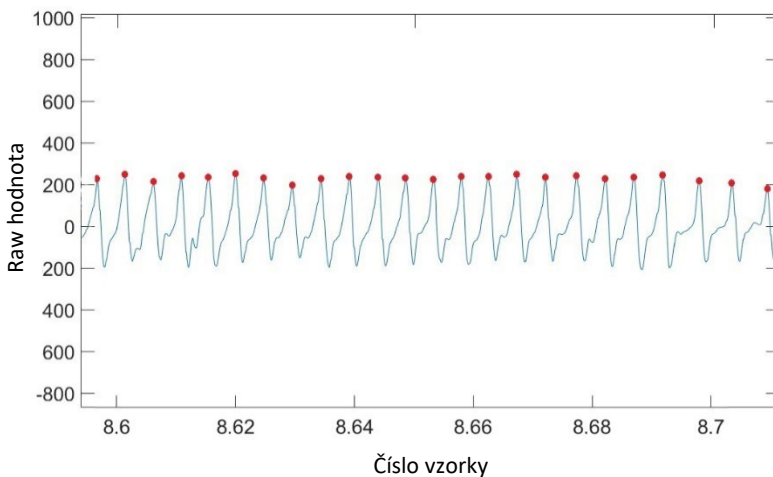


Obrázok 16 - Graf vývoja presnosti modelu počas tréninga neurónovej siete 5

Neurónová sieť číslo 6

Tento model založený len na dvoch LSTM vrstvách a vychádza z prvého overovaného modelu. Vstupom siete je sekvencia 150 vzoriek, čo zodpovedá približne jednej sekunde merania. Tieto dáta sú rozdelené na tri časti po 50 vzoriek. Každých 50 vzoriek bolo vycentrovanych podľa maximálnej hodnoty jedného segmentu PPG signálu, nájdeného pomocou algoritmu publikovaného v článku [49].

Hodnoty PPG signálu nájdené podľa algoritmu sú zobrazené na obrázku 17.



Obrázok 17 – PPG signál s označenou špičkovou hodnotou

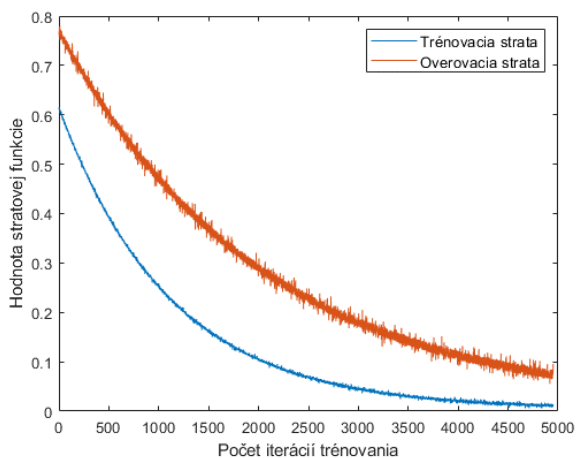
Model sa skladá zo vstupnej vrstvy, z dvoch LSTM vrstiev s TanH aktivačnou funkciou, ktoré obe majú 150 LSTM modulov. Ďalej sa neurónová sieť skladá z výstupnej vrstvy s piatimi neurónmi so

SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 18.



Obrázok 18 - Štruktúra neurónovej siete 6


Celkový dátový súbor ako v ostatných prípadoch bol rozdelený na trénovací a testovací, kde 20 % dátového súboru slúžilo na testovanie. Pri trénovaní bol použitý Gradient Descent With Momentum optimalizátor s momentom 0,9 so stratovou funkciou krížová entrópia, batch size bola 16 a celkovo bolo vykonaných 180 000 trénovacích iterácií. Trénovanie bolo ukončené po dosiahnutí 90 % úspešnosti klasifikácie na trénovacom dátovom súbore. Počas trénovania siete bol aplikovaný 0,5 dropout, čo malo za následok náhodné nulovanie váh počas trénovania, s pravdepodobnosťou 50%. Úspešnosť neurónovej siete po trénovaní zodpovedala 89 %. Výsledkom je, že použitie väčšej štruktúry LSTM siete s kombináciou algoritmu na vycentrovanie signálu zlepšuje presnosť predpovede modelu. Rovnaká štruktúra siete bez spracovania vstupu dosahovala 65 % úspešnosť klasifikácie krvného tlaku. Graf trénovania je zobrazený na obrázku 19.



Obrázok 19 - Graf vývoja presnosti modelu počas tréningovania neurónovej siete 6

Neurónová sieť číslo 7


Tento model je založený na troch LSTM vrstvách a vychádza z predošlého overovaného modelu. Tento model sa líši pridaním ďalšej LSTM vrstvy. Vstup modelu je totožný ako pri predošlom modeli. Model sa skladá zo vstupnej vrstvy, z troch LSTM vrstiev s TanH aktivačnou funkciou, ktoré majú 150 prvkov, a výstupnej, plne-prepojenej vrstvy so SoftMax aktivačnou funkciou. Štruktúra neurónovej siete je znázornená na obrázku 20.



Obrázok 20 - Štruktúra neurónovej siete 7

Celkový dátový súbor bol rovnako ako v ostatných prípadoch rozdelený na tréningový a testovací, kde 20 % dátového súboru slúžilo na testovanie. Pri tréningu bol použitý Gradient Descent With Momentum optimalizátor s momentom 0,9 so stratovou funkciou krížová entropia, batch size bola 16 a celkovo bolo vykonaných 200 000 tréningových iterácií. Tréning bolo ukončené po dosiahnutí 90 % úspešnosti klasifikácie na tréningovom dátovom súbore a počas tréningu bol aplikovaný 0,5 dropout. Úspešnosť neurónovej siete po tréningu bola 76 %.

Výsledkom je, že použitie viac LSTM vrstiev nezlepšuje predikciu modelu. Model, vďaka zložitejšej štruktúre, disponuje väčším množstvom pamäte, čo viedlo k prílišnej adaptácii na tréningové dáta. V dôsledku toho sa model pretrénoval a nedosiahol zlepšenie oproti predošlému modelu. Graf tréningu je zobrazený na obrázku 21.



