

Univerzita Hradec Králové
Přírodovědecká fakulta

Aplikace biomedicínského výzkumu
v didaktice fyziky

Komentář k souboru publikovaných prací

Habilitační práce

Autor: RNDr. Filip Studnička, Ph.D.

Hradec Králové

2023

Prohlášení

Prohlašuji, že jsem habilitační práci vypracoval samostatně a s použitím uvedené literatury.

V Hradci Králové dne 15. listopadu 2023

Filip Studnička

Anotace

Předkládaná habilitační práce se soustředí na komentář výsledků autorova původního výzkumu, který se zaměřuje na aplikace matematicko-fyzikálních modelů v biomedicínských technologiích a jejich přímé aplikaci v didaktice fyziky. Práce nastiňuje základní téma problematiky týkající se zpracování biosignálů, ukázku aktuálního stavu poznání v dané specifické oblasti a naznačuje několik směrů výzkumu, kam je možné se i v budoucnu ubírat. Téma se také dotýká často opomíjené oblasti didaktiky fyziky, což je zaměření na terciární vzdělávání. Práce se soustředí na celou cestou od základní myšlenky, po výzkum a experiment, publikaci v odborných časopisech až po ochranu duševního vlastnictví a následnou přímou aplikaci nově objevených skutečností v praxi a ve výuce fyziky, konkrétně na katedře fyziky Přírodovědecké fakulty Univerzity Hradec Králové.

Annotation

The presented habilitation thesis focuses on the commentary of the results of the author's original research, which focuses on the application of mathematical-physical models in biomedical technologies and their direct application in the didactics of physics. The thesis outlines the basic issues related to the processing of biosignals, an example of the current state of knowledge in the given specific area and indicates several directions of research where it is possible to expand in the future. The topic also touches on an often neglected area of didactics of physics, which is a focus on tertiary education. The thesis focuses on the entire journey from the basic idea, to research and experiment, publication in scientific journals to the protection of intellectual property and the subsequent direct application of newly discovered facts in practice and in the teaching of physics, specifically at the Department of Physics of the Faculty of Science of the University of Hradec Králové.

Obsah

Úvod	6
1 Balistokardiografie	9
1.1 Historie balistokardiografie	9
1.2 Senzorická řešení	13
2 Metody zpracování dat	25
3 Aplikace ve výzkumu a praxi	30
3.1 Poruchy dýchání	30
3.2 Variabilita srdečního tepu	37
3.3 Zhoršení zdravotního stavu před smrtí	40
3.4 Měření pulsní vlny	42
3.5 Veterinární medicína	44
3.6 Péče o seniory	49
3.7 Modelování pádu koček	52
3.8 Konstrukce vlhkého teploměru jako didaktické pomůcky	55
3.9 Laboratorní cvičení ze spektroskopie	57
4 Aplikace v didaktice fyziky	60
Závěr	66
Literatura	67
Příloha A – Vybrané publikované články	I
Příloha B – Vybrané publikované patenty a užitné vzory	LXVII

Úvod

Předložená práce tvoří soubor uveřejněných vědeckých prací doplněných komentářem. Základem komentáře tak jsou následující publikace, které jsou obsahem přílohy habilitační práce:

- Studnička, F., Šlégr, J., Štegner, D. (2016). Free fall of a cat—freshman physics exercise. *European Journal of Physics*, 37(4), 045002.
- Studnička, F., Šlégrová, L., Voglová, K., Šlégr, J. (2022). Heat index, wet-bulb temperature and psychrometrics: what to expect in the 21st century. *Physics Education*, 58(2), 025003.
- Bušovský, D., Křížová, M., Kříž, J., Loskot, J., Studnička, F., Šlégrová, L., Šlégr, J. (2022). Simple device for spectroscopy laboratory exercises. *Physics Education*, 57(1), 015014.
- Cimr, D., Studnička, F. (2020). Automatic detection of breathing disorder from ballistocardiography signals. *Knowledge-Based Systems*, 188, 104973.
- Cimr, D., Studnicka, F., Fujita, H., Tomaskova, H., Cimler, R., Kuhnova, J., Slegre, J. (2020). Computer aided detection of breathing disorder from ballistocardiography signal using convolutional neural network. *Information Sciences*, 541, 207-217.
- Cimr, D., Studnicka, F., Fujita, H., Cimler, R., Slegre, J. (2021). Application of mechanical trigger for unobtrusive detection of respiratory disorders from body recoil micro-movements. *Computer Methods and Programs in Biomedicine*, 207, 106149.
- Cimr, D., Busovsky, D., Fujita, H., Studnicka, F., Cimler, R., Hayashi, T. (2023). Classification of health deterioration by geometric invariants. *Computer Methods and Programs in Biomedicine*, 239, 107623.

- Cimler, R., Studnička, F., Šlégr, J., Štěpán, J., Matyska, J., Kühnová, J., Šec, D., Šeba, P. (2019). Zařízení pro sledování mikropohybů živých organismů. Úřad průmyslového vlastnictví, užitný vzor č. CZ33574U1.
- Studnička, F., Šlégr, J., Šeba, P. (2023). Method of monitoring peristalsis of organs of the gastrointestinal tract and a device for monitoring peristalsis. World Intellectual Property Organization, patent č. WO2023006134A1.
- Studnička, F., Cimler, R., Kühnová, J., Matyska, J., Štěpán, J., Šlégr, J. (2023). Systém pro monitorování pohybové aktivity a vitálních funkcí zvýšete. Úřad průmyslového vlastnictví, užitný vzor č. CZ36821U1.

Na katedře fyziky Přírodovědecké fakulty Univerzity Hradec Králové (UHK) probíhá dlouhodobý výzkum v oblasti konstrukce senzorů, zpracování časových řad, nových modelů kardiovaskulárního systému a také zde probíhá přímá aplikace těchto nových poznatků na poli vědy a techniky. Nové poznatky jsou aplikovány jak v podobě komercializace vybraných technologií, tak i v podobě, která se přímo promítá do výuky fyziky na katedře v podobě nových studijních programů zaměřených na aplikovanou fyziku, ale i v přípravě budoucích učitelů fyziky. Jedná se tak o rozsáhlý proces didaktizace výsledků výzkumu a vývoje, tedy didaktické činnosti, která vede k implementaci těchto výsledků do výuky v terciárním vzdělávání.

První část předkládané práce se zabývá uvedením čtenáře do problematiky prováděného výzkumu a senzorických řešení. Druhá část práce se zabývá úvodem do použitých matematických metod. Třetí část práce shrnuje zásadní výsledky, které jsou obsahem citovaných odborných článků, užitných vzorů a patentů. Čtvrtá část práce pak shrnuje význam provedeného výzkumu v didaktice fyziky a zabývá se právě procesem didaktické transformace recentních výsledků pro jejich využití ve výuce. Práce se tak dotýká často opomíjené oblasti didaktiky fyziky, a to procesem implementace výsledků výzkumu a vývoje do terciárního vzdělávání (alespoň na úrovni ISCED 5) [1]. Práce popisuje celou cestu od základní myšlenky, přes výzkum a experiment, publikaci v odborných časopisech, až po ochranu duševního vlastnictví, komercializaci a následnou přímou aplikaci nově objevených skutečností ve výuce fyziky. Ty jsou aplikovány konkrétně na katedře fyziky Přírodovědecké fakulty Univerzity Hradec Králové. Jedná se tak o unikátní rozvíjení osobnosti budoucích odborníků ve fyzice a budoucích učitelů formou výzkumu a vhodné propojení fyziky a aplikovaných věd, což mohou studenti učitelství v budoucnu zahrnout i do vlastní učitelské praxe. Z hlediska didaktiky je podstatné zvyšovat atraktivitu

fyziky řešením zajímavých, zejména interdisciplinárních problémů (v této práci je akcentována oblast humánní medicíny, ale i veterinární medicíny či sociální péče). Proto je téma předložené habilitační práce často popularizováno na katedře fyziky v podobě přednášek a seminářů určených jak pro odborníky, tak pro širokou veřejnost.

Hlavním cílem předložené práce je s nadhledem ukázat, co vše obnáší zařazení nových a unikátních výsledků výzkumu do přímé výuky na univerzitách, jak je možné je popularizovat a motivovat tak budoucí generace učitelů fyziky i odborníky z praxe. Komentář k souboru uveřejněných prací si tak neklade za cíl zdůrazňovat prospěšnost samotných výsledků výzkumu, ani podrobně seznámit čtenáře se všemi podrobnostmi realizovaného výzkumu nebo technickými detailemi – to je obsahem již publikovaných komentovaných prací a vedených závěrečných prací. Realizované lékařské a jiné diagnostické metody je tak třeba chápat více jako doprovodný, ale z hlediska didaktické aplikace zásadní jev.

Kapitola 1

Balistokardiografie

1.1 Historie balistokardiografie

Základním pojmem, který je nosným tématem aplikovaných didaktických výsledků témař celé práce, je balistokardiografie. Tento pojem bude často rezonovat především v první části práce, kde které je popsán rozvoj myšlenek, které vedly k samotnému odbornému výzkumu. Pojem balistokardiografie je označení metody, která studuje tzv. mikrovibrace lidského těla. Označení samotné pochází z řečtiny a vzniklo složením tří slov: *ballizein* – tančit, *kardia* – srdce, *grafein* – psát, zobrazovat [2]. V anglické literatuře se pojem uvádí jako ballistocardiography (BCG). Toto slovo může evokovat slovo podobné a i laické veřejnosti známé – elektrokardiografie (EKG). Elektrokardiografie studuje elektrickou aktivitu lidského srdce, zatímco balistokardiografie studuje jeho mechanickou aktivitu a zejména propagaci těchto pohybů po celém lidském těle.

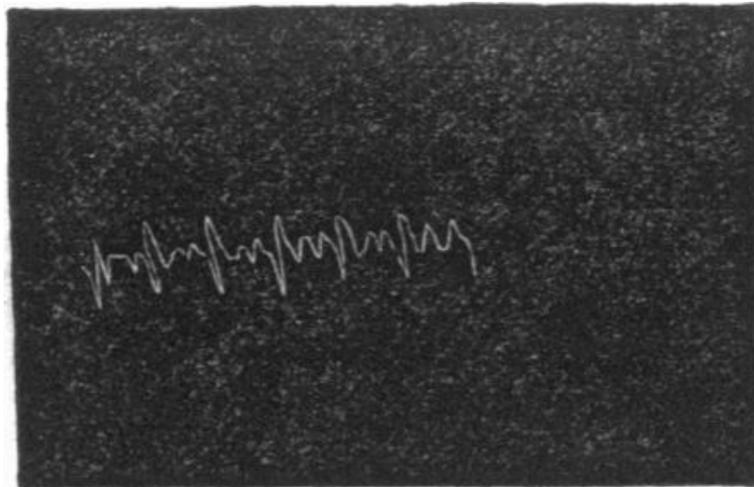
První zmínka o balistokardiografii se objevuje již v roce 1877 [3]. Níže je přiložen abstrakt historicky první odborné publikace, kde díky technickému pokroku v oblasti měřicích přístrojů J. W. Gordon zaznamenal, že tělo ležící na posteli osazené „seismografy“, vykazuje rytmické pohyby přímo korespondující s rytmem stahů lidského srdce, viz obrázky 1.1 a 1.2.

Pro vysvětlení jevu, který Gordon pozoroval, využijeme zjednodušený diagram vysvětlující děje při každém jednotlivém úderu (zdravého) srdce [4], na obrázku 1.3. Pojem srdeční cyklus označuje periodické děje, které srdce vykonává a ke kterým dochází od začátku jednoho srdečního úderu spontánním generováním akčního potenciálu v sinoatriálním uzlu do začátku dalšího srdečního úderu [5]. Pro naše účely jsou podstatné děje, které mají jasnou mechanickou odezvu. Mezi ně patří zejména (ale nikoliv výhradně) uzavření mitrální (síňové) chlopně, izovolumetrická kontrakce srdce (stlačení srdečního

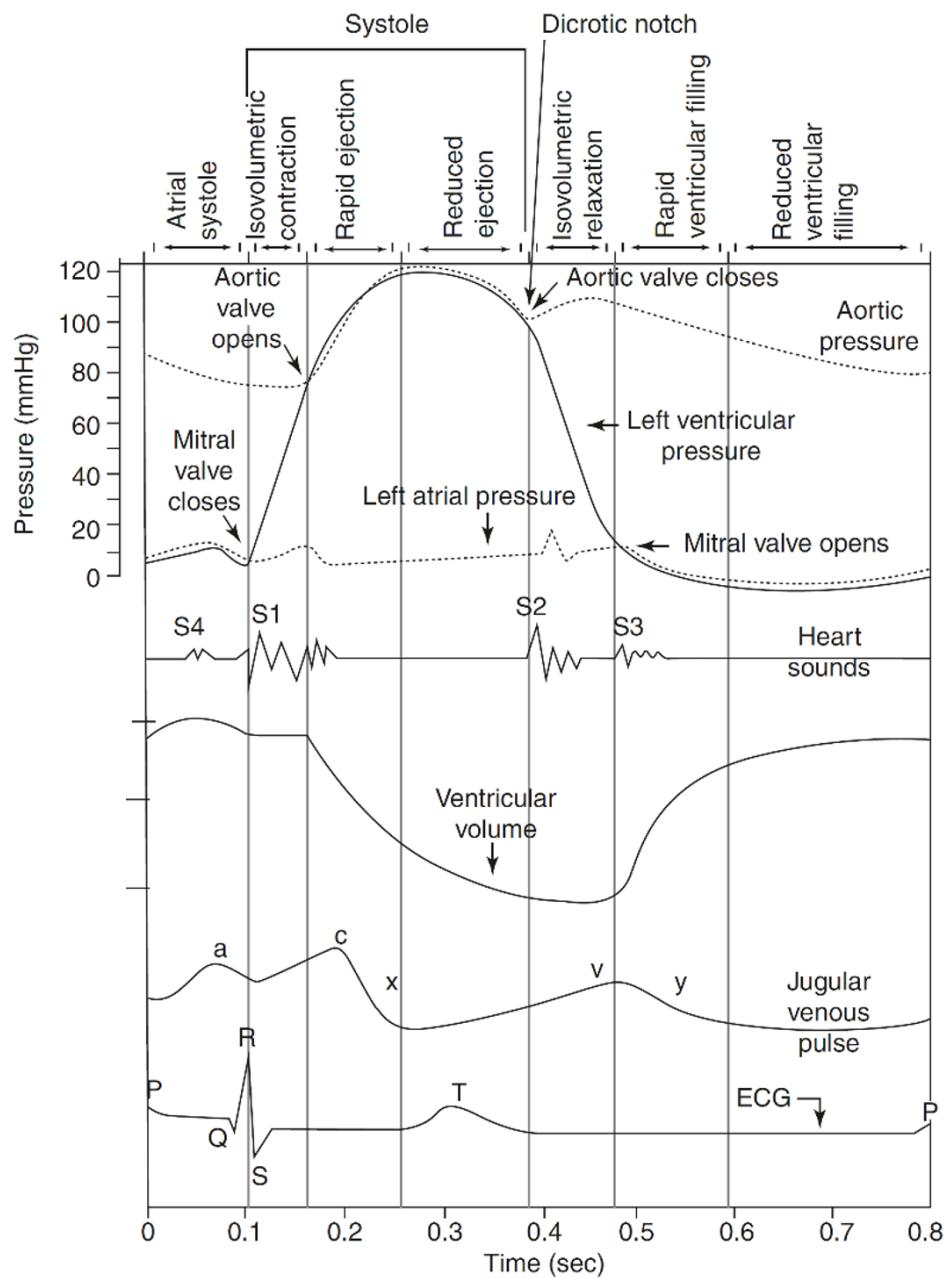
ON CERTAIN MOLAR MOVEMENTS OF THE HUMAN
BODY PRODUCED BY THE CIRCULATION OF
THE BLOOD. By J. W. GORDON.

A PERSON standing erect in a perfectly easy posture on the bed of an ordinary spring weighing-machine, and maintaining, as far as possible, perfect stillness, will be found, if the instrument is delicately adjusted, to impart a rhythmic movement to the index, synchronous with the pulse and according to the following rule:—At each occurrence of systole in the heart, the needle will be vigorously deflected toward the zero point of the dial, and in the intervals of systolic action will return by a slower movement to the starting point; this point nearly coinciding with the point at which the needle would rest if the subject were laid horizontally on the bed of the instrument. The return of the needle is effected by a series of secondary vibrations which appear to bear an appreciable but imperfect analogy to corresponding features in the sphygmograph.

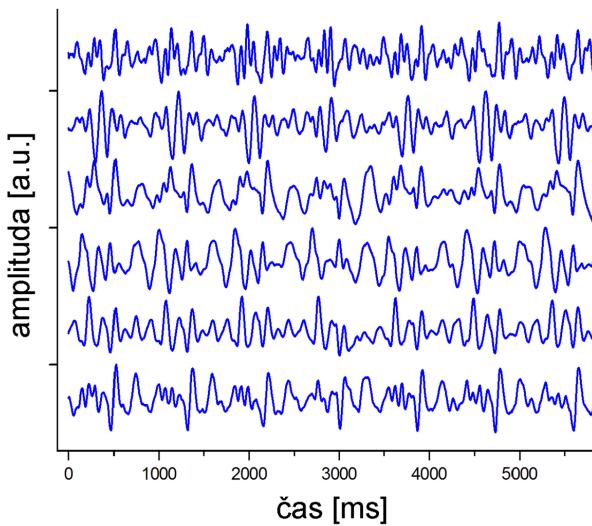
Obrázek 1.1: První článek zabývající se balistokardiografií, 1877 [3].



Obrázek 1.2: Signál rytmického pohybu těla zaznamenaný Gordonem [3].



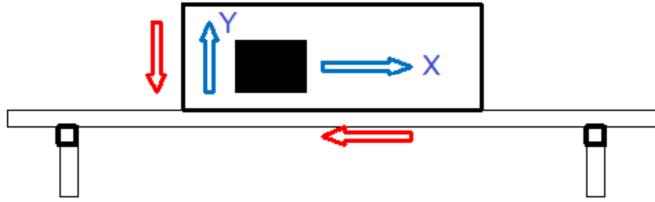
Obrázek 1.3: Podrobný popis jednoho srdečního cyklu [4].



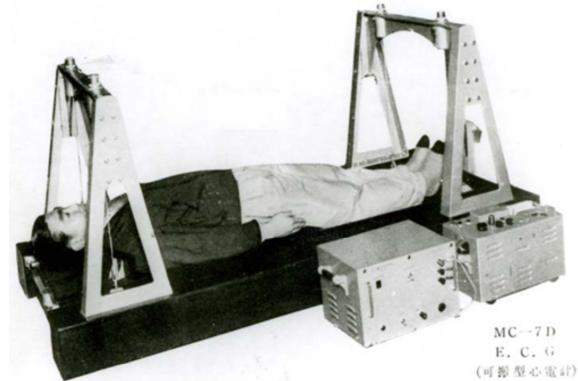
Obrázek 1.4: Moderní záznam BCG signálů – jedná se o simultánní měření pomocí šesti lokálních senzorů na různých místech anatomie člověka.

svalu při zachování načerpaného objemu krve, počátek systoly), otevření aortální chlopň (po překonání tlaku v krevním řečišti), vypuzení krve z levé srdeční komory (doprovázené šířením tlakového pulsu sítí tepen, tzv. pulsní vlny) a odraz pulsní vlny na bifurkacích (větveních) krevního řečiště. Tyto velice drobné mechanické pohyby (které je možné ve srovnání s makroskopickými pohyby lidského těla označit jako mikropohyby) se dále díky vnitřním mechanickým vazbám šíří po celém lidském těle. Informace o jednotlivých dějích srdečního cyklu je logicky v pohybu celého lidského těla ukryta. Na obrázku 1.4 je pro představu ukázáno, jak vypadá moderní záznam BCG signálu. Jedná se o měření pomocí šesti lokálních piezokeramických senzorů (viz dále).

Gordonův objev nebyl dlouhá léta rozvíjen. K pochopení důvodů uvede' me ročník objevu do historického rámce. V roce 1877 začala výstavba základů Eiffelovy věže v Paříži, do provozu bylo uvedeno první české veřejné elektrické osvětlení celoměstského významu v Jindřichově Hradci a uběhlo pouhých pět let od prvního doloženého pokusu s elektrokardiografií (1872) [6]. Mezi zásadní příčiny dočasného úpadku BCG patří nestandardizované měření, nedostatečné dobové pochopení fyziologického pozadí metody a ve 20. století rozvoj dalších neinvazivních metod sledování činnosti (nejen) lidského srdce. Technické problémy s pořízením záznamu a problémy s interpretací znamenaly odsunutí balistokardiografie do ústraní na téměř jedno století. Proto, i když se Gordonovo poznání ve své době jevilo jako vskutku revoluční objev, dlouhou dobu byl pouze zajímavostí a nedošlo k jeho dalšímu rozvoji ani výzkumu. Z dnešního hlediska je to pochopitelné, jelikož BCG kopíruje



Obrázek 1.5: Princip akce a reakce v balistokardiografii, schematické znázornění, modré akce uvnitř člověka, červeně reakce.

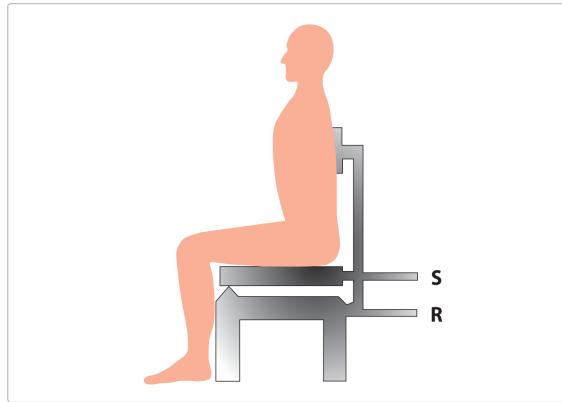


Obrázek 1.6: Přístroj od společnosti Nihon Kohden [8] – jedná se o lůžko zavěšené na pružinách se záznamem jeho pohybu.

podobnou křivku technologického rozvoje jako EKG. EKG lze zjednodušeně popsat jako projekci modelu lidského srdce jako elektrického dipólu do různých souřadnicových os závislých na tom, kde elektrickou aktivitu pomocí elektrod snímáme. Z hlediska BCG se však jednalo o zcela novou metodu na pomezí fyziky a medicíny. Z fyzikálního hlediska jde o důsledek třetího Newtonova pohybového zákona – principu akce a reakce, viz obrázek 1.5: Drobné pohyby srdce, odrazů a šíření pulsní vlny kardiovaskulárním systémem a pohyb krve v srdeci a tepnách je akce uvnitř člověka, která se na statické lůžko, na kterém může měřený člověk být, promítne jako adekvátní reakce. Tuto reakci je pak možné snímat pomocí širokého spektra senzorů, o čemž pojednává následující sekce.

1.2 Senzorická řešení

Renesance balistokardiografie byla přímo spjata s technologickým rozvojem. Po dlouhých letech zapomnění lze za první sériově vyroběný komerční přístroj pro záznam balistokardiografického signálu považovat přístroj od japonské společnosti Nihon Kohden z 50. let 20. století, viz obrázek 1.6, založený na práci Isaaca Starra [7].



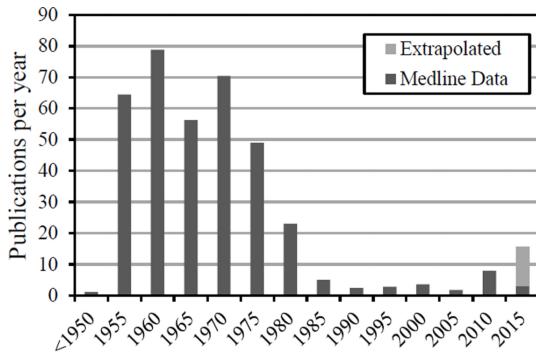
Obrázek 1.7: Přístroj ve tvaru židle snímající balistokardiografický signál [10].

Pro zajímavost je možné zmínit, že jeden z průkopníků balistokardiografie je i český rodák Zdeněk Trefný, který studoval balistokardiografický signál člověka sedícího na židli [9], viz obrázek 1.7.

Většinu senzorů, které sloužily po jedno století ke studiu balistokardiografických signálů, lze shrnout jako senzory seismografické či senzory pružinové. S rozvojem měřicí techniky ve 21. století došlo i k rozvoji měřicích senzorů umožňujících snímání mechanických pohybů. Seismografické a pružinové senzory byly postupně nahrazeny cenově dostupnými akcelerometry, které navíc přinášejí výhodu v jednoduchosti zapojení do výpočetních systémů, jelikož jejich výstupem je přímo analogový signál. Tyto senzory byly rovněž použity pro snímání BCG signálu [11], ovšem pro snímání mikrovibrací se ukázaly jako zcela nevhodné. Měření vibrací lze fyzikálně interpretovat jako měření zrychlení. Akcelerometry disponují širokým rozsahem měřených zrychlení, zpravidla minimálně $\pm g$ – tělové zrychlení. Mikrovibrace lidského těla v důsledku činnosti srdce jsou řádově slabší, a tedy pro jejich kvalitní zaznamenání by bylo nutné zajistit rozlišení příslušného analogově-digitálního převodníku s takovou bitovou citlivostí, která je nejen ekonomicky neúnosná, ale i technologicky neproveditelná, pokud bude cílem měření více než jen hledání periodických výkyvů signálu souvisejících s rytmem srdce.

Porovnáme-li počet publikací spojených s BCG v průběhu let, viz obrázek 1.8, lze pozorovat velký rozmach v 50. letech 20. století, a to zejména díky technologickému pokroku v oblasti měřicích senzorů. Bohužel vzhledem k problémům se zpracováním BCG signálu nastal postupný úpadek, který se podařilo zvrátit až počátkem 21. století.

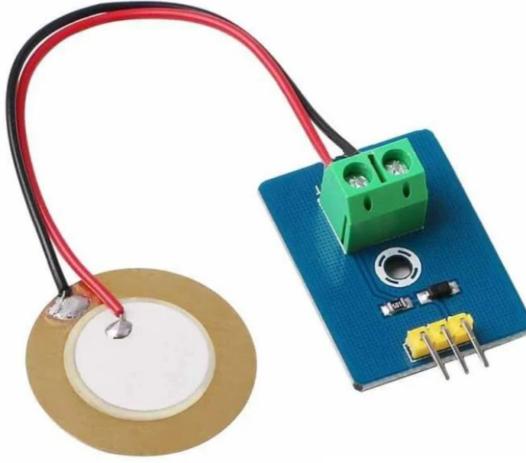
Tehdy se totiž podařilo vyřešit další překážku, a sice problém zpracování digitalizovaného signálu a výpočetní náročnosti tohoto zpracování. Budeme-li na BCG signál nahlížet z jakéhokoliv hlediska, vždy (stejně jako u EKG signálu) půjde ve výsledku o jistý



Obrázek 1.8: Počet publikací spojených s BCG v průběhu let [12]

druh projekce mechanického pohybu lidského těla. EKG signál je v dnešní době považován za zlatý standard v oblasti diagnostiky srdce. Místa, kam se umisťují měřicí elektrody jsou jasně definovaná a standardizovaná a reprodukovatelnost měření je tím plně zajištěna. BCG signál naopak trpí tím, že jeho měření není standardizované a je závislé na tom, kam se umístí měřicí senzory, jak je člověk umístěn na měřicí zařízení, a tedy jaká projekce celkového mikropohybu je ve výsledku měřena.

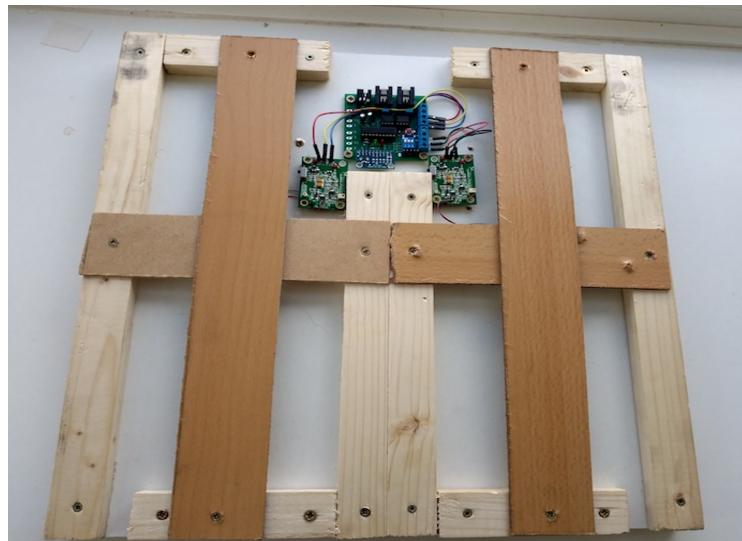
Nyní se zaměříme na řešení problematiky citlivosti a digitalizace signálu. Problematickou jejich interpretace se budou zabývat kapitoly následující. Při experimentální potřebě snímat vysoce citlivé signály bylo po mnohaletém výzkumu autora potvrzeno, že pro snímání balistokardiografických signálů je ideální konfigurace obsahující piezokeramický senzor (viz obrázek 1.9). Tento typ senzoru funguje na principu generování elektrického náboje při mechanické deformaci. Vzniklý náboj je pak snímán nábojovým zesilovačem a transformován na měřitelné elektrické napětí. Zásadní výhodou využití piezokeramických senzorů je jejich extrémní citlivost i na jemné mechanické deformace. Využití stejného typu senzoru je pak známé i v zahraničí [14], kde autoři tento senzor umístili přímo mezi podlahu a nohy lůžka. Samotný senzor je však nedostatečný pro vhodné snímání balistokardiografického signálu, jelikož jeho umístění např. přímo pod měřenou osobu nebo pod matrací postele nevyvolává jeho dostatečné mechanické namáhání. Za účelem dosažení ideálního elektromechanického přenosu, který zajistí jednak přenos těch frekvencí, které jsou žádané, a který navíc dokáže mechanicky zesílit mikropohyby, bylo nutné vyvinout pouzdro, do kterého je piezokeramický senzor umístěn a jehož součástí je kontaktní bod pevně spojený se senzorem, který tyto mechanické pohyby přenáší. I tato část výzkumu, zatím zcela oproštěná od dalších aplikací, trvala několik let. Tyto začátky lze doslova nazvat prací „na koleni“, viz obrázek 1.10. Zde bylo využito právě zkušeností z příprav na výuku fyziky, kdy je pedagog často postaven před úkol demonstrovat nějaký fyzikální děj



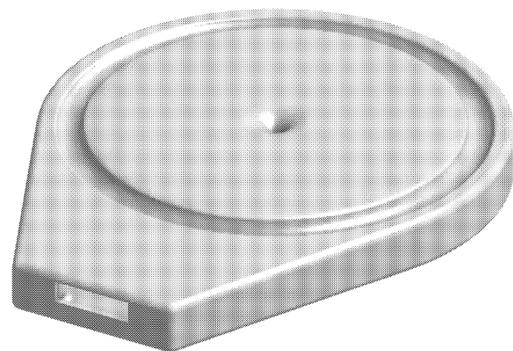
Obrázek 1.9: Piezokeramický senzor používaný při měření balistokardiografických signálů [13].

s co největší fyzikální přesností, ovšem s minimem prostředků.

Přes řadu dalších prototypů, využívající zejména výhod 3D tisku, a tedy rychlého prototypování a úprav, bylo vyvinuto speciální pouzdro pro senzor, které je ošetřeno americkým průmyslovým vzorem [15], viz obrázek 1.11. Senzor s tímto pouzdrem je dnes používán ve výzkumu zabývajícím se praktickým využitím BCG na Univerzitě Hradec Králové. Snímací elektronika vyvinutá na UHK pak disponuje snímkovací frekvencí 330 Hz, která je nezávislá na samotném senzoru. Ohledně snímkovací frekvence je vhodné vrátit se k obrázku 1.3. Z něj je patrné, že děje v srdečním svalu jsou rychlé a změny odpovídají řadově desetinám sekundy. Dle Nyquistova–Shannonova vzorkovacího teorému by pak minimální snímkovací frekvence měla být 40 Hz, ale pro zajištění dostatečné přesnosti měření a pro zajištění snímání rychlejších dějů (o kterých bude řeč v dalších kapitolách) považujeme za minimální vhodnou vzorkovací frekvenci 200 Hz, což bylo empiricky ověřeno. Výhodou popisovaného senzoru je možnost jeho umístění do v zásadě libovolného kusu nábytku. Byly tak prováděny experimenty jak v nemocničním lůžku, tak v běžné posteli, gauči či židli. Výsledky tohoto výzkumu budou shrnutý dále a jsou obsahem níže citovaných užitných vzorů a národních i mezinárodních patentů. Mezi nevýhody tohoto typu senzoru je měření pouze v jednom lokálním místě. U nábytku je toto možné řešit využitím více simultánně umístěných měřicích senzorů. Ovšem konstrukce senzoru vylučuje jeho použití jako tzv. nositelného senzoru (wearable), anebo pokrytí rozsáhlejší měřené oblasti. Z toho důvodu jsou nyní na UHK využívány i další dva typy senzorů pro snímání BCG dat. Typická ukázka BCG signálu měřeného pomocí piezokeramických senzorů je na obrázku 1.12. Graf záměrně nemá popsané osy, jedná se pouze o ukázku



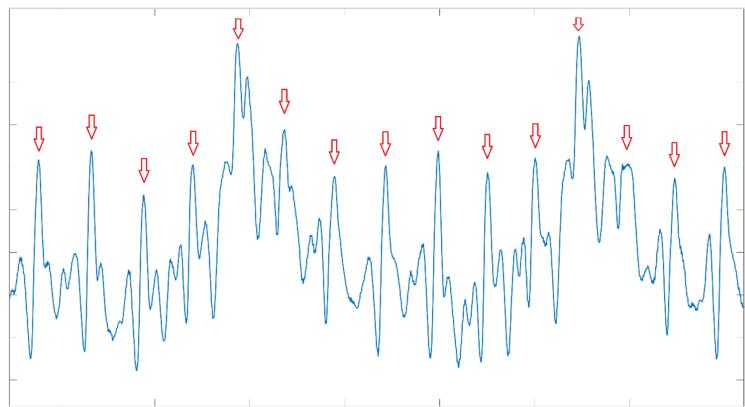
Obrázek 1.10: První verze elektromechanického pouzdra piezokeramického senzoru. Samotné senzory jsou v této konfiguraci dva, umístěné pod křížovou konstrukcí.



Obrázek 1.11: Pouzdro piezokeramického senzoru chráněné americkým průmyslovým vzemrem [15].

morfologie signálu a jeho zobrazení jakožto záznamu rytmických úderů srdce, jeho kvantitativní popis je pak obsahem přílohy této práce.

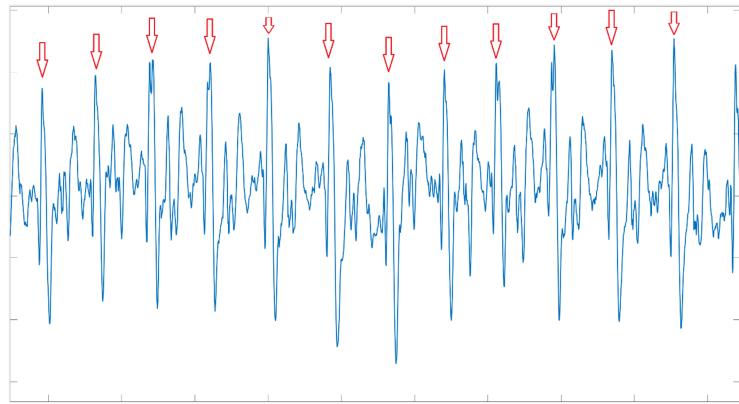
Nositelný senzor, který je využíván ve výzkumu využití BCG dat, je zařízení MetaMotionR r0.3 od společnosti Mbientlab Inc, viz obrázek 1.13. Jedná se o mikročipovou desku v plastovém pouzdře, celek pak lze připevnit za opasek, na zápěstí či přilepit na libovolné místo na těle. Zařízení vyniká nízkou energetickou náročností (doba měření je cca 24 hodin), data jsou přenášena pomocí rozhraní Bluetooth do mobilního telefonu, odkud jsou pomocí aplikace odesílána na vzdálené servery pro další zpracování. Toto zařízení obsahuje čip Nordic Semiconductor, ke kterému je přes sběrnici připojen mimo jiné trojosý gyroskop Bosch s volitelným rozsahem $125/250/500/1000/2000 \text{ } ^\circ\text{s}^{-1}$. Ve výzkumu je použita vzorkovací frekvence 200 Hz.



Obrázek 1.12: Ukázka morfologie BCG signálu měřeného piezokeramickými senzory. Červeně jsou označeny údery srdce. Graf záměrně nemá popsané osy.



Obrázek 1.13: Bezdrátový senzor MetaMotionR r0.3 [16].



Obrázek 1.14: Ukázka morfologie BCG signálu měřeného 3osým gyroskopem, v grafu je zobrazena jedna z os gyroskopu. Červeně jsou označeny údery srdce. Graf záměrně nemá popsané osy.

Využití bezdrátového gyroskopu se ukázalo jako vhodná alternativa k piezokeramickým senzorům, jelikož disponují mimořádnou citlivostí na drobné úhlové výchylky (na rozdíl od akcelerometrů). Mezi jeho nevýhody patří nemožnost získání analogového signálu. Celkové zpracování obslužné elektroniky je tedy náročnější jak na vývoj, tak i na návrh obslužného firmware. Z tohoto důvodu byl využit právě kompletní komerční senzor. Typická ukázka BCG signálu měřeného pomocí gyroskopu je na obrázku 1.14.

Posledním typem senzoru, který je aktuálně na UHK ve výzkumu i v praxi využívaný, je tenzometr. Konkrétně se jedná o tenzometry s rozsahem měření od maxima 5 kg do maxima 120 kg, dle konkrétního využití, které jsou připevněny na hliníkovou konstrukci a fungují na stejném principu jako klasické váhy, viz obrázek 1.15. Tenzometry jsou jednou stranou připevněné ke konstrukci a druhou stranou jsou opřené o podlahu, při zatížení se tenzometr prohne a úroveň prohnutí je právě výsledným signálem, který tenzometr poskytuje.

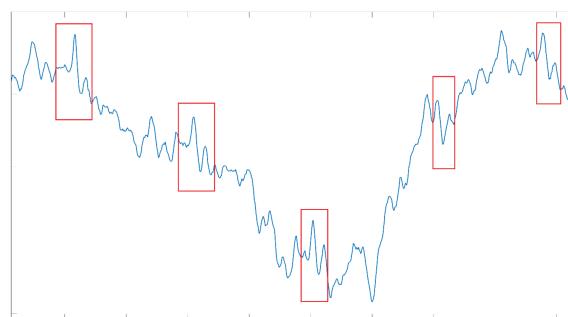
Tento modulární systém lze pak skládat do tzv. dlaždic ve tvaru obdélníku, jehož strany mohou mít variabilní rozměry od 20 do 100 cm, kde v každém rohu takového obdélníku je umístěn jeden tenzometr. Samotné tenzometry disponují mimořádným měřicím rozsahem, který po vhodné kalibraci umožnuje měřit i hmotnost tělesa umístěného na dané dlaždici, ovšem pro měření BCG signálů by takové uspořádání bylo nevhodné. Z tohoto důvodu byla na UHK vyvinuta snímací elektronika, která pomocí vestavěných filtrů dokáže signál rozdělit na dvě složky – statickou a dynamickou. Statická složka je standardní signál, který poskytuje tenzometr, tedy údaj o jeho prohnutí či nepřímo zátěži na dlaždici. Dynamická složka je pak hardwarovým filtrováním zbavena velmi nízkých frek-



Obrázek 1.15: Uchycení tenzometru na konstrukci pro měření.

vencí obsažených v signálu (pod 0,05 Hz). Teprve poté je tento signál digitalizován a díky tomu je možné zachytit drobné výchylky v měřeném signálu odpovídající právě mikrovibracím BCG signálu. Ukázka typického BCG signálu měřeného pomocí tenzometru je na obrázku 1.16. Snímkovací frekvence používaná u tenzometrů je nastavena na 1 000 Hz.

Při vývoji senzorů a snímací elektroniky byl brán zřetel i na rozlišení každého příslušného analogově-digitálního převodníku. Z výzkumného hlediska je zde jasný požadavek na co nejvyšší rozlišení za účelem zachycení i drobných změn v měřených signálech. Vzhledem k tomu, že bylo myšleno i na daný přesah do praxe, bylo nutné hledět i na



Obrázek 1.16: Ukázka morfologie BCG signálu měřeného tenzometrem v dlaždici. Červeně jsou označeny údery srdce. Graf záměrně nemá popsané osy.

finanční stránku a dostupnost. U piezokeramických senzorů a gyroskopu je použit 16bitový převodník, u tenzometrů bylo nutné použít 24 bitový převodník pro zajištění dostatečné citlivosti pro měření všech potřebných veličin při zachování cenové dostupnosti.

Z didaktického hlediska (viz dále) je vhodné zmínit i výklad fyzikálních veličin, které senzory snímají. Byly zde představeny tři poměrně odlišné typy senzorů: piezokeramický senzor, gyroskop a tenzometr. Pro pochopení měřené veličiny u piezokeramického senzoru stačí provést myšlenkový experiment: Představme si hrot, který se dotýká senzoru a je na počátku v klidu. Poté hrot začne působit konstantní silou na senzor. Piezokeramický senzor funguje na principu generování náboje na svých elektrodách v momentě, kdy dochází k jeho deformaci. Tento náboj je pak přes rezistor vybit, přičemž na daném rezistoru vznikne napětí, které tvoří měřený signál. Na počátku je signál nulový; v momentě, kdy začneme působit konstantní silou, dojde k deformaci senzoru, který tak vygeneruje signál. Při stálém působení síly však dochází k vyrovnání s odporovou silou, která je vyvolaná pnutím senzoru. V tu chvíli dojde k vybití vygenerovaného náboje a signál klesne opět na nulovou hodnotu. Jelikož působící síla je přímo úměrná zrychlení hmoty v lidském těle, měříme pouze změny v tomto zrychlení, tedy derivaci daného zrychlení a tím nepřímo derivaci silového působení v lidském těle.

Signál z tenzometrů odpovídá přímo výchylce daného tenzometru, pokud budeme uvažovat pouze výše zavedenou statickou složku. U dynamické složky se však situace mění. Tím, že filtrujieme téměř konstantní posunutí signálu, tedy jeho velmi nízké frekvenční složky, eliminujeme s dostatečnou časovou konstantou pomalé děje a provádíme tak hardwarovou derivaci signálu, opět při působení konstantní síly dojde k poklesu signálu na nulovou hodnotu a měříme opět derivaci zrychlení, a tedy derivaci silového působení.

Odlišná je situace u gyroskopu, který měří úhlovou rychlosť ve třech osách, tedy rychlost rotace. Pokud budeme na gyroskop působit konstantní silou pouze v jednom směru, všechny tři signály gyroskopu zůstanou nulové. Vzhledem k tomu, že veškeré důležité děje v lidském těle, kterými se zabývá další výzkum, jsou trojrozměrné a nedochází zde pouze k jednorozměrnému působení a vzhledem k tomu, že gyroskop není určen pro umístění např. v nábytku, kde by se akcentovalo působení pouze v jedné ose, ale jako nositelný prvek, je možné i tento senzor využít jako zdroj balistokardiografických dat.

Mezi hlavní důvody, proč má smysl zabývat se typem měřicích senzorů a balistokardiografií obecně, jsou zásadní výhody této metody. Na rozdíl od např. EKG či invazivních metod lze při využití vhodné konfigurace senzorů dosáhnout zcela neobtížujícího měření daných subjektů. Měření, při kterém není potřeba na člověka umísťovat žádné sen-



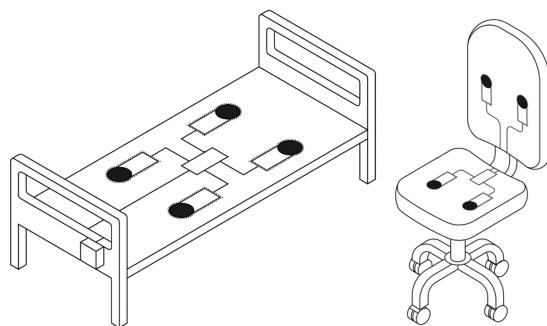
Obrázek 1.17: Umístění piezokeramických senzorů ve specializovaném lůžku určeném pro sociální služby.

zory, zamezí např. syndromu bílého pláště (změn fyziologických hodnot v důsledku stresu z měření), případně jsou s výhodou využitelná v případech, kdy není z různých důvodů možné či žádoucí na měřené osoby senzory umisťovat (typicky u seniorů, v domácí péči atd.).

Na závěr kapitoly se ještě podívejme na typické experimentální uspořádání senzorů a měřeného subjektu pro všechny tři typy senzorů. V případě použití piezokeramických senzorů v praxi zpravidla používáme konfiguraci dvou či čtyř senzorů umístěných v nemocničním lůžku nebo posteli, viz obrázek 1.17 a 1.18. Výhodou takového uspořádání je možnost umístit senzory pod matrací posteče či pod polstrovanou část židle. Je vhodné zdůraznit, že tento systém je součástí užitného vzoru [17], který se podařilo úspěšně komericializovat. V současné době se tak v případě tohoto měřicího systému jedná o systém certifikovaný pro použití ve zdravotnictví a který je kromě komericalizovaných aktivit aktivně využíván i ve výuce a výzkumu na katedře fyziky UHK, viz obrázek 1.19.

U tenzometrů je typické uspořádání do tzv. dlaždice, viz obrázek 1.20, kde dlaždice obsahuje čtyři tenzometry. Volba maximální hmotnosti osazených tenzometrů je závislá na typu měření a předpokládaném maximálním zatížení systému.

Bezdrátové gyroskopy je pak možné zpravidla umisťovat za opasek pro sledování aktivity a chůze člověka, případně je možné je lepit přímo na konkrétní místa na těle za účelem získání informací např. o dýchání či srdeční činnosti, viz obrázek 1.21.