Obrázok 21 - Graf vývoja presnosti modelu počas tréningovania
neurónovej siete 7

Zhrnutie výsledkov

Z testovania modelov vyplýva, že najlepšie výsledky klasifikácie v skupine systolického krvného tlaku dosiahla neurónová sieť 6. Táto sieť používa dve 150-prvkové LSTM vrstvy s predspracovaním vstupného signálu. Počas trénovania dosiahla táto sieť presnosť 89 %. Pre dosiahnutie ešte lepších výsledkov by bolo potrebné disponovať väčším množstvom trénovacích údajov. Komplexnejšie štruktúry neurónových sietí neboli overované, pretože by nebolo možné ich implementovať do vnoreného systému. V tabuľke 4 sú zhrnuté výsledky úspešnosti jednotlivých modelov. Úspešnosť týchto modelov je určená ako počet správne zoradených vzoriek krvného tlaku v skupine ku celkovému počtu vzoriek krvného tlaku z testovacieho dátového súboru.

Tabuľka 2 – Zhrnutie modelov

Model	Štruktúra	Úspešnosť
Neurónová sieť číslo 1	2 x LSTM 80	65 %
Neurónová sieť číslo 2	2 x BiLSTM 80	80 %
Neurónová sieť číslo 3	3 x CNN – 2 x LSTM - DNN	53 %
Neurónová sieť číslo 4	3 x DNN 150	65 %
Neurónová sieť číslo 5	5 x DNN 150	62 %
Neurónová sieť číslo 6	2 x LSTM 150	89 %
Neurónová sieť číslo 7	3 x LSTM 150	76 %

Keďže model 6 dosahoval najlepšie výsledky, v ďalšej kapitole sa budeme zaoberať optimalizáciou a implementáciou modelu číslo 6 do vnoreného systému.

4.4 Implementácia modelu do vnoreného systému

Existuje niekoľko spôsobov optimalizácie neurónových sietí. Zmyslom optimalizácie neurónových sietí je zníženie výpočtových nárokov, čoho následkom sa zníži výpočtový čas, množstvo potrebnej operačnej a dátovej pamäte a v neposlednom energetická náročnosť zariadenia, čo je pri zariadeniach napájaných z batérií mimoriadne dôležitý parameter. Najpoužívanejšie metódy optimalizácie neurónových sietí sú: kvantizácia, orezávanie a zhlukovanie váh [50], [51].

Pri kvantizácii modelu dochádza k redukcii presnosti dátových typov, ktoré slúžia na uloženie stavov neurónovej siete. Pri neurónových sieťach sa obvykle používajú dátové typy float32, ktoré majú dostatočnú presnosť, avšak pre použitie vo vnorených systémoch sú nevhodné, keďže vyžadujú viac pamäte a výpočtového výkonu. Pre vnorené systémy je vhodné použiť menej presné dátové typy, ako sú napríklad float16, int32, int16 alebo int8. Takáto zámena dátových typov môže zredukovať pamäťovú stopu siete až štvornásobne a zároveň zlepšiť výpočtový čas. Avšak takáto optimalizácia siete vyžaduje úplné pretrénovanie siete. Po zámene dátových typov a pretrénovaní modelu sa štvornásobne zmenšil rozmer siete, ale zároveň sa zhoršila presnosť z 89 % na 84 %. Kvantizácia modelu bola uskutočnená pomocou konverzie TensorFlow modelu na TensorFlowLite model [51], [52]

Orezávanie modelu sa uskutočňuje pomocou vymazávania spojení z modelu, ktoré majú váhu blízko k nule. Pomocou aplikácie orezávania modelu je možné zmenšiť rozmer modelu až trojnásobne.

Orezanie modelu bolo vykonané pomocou Kerasu. Kombinovaním kvantizácií a orezávania modelu sa podarilo získať desaťnásobne menší model pri znížení presnosti modelu na 83 % [51], [53].

Pojem zhlukovania váh alebo zdieľania váh znižuje počet unikátnych hodnôt váh v modeli, čo vedie k zmenšovaniu modelu. Pri tejto metóde sa najprv zoskupia váhy vrstiev do N zhlukov a potom tieto váhy zdieľajú hodnotu geometrického stredy všetkých hodnôt patriacich do zhuku.

Obvykle sa kombinujú metódy kvantizácie buď s orezávaním alebo so zhlukovaním. Pri našej aplikácii sme uprednostnili použitie kombinácie orezávania a kvantizácie, keďže dosahovala lepšie výsledky ako kombinácia metód zhlukovania a kvantizácie [54].

Existuje niekoľko spôsobov optimalizácie neurónových sietí. Zmyslom optimalizácie neurónových sietí je zníženie výpočtových nárokov, čoho následkom sa zníži výpočtový čas, množstvo potrebnej operačnej a dátovej pamäte a v neposlednom energetická náročnosť zariadenia, čo je pri zariadeniach napájaných z batérií mimoriadne dôležitý parameter. Najpoužívanejšie metódy optimalizácie neurónových sietí sú: kvantizácia, orezávanie a zhlukovanie váh [50], [51].

Pri kvantizácii modelu dochádza k redukcii presnosti dátových typov, ktoré slúžia na uloženie stavov neurónovej siete. Pri neurónových sieťach sa obvykle používajú dátové typy float32, ktoré majú dostatočnú presnosť, avšak pre použitie vo vnorených systémoch sú nevhodné, keďže vyžadujú viac pamäte a výpočtového výkonu. Pre vnorené systémy je vhodné použiť menej presné dátové

typy, ako sú napríklad float16, int32, int16 alebo int8. Takáto zámena dátových typov môže zredukovať pamäťovú stopu siete až štvornásobne a zároveň zlepšiť výpočtový čas. Avšak takáto optimalizácia siete vyžaduje úplné pretrénovanie siete. Po zámene dátových typov a pretrénovaní modelu sa štvornásobne zmenšil rozmer siete, ale zároveň sa zhoršila presnosť z 89 % na 84 %. Kvantizácia modelu bola uskutočnená pomocou konverzie TensorFlow modelu na TensorFlowLite model [51], [52]

Orezávanie modelu sa uskutočňuje pomocou vymazávania spojení z modelu, ktoré majú váhu blízko k nule. Pomocou aplikácie orezávania modelu je možné zmenšiť rozmer modelu až trojnásobne. Orezanie modelu bolo vykonané pomocou Kerasu. Kombinovaním kvantizácií a orezávania modelu sa podarilo získať desaťnásobne menší model pri znížení presnosti modelu na 83 % [51], [53].

Pojem zhlukovania váh alebo zdieľania váh znižuje počet unikátnych hodnôt váh v modeli, čo vedie k zmenšovaniu modelu. Pri tejto metóde sa najprv zoskupia váhy vrstiev do N zhlukov a potom tieto váhy zdieľajú hodnotu geometrického streda všetkých hodnôt patriacich do zhluku.

Obvykle sa kombinujú metódy kvantizácie buď s orezávaním alebo so zhlukovaním. Pri našej aplikácii sme uprednostnili použitie kombinácie orezávania a kvantizácie, keďže dosahovala lepšie výsledky ako kombinácia metód zhlukovania a kvantizácie [54].