Obrázek 1.18: Schematické znázornění umístění senzorů do postele a kancelářské židle.



Obrázek 1.19: Měřící podložka vyvinutá na katedře fyziky UHK.



Obrázek 1.20: Osoba měřená na sestavené dlaždici osazené čtyřmi tenzometry.



Obrázek 1.21: Osazení osoby bezdrátovým gyroskopem.

Kapitola 2

Metody zpracování dat

Před tím než se budeme zabývat ději, které jsme schopni pozorovat v samotných BCG signálech, co je z nich možné odvodit a jak je aplikovat do různých oborů, zaměřme se na metody, které byly použity ve většině publikací, komentovaných habilitační prací. Renesance oboru balistokardiografie totiž souvisí nejen s rozvojem vysoce citlivých senzorů, ale rovněž s technologickým pokrokem v oblasti výpočetní techniky. Vrátíme-li se opět k analogii se zpracováním EKG signálu, dlouhá léta byl tento signál zpracováván ručně, lékař tedy pouze studoval naměřené křivky, odhadl vybrané časové parametry tohoto signálu na milimetrovém papíře a z toho usuzoval na možné kardiovaskulární potíže a další fyziologické a patologické parametry. Tento přístup byl možný jen díky standardizaci EKG signálů. Navíc ani v dnešní době není možné spolehlivě analyzovat EKG signál plně automaticky [18]. Zpracování BCG signálu představuje mnohem větší výzvu, jelikož neexistuje žádný standard pro měření a za tento signál je obecně považován každý signál odpovídající mikropohybům lidského těla vyvolaným srdeční aktivitou a pohybem krve ve velkých tepnách. Zde prezentované metody zpracování dat jsou silně závislé na dostupném výpočetním výkonu čipů a procesorů, jelikož pouze díky tomuto výkonu je možné provádět níže uvedené výpočty takřka v reálném čase.

Jedním ze základních fyziologických parametrů, který popisuje vlastnosti rytmických úderů srdce, je tepová frekvence. Ta se zpravidla udává v počtu jednotlivých úderu srdce za jednu minutu. K výsledku lze dospět více způsoby. Jako nejjednodušší postup lze v časovém intervalu jedné minuty spočítat reálný počet úderů srdce. Tato metoda však není pro výzkum zcela vhodná. Lidské tělo nefunguje jako metronom a časové intervaly mezi jednotlivými údery se zpravidla mezi sebou liší. Pokud bychom tak sledovali skutečný počet úderů srdce za jednu minutu, ztratíme informaci právě o variabilitě těchto časových změn, která, jak ukážeme dále, je zásadní pro určité směry výzkumu. Další možností je dívat

se na kratší časová okna, kde se počty úderů počítají a počet úderů za jednu minutu se následně dopočte, což je metoda využívaná běžnými komerčními přístroji. V našem případě půjdeme ještě dál a budeme sledovat časové intervaly mezi každým jednotlivým úderem srdce. Je-li interval mezi dvěma údery srdce t , měřeno v milisekundách, lze dopočítat okamžitou tepovou frekvenci v počtu úderů za minutu jako $HR = 60000/t$.

Základním problémem, se kterým se potýká každý výzkumník na celém světě při zpracování BCG signálů, je jejich variabilita. Ať už použijeme jakýkoliv typ senzoru uvedený v předchozí kapitole, vždy bude výsledný signál kromě aktuálního děje v lidském těle závislý na umístění senzorů vůči lidskému tělu. Zjednodušeně si můžeme představit situaci, kdy využijeme konfiguraci senzorů na obrázku 1.17. Budeme-li předpokládat, že samotné fyziologické děje jsou v lidském těle stále stejné (tj. každý úder srdce a související mechanická odpověď budou stejné), bude výsledný signál měřený jednotlivými senzory závislý jednak na poloze člověka na posteli (zda leží např. v levé či pravé části postele) a dále na jeho natočení (zda leží např. na zádech či na boku). Už jen pouhé určení tepové frekvence je pak poměrně složitý úkol, což dokládá i úpadek počtu publikací zabývajících se BCG na obrázku 1.8. Z komerčního hlediska lze říci, že selhaly různé experimenty k určování tepové frekvence např. pomocí rozpoznávání patternů, tedy tvaru křivky [19], jelikož změny tvaru měřené křivky mohou být velice rychlé a reakční doba takových systémů bývá zpravidla velice pomalá. Stejně tak selhávají tradiční frekvenční metody (ať již hledání tepové frekvence pomocí Fourierovy transformace, nebo pomocí pokročilejších metod, jako je Welchova transformace), jelikož BCG signály obsahují celou řadu frekvenčních pásem a navíc rytmus srdce není zcela periodický. Pro určení frekvenčních maxim (peaků) ve spektrech tak jsou potřeba dlouhá časová okna, kde ovšem vlivem variability v srdečních úderech dochází k rozostření daného frekvenčního peaku souvisejícího s tepovou frekvencí a její určení je tak nepřesné. Vhodným nástrojem může být i spojitá vlnková transformace, jejímž velkým problémem je však vysoká výpočetní náročnost.

Výzkum v oblasti zpracování signálů využívaný na UHK je založen na pilotní práci [20], kde se autorům podařilo propojit dvě zásadní myšlenky. První z nich je využití více než jednoho senzoru pro měření. Výhodou této myšlenky je zajištění větší měřené plochy v případě lokálního měření. Je logické, že pokud bychom umístili do postele pouze jeden lokální senzor, mohou často nastat situace, kdy člověk leží zcela mimo jeho měrenou oblast. Další výhodou této myšlenky je pak využití inovativní metody zpracování dat z většího počtu senzorů. Tato myšlenka je založena na následujících stavebních kamenech:

- Na signály měřené jednotlivými senzory nahlížíme jako na vícerozměrné časové řady.

- Srdeční cyklus považujeme za základní děj, který se odehrává v lidském těle.
- Každý signál považujeme za souřadnicovou silovou projekci tohoto děje. Tedy máme-li n senzorů, získáme projekci děje do n souřadnicových os.
- Srdeční cyklus tak lze popsat jedinou křivkou v n -rozměrném prostoru, která je parametricky určena právě signály jednotlivých časových řad.

S využitím výše uvedeného přístupu se tak otevřely zcela nové možnosti zpracování BCG signálů, jelikož se oproštujeme jak od klasických frekvenčních metod, tak od hledání obecných patternů v každém jednotlivém signálu. Naopak se můžeme zaměřit na čistě geometrický přístup ke zpracování signálů a to zejména metodami diferenciální geometrie křivek v eukleidovském prostoru.

Jak bylo řečeno, jedním z problémů při měření je vzájemná poloha měřeného člověka a senzorů. V práci [20] byla zavedena myšlenka hledání matematických objektů, které by na takovém geometrickém uspořádání byly nezávislé. Z matematického hlediska lze problém posunu a natočení člověka vůči senzorům popsat jako hledání objektů invariantních vůči takovým geometrickým transformacím, konkrétně invariantním vůči translaci a rotacím v trojrozměrném eukleidovském prostoru. Takové transformace lze pak popsat grupou $\text{SO}(3) \times \mathbf{R}^n$ a je možné dále studovat objekty invariantní vůči akci této grupy. Cílem předložené práce není zabíhat do rigorózních detailů matematických metod, ty byly popsány v diplomové práci obhájené na katedře fyziky UHK pod vedením autora předložené habilitační práce [21]. Tato diplomová práce je jedním z důležitých didaktických výstupů popisovaného výzkumu. Na katedře fyziky slouží jako názorná výuková pomůcka pro výklad matematických metod používaných při zpracování signálů, včetně praktických příkladů.

Základem dalšího zpracování BCG dat je výpočet dvou hlavních invariantů vůči akci výše uvedené grupy. Těmito invarianty jsou délka oblouku a Cartanovy křivosti [22]. Délka oblouku $s(t)$ je funkce, která zjednodušeně řečeno popisuje míru nárůstu křivky v závislosti na čase:

$$s(t) = \int_0^t \sqrt{\sum_{i=1}^n \left(\frac{dC_i(\tau)}{d\tau} \right)^2} d\tau, \quad (2.1)$$

kde $C_i(\tau)$ reprezentuje i -tou křivku, tedy časovou řadu naměřenou daným senzorem, n počet křivek, tedy časových řad, τ vzorkovací čas a t vzorkovací čas odpovídající zpravidla délce měřeného signálu.

Cartanovy křivosti tvoří zobecnění klasické geometrické křivosti, která je definovaná pro křivku v dvourozměrném eukleidovském prostoru jako převrácená hodnota poloměru oskulační kružnice, do více rozměrů. Tyto křivosti lze vypočítat pomocí tzv. Frenet-Serretova přístupu, který je podrobně popsán v [21]. Tento přístup operuje s principem zavedení lokálních souřadnicových systémů v každém bodě křivky v n -rozměrném prostoru, které jsou pro názornost v trojrozměrném prostoru definovány jako soubor ortonormálních vektorů tečny, normály a binormály dané křivky. Označme si tyto Frenetovy vektory jako $(\mathbf{e}_1(t), \dots, \mathbf{e}_n(t); t \in [a, b])$, kde a resp. b označuje počáteční resp. koncový vzorkovací čas, mezi kterými určujeme dané křivosti. Pak lze j -tou Cartanovu křivost $\kappa_j(t)$ vypočítat jako:

$$\kappa_j(t) = \frac{\langle \mathbf{e}'_j(t), \mathbf{e}_{j+1}(t) \rangle}{\|C'(t)\|}, \quad (2.2)$$

kde $\langle ., . \rangle$ je skalární součin v \mathbf{R}^n , $\mathbf{e}'_j(t)$ derivace Frenetova vektoru $\mathbf{e}_j(t)$ podle času, $C(t)$ je křivka popsaná n parametrickými projekcemi $C_i(t)$ (tedy měřené signály) a $\|C'(t)\|$ velikost vektoru tvořeného derivacemi křivky $C(t)$ v daném vzorkovacím čase.

Základní matematický princip lze shrnout tak, že v dalším zpracování a výzkumu nepracujeme přímo s naměřenými signály jakožto časovými řadami, ale pracujeme až s novými vypočtenými časovými řadami v podobě délky oblouku a Cartanových křivostí. To přináší zcela nové možnosti při zpracování BCG signálů, jelikož tímto přístupem se podařilo obejmít nutnou standardizaci naměřených dat. Veskeré další výsledky vypočtené z těchto invariantů jsou totiž do jisté míry nezávislé na poloze člověka vůči použitým senzorům.

Jednou z velkých výzev také byla aplikace matematických metod, které pracují se spojitými křivkami, do praxe. V experimentálním výzkumu pracujeme vždy s digitalizovanými křivkami, jinak by jejich další zpracování pomocí výpočetní techniky nebylo možné. V tu chvíli však již pracujeme pouze s diskrétními daty. Proces transformace matematických vztahů do praxe včetně použitých matematických metod byl podrobně popsán v sérii odborných článků [23], [24] a [25] publikovaných v odborných časopisech, které jsou obsahem Přílohy A této práce. Tyto odborné publikace pak tvoří další důležitý výstup předložené habilitační práce. Byť v těchto publikacích jsou jejich cíle orientované do praxe, popis matematických metod zde tvoří didaktický most mezi teorií nabytou při vzdělávání na univerzitách a aplikací těchto znalostí na konkrétní problémy. Výstupy těchto odborných publikací slouží jako výukové pomůcky pro výklad problematiky zpracování signálů při přednáškách na katedře fyziky UHK.

Jednou z hlavních výhod představeného matematického aparátu, který je používán

pro zpracování BCG signálů, je variabilita jeho použití. Veškeré přístupy jsou nezávislé na počtu použitých senzorů, ten pouze určuje počet dimenzí, ve kterých výpočty provádíme. S vyšším počtem senzorů se zvyšuje přesnost výstupů, které budou prezentovány v dalších kapitolách, ale rovněž se zvyšuje výpočetní náročnost daného procesu a důležitým hlediskem je i ekonomická otázka. V praxi je proto nutné přejít ke kompromisu a nejčastěji jsou používané konfigurace obsahující dva až čtyři signály. Naopak v oblasti výzkumu byly prováděny experimenty s až 16 simultánně měřenými signály. Další výhodou tohoto aparátu je i jeho nezávislost na původu vstupních dat. Uvedené metody fungují stejně spolehlivě jak u piezokeramických senzorů, tak i u tenzometrů či gyroskopů. Další matematické metody, které jsou při zpracování využity, pak představují zejména celou řadu různých typů filtrování. Tyto metody nejsou součástí předkládané habilitační práce, je-likož představují často know-how aplikovaných či komerčionalizovaných výsledků. Samotné hledání frekvenčních závislostí pak probíhá zejména pomocí tzv. autokorelace zpracovaných signálů, která byla využita pro měření tepové frekvence již v roce 1993 [26] a je používána i v dalších publikacích [27].

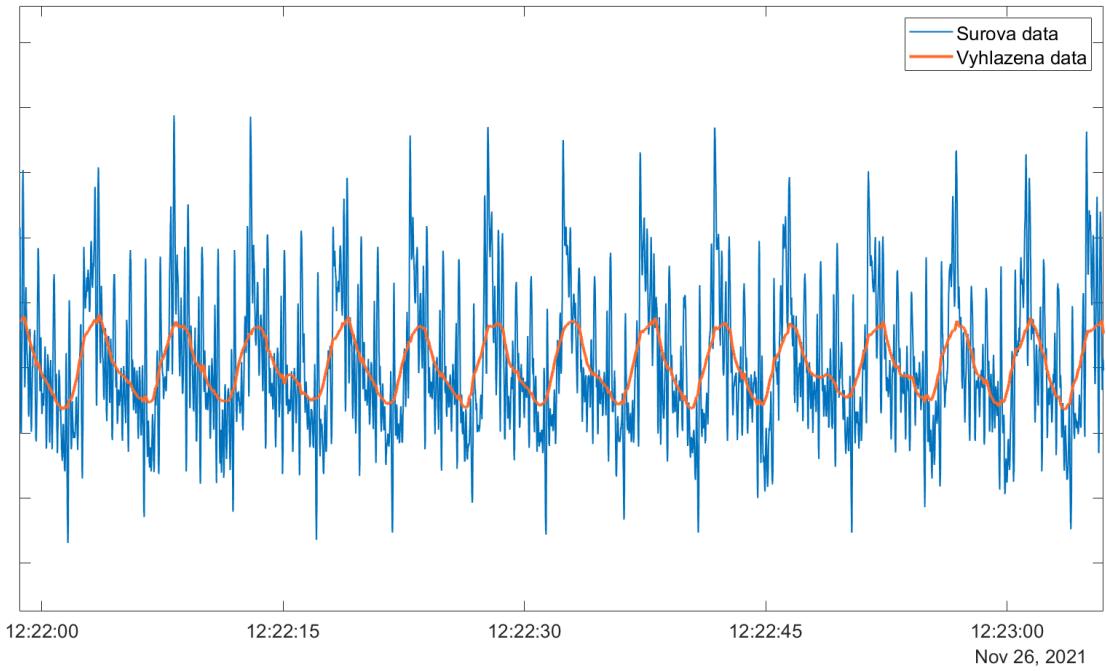
Kapitola 3

Aplikace ve výzkumu a praxi

Aplikace matematicko-fyzikálního přístupu ke zpracování BCG signálů má široké uplatnění ve výzkumu, který je pak základem didaktického využití při výuce. V předchozích kapitolách byly akcentovány matematické metody a využité senzory, z hlediska aplikací však byla zmíněna pouze tepová frekvence. Rozsah možného použití je samozřejmě výrazně větší. V této kapitole budou uvedeny vybrané výzkumné záměry, které využívají zpracování BCG dat a jejich přesah do dalších oblastí. Z tohoto hlediska je nutné poznamenat, že mikrovibrace člověka měřené pomocí různých typů senzorů nesouvisí jen a pouze se srdeční činností či šířením tlakového pulsu v cévním řečišti. Jedním z dalších významných pohybů, které lidské tělo vykonává, je např. dýchání, kterému se budeme věnovat dále. Mezi měřené pohyby ale patří i makroskopické pohyby jako převalování, mimovolní pohyby, tremor, nebo naopak pohyby ještě menší intenzity než je srdeční činnost, jako je peristaltika. Z tohoto hlediska již není možné mluvit pouze o BCG signálech, ale obecně o mikropohybech.

3.1 Poruchy dýchání

Měřené signály samy o sobě obsahují informaci o respirační činnosti člověka. Oddělení srdeční a respirační činnosti se zpravidla provádí pomocí vhodného filtrování, další zpracování pak využívá stejné matematické metody popsané v předchozí kapitole. Ukázka naměřených dat včetně křivky související s respirační činností je na obrázku 3.1. Zde, ani v řadě dalších grafů záměrně nebudeme popisovat jednotky na ose y . Důvod takového počínání je jednoduchý - v matematických metodách, které jsou využívány, se nikde nepracuje s amplitudou signálů, ale pouze s událostmi v čase a morfologií daného signálu. Při zpracování tak jsou téměř vždy signály i výstupy standardizovány (aritmetický průměr



Obrázek 3.1: Ukázka naměřených dat z jednoho senzoru (modré) a křivky získané filtrování, která reprezentuje dýchání člověka (oranžově). Na ose y záměrně nejsou jednotky.

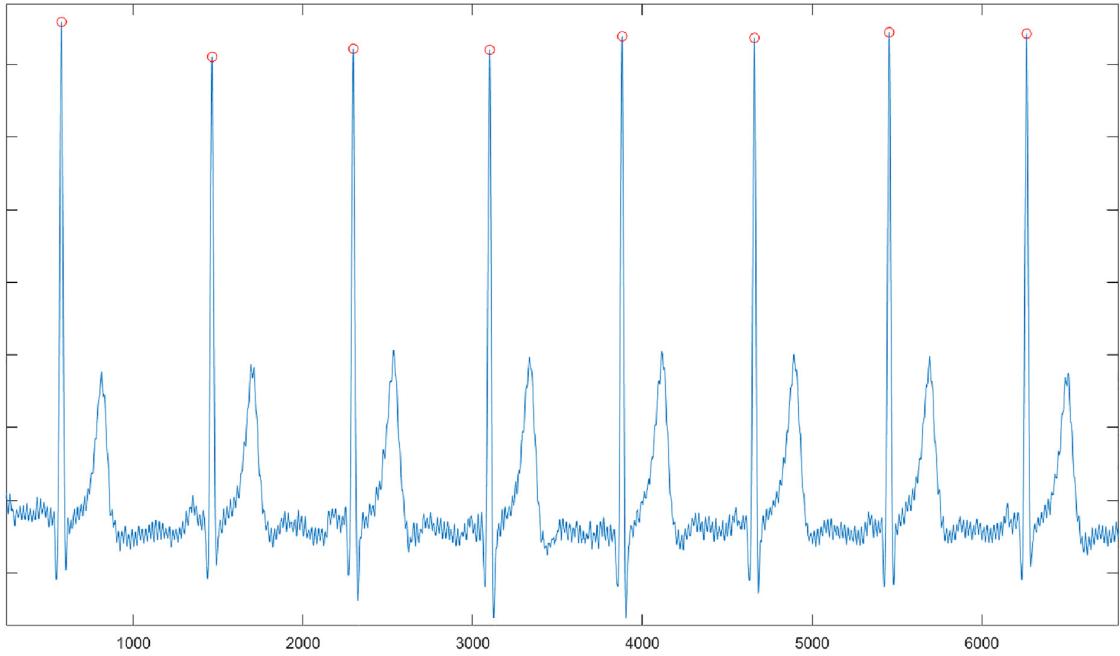
naměřených dat je nastaven na 0 a jejich rozptyl na 1). Poté se již pracuje pouze s morfologií daného signálu. Důvod je opět prostý, kdybychom pracovali přímo se samotnou amplitudou signálu, byl by výsledek měření např. na posteli ovlivněn např. změnou tukhosti nebo tloušťky matrace, což je v praxi silně nežádoucí. Vzhledem k tomu, že měřené signály nejsou ničím jiným, než digitalizovaným napětím, jedná se tak vždy o různým způsobem přepočtené elektrické napětí. Toto napětí pak samozřejmě přímo souvisí se silovým působením a silovými změnami v lidském těle, ovšem studium těchto závislostí se ukázalo nepodstatné pro výstupy prezentovaných metod, proto nejsou dosud nikde rigorózně popsány. Zde, i na dalších místech předložené práce, tedy můžeme považovat jednotky na ose y za určitou reprezentaci pohybů, které jsou snímány pomocí senzorů. V průběhu matematického zpracování pak v mnoha případech jde zejména o časové derivace těchto pohybů.

Modrá křivka na obrázku 3.1 v sobě obsahuje dvě zásadní informace, pozorovatelné peaky reprezentují činnost srdce. Ty ovšem leží na obálce děje o výrazně menší frekvenci, který je zvýrazněn oranžovou křivkou. Tato křivka do jisté míry reprezentuje křivku tzv. respiračního úsilí. Jelikož se jedná o laboratorně naměřená data, je pozorované respirační úsilí pravidelné a bez významnějších artefaktů, což v praxi samozřejmě neplatí. Kromě sledování dechové frekvence, k jejímuž určení se využívají stejné metody jako pro určení tepové frekvence, se výzkum dýchání na katedře fyziky UHK věnuje zejména zkoumání

poruch dýchání.

Série publikací [23], [24] a [25] je obecně zaměřena na automatické hledání respiračních potíží u lidí ležících na posteli. Série tří publikací spojuje nosné téma automatické detekce zástav dýchání (apnoe). Z výzkumného hlediska se pak jedná o propojení dvou moderních metod a to geometrického přístupu ke zpracování mikropohybů lidského těla a zpracování dat pomocí konvolučních neuronových sítí. Geometrický přístup si zde tak neklade za cíl dodat přesný výsledek v podobě informace o tom, zda došlo k zástavě dýchání, ale jedná se o unikátní metodu předzpracování dat pro neuronové sítě, díky čemuž bylo dosaženo mimořádné přesnosti při jejich aplikaci a při rozhodovacím procesu zda došlo či nedošlo k zástavě dýchání. Další unikátní přístup, který byl v těchto publikacích využit, je myšlenka nezaměřovat se přímo na mikropohyby vyvolané dýcháním, ale naopak na zcela jiné fyziologické děje, které nepřímo s dýcháním souvisí. Jedná se tak spíše o publikace, které se snaží ukázat, jaké netradiční metody lze využít pro řešení celkem jednoduché otázky a ukazují směr dalšího možného výzkumu, který bude již možné aplikovat do praxe. Tyto směry jsou pak využívány ve výuce na katedře fyziky UHK jako neortodoxní metody přístupu k řešení biofyzikálních problémů.

V publikaci [23] byla řada dobrovolníků měřena na posteli osazené tenzometry. Tito dobrovolníci v přesně definovaných intervalech zadržovali dech v nádechu a výdechu a v definovaných intervalech leželi na zádech, nebo na boku. Namísto zkoumání křivky respirační tíže byl využit princip popsaný v [20]. Dobrovolníkům byl simultánně snímán EKG signál a byly identifikovány tzv. R-kmity v EKG signálu, které se využívají pro hledání tzv. QRS komplexů [28], více na obrázku 3.2. Tyto časové okamžiky jsou využívány pro identifikaci začátku srdeční systoly a tedy předchází samotné izovolumetrické kontrakci, tedy stahu komor. Vzorkovací čas začátku systoly byl u každého jednotlivého úderu srdce označen jako čas 0. Dále byla z BCG signálů, viz obrázek 3.3, vypočítaná první Cartanova křivost a na základě modifikovaných metod využitých v [20] byly nalezeny v dané křivosti peaky související s odrazem pulsní vlny v kardiovaskulárním systému, a tedy byl odhadnut čas doběhu pulsu od počátku izovolumetrické kontrakce na definovaná místa v cévním řečišti pro každý jednotlivý úder srdce. Zástava dýchání se projeví ve změně tlakových poměrů v tepnách a tedy i v rychlosti šíření pulsu a tedy jeho doběhu na základě Moens-Kortewegovy rovnice. Tento děj se v publikaci ukázal jako skutečně měřitelný a výsledky doběhu pulsu sloužily jako vstup do neuronových sítí, včetně informace o tom, zda člověk dýchal nebo nedýchal. Neuronová síť v tomto případě dosahovala úspěšnosti přibližně 89 %. Z didaktického hlediska je přínos článku zejména v ukázce recentních metod zpracování signálu

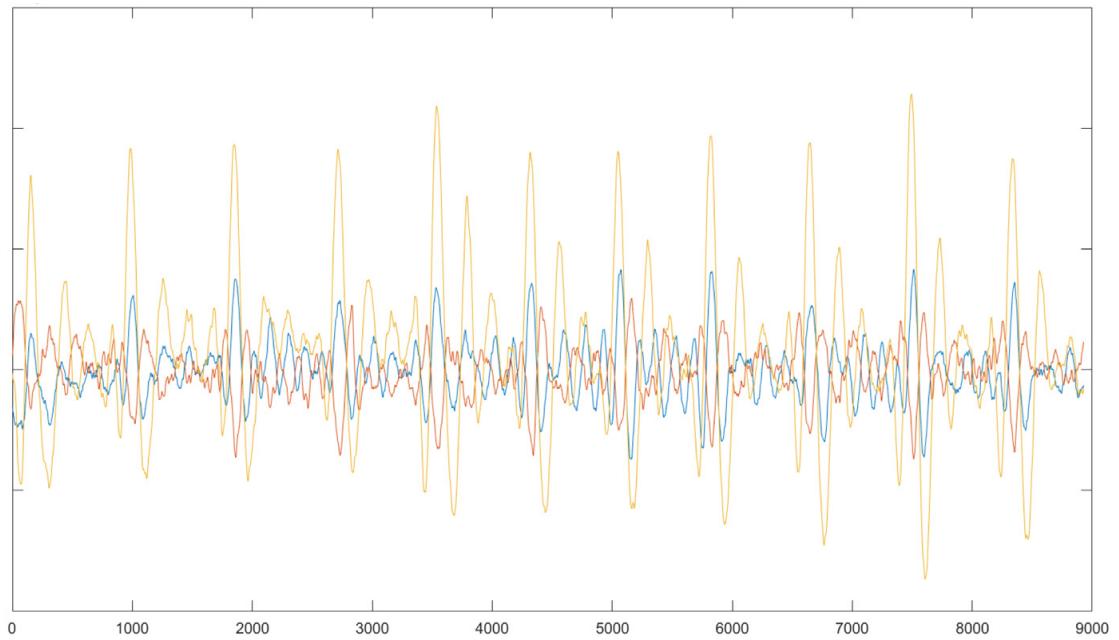


Obrázek 3.2: Naměřený EKG signál (modře), červeně označena místa identifikace R kmitu. Na ose x je čas v milisekundách.

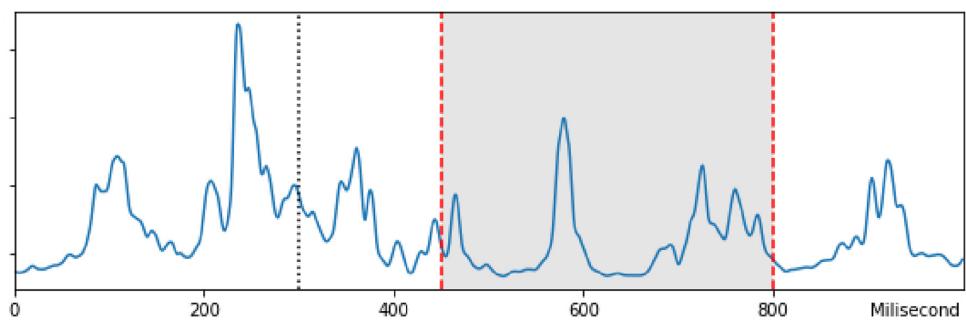
a v interdisciplinárním propojení fyziky s dalšími oblastmi výzkumu. Výsledky práce jsou součástí přednášek pro studující na katedře fyziky, kteří jsou pak často do samotného výzkumu zapojeni a právě interdisciplinarita je akcentována při samotné výuce.

Navazující publikace [24] si kladla za cíl jednak zvýšit přesnost dané metody a rovněž pokusit se oprostit od ručního hledání příslušných peaků v křivostech. Jedním z přínosů této publikace je představení efektivnějšího výpočtu první Cartanovy křivosti a tedy značné snížení výpočetní náročnosti celého systému a dále efektivnějšího filtrování této křivosti. Jako vstup do neuronových sítí nyní vstupovaly samotné kategorizované křivosti, opět rozdělené pomocí EKG do jednotlivých bloků dle jednotlivých úderů srdce, viz obrázek 3.4. Díky lepšímu filtrování a modifikaci neuronové sítě se podařilo dosáhnout její úspěšnosti 98 %. Z didaktického hlediska tato publikace opět slouží jako výuková pomůcka při přednáškách na katedře fyziky UHK, jelikož pomáhá překonávat bariéru mezi nabýtými vědomostmi v oblasti přednášek matematiky pro fyziky a jejich přímou aplikací na řešení konkrétních problémů.

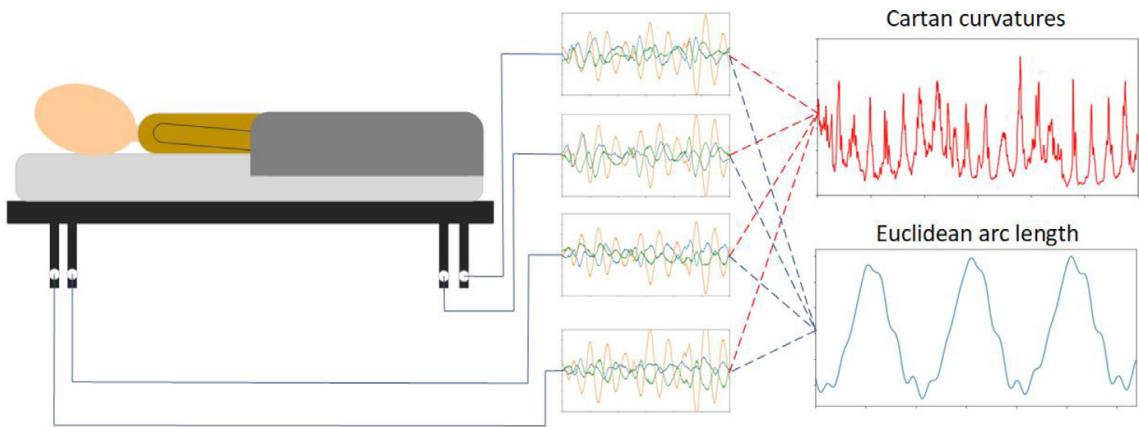
Poslední ze série publikací zaměřených na problémy s dýcháním pojednávala o možnostech odstranění hlavní nevýhody předchozích článků, a to nutnosti simultánního využití EKG při měření. V odborné literatuře byl zcela poprvé zaveden pojem mechanického triggeru jakožto startovního bodu pro studium poruch dýchání pomocí změn v kardiovaskulárním systému. Tento trigger se určuje právě pomocí popsane délkou, a tedy



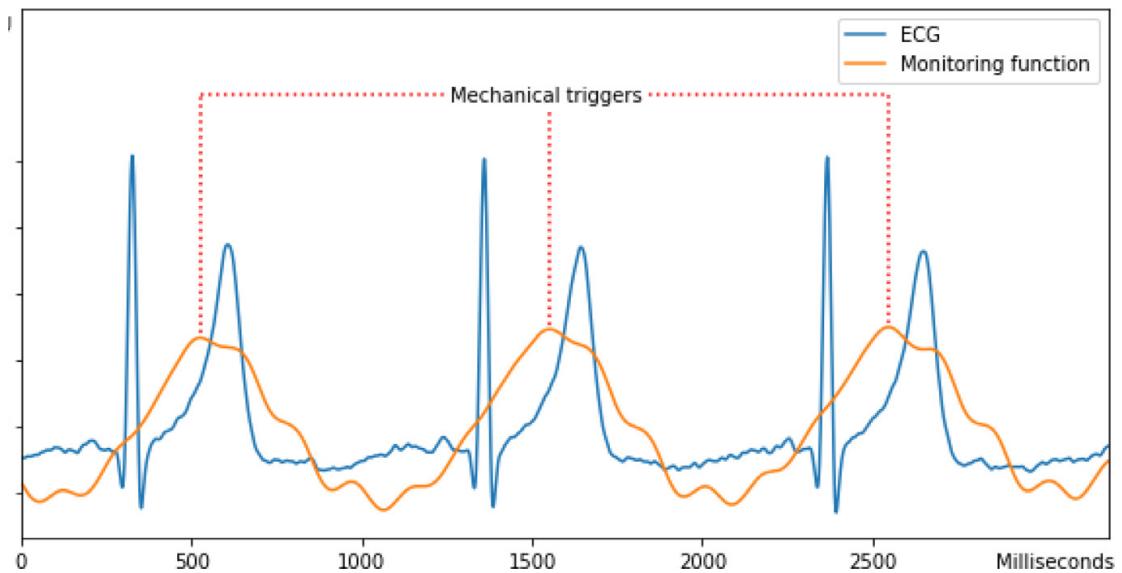
Obrázek 3.3: Ukázka tří naměřených BCG signálů z jednoho 3osého tenzometru. Na ose x je čas v milisekundách.



Obrázek 3.4: Ukázka vypočtené Cartanovy křivosti (modře), svislá černá tečkovaná úsečka značí okamžik počátku systoly, šedá oblast označuje místo významných dějů v kardiovaskulárním systému souvisejících s odrazy tlakového pulsu. Na ose x je čas v milisekundách.



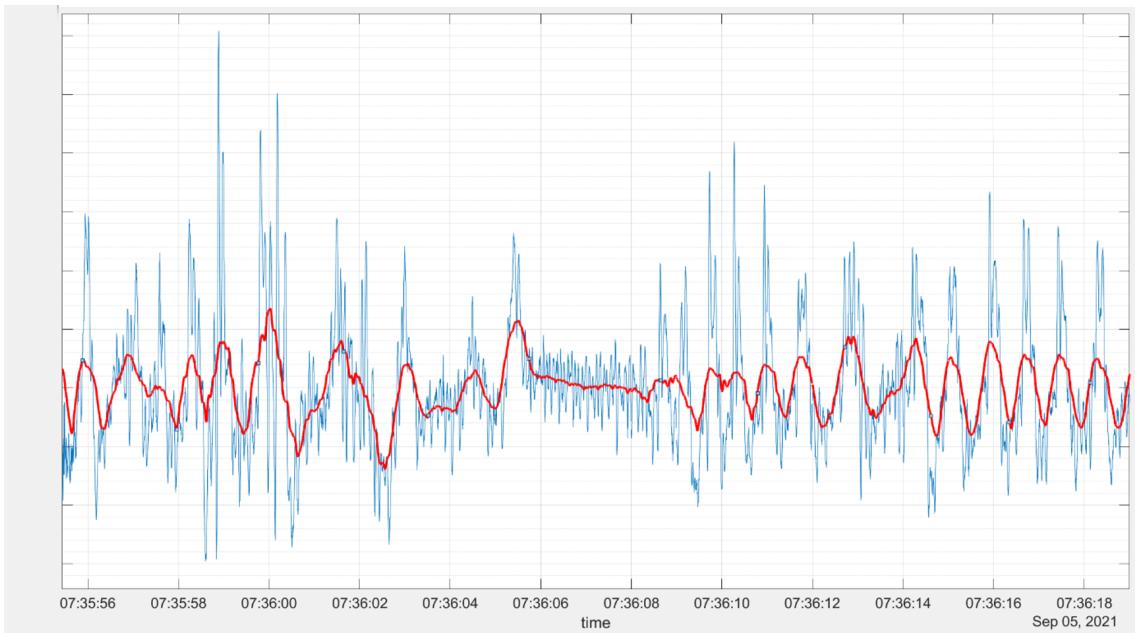
Obrázek 3.5: Architektura systému s mechanickým triggerem.



Obrázek 3.6: Porovnání EKG signálu s tzv. monitorovací funkcí, pomocí které je určován mechanický trigger.

zcela odpadá nutnost využití EKG pro podobné typy měření, viz obrázek 3.6. Úspěšnost neuronové sítě dosáhla v tomto případě přibližně 96 %. Základní architektura systému je znázorněna na obrázku 3.5. Jako unikátní se ukázal přístup extrakce dvou zdánlivě nesouvisejících informací z jednoho typu dat, kde se tyto informace vzájemně doplňují pro zajištění výsledku v podobě poruch dýchání. Z didaktického hlediska je důležitost článku zejména v podrobném popsání metody extrakce tohoto mechanického triggeru. Díky názornosti přístupu ke zpracování signálů byla tato metoda opět implementována do výuky na katedře fyziky UHK, první kvalifikační práce využívající tyto nové metody jsou již na katedře fyziky v přípravě.

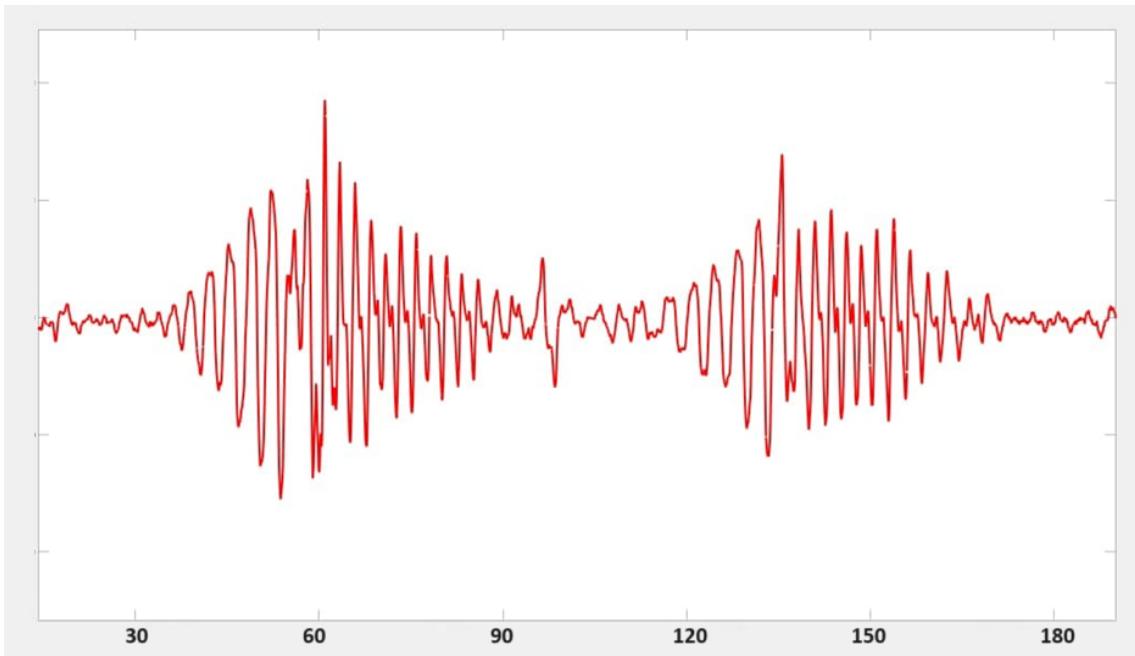
Apnoické pauzy byly v rámci výzkumu sledovány i v reálném prostředí, konkrétně na neonatologickém oddělení. Měřicí podložka byla konstrukčně upravena pro měření v in-



Obrázek 3.7: Záznam dat ze senzoru (modře) a příslušná křivka respirační tíže se zástavou dechu (červeně).

kubátorech a apnoické pauzy byly sledovány u novorozenců v kritickém stavu. Detail na jednu ze zaznamenaných apnoických pauz je možné pozorovat na obrázku 3.7. Výzkum v oblasti novorozenců stále probíhá a jeho výsledky nebyly dosud publikovány.

V závěru této části popíšeme ještě jeden typ poruch dýchání, který je možné pozorovat pomocí senzorů vyvinutých na katedře fyziky UHK. V letech 2020 a 2021 bylo značné výzkumné úsilí zaměřeno na studium respiračních projevů onemocnění COVID-19 a onemocnění příbuzných. Z tohoto důvodu probíhala rozsáhlá experimentální měření v nemocnicích po celé České republice. Jedním z výzkumných témat bylo i studium křivky respirační tíže, kde se kromě apnoe sledovaly i jiné patologie. Jednou z nich je tzv. Cheyenovo-Stokesovo dýchání, což je abnormální typ dýchání spjatý s poškozením dechového centra v prodloužené míše, který se často vyskytuje u pacientů na JIP [29]. Dechový vzorec pak sestává zpravidla ze vzestupné a sestupné části následované apnoickou pauzou, viz obrázek 3.8. Publikace na toto téma je teprve v přípravě, avšak ukázky přesahu fyzikálního výzkumu jsou pravidelně prezentovány na popularizačních akcích katedry fyziky. Systém pro monitorování dechových obtíží vyvinutý na katedře fyziky UHK umožňuje v reálném čase vykreslovat křivku respirační tíže, s čímž jsou studující pravidelně seznamováni v rámci laboratorní výuky. Z didaktického hlediska je zde zásadní motivace budoucích učitelů fyziky a snaha o přímé aplikace těchto výsledků do výuky v oborech zabývajících se biomedicínskou technikou. Experimenty založené na přímém pozorování



Obrázek 3.8: Křivka respirační tíže pacienta s Cheyeneovým-Stokesovým dýcháním. Na ose x je čas v sekundách.

fyzikálního děje jsou důležitou součástí výuky motivující studenty k hlubšímu porozumění daného tématu.

3.2 Variabilita srdečního tepu

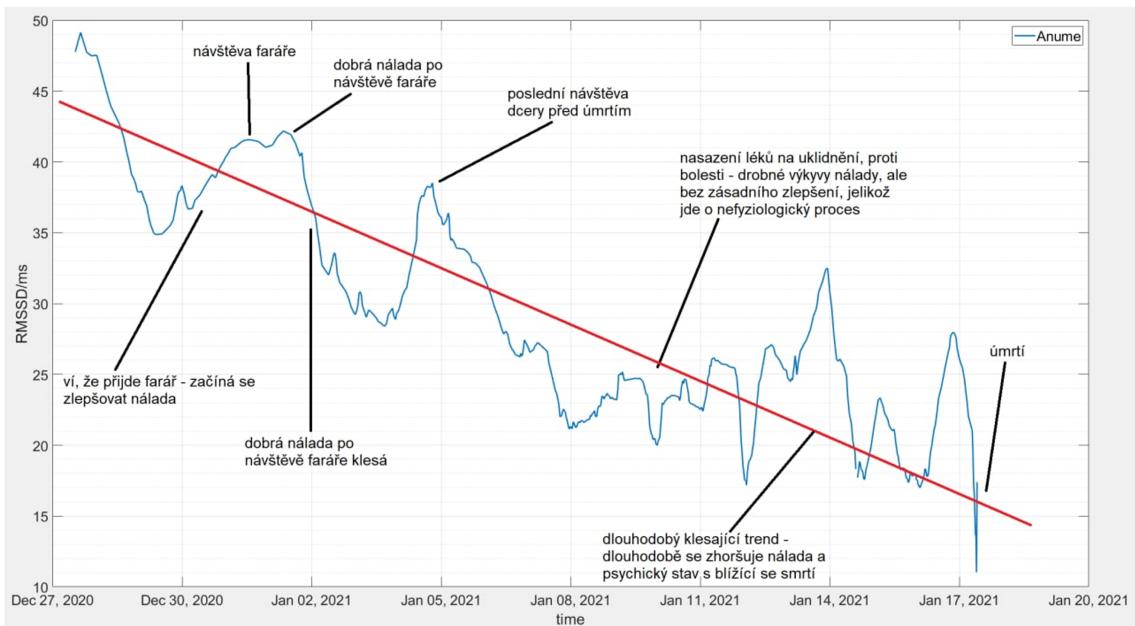
Již v 18. století bylo na základě měření frekvence pulsů srdce zaznamenáno, že velikost krevního tlaku a pravidelnost rytmu lidského srdce není konstantní, ale mění se v čase na úrovni intervalů mezi jednotlivými údery srdce a v důsledku dýchání [30]. V roce 1847 bylo zjištěno, že tyto změny mají konkrétní klinické aplikace [31], jejichž rozvoj nastal až společně s rozvojem měření EKG ve 20. století. Tyto změny tepové frekvence na úrovni jednotlivých úderů srdce (beat-to-beat) nazýváme variabilita srdečního tepu, neboli heart rate variability (HRV). HRV je nepřímý indikátor autonomní interakce mozku, sympatiku a parasympatiku na úrovni sinusového uzlu, tedy přímo na nervové úrovni ovlivňující tepovou frekvenci. Tyto beat-to-beat fluktuace hemodynamiky reflektují dynamickou odpověď kardiovaskulárního systému na okolní fyziologické vlivy [32]. Jako nejjednodušší příklad můžeme uvést dýchání, během kterého se mění nitrohrudní tlak a tím se mění i tepová frekvence (tzv. sinusová respirační arytmie). Souboj sympathiku a parasympatiku naopak ovlivňuje HRV na úrovni sekund až minut. Rychle reagující systémy zajišťují kardiovaskulární rovnováhu právě reakcí na beat-to-beat odchylky, tedy HRV. Tyto systémy

jsou řízeny např. baroreceptory a chemoreceptory. HRV tedy může sloužit k analýze reakce těchto receptorů a např. zvýšená citlivost baroreceptorů se projeví v HRV parametrech [33].

Pro studium HRV je nutné znát R-R intervaly, tedy časové intervaly mezi dvěma sousedícími R-kmity v EKG. To je zpravidla zajištěno pomocí EKG měření. Jejich měřením získáme časovou řadu sestávající z jednotlivých časových intervalů, měřenou zpravidla v milisekundách. Již z tohoto plyne, že dané intervaly je nutné měřit velice přesně. Jako minimum se zpravidla uvažuje vzorkovací frekvence analyzovaného signálu 250 Hz, což je zajištěno pomocí vyvinutých piezokeramických senzorů, které disponují vzorkovací frekvencí 330 Hz. Ve výzkumu na katedře fyziky se podařilo společně se společností MDT-Medical Data Transfer, s.r.o. ověřit, že přesnost měření beat-to-beat intervalů pomocí analýzy BCG signálů dává dostatečně přesné výsledky pro analýzu HRV.