Po návrhu a optimalizácii modelu nasleduje implementácia modelu do vnoreného systému. Na implementáciu sme zvolili využitie knižnice TensorFlow Lite for Microcontrollers v jazyku C++.

Táto knižnica je optimalizovaná pre mikrokontroléry a vyžaduje len 16 kB pamäte na svoje fungovanie. Vytvorený model vo formáte TensorFlow Lite sa konvertuje do poľa v jazyku C++ pomocou konverzného programu [55]. Následne sme do už existujúceho riadiaceho softvéru zariadenia nainportovali knižnice a hlavičkové súbory obsahujúce skonvertované váhy natrénovaného modelu.

Riadiaci softvér zariadenia sa skladá z viacerých častí. Samotný merací cyklus začína inicializáciou senzora. Počas tohto kroku sa nastaví samotný senzor a začne sa merací cyklus. Senzor po naplnení svojho FIFO registra pošle prerušenie a následkom prerušenia sa vyčítajú údaje zo senzora. Tieto údaje vstupujú do hornopriepustného a dolnopriepustného FIR filtra s medznou frekvenciou 0,8 Hz, respektíve 5 Hz. Po odfiltrovaní signálu sa pomocou algoritmu slúžiaceho na hľadanie maximálnej hodnoty signál vycentruje a vstupuje do časti kódu pre výpočet krvného tlaku. V tejto časti kódu sa odhadne systolický krvný tlak pomocou navrhnutého algoritmu. Následne sa odhadnutý krvný tlak spolu s raw nameranými údajmi odošle na server pomocou rádiových prenosu. Odhad krvného tlaku z jedného balíka PPG dát, čo zodpovedá približne trom sekundám, trvá v rozmedzí 1 až 1,5 sekundy. Takže zariadenie je schopné kontinuálne odhadovať krvný tlak pri zachovaní kontinuálneho merania PPG signálu a zároveň ostáva čas na odosielanie raw dát na server.

5 Záver

Prvá časť práce bola venovaná teoretickým základom merania vybraných fyziologických parametrov ľudského tela. V tejto časti boli zhrnuté teoretické základy fotopletyzografie, elektrokardiografie a merania krvného tlaku invazívnymi a neinvazívnymi metódami. Pri neinvazívnom meraní krvného tlaku boli zhrnuté všetky konvenčné aj inovatívnejšie prístupy. V ďalšej časti teoretickej časti práce boli vysvetlené základy vnorených systémov a strojového učenia. Najprv sme sa venovali vnoreným systémom a následne strojovému učeniu a k uplatneniu strojového učenia vo vnorených systémoch. Pri strojovom učení bola venovaná pozornosť plytkému strojovému učeniu a hlbokému strojovému učeniu.

V rámci experimentálnej časti bolo v prvom kroku prístupné k samotnému návrhu zariadenia na meranie fotopletyzografického signálu. Väčšina dostupných zariadení neposkytuje prístup k čistým (raw) dátam, neumožňuje regulovať výkon LED ani meniť vzorkovaciu frekvenciu. Z toho dôvodu bol realizovaný prvotný návrh rozloženia súčiastok na doske plošných spojov a jeho ďalšia optimalizácia s cieľom zabezpečiť ideálnu geometriu prvkov. Postupnou iteráciou viacerých prototypov bol nakoniec pripravený návrh obsahujúci špeciálne rozloženie viacerých dvojíc LED a senzorov (PPG snímačov), ktorý umožňoval účinnú softvérovú konfiguráciu jednotlivých LED. Jedná sa o unikátny návrh geometrie, vyznačujúci sa výraznou flexibilitou, vďaka ktorej je možné zabezpečiť mapovanie PPG signálu

na ľubovoľnej časti ľudskeho tela. Po stanovení geometrie bolo pristúpené k samotnému návrhu PCB. Úspešný návrh zariadenia predstavoval kritický míľnik celej práce z toho dôvodu bol na jeho optimálnu prípravu kladený vysoký dôraz. Vo výslednej iterácii návrh senzorickej časti obsahoval 15 jednotlivito ovládateľných trojfarebných elektroluminiscenčných diód, slúžiacich ako zdroj signálu. Dvojicu fotosnímačov, pričom jeden z tejto dvojice je integrovaný do analógového frontendu meracieho obvodu. Na senzorickej doske plošných spojov sa ďalej nachádzajú nevyhnutné obslužné obvody ku snímaniu signálu. Na digitálnej časti zariadenia sa nachádza riadiaci mikrokontrolér a ďalšie obslužné obvody. Jedná sa o unikátny hardvérový návrh, vzhľadom na súčasný stave techniky, ktorý sa vyznačuje použitím jednej dvojice LED a fotosnímača.

Ďalším významným míľnikom tejto práce bol zber dát a predspracovanie dát na následnú tvorbu modelov strojového učenia. V prvom kroku bola určená metodika merania, ktorá zahŕňala umiestenie senzorov, polohu a pokyny pre meraných dobrovoľníkov. Následne bolo pristúpené k samotným meraniam. Celkovo bolo získaných šesť fotopletyzmozografických kriviek pomocou spomenutých fotodetektorov na vlnových dĺžkach 530nm, 655nm a 940 nm. Vzhľadom na vlastnosti ľudskeho tkaniva, každá z vlnových dĺžok bola absorbovaná v inej hĺbke, takže bolo možné extrapolovať viacero užitočných dát na tréovanie modelov. Vďaka implementáciám akcelerometra a dátam získaným dátam bolo možné determinovať úseky PPG signálu ktoré boli poškodené vplyvom pohybu probanda.

Značnou výhodou sa pri riešení práce preukázala korelácia všetkých získaných dát s vypožičaným lekárskej prístrojom, ktorý je používaný na jednotkách intenzívnej starostlivosti. Referenčné dáta poskytnuté týmto prístrojom predstavovali údaje o systolickom a diastolickom krvnom tlaku a zároveň o pulze a saturácii krvi.

Pomocou zvolenej metodiky, voľbe zberu dát z navrhnutého zariadenia a zabezpečenia referenčného prístroja bolo celkovo vykonaných 219 meraní na 81 unikátnych osobách, z ktorých 25 bolo ženského pohlavia a 56 bolo mužského pohlavia.

Po získaní enormného množstva dát, bolo prístupné k ich spracovaniu. Na jednotlivých krivkách fotopletyzografického signálu bol aplikovaný FIR filter, ktorý odstránil nežiadané frekvenčné zložky signálu. Bol použitý hornopriepustný filter 25. rádu s medznou frekvenciou 0,8 Hz a dolnopriepustný filter 6. rádu s medznou frekvenciou 5 Hz. Dáta poškodené pohybovými artefaktmi boli následne odstránené a nahradené syntetickými dátami vypočítanými z priemeru predošlého signálu.

Zo súčasného stavu techniky a dostupnej literatúry vyplynulo, nebol nájdený žiadny zdroj, ktorý by sa zaoberal odhadom krvného tlaku z fotopletyzografického signálu na hrudi. To naznačuje, že metóda, ktorú sme si vybrali, je inovatívna. Vzhľadom na obmedzenia dané tvarom získaného signálu, ako aj samotným výpočtovým výkonom zariadenia vyplynulo, že jediné aplikovateľné metódy pre deklarovanú aplikáciu sú metódy založené na neurónových sieťach. Neurónové siete sú najlepšou možnosťou na hľadanie závislostí

medzi dátami, ktoré nie je možné získať morfológickou analýzou signálov.

Boli preto testované viaceré neurónové siete, pričom prvá neurónová sieť verifikovaná v práci sa skladala z dvoch LSTM vrstiev, kde v každej vrstve bolo 80 LSTM modulov. Toto bola pilotná overovaná sieť, ktorá slúžila ako východiskový bod na porovnanie s ďalšími zložitejšími modelmi. Úspešnosť odhadovania krvného tlaku pri tomto modeli bola 65 %, čo je veľmi nízke číslo. Avšak predstavovalo odrazový stupeň v rámci ďalších analýz. Vhodným výberom neurónovej siete a jeho optimalizáciou bolo možné zvýšiť úspešnosť odhadu až na 89%, čo môžeme považovať ako dostatočnú presnosť odhadu. Jednalo sa o neurónovú sieť s dvomi LSTM vrstvami po 150 LSTM modulov vo vrstve. Výpočet tejto siete sme rozšírili o ďalší algoritmus, ktorý slúži na hľadanie špičkovej hodnoty fotopletyzomografického signálu, podľa ktorého sme následne posunuli dáta, ktoré vstupujú do neurónovej siete, aby boli vycentrované okolo maximálnej hodnoty signálu.

Následovala optimalizácia modelu pre implementáciu do vnoreného systému. Na tento proces boli využité nástroje kvantizácie a orezávania modelu, čoho následkom sa podarilo zmenšiť model desaťnásobne pri znížení presnosti modelu na 83 %. To predstavuje významný úspech, vzhľadom na absenciu obdobného technického riešenia implementujúceho model neurónovej siete v nositeľnej elektronike s podobným zameraním. Následne sme do vnoreného systému implementovali už optimalizovaný model spolu

s algoritmami na filtrovanie signálu a hľadanie špičkovej hodnoty signálu. Odhad krvného tlaku z jedného balíka PPG dát, čo zodpovedá približne trom sekundám, trvá v rozmedzí 1 až 1,5 sekundy. Takže zariadenie je schopné kontinuálne odhadovať krvný tlak pri zachovaní kontinuálneho merania PPG signálu, a zároveň zostáva čas na odosielanie raw dát na server.

Treba ešte na záver konštatovať, že výsledky dosiahnuté v tejto práci sú ešte predmetom ďalšieho výskumu. Dosiahnuté výsledky odhadu krvného tlaku sú vysoko obmedzené rozsahom dátového súboru, keďže nazbieraný dátový súbor obsahuje málo dát od dobrovoľníkov staršieho veku. Dátový súbor obsahuje najviac dátových bodov s hodnotami nízkeho, optimálneho a mierne zvýšeného krvného tlaku, takže po dodatočnom testovaní na pacientoch so zvýšeným a kritickým krvným tlakom sa môže potvrdiť, že navrhnutý model nebude optimálne odhadovať krvný tlak. Ak sa táto skutočnosť potvrdí, bude potrebné pretrénovanie modelu na väčšej vzorke dobrovoľníkov. Zlepšenie odhadu presnosti krvného tlaku bude ešte predmetom ďalšieho výskumu a dátový súbor sa bude ešte rozširovať o ďalšie merania dobrovoľníkov.

6 Zhrnutie

Hlavné prínosy práce môžeme zhrnúť do nasledovných bodov:

- Boli zhrnuté teoretické základy fotopletyzografie, elektrokardiografie a merania krvného tlaku invazívnymi a neinvazívnymi metódami.
- Boli vysvetlené základy vnorených systémov a strojového učenia.
- Bolo navrhnuté inovatívne zariadenie na meranie fotopletyzografického signálu, s možnosťou konfigurácie geometrie zdrojov svetla, pre flexibilné umiestnenie zariadenia na ľubovoľnej časti ľudského tela.
- Navrhnuté zariadenie bolo vyhotovené do prvého funkčného prototypu.
- Bolo vyhotovených niekoľko kusov zariadenia, ktoré boli porovnané s konvenčnými PPG zariadeniami.
- Bol vytvorený systém pre zber dát a webovú konfiguráciu zariadenia.
- Bolo vytvorené meracie pracovisko na zber dát, s profesionálnym referenčným meracím prístrojom.
- Bolo nazbierané a spracované enormné množstvo tréningových dát.
- Boli vytvorené neurónové siete, ktoré sa pomocou iterácií natrénovali do stavu, keď boli schopné určiť kategóriu krvného tlaku.

- Vybraná neurónová sieť typu RNN LSTM dokázala úspešne odhadovať krvný tlak z fotopletyzmozografického signálu s vysokou úspešnosťou až 89%.
- Model vybranej neurónovej siete bol úspešne optimalizovaný a implementovaný do vnoreného systému.
- Optimalizácia prebiehala odstraňovaním nadbytočných spojení medzi neurónmi, kvantizáciou neurónovej siete a optimalizáciou štruktúry.
- Po optimalizácii mala neurónová sieť úspešnosť 83% na testovacom datasete.
- Implementácia do vnoreného systému bola vykonaná priamou implementáciou neurónovej siete do nrf52 MCU, kde bola jej funkčnosť overená na dobrovoľníkoch.
- Navrhnuté zariadenie a modely strojového učenia majú potenciál zlepšiť diagnostiku a monitorovanie krvného tlaku u pacientov, čo môže viesť k lepšej predikcii a riadeniu hypertenzie a iných kardiovaskulárnych ochorení.
- Navrhnuté zariadenie umožňuje možnosť ďalšieho výskumu.