Řada recentních publikací ukazuje význam HRV při zkoumání zdravotního stavu člověka [34]. Je nutné chápat, že HRV není jedno číslo, ale jedná se o soubor často složitých statistických parametrů, které popisují vlastnosti časové posloupnosti R-R intervalů. Jedním z nejpoužívanějších parametrů je tzv. RMSSD (root mean square of successive differences), tedy odmocnina ze směrodatné odchylky rozdílů mezi R-R intervaly v daném časovém okně, měřená zpravidla v milisekundách. Tento parametr do jisté míry přímo souvisí s psychickým stavem a pohodou měřeného člověka [33] jakož i třeba s progresí Alzheimerovy choroby [35]. Samotné HRV získalo na popularitě v poslední době díky tzv. wearables, tedy nositelným senzorům jako jsou např. chytré hodinky. Téměř všechny moderní chytré hodinky obsahují zjednodušený fotopletysmograf, tedy senzor pulsu v cévách. Díky tomu chytré hodinky umožňují měření nejen tepové frekvence, ale v poslední době stále častěji právě i informace o každém jednotlivém pulsu a umožňují tak vypočítat parametry HRV, zejména RMSSD. Díky tomu umožňují takové hodinky měřit psychickou pohodu člověka, případně i reakci jeho těla na pravidelné cvičení. Ukazuje se, že často nemusí mít hlavní vliv jen absolutní hodnota RMSSD, ale zejména trendy RMSSD v čase, kdy rostoucí RMSSD znamená zlepšování psychického stavu a nálady a naopak snižování RMSSD značí zhoršování psychického stavu a nálady [33]. Výzkumné směry katedry fyziky se zaměřují zejména na studium progrese Alzheimerovy choroby a dalších typů demence právě sledováním parametrů HRV.

Cílem této habilitační práce není seznámení s podrobnostmi o provedeném výzkumu, který je stále obsahem řešených projektů, ale je důležité upozornit na zajímavý experiment, který se podařilo realizovat v průběhu těchto měření a který má z didaktického



Obrázek 3.9: Vývoj RMSSD v posledním měsíci života měřené osoby.

hlediska velký význam, jelikož je často využíván jako silný emotivní a motivační prvek ukazující proč má smysl věnovat se studiu fyziky. Jak již bylo řečeno, tradičně se pro měření RMSSD využívá EKG, což s sebou ovšem nese problém s nutností nalepení elektrod a dalšího přístroje, který člověk musí mít u sebe aktivně přiložený. V případě seniorů trpících demencí je pak velkým problémem i samotné nošení chytrých náramků či hodinek. Tento přístroj, se kterým nemají zkušenosti, pro ně může být stresující a rovněž nutnost nabíjení pro ně může být komplikovaná. Z tohoto hlediska se osvědčilo měření HRV seniorů v moderních seniorcentrech právě pomocí neobtížující senzorů popsaných v předchozích kapitolách. K životu bohužel patří i jeho konec a vzhledem k tomu, že k dnešnímu dni je po celé České republice osazeno představeným měřicím systémem více než 200 postelí v nemocnicích a seniorcentrech, bylo možné zaznamenat i úmrtí osob na našem měřicím systému. Detailněji bude o tomto výzkumu pojednávat následující sekce, zde se ale zaměřme na obrázek 3.9.

Na tomto obrázku je možné pozorovat dlouhodobý vývoj parametru RMSSD v trvání téměř jednoho měsíce u osoby v seniorcentru. Konkrétně se jedná o poslední měsíc života této osoby. Z dlouhodobého hlediska lze na obrázku mezi 27. prosincem 2020 a 8. lednem 2021 pozorovat výkyvy v parametru RMSSD. Data naměřená pomocí senzorů byla konfrontována s hlavní sestrou příslušného seniorcentra, která byla schopná nezávisle na prezentovaných výsledcích popsat významné události v posledním měsíci života dané osoby. Tyto informace jsou zanesené v daném obrázku a jasně ukazují, jak se mění trend v růstu

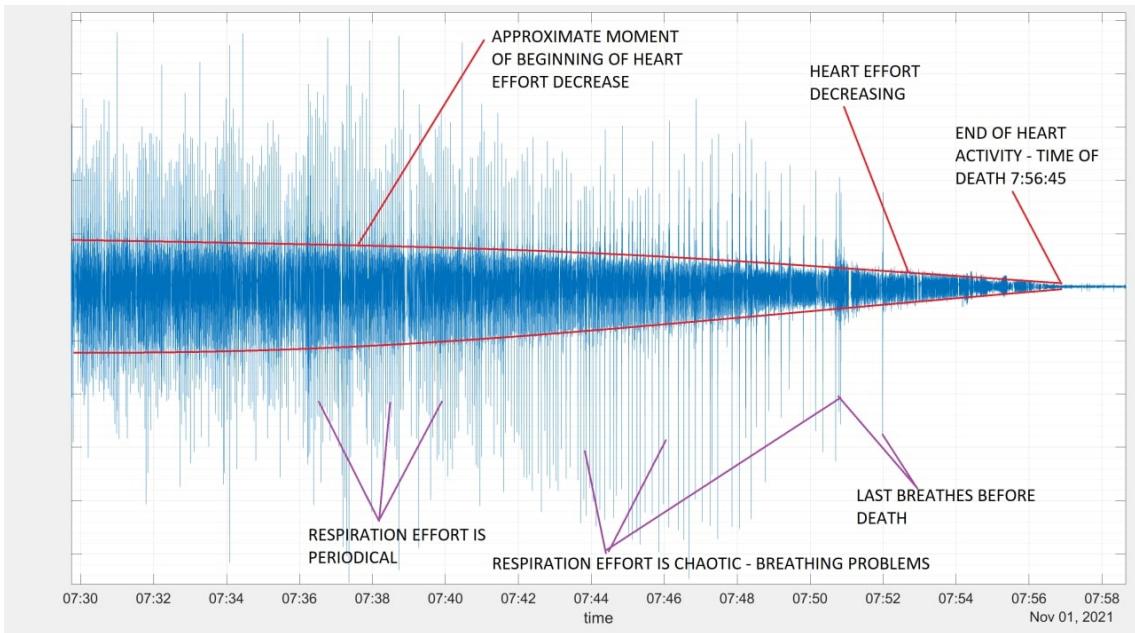
či poklesu RMSSD a tedy přeneseně řečeno v tom, zda se té osobě zlepšovala či zhoršovala nálada a její psychický stav. Celkově je možné pozorovat dlouhodobý klesající trend, který je pro účely názorné prezentace pouze naznačený červenou přímkou, nejedná se o regresní křivku. Nejzajímavější jsou ale události, které vedly ke zlepšení nálady a to konkrétně oznamení o návštěvě faráře, návštěva faráře a poslední návštěva dcery před úmrtím.

Ukazuje se zde ohromný přesah fyziky a názorný příklad toho, o jak rozsáhlý obor se jedná. Vezmeme-li chronologicky celý postup, dostali jsme se od vývoje senzorů, přes aplikování matematických metod používaných ve fyzice na měřené signály, po vývoj řady prototypů až k certifikovanému produktu, který byl použit pro monitorování zdraví reálných osob až po záznam samotného úmrtí. Při přednáškách na katedře fyziky je akcentován právě přesah a motivace ke studiu s jasnými aplikacemi, tedy jednoduchá odpověď na tradiční otázku studentů „A k čemu to je dobré?“.

3.3 Zhoršení zdravotního stavu před smrtí

Již bylo konstatováno, že měřicím systémem vyvinutým na UHK je aktuálně osazeno více než 200 lůžek po celé České republice. K tomuto rozmachu došlo zejména v letech 2020 až 2021 v období epidemie COVID-19, kdy vznikla velká poptávka po systémech dálkově sledujících zdravotní stav lidí v nemocnicích a seniorcentrech. Jen hrubým odhadem bylo pomocí poslední verze systému naměřeno více než 2 miliony člověkohodin záznamu a celkem bylo naměřeno více než tisíc různých osob. Vzhledem k místu měření nejednou nastala situace, při které na měřicím systému osoby zemřely, což je samozřejmě smutná záležitost, ovšem umožnilo nám to získat zcela unikátní dataset 16 osob, u kterých bylo jasné identifikováno úmrtí. První publikace zabývající se tímto tématem vyšla v nedávné době [36] a zabývá se zajímavým dějem, který byl pozorován u většiny lidí předtím, než zemřeli.

Základní princip lze demonstrovat na obrázku 3.10. U většiny osob, které zemřely na našem měřicím systému, bylo možné pozorovat změny v hemodynamice, tedy popisu oběhu krve na základě fyzikálních principů, a respirační činnosti v rádu desítek minut až několika hodin předtím, než došlo k úmrtí. Tyto změny se zatím nepodařilo uspokojivě vysvětlit, jelikož jde o fenomén dostatečně neprozkoumaný a neexistují k němu žádné relevantní reference. Pokud budeme studovat osobu, která nehybně leží na lůžku, můžeme postupný pokles měřeného signálu přisoudit poklesu silové intenzity srdeční činnosti, takový trend byl u těchto osob skutečně pozorován. Dále byly pozorovány i změny v křivce respirační tíže, kde se objevovala velká nepravidelnost v dechové činnosti. Expertním odha-



Obrázek 3.10: Záznam úmrtí na měřicí podložce, modře je signál z jednoho senzoru, červeně naznačení oblastí, kde došlo k patologickým změnám.

dem byl stanoven okamžik zhoršování zdravotního stavu i okamžik úmrtí. V [36] byla okna signálu transformována pomocí spojité vlnkové transformace a pomocí neuronových sítí byly okamžiky úmrtí a zhoršování zdravotního stavu verifikovány. Spojitá vlnková transformace poskytuje informace o změnách frekvencí signálu měřeného senzory, Její výhodou je zejména možnost studovat i velmi nízké (subhertzové) frekvence, což je optimální pro sledování pomalých dějů jako je dýchání. Následně byla vytrénována neuronová síť, která s úspěšností 86,5 % dokázala určit, zda dochází u osob ke zhoršování zdravotního stavu. Výzkum v této oblasti pokračuje, jelikož se postupně zvětšuje i počet osob, na kterých je možné tyto okamžiky zkoumat. Do výzkumu v této oblasti jsou již nyní zapojeni studenti katedry fyziky, jelikož se jedná skutečně o unikátní možnost propojení medicíny a fyziky. Z didaktického hlediska se tak jedná opět o způsob motivace žáka i učitele formou popularizace témat, která nejsou zcela obvyklá, ovšem mají fyzikální přesah do reálného života. Daná téma se ve výuce na katedře fyziky dotýkají i oblastí jako je zážitková pedagogika, ovšem v podobě aplikované na terciární vzdělávání. Studenti jsou zpravidla seznámeni s metodou měření dat, data jsou jim poskytnuta a dostanou zadáný dílčí úkol při jejich zpracování či zkoumání fyzikálního pozadí takových dat. Teprve později je jim oznámen přesný původ dat a studenti si tak lépe uvědomí vážnost úkolu který řeší, a o to intenzivněji se pak danému úkolu věnují.

3.4 Měření pulsní vlny

Další oblastí výzkumu, která se týká BCG signálů, je měření rychlosti pulsní vlny. Výzkum v této oblasti opět navazuje na metody publikované v [20]. Pulsní vlna je tlakový puls, který se šíří systémem cév kardiovaskulárního systému po vypuzení krve během systoly z levé komory do aorty. Při vypuzení objemu krve se systém cév s tímto rychle vypuzeným objemem vyrovnává elasticitou vlastních cév. Samotná rychlosť pulsní vlny se mění v závislosti na tom, v jakém místě systému cév ji měříme. V aortě se pohybuje standardně v rozmezí 5 až $10 \text{ m}\cdot\text{s}^{-1}$, v periferních cévách pak 10 až $20 \text{ m}\cdot\text{s}^{-1}$ [37]. V publikaci [23] se podařilo nepřímo ověřit, že metoda prezentovaná v [20] skutečně vede k měření parametrů času doběhu pulsu do různých míst v systému cév. Tato myšlenka byla dále rozvíjena a v současné době je obsahem patentů [38], [39], [40], [41] a užitného vzoru [42].

V nedávné době proběhl rozsáhlý experiment, na kterém se výrazně podíleli studující katedry fyziky, během kterého bylo měřeno 30 osob simultánně pomocí 11 senzorů. Konkrétně šlo o měření pomocí EKG, zařízení Zephyr BioPatch (měřicího dechovou frekvenci a křivku respirační tíže), systému ABI Bosco (pro určení rychlosti pulsní vlny a tlaku krve ve všech končetinách), čtyř piezokeramických senzorů v měřicí podložce pod matrací a čtyř trojosých gyroskopů (na ruce, na noze, na hrudníku, na břichu). Cílem tohoto experimentu bylo získat rozsáhlý dataset pro další výzkum právě v oblasti studia šíření pulsní vlny. Během experimentu zúčastnění dobrovolníci střídali leh na zádech a na boku, byly jim v poloze na zádech podkládány nohy do vyvýšené polohy, byli měřeni před a po cvičení, zadržovali dech v nádechu i výdechu a další. V současné době jsou v přípravě jedná bakalářská práce a jedna diplomová práce ve studijním programu Učitelství fyziky pro střední školy a jedna disertační práce ve studijním programu Didaktika fyziky na katedře fyziky UHK, zaměřené právě na analýzu dat naměřených během tohoto experimentu.

Mezi hypotézy, které se podařilo díky tomuto experimentu již prokázat a jsou obsahem zejména [42] patří:

- Ověření možnosti měření rychlosti pulsní vlny.
- Ověření, že při poloze na zádech při podložení nohou dojde ke změně tlakových poměrů v hrudníku, a tedy dojde ke změně rychlosti pulsní vlny.
- Při cvičení dochází ke změnám krevního tlaku a tedy i rychlosti pulsní vlny.

Verifikované metody jsou nyní již implementovány do výuky studujících na katedře fyziky UHK a jsou součástí laboratorních cvičení ve studijním programu Aplikovaná fyzika se specializacemi. Podařilo se tak přejít od prvního ověření hypotézy v [20] k první

verifikaci v publikaci [23], následnému rozsáhlému experimentálnímu měření, další verifikaci a ochraně duševního vlastnictví dané metody [42] se zapojením studujících, až po implementaci do výukových plánů na katedře fyziky. Tento proces z didaktického hlediska ukazuje náročnost implementace zcela nových hypotéz do přímé výuky, ale zároveň motivuje i budoucí učitele v terciárním vzdělávání k tomu, že je nutné neustále reagovat na pokrok v oblasti výzkumu a nové poznatky aplikovat, jelikož studující pracující na závěrečných pracích zaměřených na danou problematiku se zabývají skutečně recentními výsledky s výrazným přesahem do dalších oblastí přírodních věd.

Patenty [38], [39], [40], [41] spojuje další nosné téma a zcela nová metoda sledování fyziologie lidského těla nepřímo, na základě změn v rychlosti pulsní vlny. V patentech [38] a [39] je popsána nová unikátní metoda, která je založená na jednoduché fyzikální myšlence. V situaci, kdy měřená osoba leží na zádech, je aorta mírně utlačována gastrointestinálním traktem. Pokud dojde k pohybu v gastrointestinálním traktu, tedy k pohybu v důsledku peristaltiky, změní se dočasně silové poměry na aortu působící a tedy musí dojít ke změně v šíření pulsní vlny. Tato myšlenka byla na katedře fyziky verifikována na animálním modelu pomocí tří prasat, u kterých došlo k invazivnímu přerušení toku krve do gastrointestinálního systému a tedy kompletnímu zastavení peristaltiky. Tato prasata byla zároveň měřena pomocí měřicí podložky se čtyřmi piezokeramickými senzory a pomocí EKG. Data byla zpracována obdobnou metodou jako v [23], tedy opět byla vytvořena časová řada doby doběhu pulsní vlny v závislosti na jednotlivých úderech srdce. Výsledky ze zpracování naměřených dat potvrdily měřitelnou změnu v charakteru doběhu pulsní vlny před a po přerušení toku krve. Tímto se potvrdilo, že metoda sledování pulsní vlny může sloužit k určení, zda dochází či nedochází k pohybům vlivem peristaltiky. Tento závěr má pak rozsáhlé důsledky v oblasti sledování zastavení peristaltiky např. po operacích v oblasti břišní dutiny, kdy zástava peristaltiky může vyústit ve významné zdravotní potíže.

Patenty [40] a [41] využily identickou metodu, ovšem měření probíhalo u těhotných žen ve třetím trimestru ve Fakultní nemocnici Hradec Králové na Porodnické a gynekologické klinice. V průběhu experimentu bylo naměřeno celkem 34 těhotných žen, které byly současně měřeny pomocí kardiotokografu, který umožňuje mimo jiné zaznamenat pohyby plodu v děloze. U těhotných žen dochází v průběhu těhotenství ke zvětšení dělohy v důsledku růstu plodu a současnemu laterálnímu přeskupení střev. Při poloze na zádech je tedy aorta významněji utlačována právě dělohou a vyvíjejícím se plodem, nikoliv orgány gastrointestinální soustavy. Při pohybu plodu pak dojde opět ke změně silových poměrů

působících na aortu a tedy ke změně v rychlosti pulsní vlny. Zpracování naměřených dat piezokeramickými senzory poté prokázalo měřitelné změny v době doběhu pulsní vlny a potvrdilo hypotézu o měřitelnosti pohybů plodu. Důsledek je identický jako v předchozím případě - pokud dojde k zástavě pohybů plodu, značí to zásadní zdravotní problém v oblasti vývoje plodu.

Z didaktického hlediska se jedná o ukázku formování fyzikálního modelu šíření pulsní vlny, který byl verifikován, proběhla ochrana duševního vlastnictví a tyto výsledky jsou dále využívány v popularizaci fyziky na katedře fyziky UHK. Ukázka přesahu fyziky do lékařských oborů je obecně velice populární, jelikož jde o oblast, která je i poučeným laikem dostatečně uchopitelná.

3.5 Veterinární medicína

Unikátnost neobtěžujícího měření mikropohybů člověka se během výzkumu podařilo rozšířit i na další velice zajímavou oblast, kde má tato metoda přímé uplatnění, a to je měření zvířat. Na katedře fyziky probíhal výzkumný projekt zaměřený na měření a vyhodnocení dat na veterinárních klinikách. K tomuto účelu bylo využito tenzometrů umístěných v hliníkovém rámu, který byl na míru vyroben pro kotce na veterinářích, viz obrázky 3.11 a 3.12. Vzhledem k rozsahu hmotností typických zvířat byly po konzultaci s veterináři využity čtyři tenzometry s měřicím rozsahem 10 kg. Samotný rám je pak osazen krycí deskou a v daném kotci je tak pokryta celá jeho plocha, na které lze měření mikropohybů zvířat sledovat. Využití těchto senzorů na veterinárních klinikách je zcela unikátní, ale přitom logické, jelikož umisťování jakýchkoliv měřicích prvků na zvířata je velice komplikované a u zvířat taková měření vyvolávají výrazně větší stres než u lidí.

Celkově se během dvou let podařilo naměřit 110 zvířat, z 90 % psů a koček, o hmotnostech 0,5 až 26 kg. Cílem bylo neobtěžujícícm způsobem sledovat vitální funkce zvířat (jejich tepovou a dechovou frekvenci), zkoumat reakci aktivity zvířat na sedaci, probouzení zvířat z anestezie a na závěr zkoumat vývoj vitálních funkcí u zvířat, která na měřicím systému zemřela.

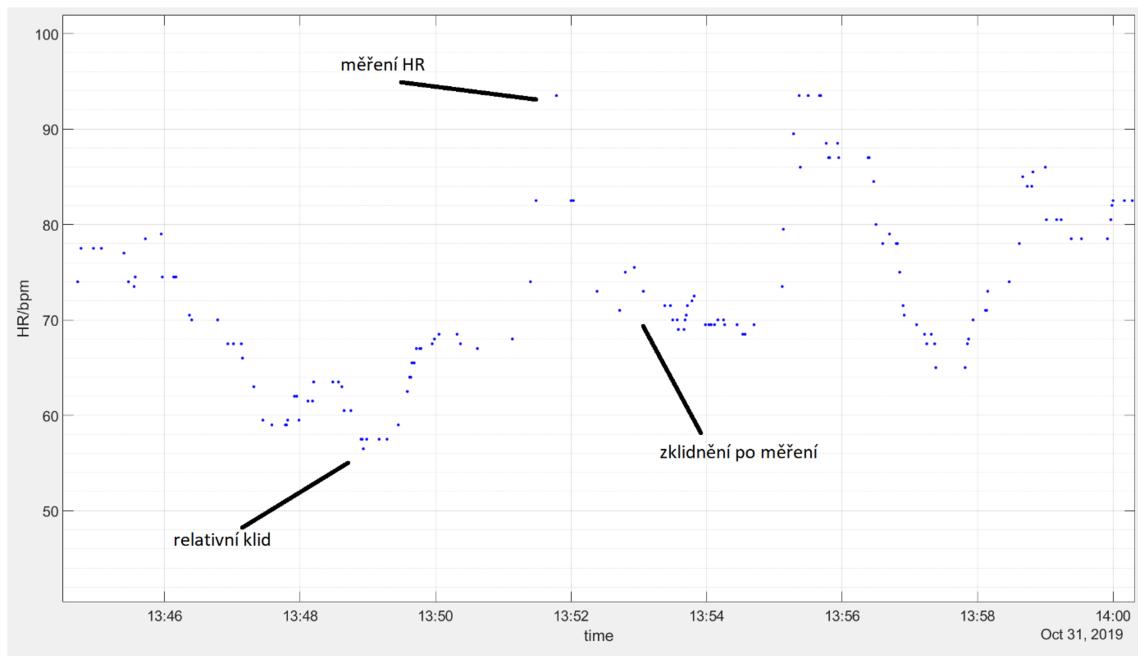
Za nejzajímavější výsledek lze považovat prokázání existence tzv. syndromu bílého pláště u zvířat. Jedná se o zvýšení tepové frekvence, dechové frekvence a krevního tlaku při měření těchto veličin z důvodu rozrušení zvířete přímo měřením. Tepová frekvence je totiž u zvířat v kotcích zpravidla měřena ručně veterináři, kteří přiloží prsty na vybranou tepnu a ručně počítají počty úderů srdce. Ač je tento děj pochopitelný a dobře zdokumentovaný u lidí [43], u zvířat je zpravidla velice obtížné ho sledovat, jelikož zvíře je ve



Obrázek 3.11: Měřicí podložka obsahující čtyři tenzometry.



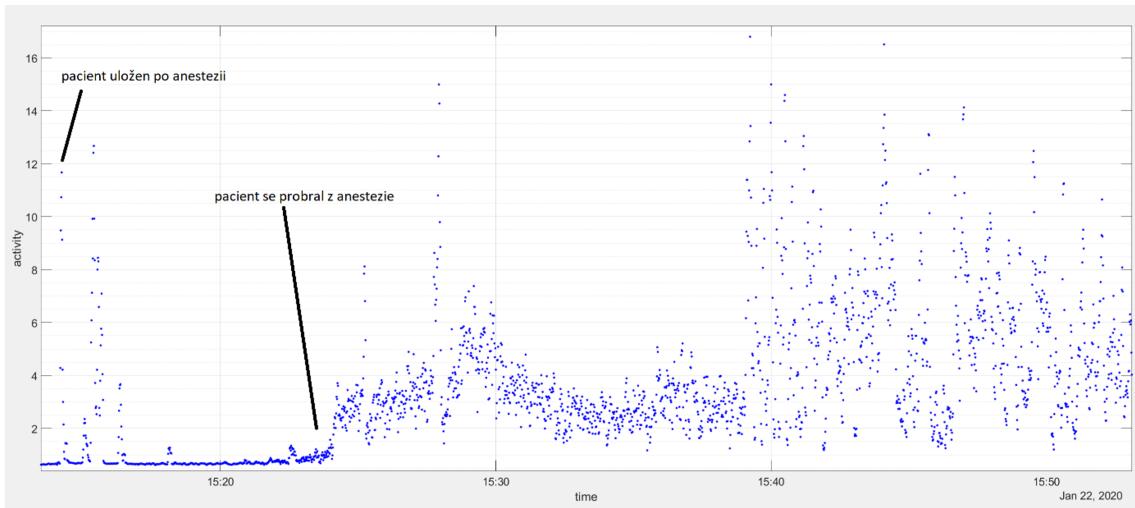
Obrázek 3.12: Ukázka umístění měřicí podložky v kotci na veterinární klinice.



Obrázek 3.13: Ukázka vývoje tepové frekvence u psa na veterinární klinice. Modře je označeno měření tepové frekvence pomocí podložky s tenzometry. V grafu je vyznačeno místo, kdy byla tepová frekvence měřená ručně veterináři.

stresu už z jakéhokoliv senzoru, který je na ně umístěn. Ve světě proběhly studie, kde byl porovnáván tlak krve u psů v klidu domova a na veterinární klinice [44], u koček proběhla studie, kdy jim byl implantován telemetrický senzor [45]. Tyto studie prokázaly existenci syndromu bílého pláště, ale nebyla nalezeno řešení použitelné pro veterinární kliniky, kde jsou zvířata hospitalizována. Měřicí podložka vyvinutá v rámci projektu tak efektivně řeší tento problém a výsledky ukazují, že skutečně vitální funkce měřené ručně veterináři často vůbec nekorespondují s reálnými klidovými hodnotami, které jsou podstatné pro správnou diagnostiku a léčbu. Na obrázku 3.13 je zobrazen vývoj tepové frekvence psa před, po i v průběhu ručního měření veterináři. Samotná tepová frekvence se před i po měření pohybovala v rozsahu 68 až 72 úderů za minutu, při měření tepové frekvence veterináři však vyskočila na 94 úderů za minutu (což souhlasilo s hodnotou naměřenou veterináři), jedná se tak o nárůst o více jak 30 %, který značně zkresluje reálné vitální údaje zvířat. Během studie byl syndrom bílého pláště pozorován u většiny zvířat. V současné době probíhá další rozsáhlé měření na veterinárních klinikách za účelem rozšíření studie s cílem publikovat zjištěné skutečnosti.

Dále bylo možné pozorovat i probouzení zvířecích pacientů po anestezii. Pro veterináře se jedná o zásadní informaci, jelikož není nutné stále kontrolovat dané zvíře a jedná se tak o telemedicínský systém, tedy dálkový přenos údajů o pacientovi lékaři. K tomuto

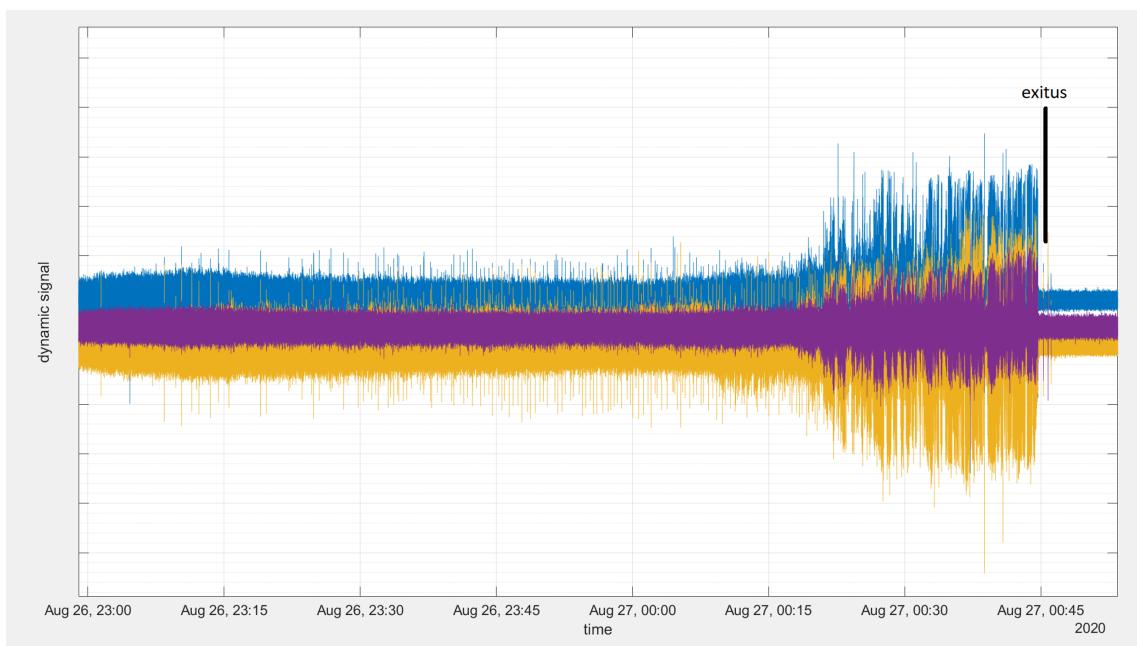


Obrázek 3.14: Ukázka vývoje aktivity u psa na veterinární klinice. Modře je znázorněna jeho aktivita, tedy míra pohybů psa. Jednotky na ose y tvoří uměle vytvořenou škálu.

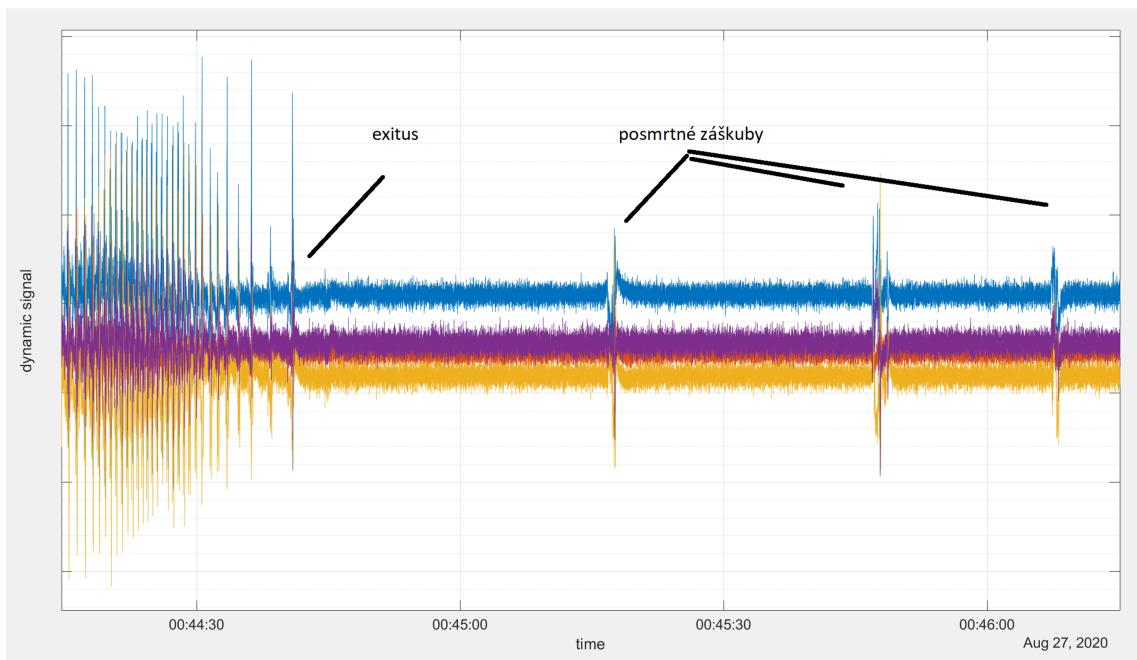
účelu byla z dat naměřených tenzometry vypočítána tzv. aktivita, jedná se zjednodušeně o variabilitu vypočtené délky oblouku. Na obrázku 3.14 je možné pozorovat pokles aktivity psa umístěného do kotce po anestezii a pak jasně identifikovatelný okamžik, kdy se pes po anestezii probral, což lze určit právě překročením prahové hodnoty jeho aktivity na podložce.

Na závěr této sekce se podívejme i na téma, kterého jsme se dotkli již při měření lidí. Jedná se o jeden z mnoha případů zvířat, která zemřela na monitorovací podložce. Konkrétně šlo o pokousaného psa. Na obrázku 3.15 je surový záznam dynamických signálů z tenzometrů posledních zhruba 100 minut života tohoto psa. Za povšimnutí stojí zejména oblast kolem času 0:20, kdy viditelně dojde ke změně charakteru morfologie měřených signálů. Na případ psa byla úspěšně aplikována neuronová síť publikovaná v [36] a skutečně odhalila v daném okamžiku zhoršení zdravotního stavu psa. Práce v oblasti detekce zhoršení zdravotního stavu před smrtí je důležitá zejména proto, aby mohli veterináři včas intervenovat v případě zhoršení a zvýšila se tak šance na záchranu zvířat. Teprve při řádném ověření funkce na zvířatech je v plánu implementovat obdobný systém i u sledování lidí.

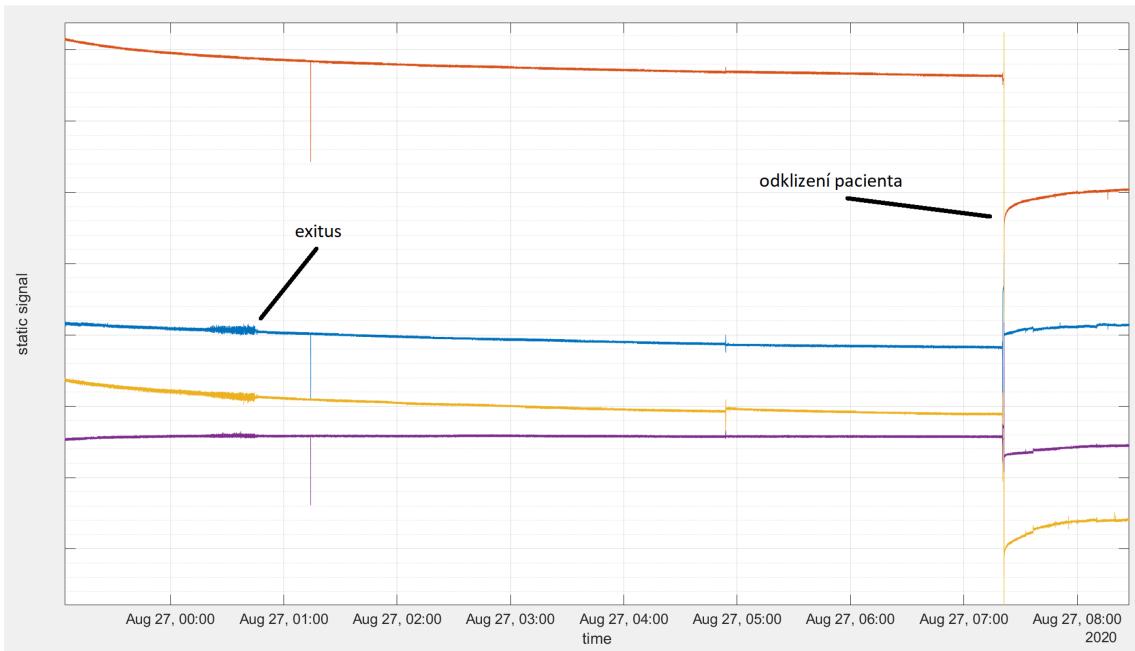
Obrázek 3.16 pak detailně zobrazuje okamžik exitu zvířete, včetně posmrtných záškubů, opět je zobrazen dynamický signál z tenzometrů. Na závěr se podívejme ještě na velice důležitou, ovšem často opomíjenou otázku, a to je samotná detekce úmrtí. Na obrázku 3.17 je zobrazen statický signál z tenzometrů, tedy na ose y je hmotnost zatížení jednotlivých senzorů. Jednotky nejsou uvedeny, jelikož v tomto případě nedošlo ke kalibraci daných tenzometrů a tedy nebyl k dispozici převodní vztah mezi statickým signálem a hmotností



Obrázek 3.15: Dynamický signál z tenzometrů u umírajícího psa, v obrázku lze pozorovat úmrtí i zhoršení zdravotního stavu před smrtí.



Obrázek 3.16: Dynamický signál z tenzometrů u umírajícího psa, v obrázku je detail na samotný okamžik úmrtí i posmrtné záškuby.



Obrázek 3.17: Statický signál z tenzometrů u umírajícího psa, v obrázku je pozorovatelná mnohahodinová prodleva mezi úmrtím a odklizením pacienta.

umístěné na měřicí podložce. V obrázku je zobrazen okamžik úmrtí psa a v čase cca 7:25 je vidět, že terpve tehdy došlo k odebrání hmotnosti z monitorovací podložky, tedy k odklizení pacienta. Prodleva mezi okamžikem úmrtí a okamžikem, kdy toto úmrtí bylo zaznamenáno, tedy činí téměř 7 hodin. Z tohoto hlediska je nutné se na detekci úmrtí i v budoucnu zaměřit, jelikož stejný problém tato prodleva představuje i u lidí a bohužel oprostíme-li se od morální otázky, jedním z mnoha problémů řešených v různých seniorcentrech jsou i případy, kdy přijde za seniorem návštěva a ta zjistí, že senior je již po smrti, jelikož není v možnostech personálu stále kontrolovat každého jednotlivého člověka.

Výsledky výzkumu prováděného na zvířatech jsou součástí užitného vzoru [46] a jsou často využívány v popularizačních přednáškách i v přímé výuce na katedře fyziky UHK. Téma zaměřené na zvířata je vždy velice populární a dokáže studenty rychle vtáhnout do problematiky měření a zpracování signálů.

3.6 Péče o seniory

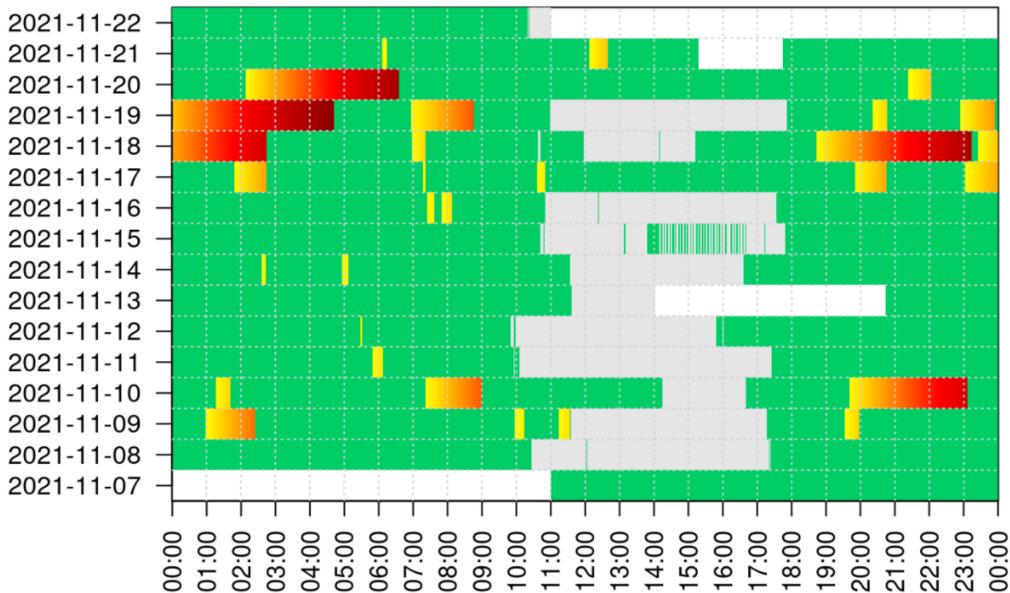
Uzavřeme nyní téma věnované sledování zdravotních funkcí lidí a zvířat částí věnovanou seniorům. Prošli jsme celým procesem od ještě nenarozených dětí, přes novorozence, dospělé lidi a zvířata až k okamžiku konce života. Věnujme se nyní oblasti, kde sledování zdravotního stavu pomáhá v praxi seniorům v seniorcentrech. Jedním z nosných vědeckých

témat na UHK je téma stáří. Obecným světovým problémem je stárnoucí populace a s tím nedostatek personálu, který by se mohl péci o stárnoucí populaci věnovat. S rostoucí průměrnou dobou dožití lidí tak roste poptávka po systémech telemedicíny, které umožní efektivněji ošetřovatelskému personálu reagovat na náhlé změny, sledovat změny v chování a zdravotním stavu seniorů v průběhu času a tím v důsledku zkvalitnit péci i ulevit přetíženému personálu. Jedním z cílů při vývoji monitorovací podložky vyvinuté na UHK tak bylo zapojení inteligentní technologie do péče o seniory i další potřebné osoby a to jak u domácí péče, tak v zařízeních pro dlouhodobý pobyt.

Podložky vyvinuté na katedře fyziky UHK osazené dvěma až čtyřmi piezokeramickými senzory jsou v současné době používány v celé řadě seniorcenter v České republice pro sledování zdravotního stavu seniorů. V rámci certifikace zdravotnických prostředků třídy I poskytuje v současné době monitorovací podložka informaci personálu o přítomnosti seniorky na lůžku a o tom, zda byl vhodně polohován. Potřeba polohování vzniká v důsledku času stráveného na lůžku, kde jako zásadní problém existuje vznik proleženin, tedy zánětlivých oblastí v podkožních částech těla, vzniklých z důvodu nedostatečného okysličení tkání v důsledku dlouhodobého utlačování. Aktivním prvkem prevence takto vzniklých proleženin je pravidelné polohování seniorů.

Samotný vyvinutý informační systém je rozdělen do tří úrovní. Na nejnižší úrovni formou mobilní aplikace upozorňuje ošetřovatelský personál na nutnost polohování seniorů u vybraných lůžek. Tím přímo aktivně dochází k prevenci vzniku proleženin a zlepšuje se tak kvalita péče o seniory. Dále pak systém upozorňuje na opuštění lůžka seniorelem, což má velký význam zejména v noci, kdy může nastat případ, že senior cestou na záchod upadne a může dojít k úrazu.

Další úrovní je pak role hlavní sestry, která má v mobilní aplikaci a pravidelných reportech přehled o celkovém stavu na oddělení a možnost kontroly, zda ošetřovatelský personál skutečně dodržuje předepsané doby polohování. Ukázka takového reportu je na obrázku 3.18, kde na ose x je zobrazen čas v průběhu každého jednotlivého dne a na ose y jsou jednotlivé měřené dny. Zelená barva značí, že měřená osoba byla v lůžku a že buď byla pravidelně polohována, nebo byla schopná se polohovat sama. Šedá barva značí, že postel byla prázdná, bílá barva pak značí výpadek měření (např. z důvodu převozu postele). Oranžová/červená barva pak značí místa, kdy již mělo dojít k polohování (které je nutné vykonávat každé cca 2 až 3 hodiny), ale nedošlo k němu i přes alarm v ošetřovatelské aplikaci. Z tohoto obrázku je pak patrná i další sledovaná skutečnost, a to je pravidelnost režimu měřené osoby. Lze vypozorovat, kdy daná osoba ráno vstává z postele, kdy si jde



Obrázek 3.18: Ukázka reportu polohování pro hlavní sestru.

lehnotu a zejména lze pozorovat, že 17. a 20. listopadu daná osoba vůbec neopustila lůžko, což může značit např. nemoc.

Poslední úrovní je pak úroveň managementu. Zde příslušní ředitelé mohou získávat komplexní reporty kvality péče celého oddělení a mohou tak sledovat např. počet problémů s případy nepolohování v daném místě a čase.

Celkově jde výhody celého systému popsat pro všechny jeho úrovně:

- Top management má jasnou přidanou hodnotu pro potenciální klienty a vymezení vůči konkurenci. Dále vede evidenci polohování, čímž dokáže zabránit případným sporům s rodinami klientů ohledně kvality péče.
- Management sester se může starat o zajištění kvality v rámci celých oddělení.
- Ošetřovatelský personál může lépe optimalizovat svoji činnost v rámci polohování a dokáže lépe identifikovat jednotlivá rizika.
- Pro samotného klienta pak jde opět o zajištění lepší kvality jeho péče, omezení rizik a zajištění lepšího komfortu.

Další téma, kterými se pak z výzkumného hlediska projekt sledování seniorů zabývá, jsou sledování doby spánku pomocí sledování přítomnosti osob na lůžku a aktivity měřených osob na lůžku a mimo jiné i sledování parkinsonovského tremoru, tedy třesu vyvolaného právě touto zákeřnou chorobou, což je i obsahem užitného vzoru [47] a jedná se o téma, které je rovněž zařazeno v praktické výuce na katedře fyziky UHK.

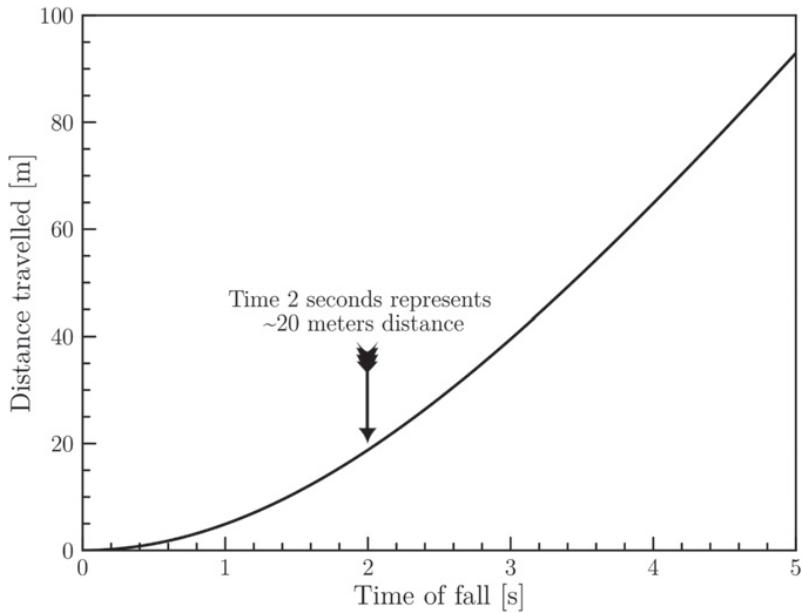
Celkově se tak jedná o příklad jasného vstupu do praxe. Studentům v rámci přednášek na katedře fyziky UHK je tak jasně ukázáno, že výzkum nemusí být jen tzv. „do šuplíku“, jak to bohužel v praxi někdy u výzkumných projektů bývá, ale vidí zde dopad odborné práce v oblasti matematiky a fyziky a jejich konkrétní využití. Další analýza dat a náměty na vylepšení systému jsou pak obsahem připravovaných kvalifikačních prací na katedře fyziky, tedy jedná se o jasné didaktické potenciál v terciárním vzdělávání.