7 Summary

The main contributions of the work can be summarized as follows:

- The theoretical foundations of photoplethysmography, electrocardiography, and blood pressure measurement by invasive and non-invasive methods were summarized.
- The basics of embedded systems and machine learning were explained.
- An innovative device for measuring photoplethysmographic signals was designed, with the possibility of configuring the geometry of light sources for flexible placement on any part of the human body.
- The designed device was produced as the first functional prototype.
- Several units of the device were manufactured and compared with conventional PPG devices.
- A system for data collection and web configuration of the device was created.
- A measurement workstation for data collection, with a professional reference measuring instrument, was established.
- An enormous amount of training data was collected and processed.
- Neural networks were created and trained through iterations to determine blood pressure categories.

- A selected RNN LSTM neural network successfully estimated blood pressure from photoplethysmographic signals with a high accuracy of up to 89%.
- The model of the selected neural network was successfully optimized and implemented into an embedded system.
- Optimization involves removing redundant connections between neurons, quantizing the neural network, and optimizing its structure.
- After optimization, the neural network achieved an accuracy of 83% on the test dataset.
- Implementation into the embedded system was done by directly implementing the neural network into the nrf52 MCU, and its functionality was verified on volunteers.
- The designed device and machine learning models have the potential to improve the diagnosis and monitoring of blood pressure in patients, leading to better prediction and management of hypertension and other cardiovascular diseases.
- The designed device allows for further research opportunities.

8 Zoznam použitej literatúry

- [1] “22% of people in the EU have high blood pressure - Products Eurostat News - Eurostat”. Cit: 31. október 2021. [Online]. Available at: <https://ec.europa.eu/eurostat/web/products-eurostat-news/-/edn-20210929-1>
- [2] “Hypertension”. Cit: 21. november 2023. [Online]. Available at: <https://www.who.int/news-room/fact-sheets/detail/hypertension>
- [3] “Biofyzika”, Cit: 05. december 2023. [Online]. Available at: <http://sk.hartmann.info/119839.php>
- [4] J. J. Polder, L. Bonneux, W. J. Meering, a P. J. Van Der Maas, “Age-specific increases in health care costs”, *Eur J Public Health*, roč. 12, č. 1, 2002, doi: 10.1093/eurpub/12.1.57.
- [5] Y. Khan *et al.*, “Monitoring of Vital Signs with Flexible and Wearable Medical Devices”, *Advanced Materials*, roč. 28, č. 22, s. 4373–4395, jún. 2016, doi: 10.1002/ADMA.201504366.
- [6] A. Pantelopoulos a N. G. Bourbakis, “A survey on wearable sensor-based systems for health monitoring and prognosis”, *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, roč. 40, č. 1, s. 1–12, 2010, doi: 10.1109/TSMCC.2009.2032660.
- [7] N. Rodriguez, D. P. Morales, A. Rivadeneyra, N. L. Kazanskiy, M. A. Butt, a S. N. Khonina, “Recent Advances in Wearable Optical Sensor Automation Powered by Battery versus Skin-like Battery-Free Devices for Personal Healthcare—A Review”, *Nanomaterials 2022, Vol. 12, Page 334*, roč. 12, č. 3, s. 334, jan. 2022, doi: 10.3390/NANO12030334.
- [8] “Wearable Medical Devices Market Size worth USD 195.57 Bn by”. Cit: 27. november 2023. [Online]. Available at: <https://www.globenewswire.com/news-release/2022/02/03/2378221/0/en/Wearable-Medical-Devices-Market-Size-worth-USD-195-57-Bn-by-2027-With-stunning-26-4-CAGR.html>
- [9] H. Yao, A. J. Shum, M. Cowan, I. Lähdesmäki, a B. A. Parviz, “A contact lens with embedded sensor for monitoring tear

- glucose level”, *Biosens Bioelectron*, roč. 26, č. 7, s. 3290–3296, mar. 2011, doi: 10.1016/J.BIOS.2010.12.042.
- [10] X. Zhu, W. Liu, S. Shuang, M. Nair, a C. Z. Li, “Intelligent tattoos, patches, and other wearable biosensors”, *Medical Biosensors for Point of Care (POC) Applications*, s. 133–150, jan. 2017, doi: 10.1016/B978-0-08-100072-4.00006-X.
- [11] A. J. Bandonkar a J. Wang, “Non-invasive wearable electrochemical sensors: a review”, *Trends Biotechnol*, roč. 32, č. 7, s. 363–371, júl. 2014, doi: 10.1016/J.TIBTECH.2014.04.005.
- [12] S. Patel, H. Park, P. Bonato, L. Chan, a M. Rodgers, “A review of wearable sensors and systems with application in rehabilitation”, *J Neuroeng Rehabil*, roč. 9, č. 1, s. 1–17, apr. 2012, doi: 10.1186/1743-0003-9-21/FIGURES/7.
- [13] K. Guk *et al.*, “Evolution of Wearable Devices with Real-Time Disease Monitoring for Personalized Healthcare”, *Nanomaterials 2019, Vol. 9, Page 813*, roč. 9, č. 6, s. 813, máj. 2019, doi: 10.3390/NANO9060813.
- [14] J. Kim, A. S. Campbell, B. E. F. de Ávila, a J. Wang, “Wearable biosensors for healthcare monitoring”, *Nature Biotechnology 2019 37:4*, roč. 37, č. 4, s. 389–406, feb. 2019, doi: 10.1038/s41587-019-0045-y.
- [15] J. Zhang *et al.*, “Diagnostic Features and Potential Applications of PPG Signal in Healthcare: A Systematic Review”, *Healthcare 2022, Vol. 10, Page 547*, roč. 10, č. 3, s. 547, mar. 2022, doi: 10.3390/HEALTHCARE10030547.
- [16] K. H. Shelley, “Photoplethysmography: Beyond the calculation of arterial oxygen saturation and heart rate”, *Anesth Analg*, roč. 105, č. SUPPL. 6, 2007, doi: 10.1213/01.ANE.0000269512.82836.C9.
- [17] C. Lee, H. S. Shin, a M. Lee, “Relations between ac-dc components and optical path length in photoplethysmography”, *J Biomed Opt.*, roč. 16, č. 7, s. 077012, júl. 2011, doi: 10.1117/1.3600769.
- [18] N. Utami, A. W. Setiawan, H. Zakaria, T. R. Mengko, a R. Mengko, “Extracting blood flow parameters from Photoplethysmograph signals: A review”, *Proc. of 2013 3rd*

- Int. Conf. on Instrumentation, Communications, Information Technol., and Biomedical Engineering: Science and Technol. for Improvement of Health, Safety, and Environ., ICICI-BME 2013*, s. 403–407, 2013, doi: 10.1109/ICICI-BME.2013.6698535.
- [19] M. Elgendi *et al.*, “The use of photoplethysmography for assessing hypertension”, *npj Digital Medicine* 2019 2:1, roč. 2, č. 1, s. 1–11, jún. 2019, doi: 10.1038/s41746-019-0136-7.
- [20] D. Marzorati, D. Bovio, C. Salito, L. Mainardi, a P. Cerveri, “Chest Wearable Apparatus for Cuffless Continuous Blood Pressure Measurements Based on PPG and PCG Signals”, *IEEE Access*, roč. 8, s. 55424–55437, 2020, doi: 10.1109/ACCESS.2020.2981300.
- [21] C. Ash, M. Dubec, K. Donne, a T. Bashford, “Effect of wavelength and beam width on penetration in light-tissue interaction using computational methods”, *Lasers Med Sci*, roč. 32, č. 8, s. 1909–1918, nov. 2017, doi: 10.1007/S10103-017-2317-4/FIGURES/8.
- [22] R. R. Anderson a J. A. Parrish, “The Optics of Human Skin”, *Journal of Investigative Dermatology*, roč. 77, č. 1, s. 13–19, júl. 1981, doi: 10.1111/1523-1747.EP12479191.
- [23] L. G. Lindberg, T. Tamura, a P. Å. Öberg, “Photoplethysmography - Part 1 Comparison with laser Doppler flowmetry”, *Med Biol Eng Comput*, roč. 29, č. 1, s. 40–47, jan. 1991, doi: 10.1007/BF02446294/METRICS.
- [24] M. Sandberg, Q. Zhang, J. Styf, B. Gerdle, a L. G. Lindberg, “Non-invasive monitoring of muscle blood perfusion by photoplethysmography: evaluation of a new application”, *Acta Physiol Scand*, roč. 183, č. 4, s. 335–343, apr. 2005, doi: 10.1111/J.1365-201X.2005.01412.X.
- [25] Y. Mendelson a B. D. Ochs, “Noninvasive Pulse Oximetry Utilizing Skin Reflectance Photoplethysmography”, *IEEE Trans Biomed Eng*, roč. 35, č. 10, s. 798–805, 1988, doi: 10.1109/10.7286.
- [26] H. Lee, H. Ko, a J. Lee, “Reflectance pulse oximetry: Practical issues and limitations”, *ICT Express*, roč. 2, č. 4, s. 195–198, dec. 2016, doi: 10.1016/J.ICTE.2016.10.004.

- [27] W. Cui, L. E. Ostrander, a B. Y. Lee, "In Vivo Reflectance of Blood and Tissue as a Function of Light Wavelength", *IEEE Trans Biomed Eng*, roč. 37, č. 6, s. 632–639, 1990, doi: 10.1109/10.55667.
- [28] P. H. Lai a I. Kim, "Lightweight wrist photoplethysmography for heavy exercise: motion robust heart rate monitoring algorithm", *Healthc Technol Lett*, roč. 2, č. 1, s. 6–11, feb. 2015, doi: 10.1049/HTL.2014.0097.
- [29] F. Elsamnah, A. Bilgaiyan, M. Affiq, C. H. Shim, H. Ishidai, a R. Hattori, "Reflectance-Based Organic Pulse Meter Sensor for Wireless Monitoring of Photoplethysmogram Signal", *Biosensors 2019, Vol. 9, Page 87*, roč. 9, č. 3, s. 87, júl. 2019, doi: 10.3390/BIOS9030087.
- [30] Y. Mendelson, R. J. Duckworth, a G. Comtois, "A wearable reflectance pulse oximeter for remote physiological monitoring", *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, s. 912–915, 2006, doi: 10.1109/IEMBS.2006.260137.
- [31] "How to design a better pulse oximeter: Implementation - Embedded.com". Cit: 27. november 2023. [Online]. Available at: <https://www.embedded.com/how-to-design-a-better-pulse-oximeter-implementation/>
- [32] E. Mejía-Mejía *et al.*, "Photoplethysmography Signal Processing and Synthesis".
- [33] IAN CHEN, "What's in store for optical biosensors? Part 1 - EDN". Cit: 21. október 2021. [Online]. Available at: <https://www.edn.com/whats-in-store-for-optical-biosensors-part-1/>
- [34] D. Marzorati, D. Bovio, C. Salito, L. Mainardi, a P. Cerveri, "Chest Wearable Apparatus for Cuffless Continuous Blood Pressure Measurements Based on PPG and PCG Signals", *IEEE Access*, roč. 8, s. 55424–55437, 2020, doi: 10.1109/ACCESS.2020.2981300.
- [35] A. Barszczyk a K. Lee, "Measuring Blood Pressure: from Cuff to Smartphone", *Current Hypertension Reports*, roč. 21, č. 11. 2019. doi: 10.1007/s11906-019-0990-3.

- [36] B. Williams *et al.*, “2018 ESC/ESH Guidelines for the management of arterial hypertensionThe Task Force for the management of arterial hypertension of the European Society of Cardiology (ESC) and the European Society of Hypertension (ESH)”, *Eur Heart J*, roč. 39, č. 33, s. 3021–3104, sep. 2018, doi: 10.1093/EURHEARTJ/EHY339.
- [37] “Understanding Blood Pressure Readings | American Heart Association”. Cit: 10. júl 2023. [Online]. Available at: <https://www.heart.org/en/health-topics/high-blood-pressure/understanding-blood-pressure-readings>
- [38] ERIC KINAST, “Guest Commentary: How blood-pressure devices work - EDN”. Cit: 20. október 2021. [Online]. Available at: <https://www.edn.com/guest-commentary-how-blood-pressure-devices-work/>
- [39] “AFE4403 data sheet, product information and support | TI.com”. Cit: 01. december 2023. [Online]. Available at: <https://www.ti.com/product/AFE4403>
- [40] “MAX86140 Datasheet and Product Info | Analog Devices”. Cit: 01. december 2023. [Online]. Available at: <https://www.analog.com/en/products/MAX86140.html>
- [41] “MAX86141 Datasheet and Product Info | Analog Devices”. Cit: 01. december 2023. [Online]. Available at: <https://www.analog.com/en/products/MAX86141.html>
- [42] T. Y. Abay a P. A. Kyriacou, *Photoplethysmography Technology, Signal Analysis and Applications*. 2022.
- [43] S. Béres, L. Holczer, a L. Hejjel, “On the Minimal Adequate Sampling Frequency of the Photoplethysmogram for Pulse Rate Monitoring and Heart Rate Variability Analysis in Mobile and Wearable Technology”, *Measurement Science Review*, roč. 19, č. 5, s. 232–240, okt. 2019, doi: 10.2478/MSR-2019-0030.
- [44] “Carescape Monitor B650 | GE HealthCare (United States)”. Cit: 30. jún 2023. [Online]. Available at: <https://www.gehealthcare.com/products/patient-monitoring/patient-monitors/carescape-monitor-b650>
- [45] A. Bayat, M. Pomplun, a D. A. Tran, “A Study on Human Activity Recognition Using Accelerometer Data from