3.7 Modelování pádu koček

Dosud se práce věnovala poměrně vážným věcem, místy na pomezí života a smrti. Jedná se o oblasti citlivé, ale k životu patřící. Věnujme se nyní trochu lehčímu tématu a pojďme se podívat ještě na další poměrně unikátní didaktický fyzikální model, který v průběhu výzkumu na katedře fyziky vznikl a byl i experimentálně ověřen. Jedná o model, který je pravidelně využíván ve výuce na katedře fyziky UHK pro svůj velký motivační potenciál. Využívá se zejména v základním kurzu mechaniky při výkladu pohybu těles v odporujícím prostředí. Studenti si pak na reálném příkladu mohou vyzkoušet výpočet Reynoldsova čísla a na jeho základě rozhodnout, na jaké mocnině rychlosti bude záviset odporová síla. Problematicce odporových sil nejen při pohybu kočky se věnuje i článek [50].

V průběhu rešerše k různým tématům dotýkajících se sledování životních funkcí zvířat bylo zjištěno, že mezi běžnou populací koluje pověst (moderně *urban legend*) ohledně pádů koček ze sedmého patra panelových či jiných domů. Existuje mýtus, že kočka dokáže přežít pády z pater, která jsou níže, ovšem bez problémů i z pater, která jsou výše, než sedmé patro. Často fatální pro kočky bývá pád právě ze sedmého patra. Tento mýtus se podařilo podložit fakty, skutečně existují práce, které naznačují, že určitá rozmezí výšek, ze kterých kočky padají, vedou k horším úrazům či úmrtí, viz [48] a [49], a že tato výška odpovídá zhruba sedmému patru běžného panelového domu.

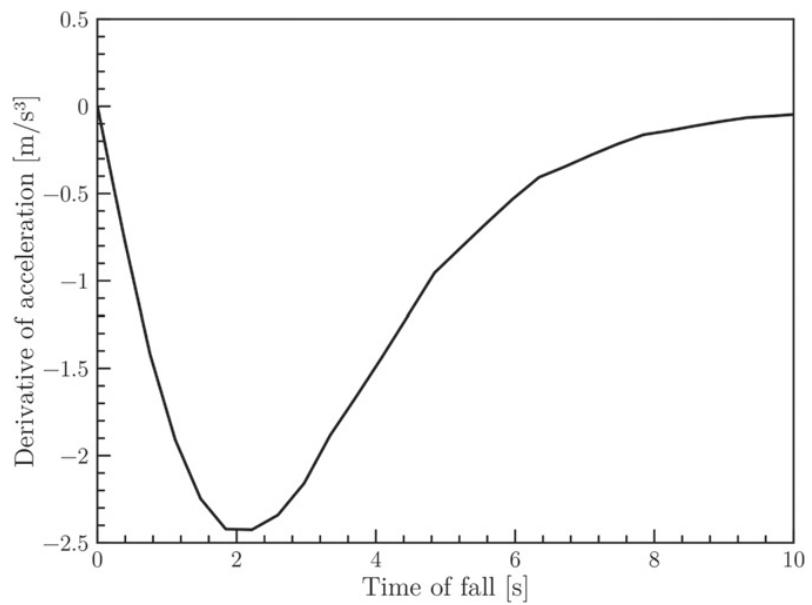
Nápad, že takový jev musí mít jasné fyzikální pozadí, byla prvním hybatelem dalšího výzkumu. Článek objasňující tento děj je rovněž obsahem přílohy této práce, proto zde budou zdůrazněny pouze jeho zásadní myšlenky. V publikaci [51] byl vytvořen jednoduchý model pádu koček demonstrující aplikaci druhého Newtonova pohybového zákona jakož i odporových sil. Dále byl v prostředí MATLAB nasimulován pád kočky a bylo studováno, co se děje těsně před dopadem právě při pádu zhruba ze sedmého patra, což odpovídá volnému pádu se započtením Newtonovy odporové síly ze zhruba 20 metrů výšky. Podíváme-li se na uraženou vzdálenost v průběhu pádu, viz obrázek 3.19, zjistíme, že pádu z 20 metrů odpovídá zhruba druhá sekunda pádu, ovšem nic zajímavého z tohoto grafu



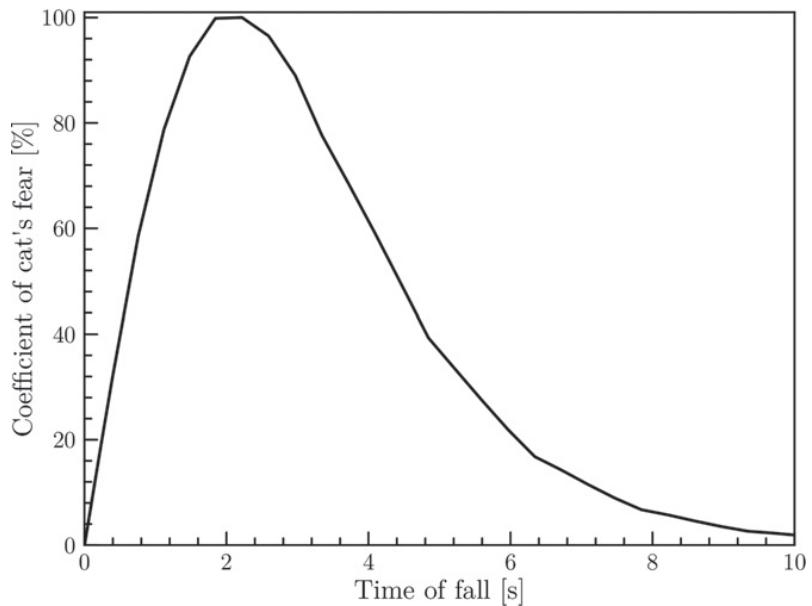
Obrázek 3.19: Závislost uražené vzdálenosti kočky při pádu na čase.

pozorovat nelze. Podíváme-li se ale na graf derivace zrychlení kočky při pádu, viz obrázek 3.20, vidíme, že právě ve druhé sekundě pádu nabývá tato derivace globálního extrému. Zamyslíme-li se nad samotnou fyziologií vnímání zrychlení člověka a savců obecně, vestibulární aparát poskytuje vědomí informaci právě o zrychlení daného tvora. To samo o sobě ještě není ale zásadní, představme si, co zažíváme např. na horské dráze. Adrenalin vyplavený při takovýchto aktivitách souvisí totiž zejména se změnami zrychlení, tedy jeho derivací. Vysvětlení toho, proč pak kočka utrpí větší zranění je nasnadě – existuje-li globální extrém v derivaci zrychlení, znamená to, že zrychlení se v tu chvíli mění v průběhu pohybu nejvíce a kočka se tak těsně před dopadem nejvíce bojí, lekne se a tedy nezvládne dostatečně korigovat dopad (pružením končetin). Zásadním výstupem této publikace je pak zavedení zcela nové veličiny nazývané koeficient strachu kočky při pádu z výšek, viz obrázek 3.21. Jedná se v podstatě o záporně vzatou derivaci zrychlení kočky normovanou na minimální hodnotu 0 a maximální hodnotu 100 %. Teoreticky předpovězené hodnoty zrychlení kočky pak byly experimentálně ověřeny na modelu kočky osazeném akcelerometrem.

Uvedený výzkum je samozřejmě třeba chápat s mírným nadhledem, avšak tato práce byla publikována v prestižním didaktickém časopise European Journal of Physics a byla dokonce zvolena jako jeden z „highlights“ tohoto časopisu roku 2016 pro jeho kvalitu a přispění komunitě didaktiky fyziky v terciárním vzdělávání. Není překvapením, že přednáška na dané téma je pravidelně využívána při popularizačních akcích katedry fyziky.



Obrázek 3.20: Závislost derivace zrychlení kočky při pádu na čase.



Obrázek 3.21: Koeficient strachu kočky při pádu z výšek v závislosti na době pádu.

3.8 Konstrukce vlhkého teploměru jako didaktické pomůcky

Komentovaná publikace [52] se zabývá moderním environmentálním tématem globální změny klimatu. V rámci publikace jsou vysvětleny základy psychrometrie a jejich aplikace včetně návodu na vytvoření vlhkého teploměru jako školní pomůcky. Výsledky obsažené v článku jsou využívány ve výuce ve studijním programu Aplikovaná fyzika se specializací Environmentální měření.

Didaktický potenciál tohoto tématu je značný – základní poznatky z termiky je možné využít k vysvětlení toho, proč je v případě vysokých teplot nebezpečná vysoká vlhkost vzduchu. Stejně tak je možné vysvětlit, proč člověk přežije v Údolí smrti (které je, pokud neuvažujeme např. sopky či geotermální prameny, nejteplejším místem na Zemi), pokud si s sebou vezme dostatek pitné vody, ale např. v Indii je možné i s neomezenou zásobou pitné vody zemřít na přehřátí organismu.

V prostředí s vysokou vzdušnou vlhkostí, kterým je právě např. Indie, nefunguje účinně ochlazování organismu pocením. Vzduch, který se blíží 100% nasycení vodní párou, brání odpařování potu z kůže. Proto se v této souvislosti pracuje s veličinou, která se obvykle označuje jako teplota vlhkého teploměru. Technicky vzato jde o teplotu adiabatické saturace. Měří se vlhkým teploměrem, u kterého je snímací prvek uvnitř hadříku napuštěného vodou, přes který prochází vzduch. Adiabatické odpařování vody odebírá teploměru tepelnou energii, což je prokázáno skutečností, že je teplota vlhkého teploměru vždy nižší než teplota suchého teploměru s výjimkou situace, kdy je relativní vlhkost 100 %. V tomto případě jsou obě teploty stejné.

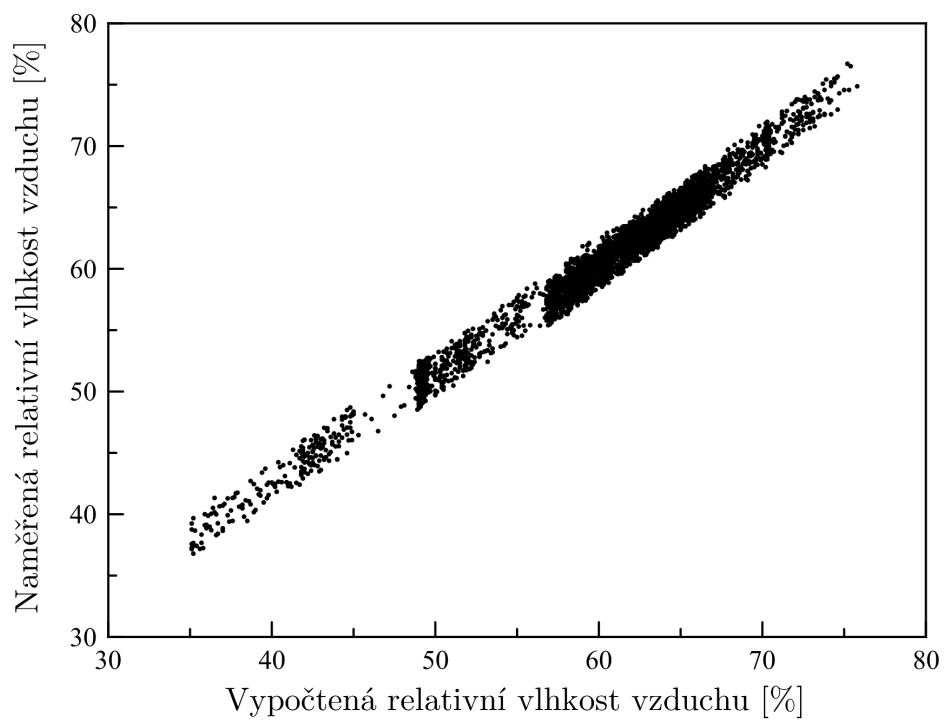
Vlhký teploměr lze realizovat poměrně snadno, viz obrázek 3.22, případně lze teplotu vlhkého teploměru vypočítat z teploty suchého teploměru a relativní vlhkosti vzduchu. Obě dvě tyto environmentální veličiny mohou být měřeny jedním digitálním senzorem, např. DHT22. Na obrázku 3.22 je jednak vlhký teploměr s teplotním senzorem DS18B20, jednak senzor DHT22 připojený k desce Arduino, která je ve výuce na katedře fyziky UHK běžně využívána.

Pomocí rovnic dostupných v literatuře lze z teploty suchého a vlhkého teploměru vypočítat vlhkost vzduchu. Tuto hodnotu studenti během laboratorní práce porovnávají s vlhkostí vzduchu změřenou senzorem DHT22. Bodový graf s 3 400 datovými body je na obr. 3.23. Pearsonův korelační koeficient je 0,97.

Vytvořená laboratorní práce v menším měřítku opakuje postup z předchozích kapitol: Pro daný fyzikální jev je hledána vhodná realizace experimentu, provedeno měření a následné zpracování dat. V tomto případě se jedná o mikrostrukturu ve smyslu, který



Obrázek 3.22: Realizace a schéma kombinovaného teploměru.



Obrázek 3.23: Bodový graf naměřené a vypočtené vlhkosti vzduchu.

bude popsán v kapitole 4. V rámci dané mikrostruktury se studenti teploměr sestaví, naprogramují ovládací software pro přenos naměřených dat do počítače přes rozhraní USB a následně data analyzují. Na rozdíl od jiných laboratorních prací, ve kterých studenti pracují s komerčními měřicími přístroji v poměrně lineárním režimu podle předem připraveného návodu, v případě zde popsané laboratorní práce mohou uplatnit různé přístupy, zejména v analýze a prezentaci dat.

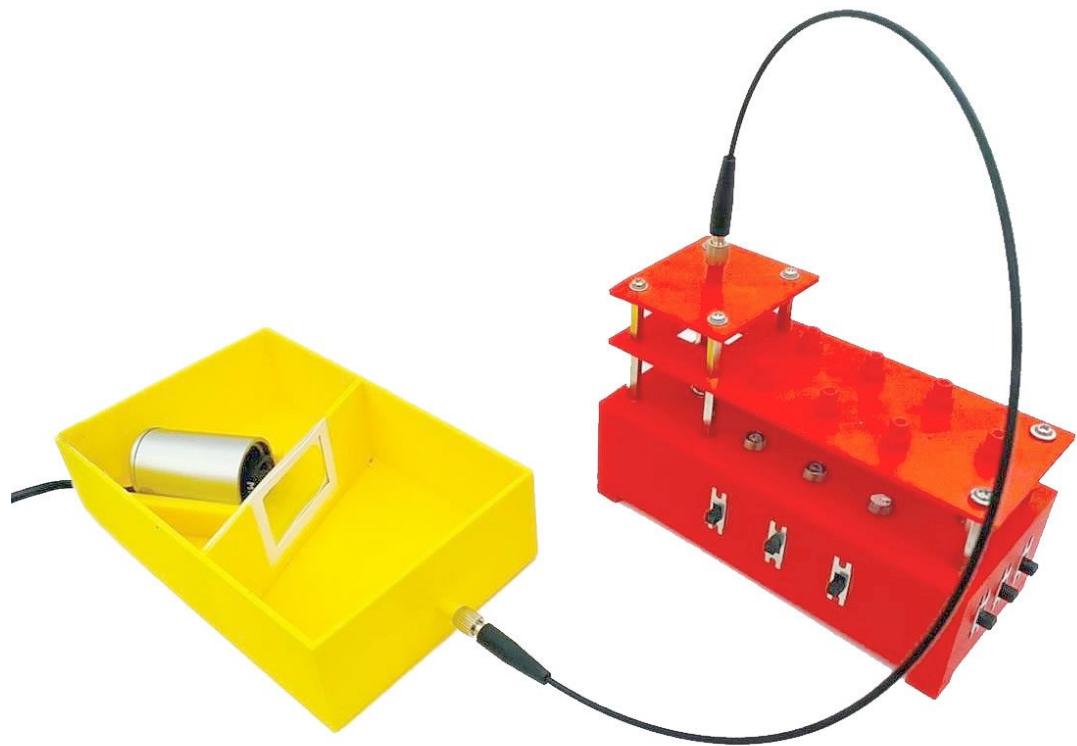
Podle současných modelů můžeme do poloviny století ve střední Evropě počítat s dvojnásobným až trojnásobným zvýšením frekvence vln veder, které pravděpodobně budou výraznější než dnes. Vzhledem k tomu, že nebezpečí vysokých teplot vlhkého teploměru se v budoucnu pravděpodobně rozšíří, je podle názoru autorů práce vhodné s tímto tématem pracovat i v přípravě budoucích učitelů, aby byli připraveni na oblast vyučovaného kritického myšlení potřebného k vysvětlení dané problematiky mezi žáky sekundárního vzdělávání.

3.9 Laboratorní cvičení ze spektroskopie

V článku [53] je popsáno laboratorní cvičení, které využívá jednoduchý spektroskop, který lze díky využití 3D tisku a webové kamery vyrobit ve větším množství velmi levně. Lze tak vybavit každého studenta, který pak může prozkoumávat různé materiály ve svém okolí ve smyslu badatelsky orientované výuky (Inquiry-based learning). Studenti sice objevují poznatky, které jsou již známé (např. které materiály kolem nás vykazují luminiscenci), avšak pro studenty má velký význam to, že je tyto poznatky získali právě oni.

Na obr. 3.24 je realizovaný vláknový spektroskop a univerzální zdroj světla, který lze napájet z USB portu počítače a který obsahuje různě barevné LED, žárovku jako inkadescentní zdroj světla, laser pro kalibraci vlnových délek a zařízení pro měření absorpcie a luminiscence. Díky 3D tisku je možné navrhnout jednoduchý způsob vložení optického vlákna. K měření luminiscence je využita ultrafialová LED. Uspořádání je podobné jako u měření absorpcie, ale v tomto případě je do držáku nad UV LED umístěna luminiscenční fólie. Tuto fólii lze získat například z luminiscenčních visaček nebo hraček. Dopadající UV záření vyvolává fotoluminiscenci, která má za následek emisi fotonů s nižší energií (ve srovnání s použitým UV zářením). Tyto fotony vytvářejí v měřeném spektru nový peak, jehož poloha je posunuta směrem k delším vlnovým délkám.

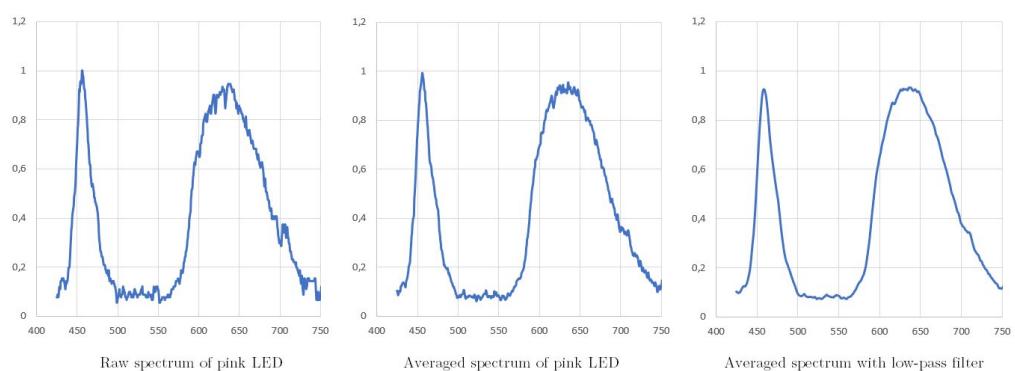
Na obrázku 3.25 je spektrum růžové svítivé diody a celkem tři spektra. Přestože pro záznam a analýzu dat jsou k dispozici bezplatné programy, podle názoru autora jsou tyto programy užitečné pouze pro úvodní měření.



Obrázek 3.24: Realizace vláknového spektroskopu a zdroje světla.



Obtained spectrum of the pink LED



Obrázek 3.25: Spektrum růžové LED a naměřené hodnoty.

Nedílnou součástí fyzikálních měření je pochopení vzniku chyb měření a možností jejich eliminace, a to zejména u studentů technických oborů. Pro mnoho studentů, kteří jsou zvyklí, že jejich měření zpracovává nějaký software, může být setkání s realitou šokující.

Údaje naměřené na obr. 3.25 byly získány z obrazu z webové kamery pomocí jednoduchého kódu v jazyce Processing, který je používán ke zpracování dat jako doplněk jazyka Wiring, ve kterém se programuje deska Arduino. Levý graf na obrázku 3.25 je získán z jednoho řádku spektra, prostřední obrázek je průměrem přes všechny řádky snímku a poslední obrázek je po aplikaci filtru typu dolní propust.

Rozlišení navrženého spektroskopu není srovnatelné s profesionálními přístroji, výsledná cena zařízení je však o dva řády nižší. I když se to může zdát zvláštní, právě nedokonalost zařízení může být při laboratorních měřeních výhodou, protože studenti jsou nuceni učit se způsoby zpracování dat, které budou potřebovat ve své budoucí praxi.

Kapitola 4

Aplikace v didaktice fyziky

Na vysokých školách univerzitního typu bývá obvyklé, že se ve výuce využívají výsledky výzkumu, který se na dané univerzitě provádí. Tento postup má celou řadu výhod: Studenti mají možnost seznámit se s aktuálním vývojem v oboru, což může zvýšit jejich motivaci a zájem o studium. Tímto způsobem mohou také získat praktické dovednosti a zkušenosti, které jsou relevantní pro jejich budoucí kariéru [54].

Obvykle tomu tak není v základních kurzech (jako je mechanika), protože výsledky výzkumu mohou být pro takový účel příliš specializované nebo pokročilé. Navíc nevšechny výsledky výzkumu jsou přímo aplikovatelné do výuky. Pak je na „pedagogickém mistrovství“ přednášejícího, aby našel vhodný přístup, spočívající v didaktické transformaci daného tématu pro použití ve výuce¹.

Didaktické využití poznatků uvedených v předchozích kapitolách je v oblasti terciárního vzdělávání velmi široké. Již v předmětu Základy fyziky – Mechanika v prvním ročníku studia na katedře fyziky lze základy balistokardiografie využít k podpoře výkladu Newtonových základů mechaniky. Data měřená balistokardiografickými senzory jsou získána díky reakci podložky na akci – pohyb ležícího těla, zrychlení pak lze získat pomocí druhého Newtonova zákona. Největší úspěch má však experiment, kdy (zdánlivě klidně) ležící experimentátor způsobuje měřitelné mikropohyby, viditelné na dataprojektoru. Obojí již bylo úspěšně do úvodního kurzu mechaniky implementováno v rámci seminářů.

V dalších kurzech lze využít balistokardiografií k účinné podpoře výkladu jinak abstraktních matematických metod. Hledání cest, jak přiblížit studentům mnohdy teoretický výklad, je základní premisou úspěšné vysokoškolské výuky. Výzkumy ukazují, že právě

¹Richard P. Feynman v této souvislosti napsat, že pokud nedokážeme výklad jevu přizpůsobit studentům prvního ročníku, znamená to, že dané problematice ještě pořádně nerozumíme [55]. Nemyslel tím však individuální schopnosti přednášejícího, ale stav vědeckého poznání o daném tématu

praktický („hands-on“) přístup k tématu je to, co pomáhá v efektivním předávání poznatků [56]. Podle meta-analýzy provedené v roce 2017 má takový stimulující výklad velký vliv na efektivitu vzdělávacího procesu [57]. V rámci současného směru přesunu od pojetí výuky jako předávání informací k výuce jako facilitaci učení (angl. shift from teaching to learning, [58]), kde není vyučující jen zdrojem poznatků, ale průvodcem studenta na jeho cestě za poznáním, roste důležitost praktických přístupů k tématu, kdy lze ve výuce využívat mikrostruktury², ucelené drobnější lekce, propojené s reálným světem. Ty podporují tzv. smysluplné učení (v rámci Ausbelovy teorie učení), kdy dochází k budování poznatkových konstruktů, které si pak studenti odnášejí [59]. Zároveň při takovém učení dochází k rozvoji celé řady metakognitivních dovedností, kreativního myšlení, dovedností k řešení problémů a dalších.

Před řádnou implementací výsledků předložené habilitační práce do výuky byla provedena rešerše výuky biofyziky a biomedicínské techniky na vybraných univerzitách v České republice. Konkrétně byly zkoumány sylaby předmětů studijních programů:

- Biofyzika na Masarykově univerzitě: Základy lékařské biofyziky, Biofyzikální praktikum, Biofyzikální praktikum UFKL, Experimentální metody biofyziky, Vybraná téma aplikované biofyziky.
- Biofyzika na Univerzitě Palackého v Olomouci: Základy experimentálních metod biofyziky.
- Lékařská elektronika a bioinformatika, Biomedicínská technika na ČVUT: Biomedicínské senzory, Úvod do signálů a systémů, Biologické signály, Modelování a simulace, Senzory v medicíně, Biomechanika a biomateriály, Lékařské přístroje a zařízení I. a II., Pacientské a přístrojové simulátory a testery, Praktika z návrhu a konstrukce lékařských přístrojů, Analýza zpracování biomedicínských dat, Zpracování obrazových dat, Laboratorní technika.

Celkově je možné konstatovat, že ze všech těchto předmětů bylo v jejich sylabech nalezeno pouze následujících pět témat, která se mírně dotýkají předložené habilitační práce: Senzory s kapacitou; Akcelerometry, gyroskopy; Kapacita - Kapacitní senzory, tlakové kapacitní senzory; Piezoodporový jev - tenzometry, tlakové senzory piezoodporové; Piezoelektrický jev - senzory s principem piezoelektrickým, tlakové senzory piezoelektrické. Obecně pak při rešerši bylo zjištěno, že z hlediska sledování vitálních funkcí se

²V tomto případě ještě neexistuje ustálená česká terminologie; v angličtině se používá termín micro structures.

dané předměty zaměřují na „klasické“ disciplíny, tedy EKG, EEG (elektroencefalogram), spirometrie a další. Pokud bylo v sylabech označení nějaké metody jako „moderní“, šlo zpravidla o měření CT (výpočetní tomografie) či MRI (magnetická rezonance), což jsou však metody běžně používané mnoho desítek let.

Postupná didaktizace výzkumných témat probíhala řadu let. Docházelo k postupné implementaci do výuky stávajících předmětů ve studijních programech Fyzikálně-technická měření a výpočetní technika, Fyzikální měření a modelování a Učitelství fyziky pro střední školy na katedře fyziky UHK, kde formou evaluací těchto předmětů byla sbírána zpětná vazba ohledně kvality výuky a rovněž probíhaly osobní diskuse se studenty, jaká téma jim připadají zajímavá a chtěli by je zařadit do výuky. Postupnými úpravami učebních plánů předmětů se dospělo k závěru, že výzkumné výsledky jsou již natolik rozsáhlé, že je není možné shrnout do pouhých drobných úprav sylabů a jedním z výstupů této práce tak je i zcela nový studijní program Aplikovaná fyzika se specializacemi, který je mimo jiné postaven právě na základech předložené habilitační práce a který je garantován autorem práce.

S těmito myšlenkami byly rozvíjeny zejména předměty Modelování a simulace, Fyzikální modely, Biomedicínské praktikum 1 a 2 a předmět Biofyzika v rámci studijního programu Aplikovaná fyzika se specializací Biomedicínská technika na Přírodovědecké fakultě Univerzity Hradec Králové. Dále bylo využito využito odborných článků autora v didaktických časopisech určených pro učitele fyziky [51], [52] a [53] pro důležité inovace předmětů Základy fyziky - Mechanika, Základy fyziky - Kmity a vlny, Praktikum z optických metod a Monitorovací systémy ochrany prostředí a zdraví ve studijním programu Aplikovaná fyzika se specializací Environmentální měření. Z didaktického hlediska tak opět šlo o přímou aplikaci didaktických publikací do praxe.

V rámci nově zavedených a inovovaných předmětů se studující seznámí se všemi oblastmi zahrnutými v předložené habilitační práci a další publikační činnosti autora, čímž je završen proces didaktizace provedené vědeckovýzkumné činnosti. Studenti se setkají s řešením skutečně recentních a zajímavých problémů a řadu měření budou vykonávat sami na sobě či s využitím přístrojů vyvinutých v rámci didaktizace výzkumných témat [52], [53]. I zde jsou pak využívány mikrostruktury, což je v laboratorních pracích obvyklé. Jedná se tak v zásadě o projektové učení (angl. Project-based learning, PBL), konstruktivistický pedagogický přístup, jehož cílem je navodit hlubokou, detailní úroveň učení se s využitím metod na bázi průzkumu či výzkumu podpořenými tématy, která jsou skutečná, zajímavá a důležitá pro studentův každodenní život [60]. Konkrétní části sylabů

těchto předmětů, které vznikly za pomocí výsledků předložené habilitační práce jsou uvedeny níže, nicméně ukázky témat zahrnutých v habilitační práci rezonují i v řadě dalších vyučovaných předmětů jako názorné ukázky v celém úvodním kurzu fyziky zaměřeného na mechaniku a v kurzu matematiky:

- Modelování a simulace, využití zejména výsledků v [51], [21], [23], [24] a [25].
 - Definice matematického modelu, proces modelování a simulace, fáze tvorby matematického modelu.
 - Vstupní data modelu, zjednodušující předpoklady, definice problému.
 - Software pro matematické modelování, představení nástrojů pro tvorbu a řešení modelů (Matlab, aj.).
 - Návrh matematického modelu.
 - Vytvoření modelu s využitím prostředí Matlab a jeho řešení na počítači.
 - Vizualizace získaných výsledků.
 - Příklady vybraných biologických problémů.
- Fyzikální modely, využití zejména výsledků [39] a [17].
 - Fyzikální modely v biologii 2 – BCG.
 - Fyzikální modely v biologii 3 – ICP.
 - Fyzikální modely v biologii 4 – pulsní vlna.
- Biomedicínské praktikum 1 a 2, využití zejména výsledků [42], [46], [47] a [17]:
 - Měření pulsní vlny.
 - Měření mikropohybů lidského těla – balistokardiografie.
 - Měření respirační frekvence.
 - Měření pohybové aktivity.
 - Měření těžiště lidského těla.
 - Měření křivky respirační tíže.
 - Měření biomechaniky.
 - Měření vybraných parametrů s využitím gyroskopů.
 - Měření vybraných parametrů s využitím akcelerometrů.
- Biofyzika, využití zejména výsledků [17], [39] a [36]:

- Transport krve v organismech; transport tekutin v organismech.
- Mechanické vlastnosti některých orgánů (svaly, plíce).
- Moderní trendy v biofyzice.
- Základy fyziky - Mechanika, využití zejména výsledků [51], [46], [17]
 - Dynamika hmotného bodu. Newtonovy pohybové zákony.
 - Inerciální a neinerciální vztažné soustavy. Zákon zachování hybnosti.
 - Deformace těles. Teorie pružnosti.
- Základy fyziky - Kmity a vlny, využití zejména výsledků [53]
 - Základní zákony optiky, interference světelných polí.
 - Ohybové jevy.
 - Optické přístroje.
- Praktikum z optických metod, využití zejména výsledků [53]
 - Disperzní křivka hranolového spektroskopu, stanovení vlnové délky spektrálních čar mřížkovým spektroskopem.
- Monitorovací systémy ochrany prostředí a zdraví, využití zejména výsledků [52]
 - Integrované environmentální monitorovací a informační systémy ČR a EU.
 - Parametry znečišťování ovzduší, emisní a imisní limity.

Stejně tak lze téma balistokardiografie a metod zpracování signálu či vývoj senzorů akcentovat v závěrečných pracích studentů, at' již bakalářských či diplomových. Na katedře fyziky byly obhájené následující práce využívající principy popsané v předkládané habilitační práci:

- Lomská, L. Sledování polohy pacienta na lůžku a jeho aplikace, Přírodovědecká fakulta Univerzity Hradec Králové, 2016, 53 s., Bakalářská práce, Vedoucí bakalářské práce Filip Studnička.
- Lomská, L. Sledování pohybové aktivity pomocí bezdrátových senzorů, Přírodovědecká fakulta Univerzity Hradec Králové, 2018, 63 s., Diplomová práce, Vedoucí diplomové práce Filip Studnička.

- Bušovský, D. Aplikovaná diferenciální geometrie křivek, Přírodovědecká fakulta Univerzity Hradec Králové, 2019, 120 s., Diplomová práce, Vedoucí diplomové práce Filip Studnička.
- Loskot, J. Praktické aplikace balistokardiografického signálu v medicíně, Přírodovědecká fakulta Univerzity Hradec Králové, 2015, 55 s., Diplomová práce, Vedoucí diplomové práce Filip Studnička.
- Veselá, A. Měření mezí slyšitelnosti lidského ucha, Přírodovědecká fakulta Univerzity Hradec Králové, 2015, 52 s., Bakalářská práce, Vedoucí bakalářské práce Michaela Křížová, Oponent bakalářské práce Filip Studnička.
- Škraňková, I. Laboratorní práce z biofyziky - elektrokardiografie, Přírodovědecká fakulta Univerzity Hradec Králové, 2017, 68 s., Bakalářská práce, Vedoucí bakalářské práce Jan Šlégr, Oponent bakalářské práce Filip Studnička.
- Škraňková, I. Lékařská vyšetření elektroencefalografie a elektromyografie jako součást výuky biologie, Přírodovědecká fakulta Univerzity Hradec Králové, 2019, 132 s., Diplomová práce, Vedoucí diplomové práce Jan Šlégr, Oponent diplomové práce Filip Studnička.

Studentům se podařilo prokázat, že vhodně aplikovali daná téma do vlastního výzkumu. Témata závěrečných prací pak budou ve studijním programu Aplikovaná fyzika se specializacemi dále rozvíjena a rozšiřována i na další metody popsané v habilitační práci.

V neposlední řadě je nutné zmínit i oblast neformálního vzdělávání. Třetí role univerzity je rolí nezastupitelnou a aktivní zapojení do širšího společenského kontextu lze realizovat nejen např. partnerstvím s průmyslem a veřejným sektorem, ale také v rámci popularizačních akcí, jako jsou Noc vědců nebo Týden Akademie věd ČR. V rámci těchto akcí proběhla na Přírodovědecké fakulty UHK celá řada přednášek, kde byly prezentovány výsledky výzkumu balistokardiografie pro veřejnost členy výzkumného týmu zabývajícího se BCG pod vedením autora předložené habilitační práce, v poslední době např.:

- doc. RNDr. Jan Šlégr, Ph.D.: Biofyzika: Věda skrytá všem na očích.
- RNDr. Damián Bušovský: Užití balistokardiografie v paliativní péči.

Závěr

Představené výsledky vědeckovýzkumné činnosti autora předkládané habilitační práce si kladly dva cíle. Prvním z nich bylo seznámení s cestou přerodu myšlenky do výzkumu, experimentálního bádání a verifikaci, ochranu duševního vlastnictví nových metod či jejich publikaci v odborných časopisech až po jejich komercializaci a na závěr nasazení nových témat do přímé výuky. Tato cesta je dlouhá, ale nezbytná pro aktualizaci často zastaralých sylabů předmětů na univerzitách, jak bylo ukázáno v kapitole 4.

Druhým cílem bylo ukázat postup didaktizace nových témat ve výuce na katedře fyziky UHK. Proces didaktizace nabytých poznatků začíná postupným zařazováním nových témat do řady předmětů ve výuce fyziky na univerzitách. Nejprve zařazením nových demonstračních experimentů podporujících výklad abstraktních matematických metod a fyzikálních principů, bez nutnosti úpravy sylabů těchto předmětů. Tyto experimenty jsou často založeny na praktickém přístupu k tématu, což pomáhá v efektivním předávání poznatků. Jedná se tak v této fázi o doplněk výuky tradičních fyzikálních témat. S touto fází je pak spojena větší popularizace těchto experimentů v rámci třetí role univerzity, čímž se zvyšuje atraktivita fyziky právě řešením zajímavých interdisciplinárních problémů.

Další fází didaktizace je pak zavedení vybraných témat do pravidelné výuky s větším důrazem na principy použitých metod a s větším zapojením studentů ve formě vedení závěrečných prací zaměřených na nová recentní téma. V této fázi se výzkumný tým rozrůstá o nové odborníky, díky čemuž bylo možné téma dále rozvíjet i formou výzkumných grantů.

V poslední fázi didaktizace, která probíhá paralelně s dokončováním různých výzkumných témat, dochází k ochraně duševního vlastnictví nových metod a jejich případné komercializaci a publikaci v odborných časopisech. Tyto odborné publikace společně s patenty či užitnými vzory poskytují základ pro plnou implementaci nových metod do sylabů a zavedení zcela nových předmětů, které jsou svým obsahem v rámci terciárního vzdělávání v České republice unikátní. S výhodou bylo možné využít faktu, že na rozdíl od didaktiky fyziky věnující se primárnímu a sekundárnímu vzdělávání nebylo nutné být

svázán Rámcovým vzdělávacím programem, ani velice omezenými časovými dotacemi výuky. V předkládané habilitační práci je tak ukázáno, jak rozdílný může být postup implementace nových témat do výuky v rámci terciárního vzdělávání. Díky výsledkům výzkumné činnosti autora předložené habilitační práce a jeho týmu bylo možné zařadit do výuky na katedře fyziky zcela nová, unikátní téma jak v rámci stávajících studijních programů, tak i v rámci nového studijního programu Aplikovaná fyzika se specializacemi.

V budoucnosti je v plánu další rozšiřování zkoumaných témat, aplikace na širší spektrum interdisciplinárních oborů, ale i prohlubování vědomostí o daných tématech a zejména jejich další popularizace za účelem motivace budoucích učitelů fyziky i odborníků z praxe. Mezi další aplikace výsledků habilitační práce pak patří postupné nasazení výzkumných témat i do nejvyšší fyzikální předmětové soutěže v České republice – zařazení do úloh fyzikální olympiády.

Literatura

- [1] Brockemyerová-Fenclová J., Čapek V., Kotásek J.: Oborové didaktiky jako samostatné vědecké disciplíny, Pedagogika, roč. 50, č. 1, s. 23-37, 2000.
- [2] Význam slova ballistocardiographia [cit. 2023 11 15]. Dostupné z: <http://www.slovník-cizich-slov.cz/ballistocardiographia.html>
- [3] Gordon, J. W. On Certain Molar Movements of the Human Body Produced by the Circulation of the Blood, J. Anat. Physiol. 11 (1877): 533.
- [4] A. T. Askari and A. W. Messerli, Cardiovascular Hemodynamics, Cham, Switzerland:Humana Press, 2019.
- [5] Berne RM, Levy MN. Physiology. 4th ed. St. Louis: Mosby; 1998.
- [6] Kapillärelektrometer, Meyers Konversationslexikon, Verlag des Bibliographischen Instituts, Leipzig und Wien, 1885–1892.
- [7] Starr I, Rawson AJ, Schroeder HA, Joseph NR. Studies on the estimation of cardiac output in man, and of abnormalities in cardiac function, from the heart's recoil and the blood's impacts; the ballistocardiogram. Am J Physiol 1939;127:1–28.
- [8] Pinheiro, E., Postolache, O., Girao, P. (2010). Theory and developments in an unobtrusive cardiovascular system representation: ballistocardiography. The open biomedical engineering journal, 4, 201.
- [9] Trefný, Z. , Hana, K. , Trojan, S. , et. al. New trends in ballistocardiography. Measurement Science Review: Measurement in Biomedicine 2003;3:45–48.
- [10] Barciakova L., Pirk J., Seba P., Kriz J.: Cor Vasa, 53:72–74, 2011.
- [11] Gregson, P. H. (1999). Sternal acceleration ballistocardiography and arterial pressure wave analysis to determine stroke volume. Clin Invest Med, 22(1), 4-14.

- [12] Giovangrandi, L., Inan, O. T., Wiard, R. M., Etemadi, M., Kovacs, G. T. (2011, August). Ballistocardiography—a method worth revisiting. In 2011 annual international conference of the IEEE engineering in medicine and biology society (pp. 4279-4282). IEEE.
- [13] Piezo keramický měnič [cit. 2023 11 15]. Dostupné z: <https://dratek.cz/arduino/5000-piezo-keramicky-menic.html>
- [14] Noninvasive Bed Sensing of Human Biosignals Via Piezoceramic Devices Sandwiched Between the Floor and Bed Shoko Nukaya, Toshihiro Shino, Yosuke Kurihara, Kajiro Watanabe, and Hiroshi Tanaka
- [15] Cimler, R., Štěpán, J., Studnička, F., Matyska, J. (2023). Biometric sensor. US FEPP, U.S. patent č. USD990700S.
- [16] Belt Clip Sensor Research Kit. In: Mbientlab Inc. Mbientlab. [online]. San Francisco (CA), 2018, [cit. 2018 05 25]. Dostupné z: <https://mbientlab.com/product/clip-sensor-research-kit/>
- [17] Cimler, R., Studnička, F., Šlégr, J., Štěpán, J., Matyska, J., Kühnová, J., Šec, D., Šeba, P. (2019). Zařízení pro sledování mikropohybů živých organismů. Úřad průmyslového vlastnictví, užitný vzor č. CZ33574U1.
- [18] Kim, S., Kim, W., Kang, G. H., Jang, Y. S., Choi, H. Y., Kim, J. G., Shin, D. G. (2022). Analysis of the accuracy of automatic electrocardiogram interpretation in ST-segment elevation myocardial infarction. Clinical and Experimental Emergency Medicine, 9(1), 18.
- [19] Friedrich D., Aubert X.L., Fuhr H., Brauers A. Heart rate estimation on a beat-to-beat basis via ballistocardiography - a hybrid approach, Conf Proc IEEE Eng Med Biol Soc., 2010:4048-51, 2010.
- [20] J. Kříž, P. Šeba, Force plate monitoring of human hemodynamics, Nonlinear Biomed. Phys. 2 (1) (2008) 1.
- [21] Bušovský, D. Aplikovaná diferenciální geometrie křivek, Přírodovědecká fakulta Univerzity Hradec Králové, 2019, 120 s., Diplomová práce, Vedoucí diplomové práce Filip Studnička.
- [22] Gallier, J. Geometric Methods and Applications: For Computer Science and Engineering (Texts in Applied Mathematics), ISBN-10 1441999604, 2011.

- [23] Cimr, D., Studnička, F. (2020). Automatic detection of breathing disorder from ballistocardiography signals. *Knowledge-Based Systems*, 188, 104973.
- [24] Cimr, D., Studnicka, F., Fujita, H., Tomaskova, H., Cimler, R., Kuhnova, J., Slegoř, J. (2020). Computer aided detection of breathing disorder from ballistocardiography signal using convolutional neural network. *Information Sciences*, 541, 207-217.
- [25] Cimr, D., Studnicka, F., Fujita, H., Cimler, R., Slegoř, J. (2021). Application of mechanical trigger for unobtrusive detection of respiratory disorders from body recoil micro-movements. *Computer Methods and Programs in Biomedicine*, 207, 106149.
- [26] Simple noninvasive system for measuring the heart rate of avian embryos and hatchlings by means of a piezoelectric film 1993
- [27] Instantaneous Heart Rate Detection Using Short-Time Autocorrelation for Wearable Healthcare Systems 2012
- [28] Strauss, D. G., Selvester, R. H. (2009). The QRS complex—a biomarker that “images” the heart: QRS scores to quantify myocardial scar in the presence of normal and abnormal ventricular conduction. *Journal of electrocardiology*, 42(1), 85-96.
- [29] Brown, H. W., Plum, F. (1961). The neurologic basis of Cheyne-Stokes respiration. *The American Journal of Medicine*, 30(6), 849-860.
- [30] S. Hales, Statical Essays. vol. II, Haemastaticks, (Innings and Manby, London, 1733).
- [31] Ludwig C. Beiträge zur Kenntniss des Einflusses der Respirationsbewegungen auf den Blutlauf im Aortensystem. *Arch Anat Physiol Leipzig* (1847), 13:242–302.
- [32] Ernst, G. (2017). Hidden signals—the history and methods of heart rate variability. *Frontiers in public health*, 5, 265.
- [33] Akselrod, S., Gordon, D., Ubel, F. A., Shannon, D. C., Berger, A. C., Cohen, R. J. (1981). Power spectrum analysis of heart rate fluctuation: a quantitative probe of beat-to-beat cardiovascular control. *science*, 213(4504), 220-222.
- [34] Yılmaz, M., Kayançık, H., Çekici, Y. (2018). Heart rate variability: Highlights from hidden signals. *J. Integr. Cardiol*, 4, 1-8.
- [35] da Silva, V. P., Ramalho Oliveira, B. R., Tavares Mello, R. G., Moraes, H., Deslandes, A. C., Laks, J. (2018). Heart rate variability indexes in dementia: a systematic review with a quantitative analysis. *Current Alzheimer Research*, 15(1), 80-88.