- Smartphones”, *Procedia Comput Sci*, roč. 34, s. 450–457, jan. 2014, doi: 10.1016/J.PROCS.2014.07.009.
- [46] “Deep Learning Frameworks | NVIDIA Developer | NVIDIA Developer”. Cit: 08. december 2023. [Online]. Available at: <https://developer.nvidia.com/deep-learning-frameworks>
- [47] “Pandas Is Now As Popular As Python Was in 2016”. Cit: 08. december 2023. [Online]. Available at: <https://ponder.io/pandas-is-now-as-popular-as-python-was-in-2016/>
- [48] K. Gupta, N. Jiwani, a N. Afreen, “Blood Pressure Detection Using CNN-LSTM Model”, *Proceedings - 2022 IEEE 11th International Conference on Communication Systems and Network Technologies, CSNT 2022*, s. 262–366, 2022, doi: 10.1109/CSNT54456.2022.9787648.
- [49] J. Allen, S. Borik, S. Lyra, M. Paul, T. P. Utomo, a N. Nuryani, “Photoplethysmogram peaks detection based on moving window integration and threshold for heart rate calculation on android smartphone”, *J Phys Conf Ser*, roč. 1825, č. 1, s. 012032, feb. 2021, doi: 10.1088/1742-6596/1825/1/012032.
- [50] “TensorFlow model optimization | TensorFlow Model Optimization”. Cit: 28. júl 2023. [Online]. Available at: https://www.tensorflow.org/model_optimization/guide
- [51] Institute of Electrical and Electronics Engineers, IEEE Circuits and Systems Society, IEEE Council on Electronic Design Automation, E. Verband der Elektrotechnik, a PRIME Conference (16th : 2021 : Online), “SMACD / PRIME 2021 : 19-22 July 2021, online event.”.
- [52] “Quantization aware training | TensorFlow Model Optimization”. Cit: 28. júl 2023. [Online]. Available at: https://www.tensorflow.org/model_optimization/guide/quantization/training
- [53] “Pruning in Keras example | TensorFlow Model Optimization”. Cit: 28. júl 2023. [Online]. Available at: https://www.tensorflow.org/model_optimization/guide/pruning/pruning_with_keras
- [54] S. Han, H. Mao, a W. J. Dally, “Deep Compression: Compressing Deep Neural Networks with Pruning, Trained

- Quantization and Huffman Coding”, *4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings*, okt. 2015, Cit: 28. júl 2023. [Online]. Available at: <https://arxiv.org/abs/1510.00149v5>
- [55] “TensorFlow Lite for Microcontrollers”. Cit: 28. júl 2023. [Online]. Available at: <https://www.tensorflow.org/lite/microcontrollers>

9 Zoznam publikácií autora

V2 Vedecký výstup publikačnej činnosti ako časť editovanej knihy alebo zborníka

- V2_01 ČERNAJ, Ľuboš [15 %] - VAVRINSKÝ, Erik [15 %] - ZÁVODNÍK, Tomáš [15 %] - KOZÁRIK, Jozef [15 %] - **GAŠPAREK, Krisztián [15 %]** - DEBNÁR, Tomáš [15 %] - MIČJAN, 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 do 2021: AFD
- V2_02 DEBNÁR, Tomáš [20 %] - **GAŠPAREK, Krisztián [20 %]** - ŠUBJAK, Ján [20 %] - ZÁVODNÍK, Tomáš [20 %] - DONOVAL, 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 do 2021: AFD
- V2_03 DEBNÁR, Tomáš [50 %] - **GAŠPAREK, Krisztián [25 %]** - ČERNAJ, Ľuboš [10 %] - KUBINEC, Peter [10 %] - DONOVAL, Daniel [5 %]. Research of methodology for indirect measurements of bending force on high voltage insulators. 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. 167-170. ISBN 978-80-554-1735-6. Kategória publikácie do 2021: AFD
- V2_04 **GAŠPAREK, Krisztián [50 %]** - DEBNÁR, Tomáš [25 %] -

KOZÁRIK, Jozef [10 %] - ZÁVODNÍK, Tomáš [10 %] - DONOVAL, 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 do 2021: AFD

V2_05 **GAŠPAREK, Krisztián [20 %]** - ZÁVODNÍK, Tomáš [20 %] - VAVRINSKÝ, Erik [15 %] - MIČJAN, Michal [10 %] - DONOVAL, Martin [10 %] - NEVŘELA, Juraj [5 %] - MATEAŠIK, Anton [5 %] - ZÁBRODSKÝ, Milan [5 %] - ŠIŠOLÁK, Vladimír [5 %] - KOSNÁČOVÁ, 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 do 2021: AFD

V2_06 KOZÁRIK, Jozef [35 %] - MAREK, Juraj [30 %] - DEBNÁR, Tomáš [10 %] - CHVÁLA, Aleš [10 %] - **GAŠPAREK, Krisztián [10 %]** - DONOVAL, Daniel [5 %]. Design of test equipment for on-die hard switching and dynamic on-resistance measurement of GaN HEMTs. In *Radioelektronika 2020 : 30th International Conference. Bratislava, Slovakia. April 15-16, 2020*. Piscataway : IEEE, 2020, S. 201-204. ISBN 978-1-7281-6469-4.
Kategória publikácie do 2021: AFD

V2_07 KOZÁRIK, Jozef [40 %] - MAREK, Juraj [30 %] - MINÁRIK,

Michal [10 %] - CHVÁLA, Aleš [5 %] - **GAŠPAREK, Krisztián [5 %]** - JAGELKA, Martin [5 %] - DONOVAL, Martin [5 %]. Degradation of 600V GaN HEMT with p-GaN gate under repetitive short circuit stress. 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. 219-222. ISBN 978-80-554-1806-3. Výstup: domáci; Kategória publikácie do 2021: AFD

V2_08 KOZÁRIK, Jozef [45 %] - MAREK, Juraj [30 %] - MINÁRIK, Michal [10 %] - CHVÁLA, Aleš [5 %] - **GAŠPAREK, Krisztián [5 %]** - DONOVAL, Martin [5 %]. Measurement of dynamic on-resistance of packaged and unpackaged GaN HEMTs and effect of repetitive short-circuit stress. 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. 161-164. ISBN 978-80-554-1884-1. Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie do 2021: AFD