- [36] Cimr, D., Busovsky, D., Fujita, H., Studnicka, F., Cimler, R., Hayashi, T. (2023). Classification of health deterioration by geometric invariants. Computer Methods and Programs in Biomedicine, 239, 107623.
- [37] Davies, J. I., Struthers, A. D. (2003). Pulse wave analysis and pulse wave velocity: a critical review of their strengths and weaknesses. Journal of hypertension, 21(3), 463-472.
- [38] Studnička, F., Šlégr, J., Šeba, P. (2023). Způsob sledování peristaltiky orgánů gastrointestinálního traktu a zařízení pro sledování peristaltiky. Úřad průmyslového vlastnictví, patent č. CZ309589B6.
- [39] Studnička, F., Šlégr, J., Šeba, P. (2023). Method of monitoring peristalsis of organs of the gastrointestinal tract and a device for monitoring peristalsis. World Intellectual Property Organization, patent č. WO2023006134A1.
- [40] Studnička, F., Šlégr, J., Šeba, P., Cimler, R., Kühnová, J., Matyska, J., Bušovský, D., Štěpán, J., Kacerovský, M. (2023). Způsob sledování pohybu plodu a zařízení pro sledování pohybu plodu. Úřad průmyslového vlastnictví, patent č. CZ309588B6.
- [41] Studnička, F., Šlégr, J., Šeba, P., Cimler, R., Kühnová, J., Matyska, J., Bušovský, D., Štěpán, J., Kacerovský, M. (2023). Method of monitoring movement of fetus and a device for monitoring movement of fetus. World Intellectual Property Organization, patent č. WO2023006133A1.
- [42] Studnička, F., Cimler, R., Štěpán, J., Šlégr, J., Bušovský, D. (2023). Systém pro měření rychlosti pulsní vlny aorty a sledování změny ABI indexu u ležícího pacienta. Úřad průmyslového vlastnictví, užitný vzor č. CZ36880U1.
- [43] Pioli, M. R., Ritter, A. M., de Faria, A. P., Modolo, R. (2018). White coat syndrome and its variations: differences and clinical impact. Integrated blood pressure control, 73-79.
- [44] Vincent, I. C., Michell, A. R., Leahy, R. A. (1993). Non-invasive measurement of arterial blood pressure in dogs: a potential indicator for the identification of stress. Research in veterinary science, 54(2), 195-201.
- [45] Belew, A. M., Barlett, T., Brown, S. A. (1999). Evaluation of the white-coat effect in cats. Journal of veterinary internal medicine, 13(2), 134-142.

- [46] Studnička, F., Cimler, R., Kühnová, J., Matyska, J., Štěpán, J., Šlégr, J. (2023). Systém pro monitorování pohybové aktivity a vitálních funkcí zvířete. Úřad průmyslového vlastnictví, užitný vzor č. CZ36821U1.
- [47] Studnička, F., Cimler, R., Štěpán, J., Kühnová, J., Šlégr, J., Bušovský, D., Faltysová, A. (2023). Systém pro monitorování parkinsonovského tremoru. Úřad průmyslového vlastnictví, užitný vzor č. CZ36755U1.
- [48] Vnuk, D., Pirkić, B., Matičić, D., Radišić, B., Stejskal, M., Babić, T., ..., Lemo, N. (2004). Feline high-rise syndrome: 119 cases (1998–2001). *Journal of feline medicine and surgery*, 6(5), 305-312.
- [49] Diamond, J. (1989). How cats survive falls from New York skyscrapers. *Natural history* (USA).
- [50] Šlégr, J., Studnička, F. Problém ohnuté kolejnice a kouzlo numerické matematiky Pokroky matematiky, fyziky a astronomie, Vol. 62 (2017), No. 4, 275–282.
- [51] Studnička, F., Šlégr, J., Štegner, D. (2016). Free fall of a cat—freshman physics exercise. *European Journal of Physics*, 37(4), 045002.
- [52] Studnička, F., Šlégrová, L., Voglová, K., Šlégr, J. (2022). Heat index, wet-bulb temperature and psychrometrics: what to expect in the 21st century. *Physics Education*, 58(2), 025003.
- [53] Bušovský, D., Křížová, M., Kříž, J., Loskot, J., Studnička, F., Šlégrová, L., Šlégr, J. (2022). Simple device for spectroscopy laboratory exercises. *Physics Education*, 57(1), 015014.
- [54] Brown, S., Smith, B. (Eds.). (2013). Research, teaching and learning in higher education. Routledge.
- [55] Goodstein, D. L. (1989) Richard P. Feynman, Teacher. *Physics Today* 42 (2): 70–75.
<https://doi.org/10.1063/1.881195>
- [56] Layne, L. (2012). Defining effective teaching. *Journal on Excellence in College Teaching*, 23(1).
- [57] Schneider, M., Preckel, F. (2017). Variables Associated with Achievement in Higher Education: A Systematic Review of Meta-Analyses. *Psychological Bulletin*, 143(6), 565–600.

- [58] Kember, D. (1997). A reconceptualisation of the research into university academics' conceptions of teaching. *Learning and Instruction*, 7(3), 255–275.
- [59] Okebukola, P. A., Jegede, O. J. (1988). Cognitive preference and learning mode as determinants of meaningful learning through concept mapping. *Science Education*, 72(4), 489-500.
- [60] Kokotsaki, D., Menzies, V., Wiggins, A. (2016). Project-based learning: A review of the literature. *Improving schools*, 19(3), 267-277.

Příloha A – Vybrané publikované články

V této příloze jsou uvedeny nejvýznamnější odborné publikace autora, komentované v habilitační práci.

Free fall of a cat—freshman physics exercise

Filip Studnička¹, Jan Šlégr^{1,2} and David Štegner²

¹ Department of Physics, Faculty of Science, University of Hradec Králové,
Rokitanského 62, Hradec Králové, Czech Republic

² Alois Jirásek Grammar School, T. G. Masaryka 590, Litomyšl, Czech Republic

E-mail: jan.slegr@uhk.cz

Received 17 December 2015, revised 24 February 2016

Accepted for publication 31 March 2016

Published 20 April 2016



Abstract

This paper describes theoretical calculation of the terminal velocity of falling cat, taking the air drag into account. The results show that a fall from the seventh floor is critical for the cat so we introduce a new quantity called the ‘coefficient of the cat’s fear’ during free fall. A subsequent experiment with a model of a cat carrying the accelerometer confirmed this conclusion. This calculation and experiment can act as a strong motivational factor during introductory physics courses.

Keywords: mechanics, air drag, ordinary differential equations

(Some figures may appear in colour only in the online journal)

1. Introduction

Even the greatest minds in history have struggled with the study of cat falls. James Clerk Maxwell studied the minimum height from which a cat can fall and is still able to use its cat-righting reflex—the reflex that enables a cat to land on all its feet [1]. This reflex seems to violate the conservation of angular momentum—the cat turns itself during the fall and always lands on its feet regardless of the initial conditions (except for the minimal height). That the cat can be divided into two independently rotating parts, which together do not violate the law of conservation of angular momentum, has already been described [2].

This paper aims to explain the urban legend that a cat can survive a fall either from very large heights (more than 100 meters) or small heights (a few meters), but it cannot survive a fall from the seventh floor of an average block of flats. Since cats are often raised in households that have balconies, the fall of a cat from a height between 2 to 30 meters is not a rare phenomenon. Some information based on observations of cat owners and veterinarians that cats are not able to survive a fall from the seventh floor or less can be found in [3] and [4].

Free fall with air drag is common topic in introductory physics courses, usually discussed using the example of a parachutist. In this paper we describe the same solution for a falling cat taking into account the behavior of the frightened animal.

2. Theoretical solution

Let us do some required estimates to simulate the free fall of the cat. Some of the assumptions are based purely on the experience of cat owners found on the internet [3]. The average weight of a cat can be estimated to be 4.5 kg [5]. The height of one floor of an average house of blocks in post-Soviet republics varies from 2.5 m to 3.0 m. Let us assume the height is 2.8 m [9]. The terminal velocity is about 27 m s⁻¹ [6]. There are known cases where a cat survived a fall from more than 150 m [3]. The minimum height of the fall from which a cat can right itself is about 30 cm [10]. The terminal velocity from this height is

$$v = \sqrt{2gh} \approx 2.4 \text{ m s}^{-1}$$

which is definitely non-lethal. When the cat-righting reflex phenomenon makes the cat turn right, the cat spreads its legs so it increases its drag coefficient, thus slowing its fall (it utilizes flying-squirrel position). It is said that the cat stops being prepared for the landing (e.g. it stiffens itself) when it changes its acceleration, because it is frightened by the changing acceleration [3].

When a cat jumps out of a balcony (or it falls by accident), two forces acts on the cat. One force is the gravitational force

$$F_g = mg$$

and the other is drag force F_d . The Reynolds number is equal to

$$R = \frac{vL}{\mu},$$

where v is the velocity of the cat relative to the fluid, L is the characteristic linear dimension and μ is the kinematic viscosity which is equal to

$$\mu = 1.460 \times 10^{-5} \text{ m}^2 \text{ s}^{-1}$$

for the atmosphere at sea level [11]. The characteristic linear dimension can be estimated as

$$L \approx 0.2 \text{ m}$$

for an average cat [2]. According to [6] the rounded terminal velocity is

$$v_t \approx 30 \text{ m s}^{-1}.$$

Thus the Reynolds number for a falling cat is about

$$R = \frac{30 \cdot 0.2}{1.460 \times 10^{-5}} \gg 1000,$$

so the drag will be turbulent and thus it is more convenient to use the drag force in the form

$$F_d = \frac{1}{2} C \rho S v^2,$$

where C is the drag coefficient, $\rho = 1.225 \text{ kg m}^{-3}$ is the density of the fluid [11], S is the orthographic projection of the object on a plane perpendicular to the direction of motion and v is the speed of the cat relative to the fluid. Using Newton's second law, the equation of motion for a falling cat is

$$\begin{aligned} m\ddot{x} &= F_g - F_d \\ m\ddot{x} &= mg - \frac{1}{2}C\rho S v^2 \\ \ddot{x} &= g - kv^2, \end{aligned}$$

where x is the vertical direction which is oriented in the same direction as the standard acceleration $g \approx 9.8 \text{ m s}^{-2}$, m is the mass of the cat estimated as [5]

$$m = 4.5 \text{ kg}$$

and

$$k = \frac{C\rho S}{2m} \approx CS \frac{1.225}{2 \cdot 4.5} \text{ m}^{-3} \approx 0.14CS \text{ m}^{-2} \quad (1)$$

is the specific drag coefficient.

When the cat reaches its terminal velocity v_t its acceleration will be equal to zero, thus

$$0 = g - kv_t^2$$

$$k = \frac{g}{v_t^2} \approx 0.01 \text{ m}^{-1}. \quad (2)$$

Comparing equations (1) and (2) we find that the product

$$CS \approx 0.07 \text{ m.}$$

We can approximate the cat as a flat plate for which the drag coefficient is approximately 1.3 [7], so

$$S \approx 0.05 \text{ m}^2$$

which means that the diameter of the cat is about 24 cm which is definitely a plausible approximation.

We must now solve numerically the equation (2) for $g \approx 9.8 \text{ m s}^{-2}$ and $k \approx 0.01 \text{ m}^{-1}$ so that we can find the dependance of acceleration of the cat over time, i.e. the equation

$$\ddot{x} + 0.01\dot{x}^2 - 9.8 = 0 \quad (3)$$

with initial conditions $x(0) = 0$ and $\dot{x}(0) = 0$. This solution was done using Matlab's integrated 'ode45' function. As an exercise this differential equation can be also solved by means of the Euler method with an ordinary spreadsheet editor (for details see [8]). The dependance of the distance the cat travels over time is shown in figure 1. The seventh floor is called critical. It is about 20 m high. From figure 1 it can be found that the cat's fall from seventh floor lasts about 2 seconds. We can now look at the derivative of the cat's acceleration over time, which is shown in figure 2. We can see that the function has a minimum at about $t = 2 \text{ s}$. This explains that at about 2 s of the cat's free fall it feels the largest absolute value of change in acceleration, which is perfectly in line with the initial statement that cats often die when falling from the seventh floor because they are frightened by the change in acceleration and are not prepared to land. We can now introduce new quantity called the 'coefficient of the cat's fear' during free fall, which is shown in figure 3. It is defined as the absolute value of the derivative of the cat's acceleration during free fall, which is scaled so that the maximum of this function is equal to 100 %.

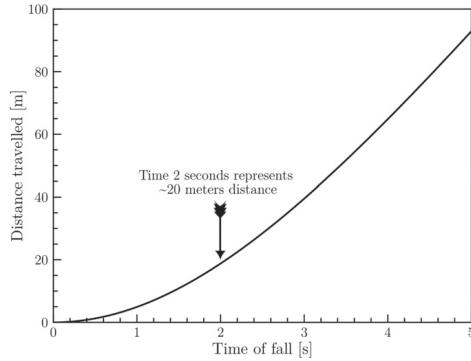


Figure 1. Cat's distance travelled over time during free fall.

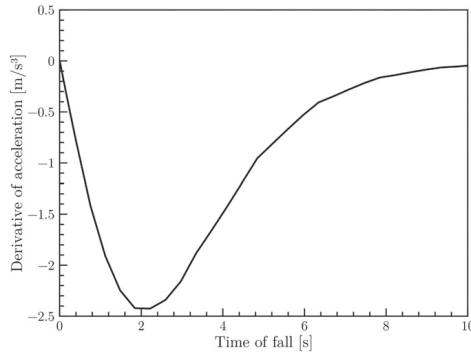


Figure 2. Derivative of cat's acceleration over time during free fall.

3. Experiment

The second part of this paper deals with the experimental proof of the correct dependence of the coefficient of the cat's fear during free fall. We want to compare the dependence of velocity and acceleration of the cat over time. These dependencies are shown in figure 4.

We used a plush toy, which of all available variants resembled a live cat the most (see figure 5).

Since it is known that during a fall a cat can ‘freeze’ and thus rewind its paws, weights were attached to the paws of the model and the interior was equipped with a wire mesh to hold its shape. The model was equipped with an X50-2 accelerometer.

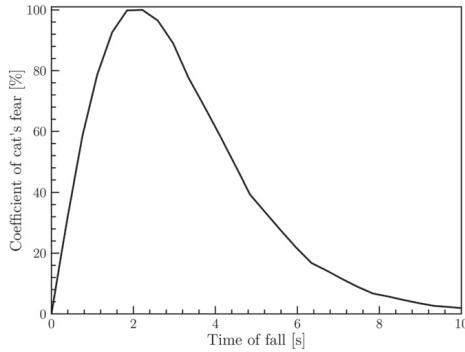


Figure 3. Cat's derivative of acceleration over time during free fall—the ‘coefficient of the cat's fear’.

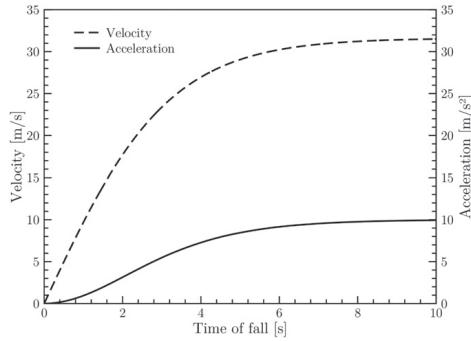


Figure 4. Cat's impact velocity and acceleration over time during free fall (in the reference frame of the cat).

The experiment was conducted so that the model was gradually released from the windows in a high-rise building at increasingly higher floors.

We have put together raw accelerometer signal data from all seven falls and then compared them with acceleration calculated from the theoretical model from equation (3) in the reference frame connected with the cat (so the acceleration at time $t = 0$ is equal to zero). The resultant dependence of acceleration on time is shown in figure 6. While it has not been possible to provide definite answers to the question of inflex point in acceleration (the point where the acceleration changes the most), the experimental data correspond well with the proposed model up to the seventh floor. The Pearson correlation coefficient between acceleration obtained from the theoretical model and the measured data is 92%. The results of the



Figure 5. Plush toy used for the experiment and an X50-2 accelerometer.

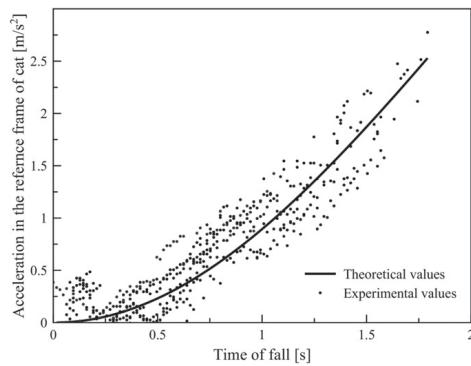


Figure 6. Acceleration in the reference frame of the cat versus time of fall.

experiment with a higher number of floors from which the cat falls will be shown in a subsequent report. A comparison between the velocities calculated from the theoretical model and acquired via integration of the experimental acceleration over time is shown in figure 7. The Pearson correlation coefficient between these velocities is 99%.

4. Conclusion

We have described a theoretical model based on the terminal velocity of a falling cat. Using this model we have introduced new quantity called the ‘coefficient of the cat’s fear’ during free fall. This quantity is in accordance with common experience of lethal cat falls [4]. We have performed experiments with a model of a cat falling from different floors, which is in accordance with the theory. The Pearson correlation coefficient between the experimental and

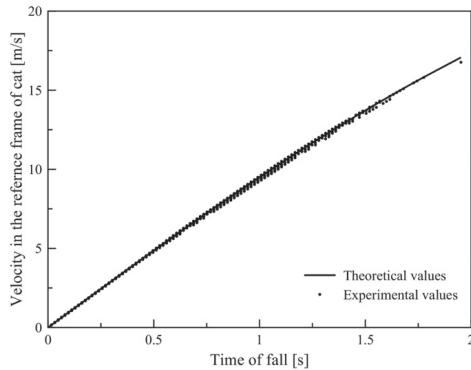


Figure 7. Velocity in the reference frame of the cat versus time of fall.

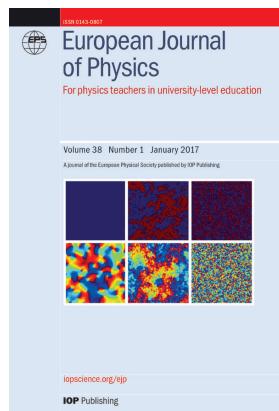
theoretical acceleration of the cat is equal to 92%. We have theoretically and experimentally proved that the cat must experience some physiological changes corresponding to the change in acceleration (especially to the inflex point of acceleration); however, the physiological process of this reaction is not exactly known. It is hoped that this study will stimulate further investigation in the field of cat physiology.

Acknowledgments

This work was supported by the SV PřF UHK nr. 2104/2014.

References

- [1] Lewis C and William G 1882 *The Life of James Clerk Maxwell* (London: MacMillan and Company) p 499
- [2] Batterman R 2003 Falling cats parallel parking and polarized light *Stud. Hist. Phil. Sci. Part B: Stud. Hist. Phil. Mod. Phys.* **34** 527–57
- [3] Vnuk D, Pirkic B, Maticic D, Radisic B, Stejskal M, Babic T, Kreszinger M and Lemo N 2004 Feline high-rise syndrome: 119 cases *J. Feline Med. Surg.* **6** 305–12
- [4] Diamond J 1989 How cats survive falls from New York skyscrapers *Nat. Hist.* **98** 20–6
- [5] Mattern M Y and McLennan D A 2000 Phylogeny and speciation of felids *Cladistics* **16** 232–53
- [6] Whitney W O and Mehlhaff C J 1987 High-rise syndrome in cats *J. Am. Vet. Med. Assoc.* **191** 1399–403
- [7] Cited on 24-02-2016 from the world wide web: www.grc.nasa.gov/www/k-12/airplane/shaped.html
- [8] Quale A 2012 On the use of a standard spreadsheet to model physical systems in school teaching *Phys. Educ.* **47** 355
- [9] Cited on 27-12-2014 from the world wide web: <http://stavba.tzb-info.cz/rekonstrukce-panelovych-domu/11074-sanaci-reseni-k-odstraneni-irhlin-ve-sparach-mazi-panele>
- [10] Thomas K and Schei M P 1969 A dynamical explanation of the falling cat phenomenon *Int. J. Solids Struct.* **5** 663–70
- [11] Cited on 27-12-2014 from the world wide web: www-mdp.eng.cam.ac.uk/web/library/enginfo/aero/thermal_dvd_only/aero/atmos/atmos.html



European Journal of Physics

This is to certify that the article

Free fall of a cat—freshman physics exercise
by **Filip Studnička, Jan Šlégr and David Štegner**

has been selected by the editors of *European Journal of Physics* for inclusion in the exclusive ‘Highlights of 2016’ collection. This paper has been chosen for its quality and contribution to the community.

Michael Vollmer

Michael Vollmer
Editor-in-Chief
European Journal of Physics
iopscience.org/ejp

IOP Publishing 

Heat index, wet-bulb temperature and psychrometrics: what to expect in the 21st century

Q1

Q2

Q3

**Filip Studnička[✉], Leontýna Šlégrová, Kateřina Voglová
and Jan Šlégr^{*}**

University of Hradec Králové, Rokitanského 62, Hradec Králové, Czech Republic

E-mail: jan.slegr@uhk.cz



CrossMark

Abstract

In recent years, the world has been facing extreme heat waves, breaking all previous records. Therefore, it is essential to emphasize teaching at least the basic knowledge of psychrometry and its impact on human health and well-being. In this paper, we explain several key concepts from the field of psychrometrics as well as instructions on how to assemble a wet-bulb thermometer easily. Methods for calculating heat index, dew point, and other quantities are also mentioned, whether using a wet-bulb thermometer or modern electronic sensors.

Keywords: thermodynamics, psychrometrics, heat transfer, wet-bulb temperature

Q4

Supplementary material for this article is available [online](#)

1. Introduction

Climate change is driving weather to extremes around the world. Two years ago, meteorologists in the United Kingdom tried to make a prediction of what will the weather forecast look like in 2050. Simon Lee, an atmospheric scientist at Columbia University in New York, noted a striking similarity between the outlook for 2050 and the forecast for July 2022 in the UK [1]. The UK has experienced temperatures 10°–15° warmer than normal for this time of year, and the number of days

when the maximum temperature exceeds 40 °C is increasing.

In April 2022, an intense heat wave in India brought the highest temperatures in the 120 years of records. India Meteorological Department [2] issues one warning after another, and on April 27, the highest temperature, 45.9 °C, was recorded in Prayagraj [3]. Citizens were warned against the high likelihood of developing heat illness and heat stroke at all ages.

The temperature of 45.9 °C is not pleasant, but the recorded temperatures are even higher in some places. The death Valley in California held the current absolute record of the warmest place on Earth for 109 years. On 10 July 1913, an air

* Author to whom any correspondence should be addressed.

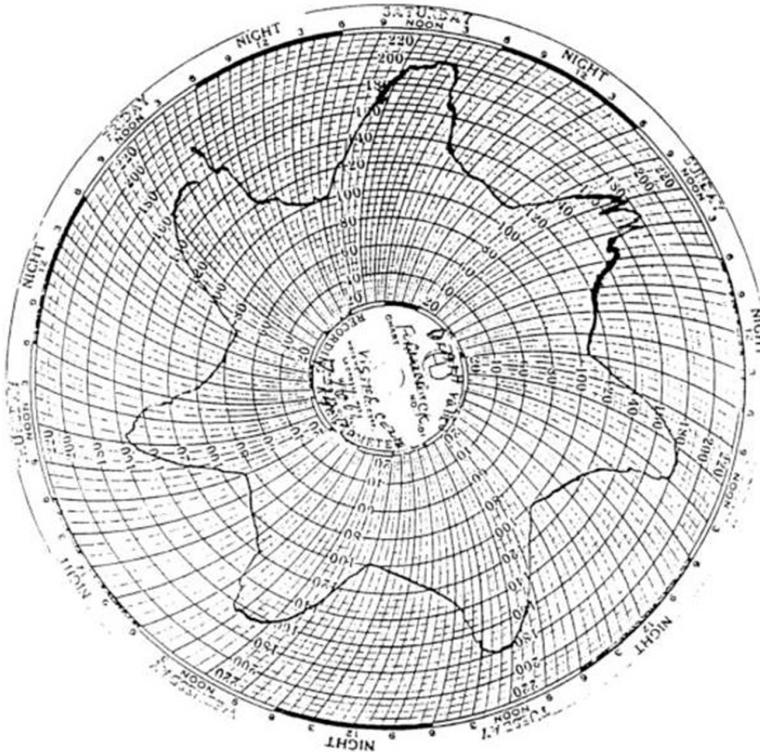


Figure 1. The Death Valley, California, ground surface temperature chart for 14–21 July 1972, revealing the temperature of 201 F (93.9 °C) on 15 July. Time is in Pacific Daylight time.

Q6

temperature of 56.7 °C in the shade was recorded. Although there are still disputes about the quality of the measurements at the time, Death Valley's status was confirmed half a century later by another record of 93.9 °C—the temperature of Death Valley's hot gravel land in direct sunlight.

Death Valley is the warmest place on the Earth's surface (taking aside geothermal springs and active volcanoes), but at the same time extremely dry. That is why if you take a tank with drinking water, you most likely survive in the Death Valley, which is not guaranteed in India

now. Why is that? The explanation follows in the next section.

2. Eccrine glands—an excellent invention of evolution

During evolution, some mammals underwent a genetic mutation that gave them an evolutionary advantage over others. They have eccrine glands in the skin, which excrete sweat composed of water, urea, salt, and trace elements of various minerals at elevated temperatures [4]. This fluid

Heat index, wet-bulb temperature and psychrometrics

gradually evaporates at high temperatures, and since it is needed to supply energy to the water to make such a phase change, it removes heat from the surface of the skin, which thus cools itself.

To be able to cool down by sweating, it is necessary that the sweat can evaporate. This is easy in Death Valley because it is extremely dry, but the relative humidity not only in India climbs to 100% (full air saturation) during the warm season. At that moment, the person stops cooling effectively by sweating because sweat cannot evaporate. The risk of overheating is then significantly increased. The hot east of California and Nevada may paradoxically be a better place than a colder India. A wet-bulb thermometer (see below) uses the same evaporative cooling, providing a good measure for evaluating comfort level.

3. Air humidity and psychrometry

Although psychrometry describes the physical and thermodynamic properties of gas-vapour mixtures, the most common system of interest is the mixture of water vapour and air, because of its application in heating, ventilation, meteorology and of course, human thermal comfort. Invisible to the human eye, water vapour in the air is extremely important. Here are a few essential physical quantities:

Absolute humidity is a measure of the amount of water vapour in the air, regardless of the temperature. It is expressed in grams of water vapour per cubic meter air volume [5].

Relative humidity measures the content of water vapour but relative to the temperature of the air [5]. It measures the amount of water vapour in the air compared to the total amount of vapour that can exist in the air at its current temperature (warm air can possess more water vapour than cold air). It should be noted that relative humidity can exceed 100%, in which case the air is *super-saturated*. This is the case of cloud formation.

Dry-bulb temperature is the temperature of a thermometer, of which the sensing element (historically the bulb with mercury) is exposed to the free air but shielded from radiation and moisture [6]. Most thermometers, if there is no condensation of atmospheric moisture on it, measure dry-bulb temperature.

Wet-bulb temperature is technically speaking the temperature of an adiabatic saturation. It is measured by the wet thermometer, in which the sensing element is inside a water-soaked cloth over which air is passed [7].

The cooling effect of adiabatic evaporation of water removes thermal energy from the thermometer, which is indicated by the fact that wet-bulb temperature is always lower than the dry bulb temperature in the air, except in the situation when the relative humidity is 100%. In this case both temperatures are equal.

Dew Point is the temperature at which the water vapour in air at constant barometric pressure condenses into liquid water at the same rate it evaporates. The dew point is the temperature to which the ambient air must be cooled to reach 100% relative humidity assuming there is no further evaporation into the air. The dew point is higher when there is more moisture in the air [8]. Above this temperature, the moisture will stay in the air.

It may seem at first look that dew point and wet-bulb temperature should be the same, but this is not the case. Reaching the dew point can be thought of as the isobaric cooling of an isolated closed system to a state of 100% relative humidity when the equilibrium between evaporation and condensation occurs.

In contrast, the wet-bulb temperature assumes a system that is not isolated and closed (it can exchange energy and matter with the surroundings). The system receives thermal energy from the air, but part of it is converted to latent heat (for water vapour from the water-soaked cloth), so the cloth has a lower temperature than the surrounding air. The drier the air, the faster the evaporation and the greater the cooling on the cloth. This is a dynamic balance in the transformation of the thermal energy into the latent heat.

Wet-bulb thermometers were historically used to find the air humidity: In table 1, dry-bulb temperature and the difference between dry-bulb temperature T_d and wet-bulb temperature T_w can be used to find the relative air humidity.

Heat index refers to the effect of humidity on human perception of temperature [10]. Most people cannot carry out normal outdoor

Table 1. Apparent temperature (heat index) in degrees Celsius according to air temperature and relative humidity [9].

Dry-bulb temperature	Difference ($T_d - T_w$) (°C)									
	1	2	3	4	5	6	7	8	9	10
10 °C	88	77	66	55	44	34	24	15	6	
11 °C	89	78	67	56	46	36	27	18	9	
12 °C	89	78	68	58	48	39	29	21	12	
13 °C	89	79	69	59	50	41	32	22	15	7
14 °C	90	79	70	60	51	42	34	26	18	10
15 °C	90	80	71	61	53	44	36	27	20	13
16 °C	90	81	71	63	54	46	38	30	23	15
17 °C	90	81	72	64	55	47	40	32	25	18
18 °C	91	82	73	65	57	49	41	34	27	20
19 °C	91	82	74	65	58	50	43	36	29	22
20 °C	91	83	74	66	59	51	44	37	31	24
21 °C	91	83	75	67	60	53	46	39	32	26
22 °C	92	83	76	68	61	54	47	40	34	28
23 °C	92	84	76	69	62	55	48	42	36	30
24 °C	92	84	77	69	62	56	49	43	37	31
25 °C	92	84	77	70	63	57	50	44	39	33
26 °C	92	85	78	71	64	58	51	46	40	34
27 °C	92	85	78	71	65	58	52	47	41	36
28 °C	93	85	78	72	65	59	53	48	42	37
29 °C	93	86	79	72	66	60	54	49	43	38
30 °C	93	86	79	73	67	61	55	50	44	39

activities past a wet-bulb temperature of 32 °C, equivalent to a heat index of 55 °C. The theoretical limit to human survival for more than a few hours in the shade, even with unlimited water, is a wet-bulb temperature of 35 °C (95 °F), equivalent to a heat index of 70 °C. The heat index values for the given temperatures and air humidity values are in figure 2(adapted from [11]).

4. Construction of wet-bulb thermometer

To measure wet-bulb temperature, it is necessary (by definition) to keep the thermometer sensor wet. This can be achieved using any material that has the properties of a wick. Specialized wicks are explicitly designed for bulb thermometers, but a cotton shoelace will serve the same purpose very well.

A thermometric sensor is placed on one side of the shoelace, while the other end is submerged in the water reservoir. During the entire measurement period, it must be ensured that there will be enough water in the reservoir.

We used the digital temperature sensor DS18B20 in the waterproof case to measure wet-bulb temperature. These sensors measure temperature from -55 to $+125$ °C with a precision of 0.2 °C. Another way to determine the wet-bulb temperature is to calculate it from the dry-bulb temperature and air humidity. That's why we connected a DHT22 sensor, measuring the temperature in the range of -40 to $+80$ °C with an accuracy of 0.5 °C and the relative humidity in the range of 0%–100% with an accuracy of 2%. Both sensors were connected to the Arduino board. The whole setup is in figure 3. 3D-printed water reservoir with a small fan and wet-bulb temperature sensor holder was designed. Technical drawings of this reservoir, a 3D model, a circuit diagram, and the program's source code for the Arduino board are part of the supplementary materials.

This device was tested in several environments, not only in the classroom or outside but also in the shower, to achieve higher air humidity.

Heat index, wet-bulb temperature and psychrometrics

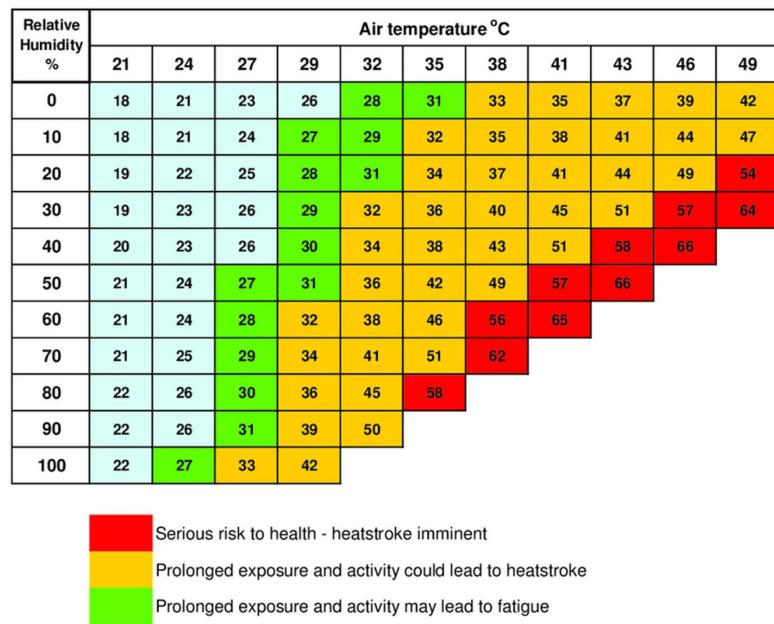


Figure 2. Apparent temperature (heat index) in degrees Celsius according to air temperature and relative humidity.



Figure 3. Construction of the wet-bulb thermometer using Arduino board (left). Schematics of the sensor connections (right).

5. Classroom activities

The first classroom activity could be the construction of the wet-bulb thermometer itself. Still, several calculations can be done in the classroom using dry-bulb and wet-bulb temperature readings.

Relative humidity (RH) can be calculated as a ratio of the actual (partial) pressure of water vapour p to the equilibrium (saturated) vapour pressure of water p_e at a given temperature (of dry thermometer):

$$RH = \frac{p}{p_d} \cdot 100\% = \frac{p_w - AP(T_d - T_w)}{p_d} \cdot 100\%$$

and such can be calculated from the wet-bulb temperature T_w and dry-bulb temperature T_d . Here A is the conversion factor which can be calculated by the empirical formula [12]:

$$A = 0.00066 \cdot (1 + 0.00115T_w)$$

and P is the mean atmospheric pressure (assumed to be 1013.25 mb).

We used the Buck formula [13] and followed the algorithm described in [14]. According to the Buck formula, we can find the saturation vapour pressure at the wet-bulb temperature

$$p_w = 6.11 \exp \frac{17.5T_w}{241 + T_w}$$

and the saturation vapour pressure at the dry-bulb temperature

$$p_d = 6.11 \exp \frac{17.5T_d}{241 + T_d}.$$

Using calculated values of p_d , p_w we can get the final equation

$$RH = \frac{p_w - 0.668(1 + 0.00155T_w)(T_d - T_w)}{p_d} \cdot 100\%,$$

that can be easily implemented in any programming language.

Interested readers can gain a better understanding in the excellent online material [15].

We used these equations to compare the relative air humidity measured by the DHT22 sensor and calculated from the dry-bulb and wet-bulb temperatures. A scatter plot of 3400 data points

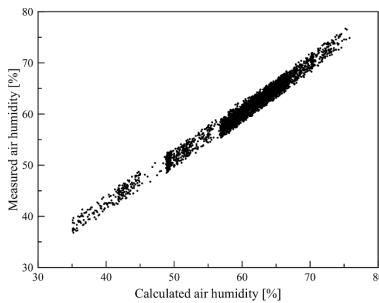


Figure 4. Scatter plot of measured and calculated air humidity.

is in figure 4. Pearson's correlation coefficient is better than 0.97.

There is also an opposite way: It is possible to calculate the wet-bulb temperature using dry-bulb temperature and relative air humidity from the DHT22 sensor. Some empirical equations can be used, for example, Apjon's formula or Liley's equation. We used this unwieldy empirical expression:

$$\begin{aligned} T_w &= T_d \cdot \text{atan} \left(0.1520 \cdot \sqrt{RH + 8.314} \right) \\ &\quad + \text{atan}(T_d + RH) - \text{atan}(RH - 1.676) \\ &\quad + 0.003918 \cdot RH^{\frac{3}{2}} \cdot \text{atan}(0.02310RH) \\ &\quad - 4.686 \end{aligned}$$

from [16], which is, in fact, an interpolation equation for the psychrometric chart in table 1. Here, T_w and T_d are in degrees Celsius and RH is relative humidity directly in percent (e.g. humidity such as 65.8% is input as the number 65.8).

This calculation was also implemented using Arduino. The software was sending measured wet-bulb temperatures as well as calculated ones, which made it possible to compare them. The measured and calculated values differed by an average of 4%, which was mainly due to the fact that the wet bulb had a greater thermal capacity and thus thermal inertia due to the stainless steel metal housing. The calculated wet temperature, on the other hand, had an almost instantaneous response due to the DHT22 sensor values.

Heat index, wet-bulb temperature and psychrometrics

The Heat Index can also be calculated from the dry-bulb temperature T_d and relative humidity RH:

$$\begin{aligned} \text{HI} = & -42.38 + (2.049T) + (10.14\text{RH}) \\ & - (0.2248T \cdot \text{RH}) - (6.837 \cdot 10^{-3} \cdot T^2) \\ & - (5.482 \cdot 10^{-2} \cdot \text{RH}^2) \\ & + (1.229 \cdot 10^{-3} \cdot T^2 \cdot \text{RH}) \\ & + (8.528 \cdot 10^{-4} \cdot T \cdot (\text{RH}^2)) \\ & - (1.990 \cdot 10^{-6} \cdot T^2 \cdot \text{RH}^2). \end{aligned}$$

There are several others formulas, sharing the same degree of ugliness for being polynomials trying to interpolate the table in figure 2. These formulas can be easily programmed on the single-chip microcomputer of the Arduino board, but for the hands-on classroom activities, it is easier to print out the table from figure 2 and hand it to the students to work with. These activities can help students understand air humidity's critical role of water evaporation in surface cooling. The weather website [Windy.com](#) [17] recently added the ability to display a layer showing the wet bulb temperature, which can be further used in teaching.

6. Conclusions

In this article, we reviewed several key concepts from the field of psychrometry as well as laboratory exercises that can be used effectively to support the teaching of the importance of humidity to perceived temperature and human well-being in the environment.

The historical approach to constructing a wet bulb thermometer using a wick is shown, as well as the modern approach to calculating this temperature using a digital sensor. By the middle of the century, in Central Europe, we can count on a two- to three-fold increase in the frequency of heat waves, their extension by roughly two to three days for the most extended wave in a given season, and an increase in intensity by approximately two degrees Celsius.

With a high probability, we will also encounter more significant heat waves when the absolute records of given places, or even entire states, will be rewritten. Since the danger of high

wet-bulb temperatures is likely to become more widespread in the future [18], in our opinion, it is appropriate to work with this topic in science teaching.

Data availability statement

The data that support the findings of this study are available upon reasonable request from the authors.

Q7

Acknowledgments

This work was supported by the SV PrF UHK nr. 2112/2022.

ORCID iDs

Filip Studnička  <https://orcid.org/0000-0001-6721-8678>

Jan Šlégr  <https://orcid.org/0000-0001-8202-4062>

Received 28 July 2022, in final form xx xx xxxx

Accepted for publication 16 November 2022

<https://doi.org/10.1088/1361-6552/aca381>

References

- [1] Fritz A A hypothetical weather forecast for 2050 is coming true next week (CNN) (available at: <https://edn.cnn.com/2022/07/15/weather-2050-uk-forecast-comes-true-in-2022/>)
- [2] India Meteorological Department *Ministry of Earth Sciences, Government of India* (available at: https://internal.imd.gov.in/pages/heatwave_mausam.php)
- [3] Levy R C Early season heat waves strike India (NASA Earth Observatory) (available at: <https://earthobservatory.nasa.gov/images/149766/early-season-heat-waves-strike-india>)
- [4] Wilke K, Martin A, Terstegen L and Biel S S 2007 A short history of sweat gland biology *Int. J. Cosmet. Sci.* **29** 169–79
- [5] Wyer S S 1906 Fundamental physical laws and definitions *A Treatise on Producer-Gas and Gas-Producers* (New York: McGraw-Hill) p 23
- [6] Wiederhold P 1995 Humidity measurements *Handbook of Drying Technology* 2nd edn, ed A S Mujumdar (New York: Marcel Dekker)
- [7] Engineering ToolBox 2004 Dry bulb, wet bulb and dew point temperatures

Q8

Q9

- (available at: www.engineeringtoolbox.com/dry-wet-bulb-dew-point-air-d_682.html)
- [8] Wallace J M, Hobbs P V 2006 *Atmospheric Science: An Introductory Survey* (New York: Academic) p 83
 - [9] Psych: an open source psychrometric plug-in for microsoft excel by Kevin Brown (available at: <https://wecc.ucdavis.edu/resources/software-resource-applications/>)
 - [10] Steadman R G 1979 The assessment of sultriness. Part I: A temperature-humidity index based on human physiology and clothing science *J. Appl. Meteorol.* **18** 861–73
 - [11] Diffey B L 2018 Time and place as modifiers of personal UV exposure *Int. J. Environ. Res. Public Health* **15** 1112
 - [12] Butler C J and García-Suárez A M 2012 Relative humidity at Armagh Observatory, 1838–2008 *Int. J. Climatol.* **32** 657–68
 - [13] Buck A L 1981 New equations for computing vapor pressure and enhancement factor *J. Appl. Meteorol. Climatol.* **20** 1527–32
 - [14] Huang Y, Zhang K, Yang S and Jin Y 2013 A method to measure humidity based on dry-bulb and wet-bulb temperatures *Res. J. Appl. Sci. Eng. Technol.* **6** 29
 - [15] The temp, humidity & dew point ONA (often needed answers) (available at: <https://users.dcc.uchile.cl/abassi/WWW/otros/RelativeHumidity.html>)
 - [16] Stull R 2011 Wet-bulb temperature from relative humidity and air temperature *J. Appl. Meteorol. Climatol.* **50** 2267–9
 - [17] Windy: wind map & weather forecast: wet-bulb temperature (available at: www.windy.com/cs/Wet-bulb-temp-wetbulbttemp?wetbulbttemp.28.651.66.504.4)
 - [18] Saeed F, Schleussner C-F and Ashfaq M 2021 Deadly heat stress to become commonplace across South Asia already at 1.5 C of global warming *Geophys. Res. Lett.* **48** e2020GL091191

Simple device for spectroscopy laboratory exercises

Damián Bušovský, Michaela Křížová, Jan Kříž, Jan Loskot✉, Filip Studnička✉, Leontýna Šlégrová and Jan Šlégr*✉

University of Hradec Králové, Rokitanského 62, Hradec Králové, Czech Republic

E-mail: jan.slegr@uhk.cz



Abstract

Undergraduate physics laboratory exercises are very important in shaping students' attitude to science, especially for future teachers. Recently, it is necessary to look for ways to easily create large quantities of experimental sets, not only for institutional use, but also for sets that can be produced in large quantities and distributed for use in distance learning. In this paper, we briefly describe the various ways to support the teaching of wave optics, and then describe one of the possible methods for performing undergraduate spectroscopic measurements using a 3D printed spectroscope and light source.

Keywords: optical spectroscopy, laboratory exercise, hands-on physics

1. Introduction

The study of physics is often conceived too theoretically, without practical demonstrations and exercises. Ray and wave optics provide many ways to liven up the teaching with experiments. There are many areas of wave optics in which demonstration aids can be used, and a number of articles are devoted to the construction of these aids.

In this paper, instead of lecture demonstrations (for details, see for example [1]), we will focus more on laboratory work, which not only serves to consolidate the theoretical knowledge, but is also a gateway to understanding how

physics works in the real world. We introduce a simple, cheap device designed for optical spectroscopy demonstrations and exercises in undergraduate optics courses.

There are of course integrated spectrometers such as Hamamatsu C12880MA or C12666MA MEMS micro-spectrometers [2], but these devices with prices over €450 are not very suitable for the mass production of low-cost devices.

There are devices that are intended for use in spectroscopy, but which are not in fact spectrometers, but only a set of photometers for different wavelengths, such as AMS AS7265X with five wavebands at 900, 760, 730, 680, and 535 nm [3]. While it is possible to use this device for such motivational laboratory exercises as monitoring the ripening and quality of fruits [4],

* Author to whom any correspondence should be addressed.

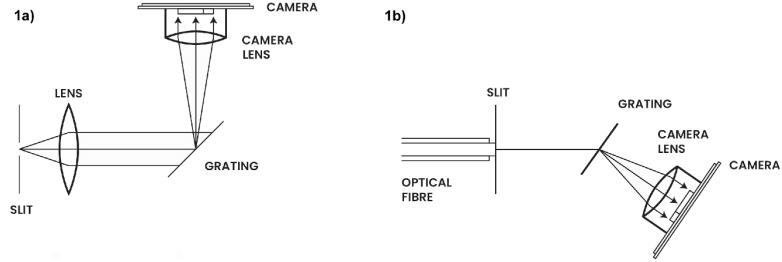


Figure 1. Spectroscopic with grid for reflection (left), spectroscopic with grid for transmission.

it is not possible to obtain a complete spectral data.

One way to obtain spectral data is to decompose the light from the source through an optical prism or grating and record the incident spectrum using a linear diode array [5]. Due to small physical dimension of the sensors and low number of channels (SL1401CL linear CMOS detector has 128 channels per 8 mm of length), the resolution of the resulting spectra is limited [6].

Very clever is the usage of webcams, external or salvaged from the old laptops. CMOS sensors are sensitive not only to visible light, but also to UV and IR radiation and at the same size as the above mentioned diode array sensors have several times higher resolution. Low cost webcams have sensors with dimensions about 4.8×3.6 mm and resolution of 640×480 pixels, high-end cameras can have sensors 9.6×7.2 mm with Full-HD resolution of 1080 pixels on the longer side, which is more than $8\times$ more than for the SL1401CL linear CMOS sensor described above.

There are several possible designs for webcam-based spectrometers: Using reflection diffraction grating (figure 1(a)), using transmission diffraction grating (figure 1(b)), using entrance slit (figure 1(a), [7]) or optical fibre (figure 1(b)). In some constructions, a professional camera lens is used, while for others the original plastic lens is kept.

2. Construction

Although basic geometrical properties of the spectroscope can be calculated using formulae from

the ray and wave optics, because the optical properties of cameras and their lenses can be very diverse and different designers can use different diffraction gratings, we strongly recommend to construct the prototype first on an optical breadboard plate. We used optical fibre with $400\ \mu\text{m}$ diameter glass core and SMA 905 connectors, holographic diffraction grating with 500 lines per mm (used in common diffraction glasses and available in sheets for reasonable price [8]) and an old webcam with its plastic lens, which can be focused by screwing the lens. The basis here is to get as large an image as possible (due to resolution) and the sharpest possible image to the webcam sensor.

In our design, we did not use a slit in the first phase, because the width of the beam is directly limited by the width of the optical fibre. By studying other solutions, we found that the slit is a critical point of many spectrometers—in some cases a professional optical product is used, in other cases it is necessary to set the slit correctly before measuring. For our simple low cost design, we decided not to use the slit, which affected the output data (see below).

After successful testing of the assembly, a solution usable for 3D printing was proposed (see figure 2). For the convenience of measurement, a universal optical source was designed, which can be powered from the computer's USB port and which contains various LEDs, a light bulb as an incandescent light source, a laser for wavelength calibration and a device for measuring absorption. All these components are cheap and easily accessible. Thanks to 3D printing, it is possible to design

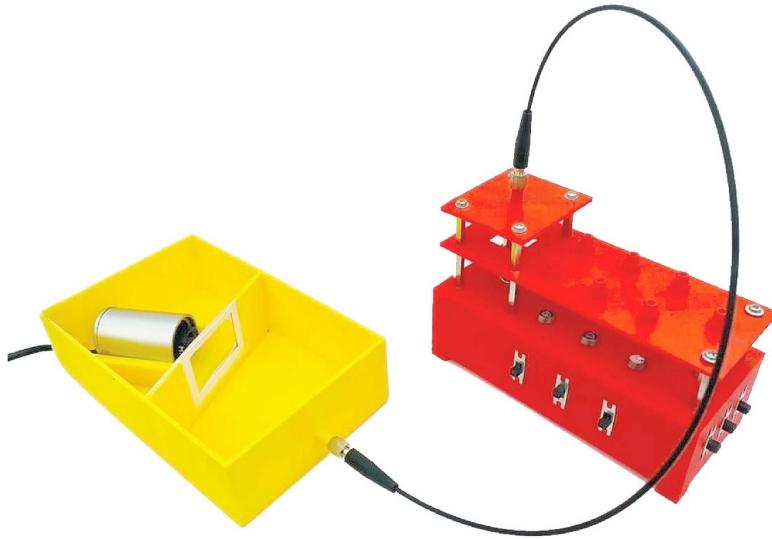


Figure 2. Spectroscope (with upper lid removed) and universal light source (see text).

a simple way to insert an optical fibre. Schematics with the proposed values of the components is in the figure 3. Technical drawing is in the [appendix](#), sources for 3D printing can be downloaded from the author's website [9].

In the second phase, we added slit (width 100 μm) for the better optical resolution. However, this requires a firm fastening of the two parts of the razor blade, which is more convenient to do with a metal fastening mechanism, so that 3D printing cannot be used to construct the entire spectrometer. Each designer of this spectrometer must therefore answer for themselves the question of whether the resolution of the device or the simplicity of the design is more important to them.

3. Measurements

Classical laboratory exercises from undergraduate wave optics can be made, including:

3.1. Comparing the spectra of different LEDs, colour mixing

In this exercise, spectra of different LEDs are measured and the positions and shapes of their peaks are compared with each other. Spectra belonging to red, green and blue colour have similar shapes, but significant differences in their peak positions can be seen easily. This demonstrates how the dominant wavelength depends on the colour of visible light.

It is also possible to switch on more diodes of the tricolour (RGB) diode at one time to demonstrate how colour mixing works. For example, when we switch on both the red and the blue light on this diode, we see the resulting violet colour, while the spectrum contains two peaks belonging to the original (red and blue) colours. A similar effect can be observed in the case of the pink diode—its spectrum reveals that also this colour is formed by mixing two separate colours, as shown in figure 5 (measured without the slit).

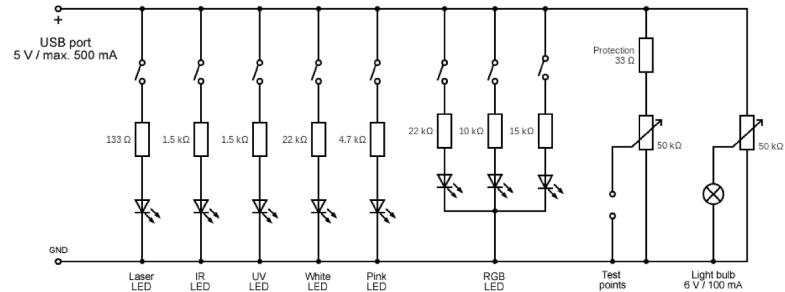


Figure 3. Wiring diagram of a simple light source for spectroscopic experiments (red box from figure 2, technical drawings in the appendix).

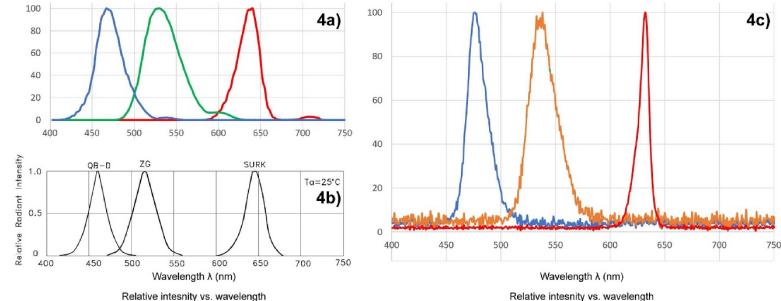


Figure 4. RGB led spectra (a) obtained with described spectroscope without a slit, (b) from the RGB LED data-sheet, (c) obtained with Vernier Emission Spectrometer.

Figure 4(a) shows spectra of the individual red, green and blue chips constituting the RGB LED. We can see that the spectrum shape is very similar to the spectrum that can be found in the LED data-sheet [10] so at first glance we can be satisfied with the results of our construction. However, if we measure the spectrum of these chips with a Vernier spectrometer, we find that the results show much narrower spectra (figure 4(c)). Measured full widths at half maximum are around 50% wider at figure 4(a) than in figure 4(c) (for example 47 nm vs. 30 nm for green LED) which is most likely due to the construction without the slit. If such a value is acceptable for the measurement,

it is not necessary to use a slit, which greatly simplifies the design.

The spectrum of solid state laser is fundamentally different. It contains only one spectral line, in this case corresponding to a red colour. The considerable sharpness of the peak is given by the fact that lasers produce monochromatic radiation (but even so, the width of this peak is not zero—here is an opportunity to explain the reasons for spectral lines broadening). The full width at half maximum is around 10 nm without the slit and 2 nm measured with the slit (see figure 5), which is comparable to the Vernier spectrometer.

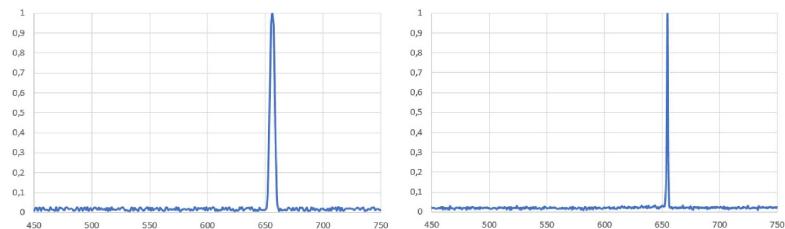


Figure 5. Spectrum of the red laser LED without the slit (left) and with the slit (right).

3.2. Spectrum of a light bulb, absorption spectra

It can be easily shown that the bulb spectrum is wider compared to those of the LEDs. The reason is, of course, the thermal principle of the bulb, i.e. the heating of its filament. Such continuous spectrum is suitable for absorption measurements. For this purpose, plastic foils of various colours are to be placed in a holder between the bulb and the optical fibre. In this arrangement, wavelengths of the colour complementary to the colour of the foil are absorbed, which can be seen in the resulting spectrum. It is also possible to use various types of sunglasses instead of foils and compare the results.

3.3. Measurement of luminescence

Luminescence experiments are especially popular in lecture demonstrations and can be found for example in [11, 12] or [13]. The UV LED can be utilised also to perform luminescence measurements. The arrangement is similar to that of absorption measurements, but in this case a luminescence foil is placed into a holder above the UV LED. Such foil can be obtained for example from luminescent hang tags or toys. The incident UV light induces photo-luminescence which results in the emission of photons with lower energy (compared to the used UV radiation). These photons create a new peak in the measured spectrum, whose the position is shifted towards longer wavelengths. This measurement

is useful when explaining the basic principle of luminescence.

4. Data processing

Although there are free programs for data acquisition and analysis, these are from our point of view useful only for an introductory measurements.

We firmly believe that an integral part of physical measurements is an understanding of ways to eliminate measurement inaccuracies, especially for students of technical disciplines who will deal with physical measurements in their future practice. From our experience we have found that for many students, who are used to the fact that their measurement is processed by some software, it is a shocking encounter with reality. Although measurements made without a slit are fairly smooth (because the low resolution of the spectrum smooths out the noise), measurements made using a slit are loaded with noise that needs to be worked with (see figure 6).

Simple image processing can be done in any programming language. We choose the Processing language [14] for several reasons: For example, it is the PC counterpart of the Wiring language used for programming Arduino boards, so it has a very simple structure and if the students have some experience with Arduino for example from the lab, the usage of the Processing language is very easy for them. What is also important is the fact that Processing is cross-platform: It is available for Windows, Linux-based systems, Mac OS and can be even run in the web browser. Here

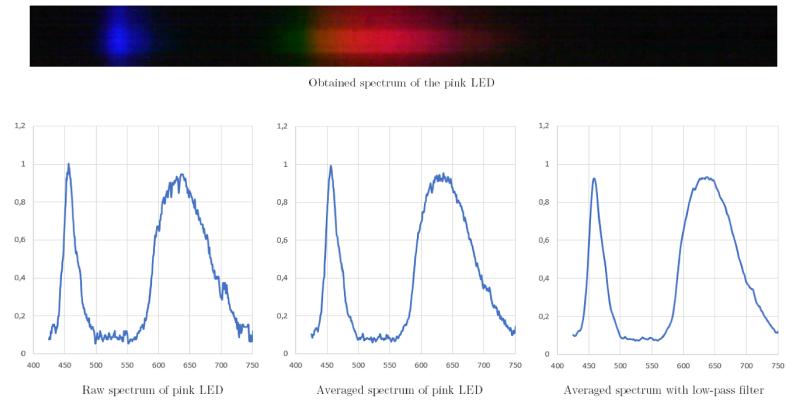


Figure 6. Spectrum of the pink LED (measured without a slit) and subsequent data processing: averaging over five measurements and filtering with low-pass filter.

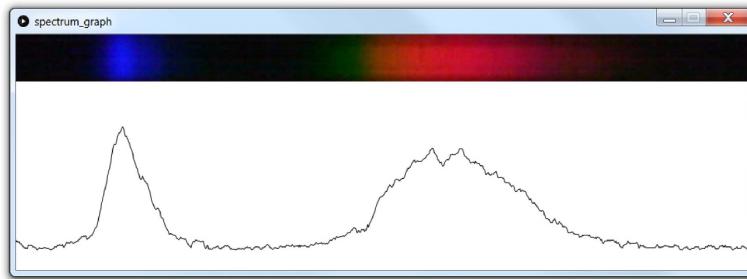


Figure 7. Spectrum image processing.

is minimal working example in the Processing language:

```
void setup() {
    size(1000, 320);
    background(255);
    img = loadImage("spectrum.jpg");

    image(img, 0, 0);

    beginShape(POLYGON);
    curveVertex(0, 300);
```

```
    for (int i = 0; i < img.width;
    i++) {
        curveVertex(i, 300-int
        (brightness(get(i, 1))));
    }
    endShape();
}
```

In this code snippet, window with dimensions of 1000 per 320 pixels is created with a white background. Then the image 'spectrum.jpg' is loaded and drawn from the upper left corner.

Simple device for spectroscopy laboratory exercises

Then pixels from first line of the image are processed: From the left to the right the brightness of the pixel is found and used for graph drawing. The result is in the figure 7.

This code snippet can be easily extended, for example by averaging values over the entire spectrum image (all lines of the picture), storing measured values in a TXT file, or using a low-pass filter to further smooth the data.

5. Conclusions

Spectroscopic measurements have a great motivational potential, which is good to use to show other necessary things, such as the importance of the data processing necessary for the analysis of measured data.

While the spectral resolution of the designed device is not even with the use of a slit comparable to the level of professional instruments,

the resulting price of the equipment is two orders of magnitude lower. The 3D printing allows mass production of these simple pieces of equipment, make it usable in the undergraduate laboratory and even for at-home practice.

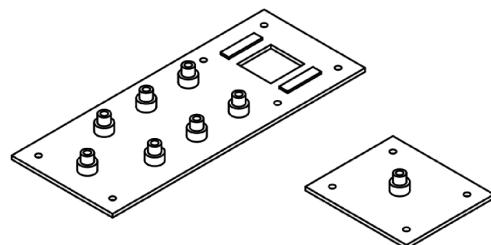
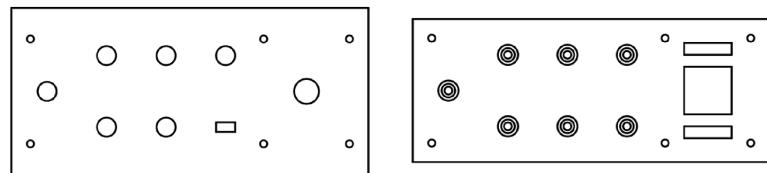
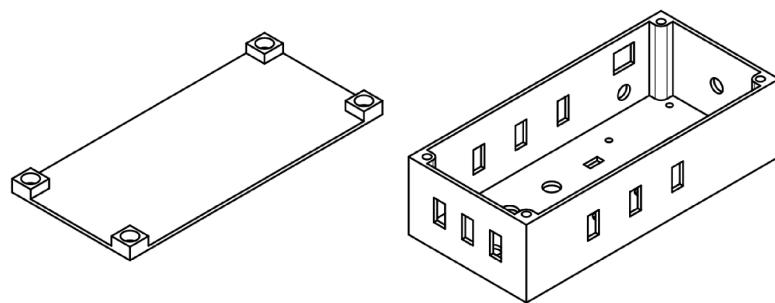
Although it may seem strange, it is the imperfection of the device that can be an advantageous in laboratory measurements, because students are forced to learn methods of data processing, which they will need in their future practice.

Data availability statement

No new data were created or analysed in this study.

Acknowledgment

This work was supported by the SV PrF UHK No. 2103/2020.



ORCID iDs

- Jan Loskot  <https://orcid.org/0000-0003-0172-4353>
 Filip Studnička  <https://orcid.org/0000-0001-6721-8678>
 Jan Šlégr  <https://orcid.org/0000-0001-8202-4062>

Received 31 July 2021, in final form 19 September 2021
 Accepted for publication 2 November 2021
<https://doi.org/10.1088/1361-6552/ac35b0>

References

- [1] Hobbs R 2018 Displaying diverse spectra using a thin white line screen (TWLS) *Phys. Teach.* **56** 603–6
- [2] Hamatsu Mini-spectrometer micro series C12880MA (available at: www.hamamatsu.com/resources/pdf/ssd/c12880ma_kacc1226e.pdf)
- [3] Gatkine P, Zimerman G and Warner E 2018 A do-it-yourself spectrograph kit for educational outreach in optics and photonics *Proc. SPIE* **10741** 107410S
- [4] Tran N and Fukuzawa M 2020 A portable spectrometric system for quantitative prediction of the soluble solids content of apples with a pre-calibrated multispectral sensor chipset *Sensors* **20** 5883
- [5] Hickman B 2013 CCD photodiode array spectrometer *Public Lab* (available at: <https://publiclab.org/notes/bhickman/10-12-2013/ccd-diodearray-spectrometer>)
- [6] Jansen P A 2013 Sneak peek: 3D-printable mini spectrometer (available at: www.tricorderproject.org/blog/sneak-peek-3d-printable-mini-spectrometer/)
- [7] Vanderveen J R, Martin B, Ooms J K 2013 Developing tools for undergraduate spectroscopy: an inexpensive visible light spectrometer *J. Chem. Educ.* **90** 894–9
- [8] Diffraction grating—diffraction gratings 6'' × 12'' film sheets—pack of 10 (available at: www.rainbowsymphony.com/products/diffraction-grating-sheets)
- [9] Šlégr J Supplementary materials for 3D printed spectrometer (available at: <https://lide.uhk.cz/prf/ucitel/slegrja1/spectra>)
- [10] T-1 3/4 (5 mm) full color LED lamp (available at: www.arduino.cc/documents/datasheets/LEDRGB-L-154A4SURK.pdf)
- [11] Birriel J J and Roe C 2015 Demonstrating fluorescence with neon paper and plastic *Phys. Teach.* **53** 328–9
- [12] Ayuga C E T and Luis A 2014 Fluorescence in cold drinks and caramel *Phys. Teach.* **52** 54
- [13] Birriel J J and King D 2018 Fluorescence spectra of highlighter inks *Phys. Teach.* **56** 20–23
- [14] Fricker P, Wartmann C and Hovestadt L 2008 Processing: programming instead of drawing *Proc. eCAADe* **2** 525–30



Automatic detection of breathing disorder from ballistocardiography signals[☆]

Dalibor Cimr^a, Filip Studnička^{b,*}

^a Faculty of Informatics and Management, University of Hradec Kralove, Rokitanskeho 62, Hradec Kralove 50003, Czech Republic

^b Faculty of Science, University of Hradec Kralove, Rokitanskeho 62, Hradec Kralove 50003, Czech Republic

ARTICLE INFO

Article history:

Received 6 March 2019

Received in revised form 14 August 2019

Accepted 19 August 2019

Available online xxxx

Keywords:

Disordered breathing

Ballistocardiography

Cartan curvature

Convolutional neural networks

Tensometers

ABSTRACT

Ballistocardiography (BCG) is a common method, wherein sensory information is used to identify blood-flow cardiac activity by measuring the mechanical micromovements of the human body generated by heart movements and blood eviction to the large arteries. BCG signals can be used to detect non-standard vital functions or predict likely health problems. However, the analysis of BCG signal is challenging because it contains various mechanical noises made by human body movements. This study is aimed at extracting information regarding the pulse arrival time from BCG signals and then establishing a connection with changes in breathing disorders, such as simulated apnoea, using convolutional neural networks. We present a novel approach toward recognizing the form of breathing which is independent of the body position while data are being collected from tensometers measuring the mechanical micromovements (motion) of the individual. The mechanical motions are caused by cardiac activity with multivariate time series output, which is processed to obtain the source data for breath detection. The signals are first processed by Cartan curvature. This is a differential geometric invariant, which enables the detection of marginal variations in the signals. Conditional dependency and short-term fluctuations are eliminated in longer measuring-periods. By these means, the breathing anomalies of individuals are subsequently detected between heartbeats using the time delay between the R-wave from the electrocardiogram (ECG) and the pulse arrival times. Moreover, ECG signals are included in the system for data sampling. In addition, the values of the time delay are used as the inputs to train a convolutional neural network classifier with two outputs (regular and disordered breathing) to validate the experiment. We achieved an average accuracy of 89.35%, sensitivity of 86.35%, and specificity of 91.22% on 828 regular and 1332 disordered breathing states from eight human subjects. The conclusion is that our novel method can detect disordered breathing from processed BCG signal, i.e. from the pulse arrival time, in a manner not previously used elsewhere.

© 2019 Published by Elsevier B.V.

1. Introduction

Ballistocardiography (BCG) is a non-invasive method of sensing body micro-movements evoked by heart activity and the blood flow in large arteries. Since the first research into the ballistic displacements of the human body [1], there has been considerable progress in the field of BCG and ballistocardiographic sensors. This is notwithstanding a certain lack of interest in the past because of insufficient knowledge of the physiology and physics underlying the method [2]. Recent advances in the

development of exceptionally sensitive sensors and fast computers for real-time calculations have resulted in a restoration of interest in this field. Presently, physicians mostly work with electrocardiogram (ECG) signals to identify heart-related health problems [3]. ECG measures only the electrical activity of the heart, whereas BCG directly measures the mechanical response of the heart to electric stimuli and the phenomena related with blood movement. Thus, BCG can provide significantly more information about the physical state of the cardiovascular system and detect similar and even more information than ECG. Nonetheless, it is significantly more challenging to obtain this information from BCG signals. One of the highest advantages of BCG measurement is that unlike ECG, it is completely unobtrusive. This implies that there is no need to place sensors directly on the skin or body of the human. The sensors can be embedded, e.g., inside the bed.

In studies of disordered breathing, the BCG signals are commonly analysed in the time domain between heartbeats. Therefore, these signals can be considered as multivariate time signals.

[☆] No author associated with this paper has disclosed any potential or pertinent conflicts which may be perceived to have impending conflict with this work. For full disclosure statements refer to <https://doi.org/10.1016/j.knosys.2019.104973>.

* Corresponding author.

E-mail addresses: dalibor.cimr@uhk.cz (D. Cimr), filip.studnicka@uhk.cz (F. Studnička).

From the numerous methods for analysing multivariate time series, we opted to study so-called Cartan curvature. This is a geometrical invariant that can be used to evaluate subtle variations in multivariate time series as described in Kříž and Šeba [4]. From the Cartan curvature, it is feasible to work with the relation between human respiration, pulse arrival time and blood pressure via the Moens–Korteweg relation [5]. Moreover, a convolutional neural network (CNN) can be developed to be trained with the samples computed by the Cartan curvature (converted by the continuous wavelet transformation (CWT) into the form of an image) to detect apnea. The CNN functions as an expert system that discriminates between healthy individuals and individuals with apnea.

The study of breathing disorders is a crucial topic because of the aging population and demand for unobtrusive or continuous monitoring of elderly individuals. There has been research in the past five years regarding health problems related to the analysis of heart function and respiration using various methods. Specifically, they are Acharya et al. [6,7], Fujita and Cimr [8], Hassan and Subasi [9], Horáček et al. [10] and Acharya et al. [11]. A few systems wherein ECG signal was used to detect sleep apnea are reported in Sharma et al. [12] and Sharma et al. [13]. From among the different methods, we selected BCG for its unobtrusiveness. With regard to BCG, there are also a few recent papers (from the past five years), e.g. Wiens and Inan [14], Javaid et al. [15], Martin et al. [16], Brüser et al. [17], Fernández-Leal et al. [18], Sun [19], Hwang et al. [20,21], Ganesan et al. [22] and Giri et al. [23]. Moreover, there has been research focused on BCG signals for sleep apnea: Zink et al. [24], Yao et al. [25], Hwang et al. [26], Sadek et al. [27], Liu et al. [28], Zhao et al. [29] and Vehkaoja et al. [30].

In Zink et al. [24], a novel algorithm was applied for detecting a long-term heartbeat cycle length. They focused on the BCG and simultaneously recorded an ECG, similar to our method. The correlation of the length of a cycle, calculated using ECG and BCG, was 0.95, albeit with an absolute difference in the cycle length of 4 ± 72 ms. This implied that it cannot be used as a very precise measurement. They used a piezoelectric foil sensor and studied individuals in a similar lying position. This position is necessary for that sensor to achieve good results. Yao et al. [25] proposed a novel method for noise reduction in an artificial BCG signal and tested this method on the heart rate and respiration components of real BCG signals. However, our method does not require special noise reduction owing to the use of advanced sensors and different mathematical processing of the signal.

Brüser et al. [17] involved the estimation of the heartbeat interval from multiple spatially-distributed force sensors integrated into a bed. They focused on developing a solid algorithm that would benefit from multiple sensors rather than one. Their algorithms were based on cepstrum analysis and Bayesian fusion. The measurements were performed in a sleep laboratory by using eight sensors for 28 nights. For comparison, a channel was derived by averaging the channels. The single-channel results achieved a beat-to-beat interval error of 2.2% with coverage of 68.7%. The best multi-channel result had an interval error of 1.0% with a coverage of 81.0%. The team of Javaid et al. [15] studied the effects of different standing and sitting postures on measured BCG signals. They implemented two novel approaches to improve estimates of projecting period from different positions and improved the J-wave detection methods. In our paper, we aim to demonstrate that our algorithm is completely independent of the positioning of the sensor.

The pulse transit time was studied in Javaid et al. [15] in order to calculate the blood pressure. A bathroom-weighing-scale-like system was assessed for BCG measurement. It used foot Photoplethysmography (PPG) to measure pulse waveforms.

The diastolic blood pressure was calculated with a correlation coefficient of -0.80 ± 0.02 and a root mean square error of 7.6 ± 0.5 mmHg. Our system also uses the relation between blood pressure and pulse transit time. However, we measure the pulse transit time indirectly inside the human cardiovascular system. Therefore, our system does not incorporate errors caused by the pulse's propagation through small muscular arteries. Wiens and Inan [14] proposed a novel method to reconstruct the BCG signal measured with a weighing scale from a wearable sensor, via a training step to remove local effects such as the distal acceleration of skin and tissue. Their results from 15 subjects reveal that the disturbances are highly dependent on both the individual and the location of the accelerometer. Meanwhile, our system is embedded in a bed to prevent problems with the appropriate positioning of the sensor. Furthermore, our algorithms calculate the BCG signal parameters, which are identical for all individuals.

Sadek et al. [27] also used a heart rate monitor in the form of a micro-bend fibre optic sensor to detect sleep apnea. Their method exhibits a very high correlation with the heart rate and breathing rate, 0.96 and 0.78, respectively. However, the proposed sensor provided very low sensitivity $24.2 \pm 12.81\%$ and specificity $85.88 \pm 6.01\%$. Liu et al. [28] studied the detection of obstructive sleep apnea. Their algorithm is based on locating the potential event segments from the raw BCG signal and dividing it into three phases of apnea by an adaptive threshold-based division algorithm. They then used a back propagation (BP) neural network to classify these phases into apnea and non-apnea events. The experimental results based on a real BCG data-sheet that contained 3790 apnea events and 2556 non-apnea events revealed that the precision, recall and AUC were 94.6%, 93.1% and 95.1%, respectively. Zhao et al. [29] used BCG signal to detect variations in the heart rate. They associated these variations with sleep apnea syndrome. They studied the modulation of this variability of the heart rate using sample entropy and detrended fluctuation analysis. These features were fed into a knowledge-based support vector machine classification model. Experimental results on 42 subjects over three nights attained a 90.46% precision rate and 88.89% recall rate.

A similar technique is described in Pagnacco et al. [31] and Kříž and Šeba [4]. Individuals lay on a force plate and were asked to stay calm without movement. The force plate had four tensometers embedded in its four corners. Each tensometer could measure the force in three orthogonal directions with a precision of up to 0.1 N. Therefore, it was feasible to obtain 12 force signals. The ECG signal was measured simultaneously with the force measurement. All the signals were registered using a 24-bit AD converter with a sampling rate of 1 kHz. The data were then stored on a computer's hard drive. This yielded 13 time-series.

In our previous study [32], we investigated pulse wave velocity and heart rate variability of over 50 volunteers using mathematical methods similar to those used in the present study. We also presented a physical model of the aorta for studying pulse wave propagation. It has been demonstrated that it is feasible to measure a quantity correlated with the pulse wave velocity by using the Cartan curvature and then transform it into direct blood-pressure monitoring by using the Moens–Korteweg relation.

The main difference between this study and the previous ones is in the independence from the position of the sensors with respect to the human body. Using novel mathematical methods, it is feasible to determine various physiological dependencies with remarkable signal-to-noise ratios. This paper starts by introducing the Cartan curvature and data analysis in detail. Subsequently, the curvature is mathematically described. Then, we introduce the extraction of the time delay between the R-wave and the pulse arrival time for the continuous wavelet transformation. We

Please cite this article as: D. Cimr and F. Studnička, Automatic detection of breathing disorder from ballistocardiography signals, *Knowledge-Based Systems* (2019) 104973,
<https://doi.org/10.1016/j.knosys.2019.104973>.

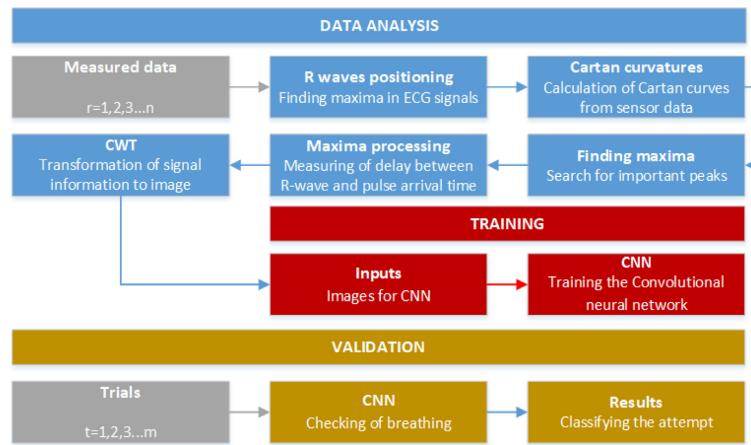


Fig. 1. Flowchart of system.

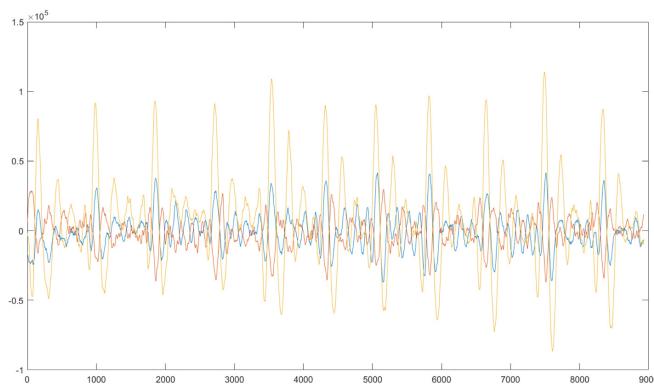


Fig. 2. Measured force signals (x: time/[ms], y: AU, standardized raw data).

also introduce convolutional neural network as a classifier of our expert system to obtain information about the breathing of individuals. This paper ends with a description of the results, a discussion section and avenues for future research.

2. Methodology

We regard BCG signals as force signals because effectively, BCG measures the force of displacement of the human body. The force signal time-series were understood as coordinate projections of a 12-dimensional curve parametrized by time.

Therefore, the geometric properties of this curve can be studied. We focused on calculating the Cartan curvature. As this is independent of the position of a person, it can be used for characterizing real-world phenomena that exhibit a similar property. The aim is to study the ballistocardiographic signals of individuals. This signal describes the mechanical activity over the whole of the cardiovascular system. It operates under various conditions,

essentially independently of the human's physiological position. That is, the heart always ejects blood into the arteries.

The curvature can be used to classify mechanical events in the cardiovascular system, such as heart contraction, or the scattering of the pulse wave on various bifurcations. The concept is that the position and amplitude of these events vary between the states of breathing and exhalation. It is essential to divide the measured time-series into samples to prepare the input for further analysis using a neural network (NN). As a natural trigger for cardiac event description, the ECG signal (R-wave) was used. After the measurement, the R-wave of each individual heartbeat was determined with a precision of 1 ms. Then, the time interval beginning 100 ms prior to and ending 400 ms after each R-wave was used as a threshold for the force signals and were selected as the input for further calculations. With an average of 60 heartbeats per minute, we obtain 60 samples per minute, to be used.

We essentially obtain a 500 × 12 matrix with a sampling rate of 1 kHz and a time interval of 500 ms. Here, each column represents a measured force signal. Thereafter, it is feasible to calculate

Please cite this article as: D. Cimr and F. Studnička, Automatic detection of breathing disorder from ballistocardiography signals, *Knowledge-Based Systems* (2019) 104973, <https://doi.org/10.1016/j.knosys.2019.104973>.

11 curvatures representing the force signal in this time interval. The positions of the maxima in these curvatures represent the time lags between the R-wave and the arrival of the pulse wave at various locations. We focus on the characterization of these maxima and on the whole shape of the curvature. Herein, we use the methods to be described subsequently in this paper. For our model, the first two curvatures of the time intervals are sufficient. The fundamental schema of the signal processing is presented in Fig. 1.

In the following chapters, the elements of the detection system are described in detail using a measuring and experimental setup as well as mathematical formulas of the Cartan curvature, in terms of their important peaks and CWT.

2.1. Measurement of the 12 force signals

Initially, the 12 force signals are measured using analogue tensometers. The signals from the tensometers are sampled at 1 kHz and measured simultaneously with a three-lead ECG. These 13 analog signals are then converted into digital signals using a 24-bit AD-converter connected to the computer in which the data are stored and processed. The 12 force signals are filtered using a moving average with a 10 ms time-window to eliminate the influence of the 50 Hz noise from the electric sockets. This is described in Fig. 2 with an example of three signals.

2.2. Determining the maxima in the ECG

Electrocardiography is the process of recording the electrical activity of the heart muscle. An ECG signal can be measured directly with electrodes placed on the skin because the amplitude of this signal is of the order of 10 mV. A typical ECG diagram consists of various waves and intervals. Of these, we are interested only in the so-called QRS complex—a complex of Q, R and S waves associated with the depolarization of the right and left ventricles. First, we standardize the ECG signal. In the standardization process, we first deduct the mean value of ECG signal from the signal so that the resulting mean value of ECG signals is zero. Then, we divide the signal by the square root of the variance of the signal. Then, we determine the local maxima of the R-waves in the standardized ECG signal. In the signal, we identify the maxima with a sufficient height to be a peak and determine the smallest distance between two adjacent peaks. An example of a result is shown in Fig. 3.

The standardization of the signal enables us to use a simple method to determine the ECG maxima. Moreover, the R-wave can be conveniently detected because none of the measured individuals suffered from severe heart disease. The reason for working with the R-wave from the ECG is that it is the most pronounced ECG signal. Moreover, it is the starting point of the propagation of an electric signal to the chambers. Therefore, mechanically, it starts the isovolumetric contraction of the chambers and all the important phenomena with regard to the cardiac cycle.

2.3. Calculation of 11 Cartan curvatures

The invariants of curves in n -dimensional Euclidean space under the actions of various transformation groups have been studied by means of differential geometry. One of these invariants is the so-called Cartan curvature. It is an object that does not vary when we consider groups of translations, rotations and reparametrizations. The Frenet-Serret theory of curves provides us tools to study the local properties of these curves. It states that it is natural to describe the curve with a local coordinate system connected with each point of the curve, rather than a global

coordinate system. The local coordinate system in the Frenet-Serret theory is constructed so that the first axis is tangential to the curve at the specified point, the second axis is the normal, the third axis is the bi-normal, etc. Then, variations in the axes of this local coordinate system (called Frenet-Serret frame) are described by the Cartan curvature [33].

For each R-wave, we calculate the time-dependent Cartan curvature. Here, 12 blocks of data represent 12 projections of a one-dimensional curve embedded in 12-dimensional Euclidean space. A similar method was used in Kříž and Šeba [4] and Studnička [32]. The curvature is calculated as

$$\kappa(t) = \frac{E'_1(t) \cdot E'_2(t)}{|c'(t)|},$$

where E'_1 and E'_2 are the derivatives of the tangent and normal vectors, respectively, of the Frenet frame. $|c'(t)|$ is the absolute value of the derivative of the time parametrized curve $c(t)$ in 12-dimensional space, where the projections of this curve into each dimension are the measured signals. E_1 and E_2 are defined as follows:

$$E_1(t) = \frac{c'(t)}{|c'(t)|}$$

$$E_2(t) = \frac{-(c'(t)c''(t))c'(t) + |c'(t)|^2c''(t)}{|-(c'(t)c''(t))c'(t) + |c'(t)|^2c''(t)|}.$$

An example of the Cartan curvature, consisting of a beat-to-beat analysis, is shown in Fig. 4.

In the first 300 ms, reverberations of body oscillations, atria filling, and pumping of blood to the chambers occur. These phenomena are mechanically weak and chaotic and different in each heartbeat. Therefore, it is reasonable to use the ECG to determine the R-wave, as that is when strong mechanical events start. In the range of 300 and 600 ms, an isovolumetric contraction of the chambers and the propagation of the pulse wave occur. These are the most important phenomena for our research. The final part corresponds to the repolarization of the chambers and the oscillations of the body. These time ranges are not equal for all the samples and are only for the purposes of illustration. The velocity of the pulse wave depends on the pulse frequency of the body and other situations described in Section 2.5 in detail.

2.4. Finding the maxima in the Cartan curvature

From the physiological interpretation of the events in the Cartan curvature described in Kříž and Šeba [4], we identify events related to the phenomena we are interested in. These phenomena are represented by peaks in the curvature. Thus, the positions of the maxima in the Cartan curvature is used for each R-wave in the time range we are interested in. The events we will use are related to the pulse arrival time. This time is related to the blood pressure via the Moens-Korteweg relation:

$$BP = a \ln \left(\frac{b}{(\frac{d}{PWV} - c)^2} - 1 \right),$$

where BP represents the blood pressure; PWV is the pulse wave velocity and a , b , c and d are constants depending on human physiology. It is feasible to observe variations in the blood pressure with beat-to-beat precision. Hence, we are able to observe variations related even to respiration and respiration variations.

2.5. Processing the maxima

We can use two approaches to sample the resulting position of the maxima in the Cartan curvature. The first approach is to sample using time measured in ms. This can be used for linear

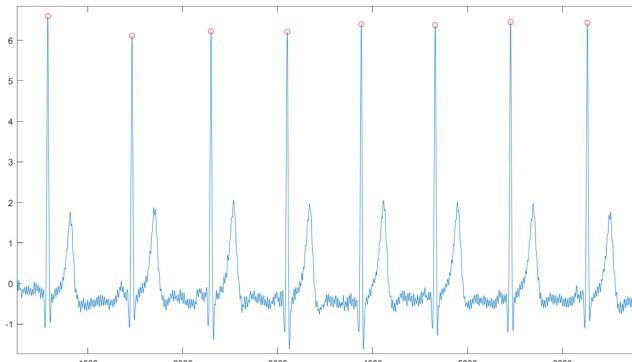


Fig. 3. Maxima of ECG (x: time/[ms], y: AU, red dots—maxima, blue—ECG signal). (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

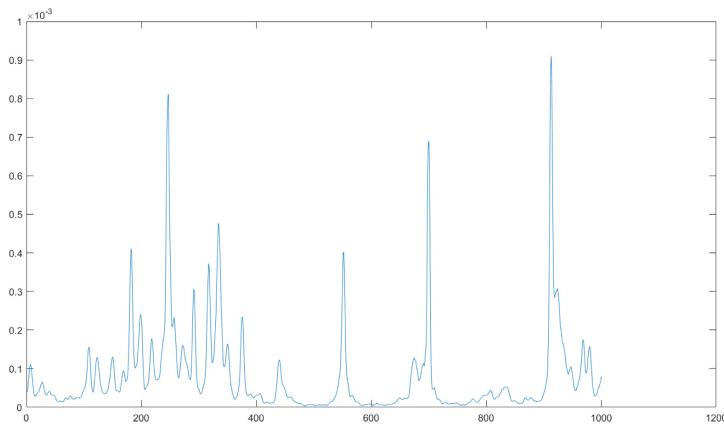


Fig. 4. Cartan curvature (x: time [ms], y: 1/AU, blue - curvature). (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

interpolation of these maxima over time. It is more appropriate to use a sampling based on heartbeats, particularly the R-waves, because the ECG is the trigger of our process. The curve connecting the points is then interpolated in linear time space because each heartbeat has an associated time-stamp. This was carried out only to illustrate how the points vary over time. In each heartbeat, the time delay between the R-wave and the pulse arrival time is measured. It is shown on the y-axis in Fig. 5.

This measurement can be performed because we have an identical number of heartbeats in the measurement and therefore, an identical number of samples. This is because the heartbeats, rather than time, function as our sampling points. Certain artefacts of pulse waves may occur during measurement, and body pressure exhibits certain limits. Therefore, the pulse wave cannot grow to infinity. After a certain period of time, it stabilizes. Therefore, a moving average with a window size of 10 samples was used to smooth the signal and better display disordered breathing states (Fig. 5). Short-time breath-holding creates a peak

and a long-time plateau, which depends on the size of the moving average window. Our contribution is the determination of the relation between the pulse arrival time obtained from the BCG signals using Cartan curvatures and of breathing disorders, which are related to blood pressure variations. The blood pressure variations are in turn related by Moens-Korteweg relation with the variations in the pulse arrival time. Our novel method is based on a study of the maxima in the Cartan curvature and their variations.

2.6. Continuous wavelet transform

In this part, we divide the function of pulse waves into wavelets by the continuous wavelet transformation (CWT) using the Morse wavelet (MW). CWT is type the time-frequency-based feature extractor, which represents signals in both the time and frequency domains concurrently [34]. MW analysis depends on two main parameters: symmetry and time-bandwidth. These specify the form of the wavelet and the transform. The symmetry

Please cite this article as: D. Cimr and F. Studnička, Automatic detection of breathing disorder from ballistocardiography signals, *Knowledge-Based Systems* (2019) 104973, <https://doi.org/10.1016/j.knosys.2019.104973>.

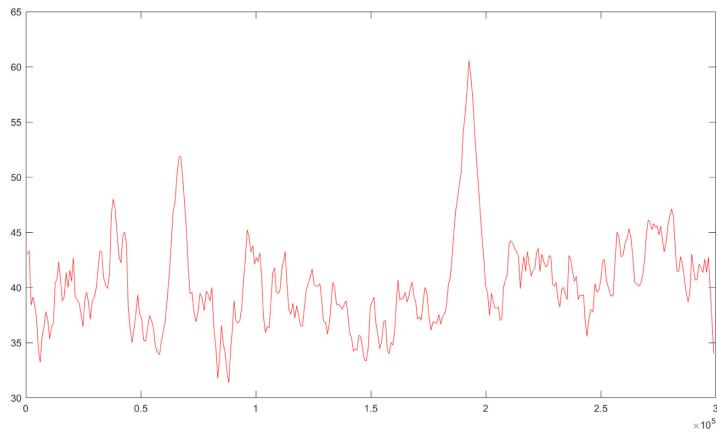


Fig. 5. Pulse wave times (x: time [ms], y: pulse arrival time minus a constant).

Table 1
Measurement schedule.

Time (s)	Event
0	Start of a measurement on back
60	Breath-holding during inhalation
180	Breath-holding during exhalation
300	End of a measurement

parameter controls the symmetry of the wavelet in time. The time-bandwidth parameter is proportional to the duration of the wavelet in time. The CWT is computed for each step by

$$CWT_{b,s}(i) = U(i)n_{b,s}i^{\frac{b^2}{s}}e^{-\frac{i}{s}}$$

where $U(i)$ represents the unit step, $n_{b,s}$ is a normalizing constant, s characterizes the symmetry of the Morse wavelet and b is the time-bandwidth parameter. As an example to illustrate how the different parameter values vary the CWT output, Fig. 6 shows the results of using four combinations of the values of the parameters s and b for the same signal.

It is apparent that if the time-bandwidth is exceptionally small, as in Fig. 6a, the diagram contains the necessary information in a very clear form. As the time-bandwidth increases, the analysis starts to become less clear when the difference between the time-bandwidth and symmetry is widened. Owing to the condition that the symmetry has to be smaller than the time-bandwidth, another option is to have a more balanced result by varying the power range (Fig. 7). If the maximum value of the power is exceptionally small, the diagram contains excessive information, and the result is distorted by the breathing frequency. Meanwhile, an excessive power causes the loss of all the information necessary for the future classification.

In this manner, we obtain images containing information about the individual's breathing, to be used as the inputs of the training session.

3. Training the convolutional neural network

At the beginning of the training of the CNN, the BCG sensor data from seven-minute long measurements are obtained from eight tested individuals by the schedule presented in Table 1.

These data are analysed in the manner described in the previous chapter. The symmetry of the CWT has been set to one, the time-bandwidth to two and the power to 100. Apart from this, information regarding the time when the individuals started to breathe again was recorded during the measurement. This is because this event is different for each person. To establish the independence from the lying positions of the individuals, the measurement was realized both on the back and on the side.

Because disordered breathing can occur at different times, the CWT was performed on 30 s long pieces with a step of 1 s to obtain information regarding the problems in different parts of an image. The creation of the pieces provided us 828 images of regular breathing and 1332 images of disordered breathing for the training and testing of the CNN. The whole dataset was divided by a stratified ten-fold cross-validation strategy [35] for testing the model performance. The image resolution of the input is 50×50 pixels, and the maximum number of epochs is 30. The learning rate does not have to be constant for the entire training process. The image resolution of the input is set as small as feasible without loss of important information from the measured data. We set it to $1 \cdot 10^{-3}$ for the first 20 epochs and $3 \cdot 10^{-4}$ for the remaining. Completion of all epochs is not guaranteed because early stopping by increasing validation loss accuracy is set on to prevent overfitting. The gradient descent was computed by ADAM (adaptive moment estimation) to optimize the convergence of the model. The architecture of the CNN is illustrated in Table 2. It consists of three main blocks. The first block contains a convolutional filter performed over a 7×7 pixel window and having a stride size of one, and a max-pooling layer with a kernel size of 2×2 pixels and a stride of two pixels. The second block has similar characteristics of kernel size and stride as the first block, except for the kernel size of the convolutional layer, which is 5×5 . The final block has two fully connected layers. The first contains 20 neurons, and the second has two output neurons corresponding to the two classes of breathing (regular and disordered). As the activation functions, rectified-linear unit layer (ReLU) is used after both the convolutional layers and the softmax function at the end of the model for suitable classification from the previous fully-connected layer. The whole CNN model contains 71972 trainable parameters.