V2_09 KOZÁRIK, Jozef [20 %] - ZÁVODNÍK, Tomáš [20 %] - ČERNAJ, Ľuboš [10 %] - DEBNÁR, Tomáš [5 %] - MIČJAN, Michal [5 %] - DONOVAL, Martin [5 %] - **GAŠPAREK, Krisztián [5 %]** - VAVRINSKÝ, Erik [15 %] - KOSNÁČOVÁ, 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 do 2021: AFD

- V2_10 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 do 2021: AFD
- V2_11 MATEAŠÍK, Anton [50 %] - REVILÁKOVÁ, Alexandra [10 %] - ŠIŠOLÁK, Vladimír [30 %] - **GAŠPAREK, Krisztián [5 %]** - ZÁBRODSKÝ, Milan [5 %]. Detekcia maximálnych signálov v fotopletyzmozografii. In *Fotonika 2022 : 17. výročný vedecký seminár Medzinárodného laserového centra CVTI SR. Bratislava, Slovakia. 07. december 2022*. Bratislava : Medzinárodné laserové centrum, 2022, S. 17-20. ISBN 978-80-8240-033-8. Typ výstupu: príspevok z podujatia; Výstup: domáci; Kategória publikácie do 2021: AFD
- V2_12 VAVRINSKÝ, Erik [30 %] - DONOVAL, Martin [5 %] - MIČJAN, Michal [5 %] - KOPÁNI, Martin [5 %] - STRÉMY, Maximilián [10 %] - ZÁVODNÍK, Tomáš [10 %] - **GAŠPAREK, Krisztián [5 %]** - VIŤAZKOVÁ, 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 do 2021: AFD

V2_13 VAVRINSKÝ, Erik [30 %] - POLÁK, Marek [18 %] - STRÉMY, Maximilián [5 %] - PROKS, Daniel [5 %] - KOPÁNI, Martin [5 %] - ZÁVODNÍK, Tomáš [5 %] - **GAŠPAREK, Krisztián [5 %]** - VIŤAZKOVÁ, 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 do 2021: AFD

V2_14 VAVRINSKÝ, Erik [30 %] - STRÉMY, Maximilián [15 %] - HORVÁTH, Dušan [20 %] - ZÁVODNÍK, Tomáš [5 %] - **GAŠPAREK, Krisztián [5 %]** - VIŤAZKOVÁ, Diana [10 %] - KOSNÁČOVÁ, 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 do 2021: AFD

V2_15 VAVRINSKÝ, Erik [40 %] - ZÁVODNÍK, Tomáš [15 %] - **GAŠPAREK, Krisztián [15 %]** - DONOVAL, Martin [10 %] - KOSNÁČOVÁ, 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 do 2021: AFD

- V2_16 VIŤAZKOVÁ, Diana [29 %] - ZÁVODNÍK, Tomáš [15 %] - **GAŠPAREK, Krisztián [8 %]** - ČERNAJ, Ľuboš [5 %] - KOSNÁČOVÁ, Helena [5 %] - VAVRINSKÝ, Erik [10 %] - MIČJAN, Michal [8 %] - BÁNOVČIN, Peter [10 %] - KOCAN, Ivan [10 %]. Advanced photoplethysmographic multisensor used in polysomnographic examinations. In *ELITECH'23 [elektronický zdroj] : 254th 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 do 2021: AFD

- V2_17 ZÁVODNÍK, Tomáš [60 %] - ČERNAJ, Ľuboš [20 %] - **GAŠPAREK, Krisztián [5 %]** - MIČJAN, 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 do 2021: AFD

V3 Vedecký výstup publikačnej činnosti z časopisu

- V3_01 KOZÁRIK, Jozef [50 %] - MAREK, Juraj [30 %] - CHVÁLA, Aleš [5 %] - MINÁRIK, Michal [5 %] - **GAŠPAREK, Krisztián [5 %]** - JAGELKA, Martin [5 %]. Development of a device for on-die double-pulse testing and measurement of dynamic on-resistance of GaN HEMTs. In *Advances in*

Electrical and Electronic Engineering. Vol. 19, No. 4 (2021), s. 361-368. ISSN 1336-1376 (2021: 0.202 - SJR, Q4 - SJR Best Q). V databáze: DOI: 10.15598/aeec.v19i4.4136 ; WOS: 000739869600010 ; SCOPUS: 2-s2.0-85122089077. Kategória publikácie do 2021: ADM

O2 Odborný výstup publikačnej činnosti ako časť knižnej publikácie alebo zborníka

- O2_01 VIŤAZKOVÁ, Diana [40 %] - ZÁVODNÍK, Tomáš [20 %] - **GAŠPAREK, Krisztián [8 %]** - KOSNÁČOVÁ, Helena [7 %] - VAVRINSKÝ, Erik [15 %] - MIČJAN, 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 do 2021: BEF

D1 Dokument práv duševného vlastníctva

- D1_01 ČERNAJ, Ľuboš [20 %] - NEVŘELA, Juraj [10 %] - DONOVAL, Martin [10 %] - MIČJAN, Michal [10 %] - DEBNÁR, Tomáš [5 %] - **GAŠPAREK, Krisztián [10 %]** - ZÁVODNÍK, Tomáš [20 %] - KOZÁRIK, Jozef [10 %] - JAGELKA, Martin [5 %]. *Nositel'né 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 do 2021: AGJ
- D1_02 KOZÁRIK, Jozef [25 %] - ČERNAJ, Ľuboš [10 %] - **GAŠPAREK, Krisztián [10 %]** - DEBNÁR, Tomáš [10 %] - ZÁVODNÍK, Tomáš [25 %] - NEVŘELA, Juraj [5 %] - MAREK,

Juraj [5 %] - MIČJAN, 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 do 2021: AGJ

- D1_03 ZÁVODNÍK, Tomáš [10 %] - ČERNAJ, Ľuboš [5 %] - **GAŠPAREK, Krisztián [10 %]** - DEBNÁR, Tomáš [10 %] - NEVŘELA, Juraj [5 %] - MIČJAN, 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 do 2021: AGJ

Štatistika: kategória publikačnej činnosti od 2022

V2	Vedecký výstup publikačnej činnosti ako časť editovanej knihy alebo zborníka	17
V3	Vedecký výstup publikačnej činnosti z časopisu	1
O2	Odborný výstup publikačnej činnosti ako časť knižnej publikácie alebo zborníka	1
D1	Dokument práv duševného vlastníctva	3
Súčet		22