Within the setting of the values of symmetry, time bandwidth and power used to analyse the signal, information regarding a

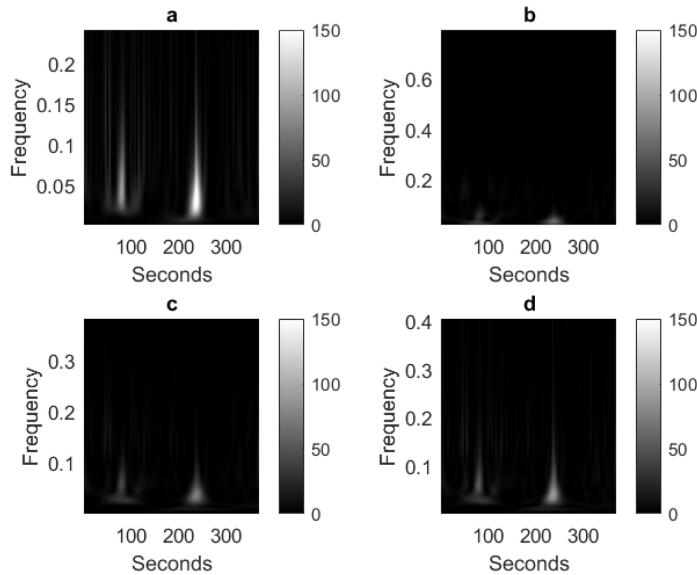


Fig. 6. Results of CWT analysis: (Symmetry, Time band-width): a. (1,2), b. (1,10), c. (5,10), d. (9,10).

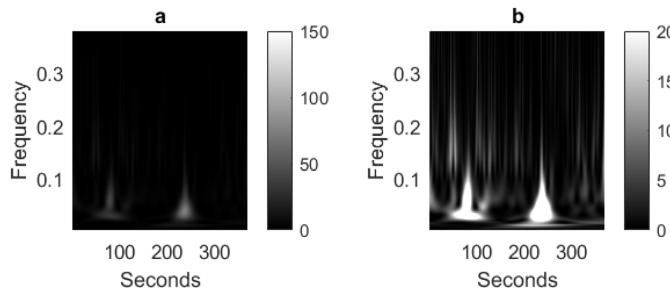


Fig. 7. Results of CWT analysis: Power: a. 150, b. 20.

Table 2

Detailed structure of CNN for detecting regular and disordered breathing.

Layers	Type	Number of neurons	Kernel size	Stride
0-1	Convolution	46 × 46 × 30	7 × 7	1
1-2	Max-pooling	23 × 23 × 30	2 × 2	2
2-3	Convolution	19 × 19 × 30	5 × 5	1
3-4	Max-pooling	9 × 9 × 30	2 × 2	2
4-5	Fully-connected	20	-	-
5-6	Fully-connected	2	-	-

breath disorder is displayed on approximately one-tenth of the image. This way, the first convolutional layer was designed in connection with the image resolution. The second convolutional layer serves for the recognition of the real problem, which has a

specific characterization, from unexpected deflections in the human body. These deflections include muscle tremor, involuntary movements to ensure re-oxygenation of tissues or sneezing.

4. Experiment

Noninvasive measurement was performed on a standard bed with tensometric sensors embedded in the four corners of the bed. Approval for electrical safety was not required because the whole apparatus operates with a voltage lower than 50 V. According to the electrical safety regulations in the Czech Republic, this does not require electrical revision and is considered safe. Written informed consent was obtained from all the participants prior to the commencement of the study.

During the experiment, eight subjects were measured. Data from the ECG and tensometers were acquired and processed on a PC. The ECG maxima were identified, and the signal was divided

Please cite this article as: D. Cimr and F. Studnička, Automatic detection of breathing disorder from ballistocardiography signals, *Knowledge-Based Systems* (2019) 104973, <https://doi.org/10.1016/j.knosys.2019.104973>.

Table 3
Confusion matrix.

Real Predict	Positive	Negative	ACC (%)	PPV (%)	SEN (%)	SPEC (%)
Positive	TP	FN	$\frac{TP + TN}{TP + TN + FP + FN}$	$\frac{TP}{TP + FP}$	$\frac{TP}{TP + FN}$	$\frac{TN}{TN + FP}$
Negative	FP	TN	$\frac{TP + TN}{TP + TN + FP + FN}$	$\frac{TN}{TN + FN}$	$\frac{TN}{TN + FP}$	$\frac{TP}{TP + FN}$

Table 4

Overall results of classification of regular and disordered.

Original/predicted	Regular	Disordered	ACC (%)	PPV (%)	SEN (%)	SPEC (%)
Regular	715	113	89.35	85.94	86.35	91.22
Disordered	168	1164	89.35	91.49	91.22	86.35

into subsequent blocks. Then, the Cartan curvatures from the tensometers were calculated. Furthermore, the maxima relevant to the pulse arrival time were identified for each individual block. In the experiment, the correlation between the pulse arrival time and normal/disordered breathing was investigated using CWT calculation of these maxima and processed using the neural network.

Differences between 30 s records with and without breathing problems on CWT are shown in Fig. 8. For illustrative purposes, pure examples as well as cases with unexpected deflections of a signal relating to unaffected body processes are presented. Because of the large quantity of deflections, apparent differences occurred between the two classes as well as within each class. These differences can depend on the states of regular/disordered breathing both with and without the occurrence of a deflection and, when it occurs, on the type and power of the deflection. The final input that can influence the output from the system is the body position. However, this can vary the signal shape only to an extent that should not dramatically impact the classifier.

As described in Table 1, the measurement is carried out in the position on the back and on the side. The experiment was intended to establish the independence of the results from the body position. The first tests did not include mattresses on the bed, and its results were unsatisfactory. This was caused by the hard surface under the individual, because of which the individuals had to maintain stability on their side. This was not a naturally comfortable position and resulted in larger muscle tone and thus distorted data. Another advantage of the mattress is that it operates as a low-frequency filter, i.e. it filters out high frequencies, which are mostly noise.

5. Results

The overall results of the classification of regular and disordered breathing are presented in Table 4. Mathematical formulas for computing true positive (TP), false positive (FP), true negative (TN) and false negative (results) are described in Table 3. The data contain measurements of eight male and female human subjects with different body proportions and ages. The average time required for training each epoch is 6.7 s, i.e. 5 ms per step. In the case of testing, 2 ms per step was measured. So 217 images in one of ten fold of cross validation is validated after half of the second. The proposed network was trained on a workstation with Intel Core i7 2.50 GHz processor, 16 GB RAM and GeForce GTX 860M with 2 GB memory. It is observed that from 828 instances of regular breathing, approximately 13.65% of the images, are incorrectly classified as disordered. Meanwhile, from the 1332 tested images representing disordered breathing, 8.78% are incorrectly classified as regular.

The positive predicted values (PPVs) for the regular and disordered classes are also presented in Table 4. The PPV in the

regular class is 85.94% and that in the disordered class is 91.49%. This indicates that in contrast with regular breathing, the correct detection probability of disordered breathing from BCG sensors is higher. Finally, the average accuracy (ACC) of detection is 89.35%.

The receiver operating characteristics (ROC) curve for the proposed classifier is shown in Fig. 9 on the left. The ROC represents the performance of the proposed classifier relative to the false accept rate (FAR) and false rejection rate (FRR). The main desideratum for a classifier is for the ROC curve to be as far away from the dashed line as feasible. The accuracy is measured by the area under the ROC curve (AUC), which is equal to one in an ideal situation. In our case, the AUC is 0.9721.

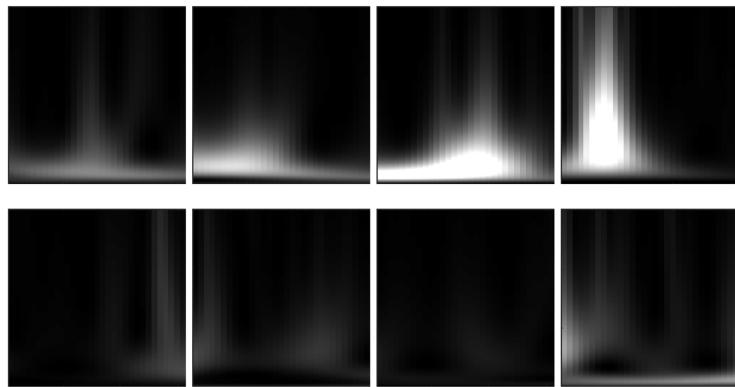
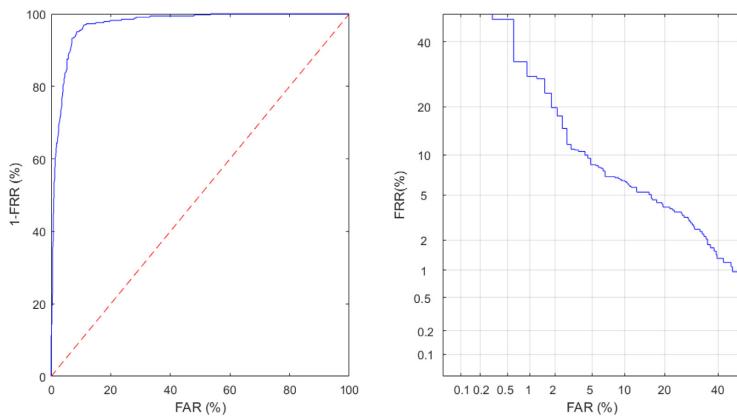
The second representation of classifier performance is the detection error tradeoff (DET). The point of intersection of the DET curve and the imaginary line $x = y$ are on the right of Fig. 9. This intersection is called equal error rate (EER). Unlike the ROC curve, an ideal situation has an EER equal to zero. In our case, the EER is approximately 6.97%.

6. Conclusion and discussion

A classifying system using the Cartan curvature and a convolutional neural network has been proposed for detecting disordered breathing. Information about an individual's breathing was gathered from the pulse propagation time, which is related to the blood pressure. The pulse propagation time was measured because the delay between the R-wave (obtained from the ECG) and the pulse arrival time (extracted from the local maxima in the Cartan curvature) represent the phenomena of interest. Thereafter, the continuous wavelet transformation turns the function of pulse propagation times into wavelets for input to the CNN, which is similar to an expert system.

The main benefit compared to other studies is that our approach is independent of the position of the body during the measurements. We performed an experiment in which individuals were lying on their backs, as in other studies. However, the part of bed on which they lay was of no consequence. In Table 5, the results of other studies addressing the detection of disordered breathing or apnea are provided for an overview. A few values of the other studies are absent as they were not measured by the concerned authors. Moreover, a few papers from the literature review have a different measurement methodology and different objectives. Therefore, it is incomparable with this work. Although measurement accuracy is not the highest in comparison with the other researches, the results are comparable from a general perspective. The main benefit of this study is the method of data measurement that is unobtrusive and does not depend on the body position on the measuring bed.

Two major challenges were encountered in this research. The first was the determination of the connection between breathing and the mechanical micromovements of the body measured by ballistocardiography. During the initial experiments, it was verified that there is a relation between the blood pressure and the pulse arrival time. The second was the selection of the correct combinations of the symmetry and time-bandwidth parameters with the power range of the CWT results. The parameters should not be too high. Moreover, the difference between these and the

**Fig. 8.** Top: Examples of disordered breathing; Bottom: regular breathing.**Fig. 9.** Left: ROC curve; Right: DET curve.**Table 5**
Comparison of results between prominent studies.

Authors	Method	ACC	Sensitivity	Specificity	AUC
This study	Cartan curvature + CNN	89.35	86.35	91.22	0.9721
Sadek et al. [27]	Adaptive thresholding		24.24	85.88	
Liu et al. [28]	Threshold-based division + BPNN	94.6			0.951
Zhao et al. [29]	Detrended fluctuation + SVM	90.46			
Yao et al. [25]	LNPR	92.7			

power range should not be too small owing to the consequent distortion of the output by normal breathing.

Regarding CWT, the Morse wavelet appear to be an appropriate method for data transformation [36]. Although either 'Morlet' or 'Ricker' could have been selected, Morse was optimal for this research because of its characterization of the pulse arrival times. In this context and with these CWT outputs, we selected the CNN as the classifier to be applied to analyse the visual images.

The main method for heart rate analysis has been the use of ECG. However, there are novel approaches focused on unobtrusive sensors. One of them is measurement by BCG or SCG [2,37,

38]. A few of the articles in the literature regarding respiration address BCG sensors. Therefore, the method of data extraction is more or less similar. However, those studies worked with different types of BCG sensors such as a foil sensor. Moreover, their methods are dependent on the position of the sensor. With the use of the Cartan curvature, the dependence on the person is eliminated. Therefore, the sensors can be placed firmly on the measuring lounger, and the data acquisition is completely unobtrusive. Moreover, the Cartan curvature processes the data of all the mechanical micromovements of the body obtained from the tensometers. Therefore, we can work with only the part of

the potential options of this method. We consider that the right understanding of the curvature results will open a wide range of possibilities in health care, in the design of expert systems for detecting these health problems by novel approaches, and in the analysis of states that would otherwise be obtained only invasively. Therefore, the use of ECG for determining the R-wave and the moment of isovolumetric contraction of the chambers, as achieved in this study, can be omitted in the future.

Finally, in terms of practical use, the system can be deployed in the medical area for detecting sleep-disorders in patients. The results from the classifier can be stored for future analysis or to report health problems to medical staff for preventing sleep apnea and other respiratory disorders. The potential use in a sleep laboratory, where unobtrusive sensors are highly necessary, is apparent. The presented system can also be used at home by family members to monitor elderly patients, with an alarm for disordered breathing.

7. Future research

The method presented in this article is one of many feasible approaches to evaluating this type of data. In our future research, we intend to focus on several tasks such as patient health care monitoring, particularly with a focus on monitoring the heart rate and its abnormalities. We also intend to study breathing disorders in various lying positions of an individual, where the neural network will be fed with complex greyscale images with the information regarding the whole process of a heartbeat.

Furthermore, we intend to replace the ECG signal with BCG. Presently, we are compelled to use ECG as a signal trigger to enable us to cut the signal into individual pieces for evaluation. In the future, we intend to focus on determining an adequate trigger for these cuts within the BCG signal. Replacing the ECG will provide higher comfort to the individual during the measurement. Thereby, the individual will not be limited by wires or on-body sensors. Our long-term objective is to install all the technology in a bed, sofa, chair or other standard pieces of furniture for all-day monitoring of a person. Long-term data can provide valuable information about variations in the health state of an individual and can be used for detecting the beginning of a health problem or predicting such problems.

Another aspect that has potential for use in real applications and can aid with monitoring health states is the monitoring of blood pressure variations and variability. We intend to achieve this by calculating the pulse arrival time and blood pressure via the Moens-Korteweg equation. Although the preprocessing of the signal appears highly computationally demanding, it can be achieved with a simple real-time model using a microchip, which has already been tested by us. We plan to develop such a physical real-time model in our future research. A similar concept has been studied in Huang et al. [39] and Fierro et al. [40]. However, they also used ECG signals.

In the present research, built-in sensors in the bed are used. There are several wearable solutions equipped with accelerometers and gyroscopes, which can provide similar information albeit with significantly lower frequency and precision. It may be feasible to apply a few of the used methods to the data from similar systems. This can give us the possibility of monitoring a person not only when lying on a special bed. Our previous research [41] verified the feasibility of monitoring breath frequency and heartbeat using wearable sensors on dogs. There is also the feasibility of observing certain types of a breathing disorder, and current research is focused on monitoring the beginning of epileptic seizures in dogs.

We also intend to further verify our assumption that the pulse arrival time is correlated with breathing patterns. More

complex experiments including clinical study are necessary for this verification. Finally, premature ventricular contraction is the most common type of arrhythmia. It should be feasible to detect and monitor its occurrence because there may be a connection with a mechanical event linked via baroreceptors.

Acknowledgements

This work was supported by Specific Research Project of Faculty of Informatics and Management, University of Hradec Králové and the project PERSONMED—Center for the Development of Personalized Medicine in Age-Related Diseases, Reg. Nr. CZ.02.1.01/0.0/0.0/17_048/0007441.

References

- [1] J. Gordon, Certain molar movements of the human body produced by the circulation of the blood, *J. Anat. Physiol.* 11 (Pt 3) (1877) 533.
- [2] O.T. Inan, P.-F. Migeotte, K.-S. Park, M. Etemadi, K. Tavakolian, R. Casanella, J. Zanetti, J. Tan, I. Funtova, G.K. Prisk, et al., Ballistocardiography and seismocardiography: A review of recent advances, *IEEE J. Biomed. Health Inform.* 19 (4) (2015) 1414–1427.
- [3] O. Faust, Y. Hagiwara, T.J. Hong, O.S. Lih, U.R. Acharya, Deep learning for healthcare applications based on physiological signals: a review, *Comput. Methods Programs Biomed.* (2018).
- [4] J. Kříž, P. Šeba, Force plate monitoring of human hemodynamics, *Nonlinear Biomed. Phys.* 2 (1) (2008) 1.
- [5] E. Pinheiro, O. Postolache, P. Girão, Non-intrusive device for real-time circulatory system assessment with advanced signal processing capabilities, *Mech. Sci. Rev.* 10 (5) (2010) 166–175.
- [6] U.R. Acharya, H. Fujita, S.L. Oh, U. Raghavendra, J.H. Tan, M. Adam, A. Gertych, Y. Hagiwara, Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network, *Future Gener. Comput. Syst.* 79 (2018) 952–959.
- [7] U.R. Acharya, H. Fujita, O.S. Lih, M. Adam, J.H. Tan, C.K. Chua, Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network, *Knowl.-Based Syst.* 132 (2017) 62–71.
- [8] H. Fujita, D. Cimr, Computer aided detection for fibrillations and flutters using deep convolutional neural network, *Inform. Sci.* 486 (2019) 231–239.
- [9] A.R. Hassan, A. Subasi, A decision support system for automated identification of sleep stages from single-channel EEG signals, *Knowl.-Based Syst.* 128 (2017) 115–124.
- [10] J. Horáček, V. Koucký, M. Hladík, Novel approach to computerized breath detection in lung function diagnostics, *Comput. Biol. Med.* 101 (2018) 1–6.
- [11] U.R. Acharya, H. Fujita, V.K. Sudarshan, S.L. Oh, M. Adam, J.H. Tan, J.H. Koo, A. Jain, C.M. Lim, K.C. Chua, Automated characterization of coronary artery disease, myocardial infarction, and congestive heart failure using contourlet and shearlet transforms of electrocardiogram signal, *Knowl.-Based Syst.* 132 (2017) 156–166.
- [12] M. Sharma, M. Raval, U.R. Acharya, A new approach to identify obstructive sleep apnea using an optimal orthogonal wavelet filter bank with ECG signals, *Inform. Med. Unlocked* (2019) 100170.
- [13] M. Sharma, S. Agarwal, U.R. Acharya, Application of an optimal class of antisymmetric wavelet filter banks for obstructive sleep apnea diagnosis using ECG signals, *Comput. Biol. Med.* 100 (2018) 100–113.
- [14] A.D. Wiens, O.T. Inan, A novel system identification technique for improved wearable hemodynamics assessment, *IEEE Trans. Biomed. Eng.* 62 (5) (2015) 1345–1354.
- [15] A.Q. Javaid, A.D. Wiens, N.F. Fesmire, M.A. Weintrauer, O.T. Inan, Quantifying and reducing posture-dependent distortion in ballistocardiogram measurements, *IEEE J. Biomed. Health Inform.* 19 (5) (2015) 1549–1556.
- [16] S.L.-O. Martin, A.M. Cerek, C.-S. Kim, H. Ashouri, O.T. Inan, J.-O. Hahn, R. Mukkamala, Weighting scale-based pulse transit time is a superior marker of blood pressure than conventional pulse arrival time, *Sci. Rep.* 6 (2016).
- [17] C. Brüser, J.M. Kortelainen, S. Winter, M. Tenhunen, J. Pärkkä, S. Leonhardt, Improvement of force-sensor-based heart rate estimation using multichannel data fusion, *IEEE J. Biomed. Health Inform.* 19 (1) (2015) 227–235.
- [18] Á. Fernández-Leal, M. Cabrero-Canosa, E. Mosquera-Rey, V. Moret-Bonillo, A knowledge model for the development of a framework for hypnogram construction, *Knowl.-Based Syst.* 118 (2017) 140–151.

- [19] S. Sun, An innovative intelligent system based on automatic diagnostic feature extraction for diagnosing heart diseases, *Knowl.-Based Syst.* 75 (2015) 224–238.
- [20] S.H. Hwang, H.N. Yoon, Y.-J.G. Lee, D.-U. Jeong, K.S. Park, et al., Nocturnal awakening and sleep efficiency estimation using unobtrusively measured ballistocardiogram, *IEEE Trans. Biomed. Eng.* 61 (1) (2014) 131–138.
- [21] S.H. Hwang, G.S. Chung, Y.-J. Lee, D.-U. Jeong, K.S. Park, et al., Estimation of sleep onset latency based on the blood pressure regulatory reflex mechanism, *IEEE J. Biomed. Health Inform.* 17 (3) (2013) 539–544.
- [22] M. Ganeshan, R. Lavanya, E. Sumesh, A survey on ballistocardiogram to study the mechanical activity of heart, in: *Communication and Signal Processing (ICCP), 2017 International Conference on IEEE*, 2017, pp. 0557–0561.
- [23] D. Giri, U.R. Acharya, R.J. Martis, S.V. Sree, T.-C. Lim, T.A. Vi, J.S. Suri, Automated diagnosis of coronary artery disease affected patients using LDA, PCA, ICA and discrete wavelet transform, *Knowl.-Based Syst.* 37 (2013) 274–282.
- [24] M.D. Zink, C. Brüsler, B.-O. Stüben, A. Napp, R. Stöhr, S. Leonhardt, N. Marx, K. Mischke, J.B. Schulz, J. Schiefer, Unobtrusive nocturnal heartbeat monitoring by a ballistocardiographic sensor in patients with sleep disordered breathing, *Sci. Rep.* 7 (1) (2017) 13175.
- [25] Y. Yao, C. Brüsler, U. Pietrzkyk, S. Leonhardt, S. van Waasen, M. Schiek, Model-based verification of a non-linear separation scheme for ballistocardiography, *IEEE J. Biomed. Health Inform.* 18 (1) (2014) 174–182.
- [26] S.H. Hwang, Y.J. Lee, D.-U. Jeong, K.S. Park, et al., Oxygen desaturation index estimation through unconstrained cardiac sympathetic activity assessment using three ballistocardiographic systems, *Respiration* 92 (2) (2016) 90–97.
- [27] I. Sadek, E. Seet, J. Biswas, B. Abdulrazak, M. Mokhtari, Noninvasive vital signs monitoring for sleep apnea patients: A preliminary study, *IEEE Access* 6 (2018) 2506–2514.
- [28] F. Liu, X. Zhou, Z. Wang, T. Wang, H. Ni, J. Yang, Identifying obstructive sleep apnea by exploiting fine-grained BCG features based on event phase segmentation, in: *Bioinformatics and Bioengineering (BIBE), 2016 IEEE 16th International Conference on IEEE*, 2016, pp. 293–300.
- [29] W. Zhao, H. Ni, X. Zhou, Y. Song, T. Wang, Identifying sleep apnea syndrome using heart rate and breathing effort variation analysis based on ballistocardiography, in: *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE, IEEE*, 2015, pp. 4536–4539.
- [30] A. Vehkaoja, A. Kontunen, J. Lekkala, Effects of sensor type and sensor location on signal quality in bed mounted ballistocardiographic heart rate and respiration monitoring, in: *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE, IEEE*, 2015, pp. 4383–4386.
- [31] G. Pagnacco, E. Oggero, P. O'Reilly, M. Warnecke, N. Berme, Design and testing of a 6-component ballistocardiographic bed, *Biomed. Sci. Instrum.* 35 (1999) 57–62.
- [32] F. Studnička, Analysis of biomedical signals using differential geometry invariants, *Acta Phys. Polon. A* 6 (120) (2011) A–154.
- [33] J. Gallier, *Geometric Methods and Applications: for Computer Science and Engineering*, Vol. 38, Springer Science & Business Media, 2011.
- [34] Y. Hagiwara, H. Fujita, S.L. Oh, J.H. Tan, R. San Tan, E.J. Ciaccio, U.R. Acharya, Computer-aided diagnosis of atrial fibrillation based on ECG signals: a review, *Inform. Sci.* 467 (2018) 99–114.
- [35] R.O. Duda, P.E. Hart, D.G. Stork, et al., Pattern classification, *Int. J. Comput. Intell. Appl.* 1 (2001) 335–339.
- [36] O. Kocaban, E. Tiryalı, E. Coskun, S. Ozder, Determination of phase from the ridge of CWT using generalized Morse wavelet, *Meas. Sci. Technol.* 29 (3) (2018) 035203.
- [37] V. Zakeri, A. Akbardeh, N. Alamdar, R. Fazel-Rezai, M. Paukkunen, K. Tavakolian, Analyzing seismocardiogram cycles to identify the respiratory phases, *IEEE Trans. Biomed. Eng.* 64 (8) (2017) 1786–1792.
- [38] N. Alamdar, K. Tavakolian, V. Zakeri, R. Fazel-Rezai, M. Paukkunen, R. Sepponen, A. Akbardeh, Using electromechanical signals recorded from the body for respiratory phase detection and respiratory time estimation: A comparative study, in: *Computing in Cardiology Conference (CinC), 2015, IEEE*, 2015, pp. 65–68.
- [39] J.-J. Huang, H.-Y. Syu, Z.-L. Cai, A.R. See, Development of a long term dynamic blood pressure monitoring system using cuff-less method and pulse transit time, *Measurement* 124 (2018) 309–317.
- [40] G. Fierro, F. Silveira, R. Armentano, Central blood pressure monitoring method oriented to wearable devices, *Health Technol.* 6 (3) (2016) 197–204.
- [41] D. Šec, J. Matyska, B. Klímová, R. Cimler, J. Kuhnova, F. Studnička, System for detailed monitoring of dog's vital functions, in: *International Conference on Computational Collective Intelligence*, Springer, 2018.

Please cite this article as: D. Cimr and F. Studnička, Automatic detection of breathing disorder from ballistocardiography signals, *Knowledge-Based Systems* (2019) 104973, <https://doi.org/10.1016/j.knosys.2019.104973>.



Computer aided detection of breathing disorder from ballistocardiography signal using convolutional neural network



Dalibor Cimr^a, Filip Studnicka^b, Hamido Fujita^{c,d,e,*}, Hana Tomaskova^a, Richard Cimler^b, Jitka Kuhnova^b, Jan Slegre^b

^a Faculty of Informatics and Management, University of Hradec Kralove, Hradec Kralove, Czech Republic

^b Faculty of Science, University of Hradec Kralove, Rokitanskeho 62, Hradec Kralove 50003, Czech Republic

^c Faculty of Information Technology, Ho Chi Minh City University of Technology (HUTECH), Ho Chi Minh City, Viet Nam

^d DaSCI Andalusian Institute of Data Science and Computational Intelligence, University of Granada, Granada, Spain

^e Faculty of Software and Information Science, Iwate Prefectural University, Iwate, Japan

ARTICLE INFO

Article history:

Received 2 December 2019

Received in revised form 28 March 2020

Accepted 14 May 2020

Available online 19 May 2020

Keywords:

Disordered breathing
Ballistocardiography
Cartan curvature
Convolutional neural networks
Computer-aided diagnostic
Tensometers

ABSTRACT

Sleep-related breathing disorders are diseases related to pharyngeal airway collapse. It can lead to several health problems such as somnolence, poorer daytime cognitive performance, and cardiovascular morbidity and mortality. However, computer-aided diagnostic (CAD) tools play a very important role in the detection of breathing disorders. It is possible to measure breathing activity, but most approaches require some type of device placed on the human body. This paper proposes a novel methodology of an unobtrusive CAD system to the breathing disorder detection. Unobtrusive approach is ensured by ballistocardiography (BCG) sensors located on the measured bed. The significant pieces of information from the signals are extracted by Cartan curvatures. Thereafter, important features are separated from individual samples as an input to our 9-layer deep convolutional neural network. We achieved an average accuracy of 98.00%, sensitivity of 94.26%, and specificity of 99.22% on 4009 regular and 1307 disordered breathing samples.

© 2020 Elsevier Inc. All rights reserved.

1. Introduction

Breathing disorders are common sleep-related problems that affect the entire population (irrespective of gender or age) of a major group of individuals who suffer from obesity or are overweight. These disorders manifest via pharyngeal airway collapse, preventing regular breathing during sleep. Hence, patients suffer from somnolence, reduced daytime cognitive performance, and cardiovascular morbidity and mortality [1]. Disordered breathing includes sleep apnea and nocturnal hypoventilation. Sleep apnea is induced by an obstruction in the upper respiratory tract, and the breathing effort is maintained and nocturnal hypoventilation causes shallow and slowed breathing where the airflow is less than the actual requirements of the body [2].

To detect breathing disorders [3,4], computer-aided diagnostic (CAD) techniques can be implemented in many feasible approaches, including different ways of measurements and different type of sensors. The first group of approaches is based on electrocardiogram (ECG) devices and works on the principle of measuring the projection of the heart polarization vector. It is measured via two or three electrodes placed on the human body, where multiple electrodes have a better signal-to-noise

* Corresponding author at: Faculty of Information Technology, Ho Chi Minh City University of Technology (HUTECH), Ho Chi Minh City, Viet Nam.
E-mail address: dalibor.cimr@uhk.cz (D. Cimr).

ratio [5]. Another complex practice of ECG measuring is via 10 electrodes used by 12-lead ECG systems used commonly in arrhythmia detection [6]. Various articles over the past five years have focused on breathing disorder diagnosis from ECGs [1,7–13].

A. R. Hassan [1] presented normal inverse Gaussian (NIG) modeling in the tunable-Q factor wavelet transform (TQWT) domain. It forms a CAD system on single-lead ECG signals for sleep apnea diagnosis. First, TQWT decomposes the ECG signal segments, and corresponding NIG parameters are computed from each of the sub-bands. Thereafter, the adaptive boosting approach is used as a classifier on intuitively, statistically, and graphically selected features. [7] Proposed an SVM and random forest classifiers for breathing disorder detection via heart rate variability, which is widely accepted as a characteristic of sleeping apnea. They used the principal component analysis method for feature extraction. In the task of classification, a random forest with feature reduction is the optimal approach to compare accuracy, sensitivity, and specificity of the model [14].

The second type of sensors that can be used for breathing disorder detection are ballistocardiography (BCG) tensiometers. Specifically, BCG is a non-invasive method for body micro-movement detection caused by heart activity and blood flow in large arteries. Compared with ECG, BCG can provide significantly more information on the physical state of the cardiovascular system. Another advantage of BCG is that it is an unobtrusive method of measurement, as it eliminates the need for placing sensors directly on the human body to collect information [15].

In [16], a novel approach was proposed for detecting a long-term heartbeat cycle length. They measured BCG and ECG concurrently to assess the correlation between the beat-to-beat cycle of both types of sensors. The correlation of the length of a cycle was 0.95 with an absolute difference in the cycle length of 4 ± 72 ms. A piezoelectric foil sensor was used, and individuals were examined in a prone position on their back, which was necessary to achieve good results. In [17], an algorithm was proposed for the task of separating cardiac and respiratory components with noise reduction on the heart rate and respiration components of BCG signals. This was performed via the locally projective noise reduction (LPNR) algorithm for denoising deterministic chaotic time series. It is applied to signals that are not cleanly deterministic such as physiological time series like ECG, BCG and EEG. In another study [18], overnight polysomnography and ballistocardiography recording pairs were collected from patients with and without nocturnal hypoxemia. Regression analysis indicated an average accuracy of 96.5%. Sadek et al. [19] evaluated the capacity of the microbend fiber optic sensors to monitor heart rate and respiration in a noninvasive manner. Additionally, they tested discrimination between shallow and no breathing. The approach achieved a high correlation between the heart rate and breathing rate of 0.96 and 0.78. However, the proposed sensor provided extremely low sensitivity of $24.2 \pm 12.81\%$ and specificity $85.88 \pm 6.01\%$. Liu et al. [20] examined the detection of obstructive sleep apnea. Their algorithm first preprocessed raw BCG data and located potential event segments by detecting arousals. Thereafter, the distribution of each potential event into three phases and the selection of features to detect respiratory patterns was performed. Subsequently, they used a backpropagation (BP) neural network to classify the events into apnea and non-apnea classes. The experimental results based on a real BCG data-sheet revealed that the accuracy, recall, and AUC corresponded to 94.6%, 93.1%, and 95.1%, respectively. Zhao et al. [16] used BCG signals to detect variations in the heart rate, which they associated with sleep apnea syndrome. They applied wavelet decompositions extraction to analyze the BCG signal to obtain the heartbeat interval. The features were used as inputs to the support vector machine classification model. Experimental results on 42 subjects with 5-fold cross-validation achieved a 90.46% precision rate and 88.89% recall rate. In another related study [21], the signals of five sensors and their placement combinations for measuring of a sleeping person were compared from the perspective of their measurement sensitivities and waveform quality. The study concluded that heartbeat and respiration parts are optimally represented in the signals measured with mattress force sensors.

In a previous study [22], a novel approach was presented to recognize the form of breathing (independent of body position) by using BCG sensors. The signals were processed via Cartan curvature, and pulse arrival time related to human respiration and blood pressure were extracted via the Moens-Korteweg relationship [23]. Subsequently, breathing anomalies were detected between heartbeats measured by ECG and pulse arrival times. The delays of heartbeat and pulse wave were used as the inputs to train a convolutional neural network classifier. The novelty of the paper consists of two main objectives. The first one is the independence of the position of the human body on the bed from the mutual position of the sensors. The second one is the study of advanced physiological phenomena rather than calculating just heart rate. Sensors were placed at the legs position part of the bed for measuring the micro-movements of furniture caused by movements in the human body. In [24] authors study changes in BCG signals with different positions of the measured individual however their goal was only to estimate the heart rate without any other phenomena physicians may be interested in (such as pulse wave velocity, elastic properties of the aorta, etc.). In [25] authors present a novel approach to estimate heart rate from BCG signals with beat-to-beat precision and they recognized phase shift between BCG and ECG signal however, in such work there is no physiological explanation of this phenomena. Using Cartan curvatures, pulse arrival time t_p could be able calculated. It is directly related with blood pressure through Moens-Korteweg relation by formula (1):

$$BP = a \ln \frac{b}{(dt_p - c)^2} - 1, \quad (1)$$

where BP represents the blood pressure and a, b, c and d are constants dependent on the human physiology [23].

Usually, when using CNN (convolution Neural Network) based architecture, it requires significant preprocessing analysis for data. After Cartan curvature computation, it was necessary to detect a pulse wave in the signal to recognize its relation-

ship with breathing patterns. This detection also needs some considerable computation time. Moreover, differences in delays of pulse waves between individual heartbeats are in milliseconds, meaning the model is very sensitive and leads to issues in detection with a person lying on their side and not on the back where the signal to noise ratio is better.

In this study, a new approach of processing ballistocardiography signals and classification of breathing disorders is introduce. The system worked with four ballistocardiography sensors placed on the corners of a measuring bed. Using new optimal formulas of Cartan curvatures, it is feasible to recognize breathing problems without dependencies on body position during measuring (Cartan curvatures are invariant under rotational or translational changes of the subject), and obtain clearer results compared to other works. The study commences with a presentation of the classical method for R peak detection from the ECG signal. Subsequently, it continues with a formulation of Cartan curvatures and a description of the information, which can be found in them. The final part of data processing is input preparation for our CNN classifier. Finally, the paper presents results and a discussion related to other articles from branch and conclusion.

2. Materials and methods

2.1. Data description

The BCG samples used in this work was collected from public Mendeley database [26] and measured in laboratory of University of Hradec Kralove. The BCG sensor dataset is obtained from twenty tested individuals. The subjects were 11 men aged 23 to 33 years, and 9 women aged 24 to 65 years, lying on the bed with sensors placed on bed legs. The 20 people are enlisted with clear information on their preferences in **Table 1**. The schedule of measuring was in two types (V1 and V2) described in **Table 2**. Every breath-holding was done for the time of the approximately 30 s, where several samples were ignored for the ambiguity of classification. Measurement of a force plate in the form of a bed is used. The force plate had four tensometers embedded in its four corners. Each tensometer could measure the force in three orthogonal directions with a precision of up to 0.1 N. Therefore, it is feasible to obtain 12 force signals. The ECG signal is measured simultaneously with the force measurement. All the signals are registered using a 24-bit AD converter with a sampling rate of 1 kHz. The data are then stored on a computers hard drive. This yielded 13 time-series where 12 force signal time-series represents a coordinate projection of a 12-dimensional curve parametrized by time. Data annotation is made manually based on measuring observation. Every measuring is representing by matrix, where row are individual samples every 1 ms and 14 columns are one value of data loading (0 correct, 1 incorrect), twelve force signals and ECG value.

2.2. R peak detection

To detect the R peak in an ECG signal, a simple algorithm consisting of three parts was used. First, it is necessary to smooth raw data with a band-stop filter at a frequency of 50 Hz. This is necessary to attenuate the electromagnetic noise generated by electrical sockets. To filter the data, a simple moving average with 20ms window size was applied to the raw data. Subsequently, calculation of the z-score of the smoothed ECG signal was performed by calculating the mean value and standard deviation of the smoothed data. The next part involved the subtraction of the mean value from the smoothed data, and the result was divided by the square root of standard deviation. Finally, the detection of Rpeak was performed by searching for local maxima. This function automatically determines relevant peaks with defined properties. Specifically, the condition for minimum peak distance equal to 350ms was used.

The result of the algorithm is the array of time positions of R peaks in the raw data, which is shown in **Fig. 1**. The process can also be performed on a microchip for real-time analysis, where the z-score calculation is performed on a small window with a size of at least 2000ms to ensure that at least one heartbeat is present.

Table 1
List of individuals with their preferences.

No. of subject	Sex	Age	Schedule	No. of subject	Sex	Age	Schedule
1	male	26	V1	11	female	62	V1
2	male	26	V2	12	female	35	V2
3	male	23	V1	13	female	65	V1
4	male	28	V2	14	female	35	V2
5	male	28	V2	15	female	35	V2
6	male	28	V1	16	female	35	V2
7	female	24	V1	17	female	28	V1
8	male	30	V1	18	male	30	V2
9	female	36	V1	19	male	33	V2
10	male	30	V2	20	male	33	V2

Table 2
Schedules of measuring.

V1 schedule		V2 schedule	
Time (s)	Event	Time (s)	Event
0	start of measuring on back	0	start of measuring on back
60	breath-holding during inhalation	60	breath-holding during inhalation
120	breath-holding during inhalation	150	breath-holding during exhalation
180	breath-holding during exhalation	240	breath-holding during inhalation
240	breath-holding during exhalation	330	breath-holding during exhalation
300	underlay of legs for position change	420	end of measuring
420	turning on the side		
480	breath-holding during inhalation		
540	breath-holding during inhalation		
600	breath-holding during exhalation		
660	breath-holding during exhalation		
720	end of measuring		

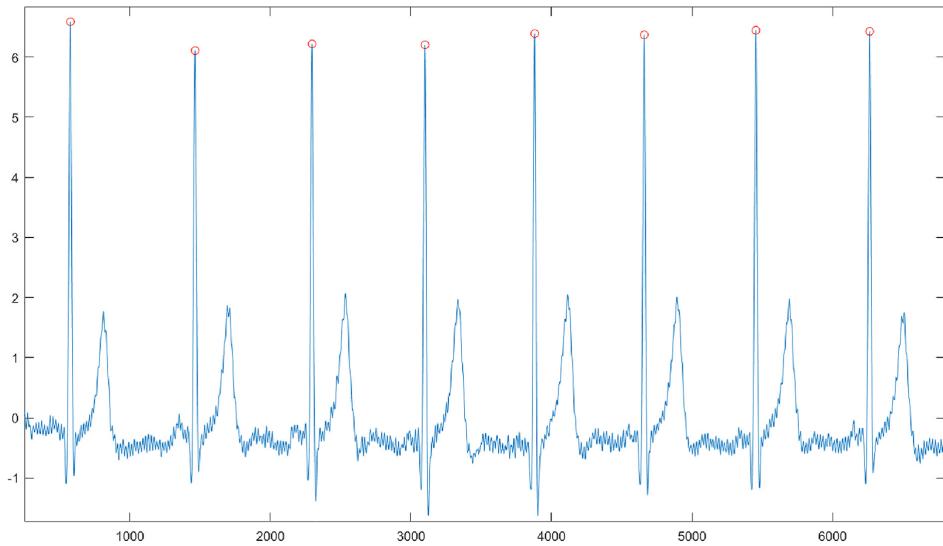


Fig. 1. Maxima of ECG (x: time/[ms]. y: AU, red dots—maxima, blue—ECG signal).

2.3. Cartan curvatures

In signal preprocessing, the amplification of studied phenomena is an important task. In this type of amplification, processes not related to breathing disorders were neglect by using Cartan curvatures. As known from differential geometry, Cartan curvatures are invariant under the action of group $SO(3) \times \mathbb{R}^n$, i.e. under the rotation and translation in Euclidean space [27]. This is also the case in the present study, in which the patient lying on a bed was measured for the detection of breathing disorders. First, the process should be measured irrespective of the rotation or movement of the body on the bed. Cartan curvatures exhibit properties that result from its mathematical expression. Collective movement (movement of the body parts generated by the BCG such as the movement of the whole skeleton) generates collective parts of the 12 force signals (i.e. parts where all of the signals are changing in a similar way). In chaotic parts of the signals (where the human body is moving in a random way or where there are small discrepancies among individual signals) Cartan curvatures increase, while in collective parts of the signals Cartan curvatures decrease hence neglect these collective parts. To express the discrepancies, the Cartan curvature is first calculated, because higher order curvatures contain derivatives of higher orders, thereby also amplifying mechanical noise. Derivatives indicate this difference, because the system deals with discrete signal and subtractions of noisy data increases random noise. Only the first Cartan curvature following the algorithm has been used for calculation purposes, which is more efficient in term of time than the approach used in a previous study [22].

The 12 force signals were treated as a twelve-dimensional discrete-time parameterized curve C , where each signal is expressed as $C_i(t)$, and where t denotes discrete-time and i runs from 1 to 12. Discrete time moments are denoted as t_1, t_2, \dots, t_n , where for every possible $j : t_{j+1} - t_j = \frac{1}{f}$, where f denotes sampling frequency (for our case $f = 1000\text{Hz}$). By derivation $C_i(t)$, a new curve is constructed wherein the derivative for $j > 1$ is as follows formula (2):

$$C'_i(t_j) = C_i(t_j) - C_i(t_{j-1}). \quad (2)$$

Such method was used to obtain the $n - 1$ points for the derivative of the curve defined with n points. Therefore, there will be always deleted either the first point of the original curve when using the first derivative or first and second point of the original curve and first point of the first derivative when using the second derivative.

The calculation of first Cartan curvature is as follows. First, $C'_i(t)$ is computed for every i using the aforementioned method. Subsequently, $C''_i(t)$ is computed for every i using the aforementioned method, i.e. the derivative of $C'_i(t)$. For every individual t , the norm of vector $(C'_1(t), C'_2(t), \dots, C'_{12}(t))$, is computed i.e. the vector of norms $N(t)$ is obtained where its first term is as in formula 3:

$$\sqrt{C'_1(t_1)^2 + C'_2(t_1)^2 + \dots + C'_{12}(t_1)^2}. \quad (3)$$

Subsequently, cumulative sum of $N(t)$ is computed, i.e. vector $CN(t)$ is obtained where

$$CN(t_1) = N(t_1), \quad (4)$$

$$CN(t_j) = CN(t_{j-1}) + N(t_j). \quad (5)$$

$CN'(t)$ is computed by using the aforementioned method and $CN'(t)^2$ is computed for every point of $CN'(t)$. For every individual t and for i from 1 to 12 $C''_i(t_j)$ is divided by $CN'(t_j)^2$, and the vectors in formula 6 is obtained:

$$D_i(t) = \frac{C''_i(t)}{CN'(t)^2}. \quad (6)$$

For each individual t , the norm of vector $(D_1(t), D_2(t), \dots, D_{12}(t))$ is computed, i.e. the vector of norms $DN(t)$ is obtained where first term is as follows:

$$\sqrt{D_1(t_1)^2 + D_2(t_1)^2 + \dots + D_{12}(t_1)^2}. \quad (7)$$

Finally, for every individual t , the vector $\kappa(t) = \frac{1}{DN(t)}$ is obtained. The $DN(t) \neq 0$ for every t was initially checked. If this holds, such particular point is omitted without losing any important information due to the high sampling rate of a discrete signal. Thus, $\kappa(t)$ is equal to first Cartan curvature in time t .

In a manner similar to ECG signals, the 12 possible leads are measured [28] as described by Einthoven's triangle [29], where each lead measures different projections of the polarization vector, and differences between each curvature consist of the number of derivations needed for their computation related to torsion in Euclidean space. When curvature increases, the number of derivatives required for the description increases, and more noise enters the system. This indicates that the use of other curvature other than the first (as in this study) cannot work in classifications or networks that need to be trained on a different type of input.

An example of compute Cartan curvature is shown on Fig. 2, where in 300ms, R peak trigger is shown and from 450ms to 800ms is a range of important patterns. In a typical cardiac cycle, [30] the most important events occur between approximately 150 and 500ms after the R peak. The aortic valve opens at approximately 80ms, and closes approximately 300ms

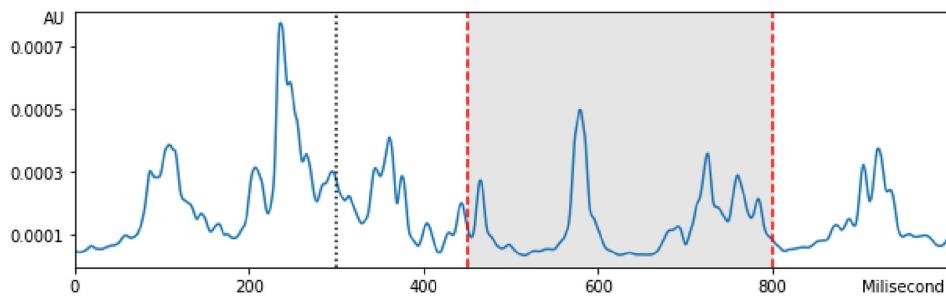


Fig. 2. Example of Cartan curvature with important section.

after the R peak. The pulse wave velocity through the aorta is approximately 30 m/s. The important reflections of the pulse wave emerge at aortic arch (in the starting part of the aorta, right next to aortic valve) and at the bifurcation in the abdomen (ending part of the aorta). The distance from the aortic valve to the bifurcation is approximately 60 cm. This implies that if the pulse propagates immediately after the aortic valve opening, it arrives at the bifurcation in approximately 20 ms. However, the rapid ejection phase of the cardiac cycle takes approximately 100 ms, and thus, the region between 150–500 ms after the R peak is sufficient to record all the important reflections of pulse wave related to changes in blood pressure that is relative to changes in breathing.

2.4. Classifier input preparation

For the CNN classifier, it is recommended to prepare the data range to a known form [40]. There are several methods for this task, such as Daubechies-6 [31,32] and Z-score normalization [33,32]. These methods are also used for signal denoising. However, a deep analysis of data for simple normalization is presented in [5]. Here, it has been verified that the right thresholds in combination with a well-formed network architecture could provide good performance. Hence, deep analysis of Cartan curvatures is performed and the normalization formula is as shown in formula 8:

$$x = \begin{cases} 4 \cdot 10^{-4}, & x > 4 \cdot 10^{-4}, \\ x, & x \leq 0 \end{cases} \quad (8)$$

where x denotes the value of the sample and $4 \cdot 10^{-4}$ denotes the threshold selected on the base of an expert estimate. Subsequently, 30 consecutive 350-ms parts described in Section 2.3 are sorted to the two-dimensional input of the classifier. The input is converted to a grayscale image and resized to 30×150 to obtain an optimal input in case of algorithm asymptotic complexity. Several examples of network inputs are shown in Fig. 3, where regular breathing is placed at the top and disorders at the bottom. Moreover, for the understanding of expert estimation, Fig. 4 shows a difference of inputs with a distinct threshold. It is obvious that the smaller value extract too much information about micro-movements and higher value loses important information for the detection of breathing disorders. This expert estimation is constant for all subjects so it is a part of the system and it is not needed to perform this estimation again.

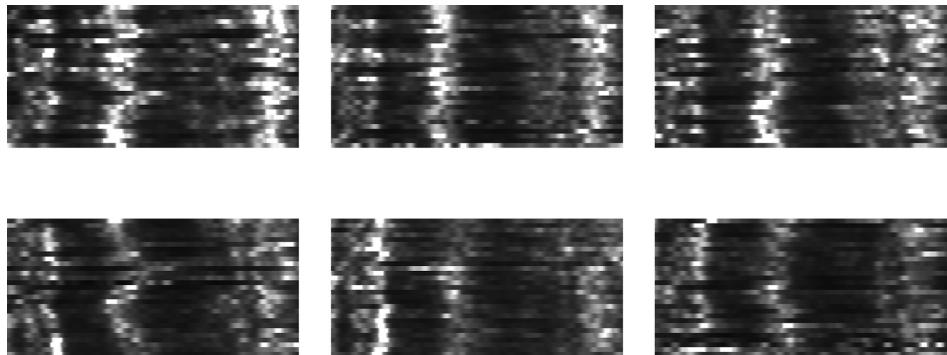


Fig. 3. Examples of classifier input (Top: regular breathing; Bottom: disorder breathing).

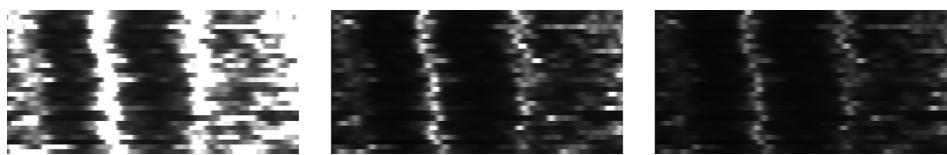


Fig. 4. Examples of distinct threshold (Left: $2 \cdot 10^{-4}$; Center: $4 \cdot 10^{-4}$; Right: $6 \cdot 10^{-4}$).

2.5. Experiment design

The proposed CNN architecture was trained on a computer with Intel Core i7 2.20 GHz processor, 16 GB RAM and graphical unit GeForce GTX 1060 with 6 GB memory. The complete system is developed in Python 3 programming environment. The average time per one epoch is achieved as 1.72 s on 5758 training data and 2469 validating samples, and evaluation time across 916 samples is 0.09 s. In the case of using CPU, average time of training process per one epoch is 19.52 s and evaluation process per cross validation is completed after 1.15 s.

3. Classification

3.1. Architecture

The CNN architecture is mainly constructed from two types of layers: convolutional and pooling. The convolutional layer contains a set of convolutional kernel filters of the same size through which the convolution operation is performed on the layer's input data. The convolution layer filter is a grid of the same (or smaller) dimension and smaller size containing discrete numbers. The pooling layer optimizes the number of hidden neurons from the previous layer. In a manner similar to the convolution layer, the level of optimization is based on the kernel size and stride [34].

In our model, convolution operations with a kernel size of 7×3 on 30 filters are implemented in the first layer. Thereafter, the max-pooling layer follows up, where the biggest value on the kernel with size 2×2 inputting to the next layer. The next part is another convolutional layer with a kernel size of 5×2 with 20 filters followed by the second max-pooling layer with the same kernel size as in the previous case. The same sequence of convolutional and max-pooling with the same kernel size and stride, such as in the third and fourth layer, is designed on the fifth and sixth layers. All convolutional layers use stride size 1 and max-pooling use stride 2. The output of the last max-pooling layer is 20 filters containing 30 neurons in a resolution of 15×2 . The neurons are input to the first fully connected layer with 30 neurons. It represents the part of the architecture with the most number of inner parameters, 18030 concretely. In the next step, another fully connected layer with 25 neurons is designed. Finally, the last fully connected layer contains two neurons representing normal and disordered breathing as a prediction of the system. The complete model is summarized in Fig. 5 graphically and tabulated in Table 3.

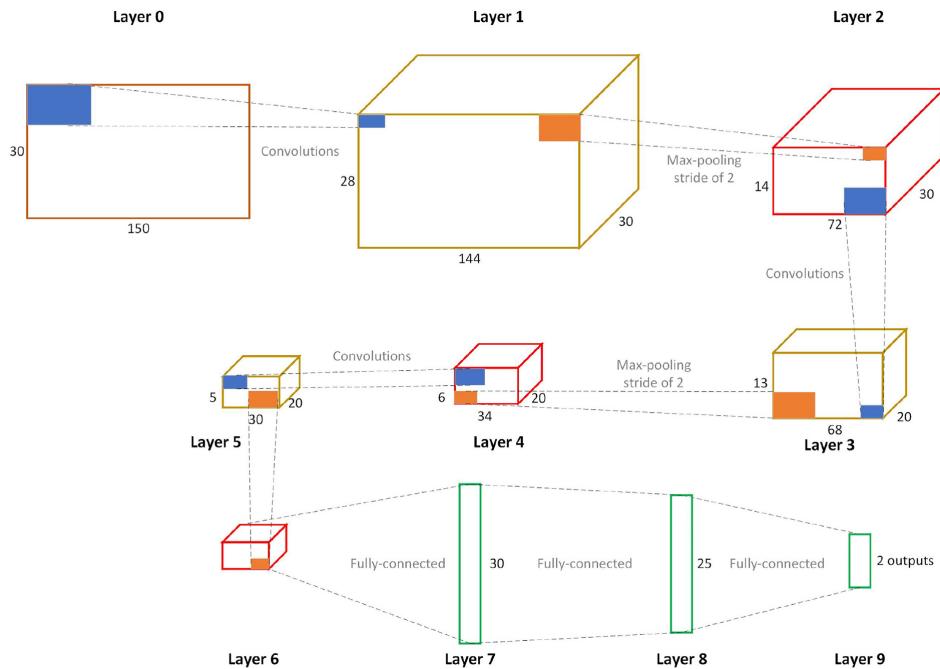


Fig. 5. Architecture of the proposed CNN model.

Additionally, dropout layers and rectifier linear unit (Relu) layers are used to prevent the problem of optimization and over-fitting [35]. The Relu layer is designed as an activation function for all convolutional layers and dropout layer is implemented following the first fully connected layer with a value of 0.3. Finally, a normalization function is necessary for a suitable result, where the normalized exponential function termed as the softmax function is used. This guarantees that the summarization of the prediction of outputs is equal to 1.

3.2. Training and testing

The input dataset is first divided by stratified 10-fold cross-validation strategy [36]. It is a common method to prove model performance where data are separated into the same equally large n groups. One group is used for the validation of the model and the rest nine groups are used for the training and testing process. Training and testing parts are percentages divided as 70% and 30%, respectively. In the training process, the number of used epochs is 30. It means that each training sample is used one time for weights and biases updating in each epoch.

Furthermore, another important parameter of the neural network is the learning rate. The learning rate represents the size of the step towards minimizing the cost function of the model. In our case, the value of the learning rate is not constant for the whole training process. The parameter on $1 \cdot 10^{-3}$ was selected for first 15 epochs and $3 \cdot 10^{-4}$ for the rest. The reason why the value of the learning rate is changed after 15 epochs is related to the training accuracy stuck. It was necessary to reduce the value of the learning rate for the further learning process. The next decreasing of the learning rate value has not been done because it has not brought any further classification improvement.

4. Results

The classification results of the proposed system are shown in Table 4. It can be observed that the positive predicted values (PPVs) for the normal class is 97.54%, and 98.14% for the disorder class. This indicates that in comparison with normal breathing, the probability of correct detection for the disorder class is fractionally higher. Furthermore, it is observed that 6.74% of normal samples are incorrectly classified as disorders, and 0.78% of problematic sequences are erroneously classified to the normal class. In summary, it is concluded that the accuracy of the system is 98.00%.

The receiver operating characteristics (ROC) curve for the proposed classifier is shown in Fig. 6 on the left side. The ROC represents the performance of the proposed classifier relative to the false accept rate (FAR) and false rejection rate (FRR). The main requirement for classifier is for the ROC curve to be as far as possible from the dashed blue line. The accuracy is measured by the area under the ROC curve. In our case it is 0.995, where the optimal solution is equal to 1. The second type of classifier performance representation is the detection error tradeoff (DET), which is shown on Fig. 6 on the right side. The point of intersection of the DET curve and blue dash line is defined as the equal error rate (EER). When comparing it with the ROC curve, an ideal situation exhibits an EER equal to zero. EER value of approximately 3.21% was achieved which proves the quality of presented solution.

5. Discussion

Typically, CAD systems are implemented with preprocessing, feature extraction, feature selection, and classification tasks in this order [37]. Currently, feature selection is generally part of the classifier model, e.g. values of weights and biases in the neural network. In this work, the feature extraction has not been used. This is provided by the right set of CNN architecture, where the convolution operation operates in a manner similar to feature extractors during a training process. This guarantees the reduction of redundancy and asymptotic complexity of the designed system, with respect to the time needed for problem-solving.

A comparison of system performance with other articles is shown in Table 5. A significant difference is the type of sensors used for data measuring. A few studies built a system on ECG signals for the detection of sleeping apnea. Others used a combination of ECG as a complementary device to BCG, or only a BCG measuring approach. Thus, BCG sensors are placed related

Table 3
Details of the CNN structure.

Layers	Type	No. of output neurons	Kernel size	Stride
0-1	convolution	144 × 28 × 30	7 × 3	1
1-2	max-pooling	72 × 14 × 30	2 × 2	2
2-3	convolution	68 × 13 × 20	5 × 2	1
3-4	max-pooling	34 × 6 × 20	2 × 2	2
4-5	convolution	30 × 5 × 20	5 × 2	1
5-6	max-pooling	15 × 2 × 20	2 × 2	2
6-7	fully connected	30	-	-
7-8	fully connected	25	-	-
8-9	fully connected	2	-	-

Table 4
Overall classification.

O/P	Normal	Disordered	Acc (%)	PPV (%)	Sen (%)	Spec (%)
Normal	1232	75	98.00	97.54	94.26	99.22
Disordered	31	3978	98.00	98.14	99.22	94.26

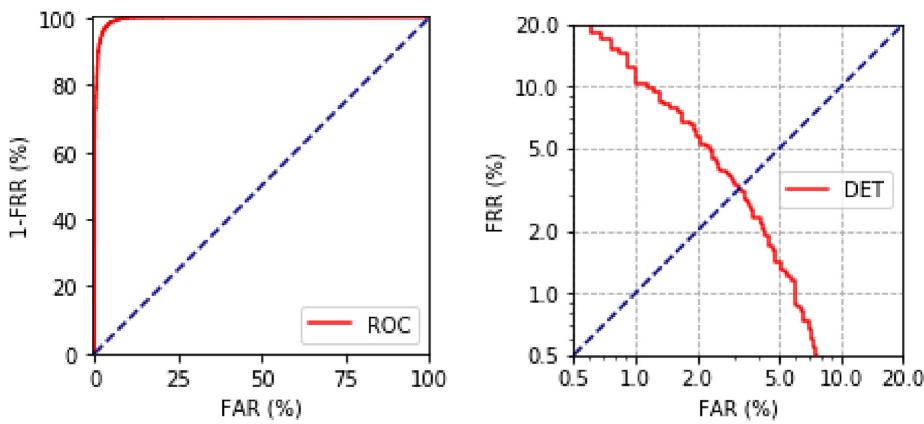


Fig. 6. ROC and DET curve.

Table 5
Selected studies of an detection of breathing disorders.

Author	Approach	Classification	Types of sensors	Performance (%)
Current	Cartan curvatures with normalization	CNN	BCG	Acc = 98.00 Sen = 94.26 Spec = 99.22
[22]	Cartan curvatures with CWT on pulse arrival	CNN	BCG	Acc = 89.35 Sen = 86.35 Spec = 91.22
[19]	Adaptive thresholding	Statistically	BCG	Sen = 24.24 Spec = 85.88
[20]	Threshold-based division	BPNN	BCG	Acc= 94.6
[39]	STC-Min	SVM	BCG	Acc = 90.46
[17]	Locally Projective Noise Reduction	Heuristic	BCG	Acc = 92.7 Sen = 99.5
[1]	Tunable-Q factor wavelet transform	Adaptive boosting	ECG	Acc = 87.33 Sen = 81.99 Spec = 90.72
[7]	Linear and non-linear features	Random Forest	ECG	Acc = 91.77 Sen = 89.53 Spec = 93.43

to body position, such as piezoelectric foil under the body positioned on the back. In the proposed approach, BCG sensors are positioned into measuring bed; hence, the signals processed by Cartan curvatures are independent of body position.

Aside from the complete unobtrusiveness of the system, there are two major advantages in comparison with recent studies. Cartan curvatures contain information not only about pulse arrival time but also about the complex hemodynamics of the person [38]. In previous work [22], the focus has been on the pulse arrival time at one specific point, but in this work the work is extended in employing CNN at the whole beat-to-beat Cartan curvatures. These could open various topics in the future with a focus on the study of Cartan curvatures without the use of ECG thus enabling full automation of the system and studying other aspects of human hemodynamics. Another advantage in the study of whole Cartan curvatures is in the possibility of achieving higher precision of the system with fewer errors due to falsely detected pulse arrival times. This method works with different positions of measured person. This is indirect proof that Cartan curvatures are invariant under the rotational and translational changes of the human body on the bed. Without the need to find pulse arrival time precisely the computational power needed to preprocessing has also decreased.

The disadvantage of our system still lies in the need for ECG signal being measured simultaneously. There is also an economical aspect since the system works with tensometers embedded in the bed which is not easily achievable in the home environment. Further studies should focus on implementing the precision of tensometers in a movable system with an aim to have a cheap device capable of measurement in the home environment.

6. Conclusion

In this study, a computer-aided detection system for breathing disorders was developed. The system worked with four ballistocardiography sensors embedded on the corners of a measuring bed. The proposed solution depends on novel optimal Cartan curvatures and data normalization based on expert estimation as a constant for all subjects. After data processing, a 9-layer deep CNN model is designed to recognize breathing problems. The achieved accuracy, sensitivity, and specificity are of 96.21%, 88.31%, and 98.69%, respectively.

Therefore, the proposed solution can effectively be deployed as a decision support system in a clinical environment, or as a health care system in the home for early warning of eventual problems. Future research should focus on eliminating the need for ECG to be measured simultaneously with a trigger calculated from BCG data. This will further improve the comfort of the measurement and can provide a wholly unobtrusive solution without necessitating any device on the human body. The system is proven to be functional however it requires several adjustments to the furniture in order to be placed in-home care because of the need for precise tensometers embedded in the legs of the bed. It means the system may be too expensive in its current state to be cost-effective. The importance of this paper is however in the proposed mathematical method which proved to be novel in BCG signal processing. Furthermore, mechanical data from BCG signals can contain more information about a patient's health condition. We also intend to focus on studying BCG in correlation with other well-known approaches to determine other types of diseases.

CRediT authorship contribution statement

Dalibor Cimr: Methodology, Software, Writing - original draft, Writing - review & editing, Visualization. **Filip Studnicka:** Conceptualization, Methodology, Software, Formal analysis, Writing - original draft, Writing - review & editing, Supervision. **Hamido Fujita:** Writing - review & editing, Conceptualization, Methodology, Visualization. **Hana Tomaskova:** Funding acquisition. **Richard Cimler:** Project administration. **Jitka Kuhnova:** Data curation, Investigation, Resources. **Jan Slegr:** Investigation, Data curation, Resources.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgements

The study is partially supported by the Faculty of Informatics and Management UHK specific research project 2107 "Computer Networks for Cloud, Distributed Computing, and Internet of Things II". Financial support of Faculty of Science, University of Hradec Kralove is also gratefully acknowledged.

References

- [1] A.R. Hassan, Computer-aided obstructive sleep apnea detection using normal inverse gaussian parameters and adaptive boosting, *Biomed. Signal Process. Control* 29 (2016) 22–30.
- [2] D. Orlikowski, H. Prigent, M.-A.Q. Salva, N. Heming, C. Chaffaut, S. Chevret, D. Annane, F. Lofaso, A. Ogna, Prognostic value of nocturnal hypoventilation in neuromuscular patients, *Neuromuscul. Disord.* 27 (4) (2017) 326–330.
- [3] A. Pregowska, K. Proniewska, P. van Dam, J. Szczepanski, Using lempel-ziv complexity as effective classification tool of the sleep-related breathing disorders, *Computer Methods Programs Biomed.* 182 (2019) 105052.
- [4] W. Faizal, N. Ghazali, I.A. Badruddin, M. Zainon, A.A. Yazid, M.A.B. Ali, C. Khor, N.B. Ibrahim, R.M. Razi, A review of fluid-structure interaction simulation for patients with sleep related breathing disorders with obstructive sleep, *Computer Methods Programs Biomed.* 105036 (2019).
- [5] H. Fujita, D. Cimr, Computer aided detection for fibrillations and flutters using deep convolutional neural network, *Inf. Sci.* 486 (2019) 231–239.
- [6] Q. Yao, R. Wang, X. Fan, J. Liu, Y. Li, Multi-class arrhythmia detection from 12-lead varied-length eeg using attention-based time-incremental convolutional neural network, *Inform. Fusion* 53 (2020) 174–182.
- [7] B.B. Rekha, A. Kandaswamy, R. Ramanathan, Ensemble classification approach for screening of obstructive sleep apnoea using ecg, *Int. J. Biomed. Eng. Technol.* 27 (1–2) (2018) 139–150.
- [8] C. Varon, A. Caicedo, D. Testelmans, B. Buyse, S. Van Huffel, A novel algorithm for the automatic detection of sleep apnea from single-lead eeg, *IEEE Trans. Biomed. Eng.* 62 (9) (2015) 2269–2278.
- [9] N.M. Ghahjaverestan, M.B. Shamsollahi, D. Ge, A.I. Hernández, Switching kalman filter based methods for apnea bradycardia detection from ecg signals, *Physiological Measur.* 36 (9) (2015) 1763.
- [10] T. Shimizu, A. Yoshihisa, S. Iwaya, S. Abe, T. Sato, S. Suzuki, T. Yamaki, K. Sugimoto, H. Kunii, K. Nakazato, et al, Cyclic variation in heart rate score by holter electrocardiogram as screening for sleep-disordered breathing in subjects with heart failure, *Respiratory Care* 60 (1) (2015) 72–80.
- [11] D. Dey, S. Chaudhuri, S. Munshi, Obstructive sleep apnoea detection using convolutional neural network based deep learning framework, *Biomed. Eng. Lett.* 8 (1) (2018) 95–100.
- [12] P. Fontana, N.R.A. Martins, M. Camenzind, M. Boesch, F. Baty, O.D. Schoch, M.H. Brutsche, R.M. Rossi, S. Annaheim, Applicability of a textile ecg-belt for unattended sleep apnoea monitoring in a home setting, *Sensor.* 19 (15) (2019) 3367.
- [13] T.S. Kumar, V. Kanhangad, Automated obstructive sleep apnoea detection using symmetrically weighted local binary patterns, *Electron. Lett.* 53 (4) (2017) 212–214.
- [14] A. Erdem, O. Dogan, O. Yontar, K. Epozturk, M. Ozlu, S. Ozturk, S. Ayhan, F. Erdem, M. Yazici, I. Akkurt, et al, The pure effects of obstructive sleep apnea syndrome on cardiac autonomic functions: heart rate turbulence analysis, *Eur. Rev. Med. Pharmacol. Sci.* 17 (20) (2013) 2778–2783.

- [15] O.T. Inan, P.-F. Migeotte, K.-S. Park, M. Etemadi, K. Tavakolian, R. Casanella, J. Zanetti, J. Tank, I. Funtova, G.K. Prisk, et al, Ballistocardiography and seismocardiography: A review of recent advances, *IEEE J. Biomed. Health Inform.* 19 (4) (2015) 1414–1427.
- [16] M.D. Zink, C. Brüser, B.-O. Stüben, A. Napp, R. Stöhr, S. Leonhardt, N. Marx, K. Mischke, J.B. Schulz, J. Schiefer, Unobtrusive nocturnal heartbeat monitoring by a ballistocardiographic sensor in patients with sleep disordered breathing, *Sci. Rep.* 7 (1) (2017) 13175.
- [17] Y. Yao, C. Brüser, U. Pietrzik, S. Leonhardt, S. van Waesen, M. Schiek, Model-based verification of a non-linear separation scheme for ballistocardiography, *IEEE J. Biomed. Health Inform.* 18 (1) (2014) 174–182.
- [18] S.H. Hwang, Y.J. Lee, D.-U. Jeong, K.S. Park, et al, Oxygen desaturation index estimation through unconstrained cardiac sympathetic activity assessment using three ballistocardiographic systems, *Respiration Cardiol.* 92 (2) (2016) 90–97.
- [19] I. Sadek, E. Seet, J. Biswas, B. Abdulrazak, M. Mokhtari, Noninvasive vital signs monitoring for sleep apnea patients: a preliminary study, *IEEE Access* 6 (2018) 2506–2514.
- [20] F. Liu, X. Zhou, Z. Wang, T. Wang, H. Ni, J. Yang, Identifying obstructive sleep apnea by exploiting fine-grained bgc features based on event phase segmentation, in: 2016 IEEE 16th International Conference on Bioinformatics and Bioengineering (BIBE), IEEE, 2016, pp. 293–300.
- [21] A. Vehkaoja, A. Kontunen, J. Lekkala, Effects of sensor type and sensor location on signal quality in bed mounted ballistocardiographic heart rate and respiration monitoring, in: Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE, IEEE, 2015, pp. 4383–4386.
- [22] D. Cimr, F. Studnicka, Automatic detection of breathing disorder from ballistocardiography signals, *Knowl.-Based Syst.* 104973 (2019).
- [23] E. Pinheiro, O. Postolache, P. Girão, Non-intrusive device for real-time circulatory system assessment with advanced signal processing capabilities, *Measure. Sci. Rev.* 10 (5) (2010) 166–175.
- [24] M. Liu, F. Jiang, H. Jiang, S. Ye, H. Chen, Low-power, noninvasive measurement system for wearable ballistocardiography in sitting and standing positions, *Comput. Ind.* 91 (2017) 24–32.
- [25] G. Shen, R. Ding, M. Yang, D. Han, B. Zhang, An elastic manifold learning approach to beat-to-beat interval estimation with ballistocardiography signals, *Adv. Eng. Inform.* 44 (2020) 101051.
- [26] F. Studnicka, Ballistocardiography with breathing disorders, mendeley Data, v1, URL:<https://data.mendeley.com/datasets/9fmfn6kfn7/1> (2020).
- [27] J. Gallier, Geometric methods and applications: for computer science and engineering, vol. 38, Springer Science & Business Media, 2011.
- [28] D. Corrado, A. Pelliccia, H. Heidbuchel, S. Sharma, M. Link, C. Basso, A. Biffi, G. Buja, P. Delise, I. Gussac, et al, Recommendations for interpretation of 12-lead electrocardiogram in the athlete, *European Heart J.* 31 (2) (2009) 243–259.
- [29] F.T. Bennett, K.R. Bennett, A.K. Markov, Einthoven's triangle: lead errors and an algorithm for solution, *Ame. J. Med. Sci.* 329 (2) (2005) 71–77.
- [30] W.F. Boron, E.L. Boulpaep, Medical Physiology E-Book, Elsevier Health Sciences (2016).
- [31] U.R. Acharya, H. Fujita, M. Adam, O.S. Lih, V.K. Sudarshan, T.J. Hong, J.E. Koh, Y. Hagiwara, C.K. Chua, C.K. Poo, et al, Automated characterization and classification of coronary artery disease and myocardial infarction by decomposition of ecg signals: a comparative study, *Int. Sci.* 377 (2017) 17–29.
- [32] U.R. Acharya, H. Fujita, S.L. Oh, U. Raghavendra, J.H. Tan, M. Adam, A. Gertych, Y. Hagiwara, Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network, *Future Generation Computer Syst.* 79 (2018) 952–959.
- [33] U.R. Acharya, H. Fujita, O.S. Lih, Y. Hagiwara, J.H. Tan, M. Adam, Automated detection of arrhythmias using different intervals of tachycardia ecg segments with convolutional neural network, *Inform. Sci.* 405 (2017) 81–90.
- [34] L. Zhang, L. Zhang, B. Du, Deep learning for remote sensing data: a technical tutorial on the state of the art, *IEEE Geosci. Remote Sensing Mag.* 4 (2) (2016) 22–40.
- [35] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1–9.
- [36] R.O. Duda, P.E. Hart, D.G. Stork, et al, Pattern classification, *Int. J. Comput. Intell. Appl.* 1 (2001) 335–339.
- [37] Y. Hagiwara, H. Fujita, S.L. Oh, J.H. Tan, R. San Tan, E.J. Ciaccio, U.R. Acharya, Computer-aided diagnosis of atrial fibrillation based on ecg signals: a review, *Int. Sci.* 467 (2018) 99–114.
- [38] J. Kříž, P. Šeba, Force plate monitoring of human hemodynamics, *Nonlinear Biomed. Phys.* 2 (1) (2008) 1.
- [39] W. Zhao, H. Ni, X. Zhou, Y. Song, T. Wang, Identifying sleep apnea syndrome using heart rate and breathing effort variation analysis based on ballistocardiography, in: Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE, IEEE, 2015, pp. 4536–4539.
- [40] A. Hernandez-Matamoros, H. Fujita, H. Perez-Meana, A Novel Approach to Create Synthetic Biomedical Signals Using BiRNN, *Inf. Sci.* 541 (2020) 218–241.



Application of mechanical trigger for unobtrusive detection of respiratory disorders from body recoil micro-movements

Dalibor Cimr^a, Filip Studnicka^a, Hamido Fujita^{b,c,d,*}, Richard Cimler^a, Jan Slegr^a

^a Faculty of Science, University of Hradec Kralove, Rokitanskeho 62, Hradec Kralove 50003, Czech Republic

^b Faculty of Information Technology, Ho Chi Minh City University of Technology (HUTECH), Ho Chi Minh City, Vietnam

^c DaSCI Andalusian Institute of Data Science and Computational Intelligence, University of Granada, Granada, Spain

^d Regional Research Center, Iwate Prefectural University, Iwate, Japan

ARTICLE INFO

Article history:

Received 4 March 2021

Accepted 29 April 2021

Keywords:

Disordered breathing
Ballistocardiography
Cartan curvature
Convolutional neural networks
Mechanical trigger
Tensometers
Euclidean arc length

ABSTRACT

Background and Objectives Automatic detection of breathing disorders plays an important role in the early signalization of respiratory diseases. Measuring methods can be based on electrocardiogram (ECG), sound, oximetry, or respiratory analysis. However, these approaches require devices placed on the human body or they are prone to disturbance by environmental influences. To solve these problems, we proposed a heart contraction mechanical trigger for unobtrusive detection of respiratory disorders from the mechanical measurement of cardiac contractions. We designed a novel method to calculate this mechanical trigger purely from measured mechanical signals without the use of ECG. **Methods** The approach is a built-on calculation of the so-called euclidean arc length from the signals. In comparison to previous researches, this system does not require any equipment attached to a person. This is achieved by locating the tensometers on the bed. Data from sensors are fused by the Cartan curvatures method to beat-to-beat vector input for the Convolutional neural network (CNN) classifier. **Results** In sum, 2281 disordered and 5130 normal breathing samples was collected for analysis. The experiments with use of 10-fold cross validation show that accuracy, sensitivity, and specificity reach values of 96.37%, 92.46%, and 98.11% respectively. **Conclusions** By the approach for detection, the system offers a novel way for a completely unobtrusive diagnosis of breathing-related health problems. The proposed solution can effectively be deployed in all clinical or home environments.

© 2021 Elsevier B.V. All rights reserved.

1. Introduction

Breathing disorders like rhinitis, asthma, and chronic obstructive pulmonary diseases (COPD), influence the health condition of a large group of the world population. Sleep affects large-scale physiological functions including breathing as well. The effects of disordered breathing can lead to somnolence, irritability, daytime sleepiness, decreased mood and reduced performance during the day [40]. Above that, obstructive sleep apnea can be included in the pathogenesis of sleep breathing disorders [8]. It is characterized by episodic sleep collapse of the upper respiratory tract, which leads to periodic reductions or cessations in ventilation, with a following of hypoxia or hypercapnia. The disease most often affects people with obesity [34]. In the literature, there are many ways and approaches to respiratory disorders detection. Researches differ in different classification methods and physiological signals.

The first group of approaches is the electrocardiogram (ECG) signals measure [10,23,29,32]. It works on the principle of detecting the small electrical changes in depolarization followed by repolarization of muscle in the heartbeat [28]. It is measured with two, three, or ten electrodes placed on the skin, which provide up to 12 possible leads [38] described by Einthoven's triangle [3]. A. R. Hassan [10] proposed sleep apnea detection using the normal inverse Gaussian parameters and adaptive boosting. First, tunable Q factor wavelet transform decomposes the ECG segments, where is computed normal inverse Gaussian parameters. Thereafter, the adaptive boosting approach is used as a classifier that creates a set of hypotheses for weighted majority voting of the class prediction. B. B. Rekha et al. [23] presented an ensemble classification approach for screening of obstructive sleep apnoea. In their work, the twenty-two features set was derived from heart rate variability and classified by two classifiers. One is an ensemble-based classifier called Random Forest, and the second is a machine learning-based classifier called Support Vector Machine.

* Corresponding author.
E-mail addresses: h.fujita@hutech.edu.vn, H.Fujita-799@acm.org (H. Fujita).

The second group of detection is based on the sound from microphones, where related snoring and breathing sounds were acquired [15,21]. S. Akhter et al. [1] proposed the solution of automatic rapid eye movement (REM) and non-rapid eye movement (NREM) phases detection. Recognition of these phases is important for the selection of feature extraction in the next step before the logistic regression model (LRM) to classify. On the other hand, H. Nakano et al. [22] used polysomnography (PSG) data for analysis by tracheal sound spectrogram predicted by a deep neural network.

The third group of methods works on the analysis of signals from pulse oximetry. All of the works are based on monitoring biosignals regarding airflow, abdominal effort, thoracic effort, or oxygen saturation, and they study the possible presence of apnea [33]. Rolin et. al [24] used neural networks directly on the oximetry signal. Lee et. al [19] proposed a novel method to detect sleep apnea and hypopnea using a new algorithm applied to nasal pressure signals. Kaimakamis et. al [17] measured necessary data during polysomnography. They used signals from airflow from the nasal cannula, thoracic movement, and oxygen saturation as input to their nonlinear model. All of these approaches have in common the necessity of obtrusive instruments. Kagawa et. al [16] understood the problem with obtrusiveness and proposed a method using Doppler radar under the mattress to detect vibrations of the chest and abdomen. Their method is based on measuring phase differences between the signals. This system satisfies the unobtrusiveness of the method however they used two microwave Doppler radars with a radiating frequency of 24 GHz. The potential use of this device is extremely limited, and the process of certification of the devices to be compliant with electromagnetic compatibility is highly improbable. Needless to take into consideration that the willingness of the patients to be radiated by microwave radar may not be very high.

The last group of researchers is derived from ballistocardiography (BCG) signals. BCG is an unobtrusive method studying mechanical recoil movement of the body due to the heart movement, and blood flow throws large arteries. This recoil movement propagates through the skeleton and soft tissue to the whole body and then to the measuring sensors [27]. M. D. Zink et al. [43] proposed detecting a long-term heartbeat cycle length. They measured ECG and alternatively tested a sensor foil for mechanical vibrations to perform a ballistocardiography. This study aimed to assess the correlation between heartbeat detection by the BCG algorithm and simultaneously recorded ECG. For obtaining applicable results, individuals were examined in a prone position on their back, and foil was placed under them. Yao et al. [39], proposed an algorithm for the separation of cardiac and respiratory components via the locally projective noise reduction (LPNR) on the heart rate and breathing parts of BCG signals. This was performed for denoising deterministic chaotic time series before the heuristic BCG heartbeat detector. Z. Wang et al. [36] came with assessing the severity of sleep apnea syndrome based on a ballistocardiogram. The article approach is constructed on utilizing wavelet decomposition to obtain the outline information. As a classifier, the Physio_ICSS algorithm, which computes the iterative cumulative sums of squares, was used. Sadek et al. [26] evaluated the capacity of the microbend fiber optic sensors to monitor and respiration for a less cumbersome system to diagnose sleep-related problems. Additionally, they tested discrimination between shallow and no breathing. The sleep apnea was identified using an adaptive threshold method based on the standard deviation of the respiratory signal. Liu et al [20] examined the algorithm that firstly preprocessed measured BCG data for the location of important segments by detecting arousals. Thereafter, the selection of features to detect respiratory patterns were performed. As a classifier, they used a backpropagation (BP) neural network to predict the events into apnea and non-apnea

classes. Zhao et al. [41] measured BCG signals and detect deviations in the heart rate activity associated with sleep apnea. They applied wavelet decompositions extraction to analyze the BCG signal to obtain the heartbeat interval for the support vector machine classification model.

In the previous works [5,6], we presented novel approach based on differential geometry invariants. The R wave was used from ECG as a trigger for creating the input to Convolutional neural network (CNN) in the form of Cartan curvatures. We treated signals from force sensors as the projection of a one-dimensional curve embedded in 12-dimensional Euclidean space. Then it is possible to calculate Cartan curvatures using Frenet-Serret theory [37]. Cartan curvatures are uniform functions that describe the original one-dimensional curve in the form of its local properties using higher derivatives of tangent, normal, bi-normal, and higher-order invariants [37]. The curvatures are also independent of euclidean transformations, which include rotation or translation of coordinate system. These curvatures are calculated directly from the BCG signals from force sensors embedded in the bed, and their main advantage is in their complete independence on the position of the body on the bed. The use of Cartan curvatures was proven as a strong mathematical tool to study breathing disorders, so we decided to take advantage of them and use them also in the presented paper.

All of the methods mentioned above have various disadvantages. ECG and oximetry are in common not unobtrusive. It is still needed to connect something directly to the human body, which can be problematic e.g. for the patients with burns or when the patient tries to tear down equipment from the body. The use of the microphone means a high invasion of privacy. The devices can also record the voices so the approach is still obtrusive since the measured individual can be stressed by the measurement. Besides, any microphone is much more sensitive to any external disruption, so any movement, even around the measured person, can rapidly decrease or interfere the accuracy of the measurement. Doppler radar uses ionizing radiation, although the power is very low. Each of these methods is also disrupted by the movement of the patient. There is no real difference in terms of accuracy and robustness against the mechanical movements of the measured person. Moreover, in the works where BCG was used itself, the proposed methods can work theoretically only in the laboratory environment since the measured person can lie on the bed in various positions, which differ in rotation and translation on the bed where translation should be understood as a shift of the coordinate system with respect to the measured subject, i.e. the difference between subject lying in the center of the bed or outside the center). The solution proposed in our previous work [5,6] counts with this situation and introduces a novel method based on differential geometry invariants, which proved to be working even under different conditions, however, with need of ECG as a trigger to create input to CNN. The need for ECG to create a trigger destroys the unobtrusiveness of the system and presents discomfort for the measured subject.

In this paper, we propose a new approach to achieving mechanical triggers for breathing disorders detection. This trigger is based purely on the BCG data, thus enabling the true unobtrusiveness of the system. The trigger is based on the detection of ejection of the blood from the heart. We take advantage of using differential geometry invariants and suggest the use of a new differential invariant - euclidean arc length [37] - which can serve as a trigger for the categorization of Cartan curvatures for CNN. The main advantage of this mechanical trigger is its complete unobtrusiveness and also its properties, which are invariant in the same way as Cartan curvatures, so the solution is applicable even for people lying on the bed in different positions. Moreover, arc length is calculated directly from measured signals.

In summary, our previous [5,6] work stood on three pillars, finding the trigger for individual heartbeats, calculating Cartan cur-

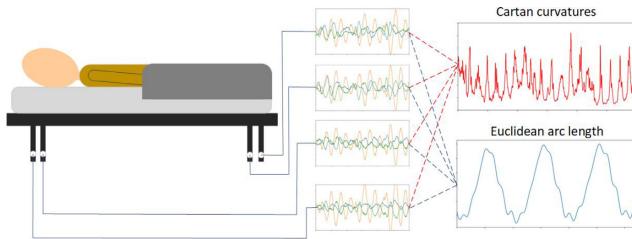


Fig. 1. System architecture.

vatures, and processing the result using CNN. In this paper, we have introduced a completely new algorithm for calculating the first part, i.e. the trigger, which must be precise enough to capture subtle variations in pulse arrival time processed using Cartan curvatures. The main novelty of the paper also lies in implementing of this new trigger and improving CNN to develop the new completely unobtrusive mechanical system without the need to connect any equipment to the measured person or using any ionizing radiation for measurement, unlike in similar systems presented above. The calculations and techniques are described in the following sections.

2. Methods

The core of the proposed solution is in data measuring and pre-processing before classification itself, as illustrated in Fig. 1. The person is not connected to any device and all four sensors are placed on the legs of the bed. It can be seen here that four tensometers measure micro-movements in three dimensions, which represents 12-dimension information for the next analyses. The analysis consists of 12-dimension information fusion into needed features, Cartan curvatures, and Euclidean Arc Length. The movements of the person propagate through the frame of the bed to the legs of the bed. The tensometers are placed as a supporting part of the legs, and the whole frame lies on the tensometers. The architecture is similar to dynamical posturography measurements [12]. The corresponding propagating forces can be measured using the tensometers. With the focus on the micro-movements, there is obtaining of forces generated by the blood propagation and heart contractions.

2.1. Mechanical trigger

Electrocardiography (ECG) is a device used for decades to measure and diagnose problems related to the cardiovascular system [9]. The main principle is the measurement of the electric activity of the heart muscle. During the cardiac cycle, there is a measurable difference in electric potentials from the heart, so-called action potentials. Heart muscle can be imagined as an electric dipole, and ECG leads then represents projections of this dipole into a different axis. Typical ECG signal is shown in Fig. 2. The signal consists of three main parts. The first part is the P wave, which is the part related to atria filling with blood (atrial depolarization). The second part is the QRS complex, where the main spike is represented by the R wave (ventricular depolarization). The last part is called the T wave represents ventricular repolarization. The section between the R wave and the end of the S wave starts with mitral valve closure, followed by isovolumetric contraction and aortic valve opening. After that, the blood is ejected to the aorta, and the pulse wave starts to propagate through the whole cardiovascular system.

In our previous work [6], we used R wave as a uniform trigger for detection of the pulse arrival time of the pulse wave. This approach proved the accuracy of our solution and was able to detect breathing disorders. However, from a practical point of view, the measured person had to have ECG leads connected to the body. This is not expected to be a problem in the hospital environment but in the home environment where is a need for a completely unobtrusive system. The unobtrusiveness of the system enables the usage in a home environment without any discomfort of a measured person. This broadening the practical applicability of the system. Moreover, an unobtrusive approach in the hospital environment eliminates the need for ECG implementation.

The fundamental schema of the computation of monitoring function is presented in Fig. 3. All measured data have been mathematically analyzed using differential geometry invariants. The euclidean invariant theory was used to study the invariants under the actions of the group $SO(3) \times \mathbb{R}^n$. The elements of this group are invariants under rotation and translation. The phenomenon is similar to the human body lying on the bed, since the human cardiovascular system does not change significantly if the patient is lying on his back or the side, so it is invariant under those transformations. In this work, there are acquired 12-signals in the measurement and have treated those 12-signals as a 1D manifold embedded in \mathbb{R}^{12} so these signals are fused into one curve. Using classical Frenet-Serret theory [18] the euclidean arc length and the first Cartan curvature are evaluated. The euclidean arc length is calculated using formula

$$s(t) = \int_0^t \sqrt{\sum_{i=1}^n \left(\frac{dC_i(\tau)}{d\tau} \right)^2} d\tau, \quad (1)$$

where $s(t)$ is the euclidean arc length, t is time, a and b represent the initial and final time for which $s(t)$ is calculated, n is the number of sensors (in our case $n = 12$) and $C_i(\tau)$ is the measured discrete signal from i -th sensor. Arc-length basically calculates the cumulative sum of the length of the n -dimensional curve. The formula for arc-length is derived from basic principles of differential geometry of curves [37]. Euclidean arc length is an invariant which is used to determine the mechanical trigger after some transformation. This resulting function is called a monitoring function. To calculate the monitoring function calculations start with $l \times n$ matrix called C with raw measured data from tensometers, where $n = 12$ is the number of sensors and l is the number of sampling points used (e.g. for 60-second measurement at a sampling frequency of 1 kHz there will be 60,000 sampling points). Let $C_{i,j}$ be the value in i -th row and j -th column of this matrix. The difference CD of the matrix C is calculated with respect to rows. CD is $(l-1) \times n$ matrix. Let $CD_{i,j}$ be the value in i -th row and j -th column of this matrix. Then $CD_{i,j} = C_{i+1,j} - C_{i,j}$. Next, the vector of norms is calculated with respect to columns of the matrix CD . To do so, a row vector N of length $l-1$ is defined. For the i -th row of the vector

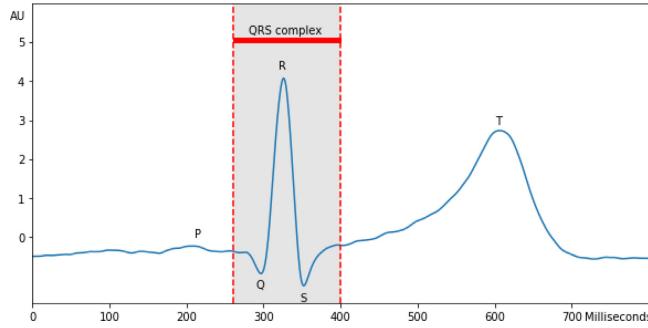


Fig. 2. Example of ECG.

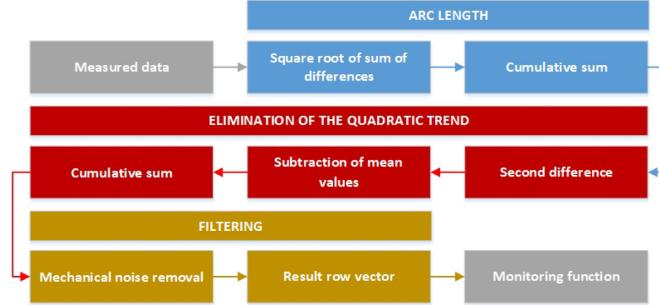


Fig. 3. Flowchart of monitoring function computation.

following formula holds

$$N_i = \sqrt{\sum_{j=1}^n CD_{i,j}^2} \quad (2)$$

In the next step, the euclidean arc length is calculated as a cumulative sum of vector N . Let A be a row vector of length $l - 1$. Let $A_1 = N_1$. Then for i -th row of A , $i > 1$, following formula holds

$$A_i = A_{i-1} + N_i. \quad (3)$$

Final form of the vector A is euclidean arc length.

In order to extract information about the mechanical trigger, arc length by itself is not sufficient. It can be described as a function measuring the "cumulative length" of 12 measured signals which is treated as projections of 1D manifold embedded in \mathbb{R}^{12} . Thus even for constant signal, vector A will be a linear curve. This natural linear trend, which is always present, must be subtracted from the vector A . In advance to further improve the results, the quadratic trend of this curve is subtracted. The first-order difference AD of the row vector A is calculated with respect to rows. Let AD be row vector of length $(l - 2)$ and AD_i be the value in i -th row of this vector. Then

$$AD_i = A_{i+1} - A_i. \quad (4)$$

Thereafter, the second-order difference ADD of the row vector A is calculated with respect to rows. Let ADD be row vector of length $(l - 3)$ and ADD_i be the value in the i -th row of this vector. Then

$$ADD_i = AD_{i+1} - AD_i. \quad (5)$$

From this second difference (discrete form of derivative) of vector A , the quadratic trend can be eliminated by removing the inconstant term during a double cumulative sum (discrete form of integration) back to vector A . To ensure it, the mean value of cumulative sum input is subtracted from itself. To do so let $M2$ be mean value of values of vector ADD , i.e.

$$M2 = \frac{1}{l-3} \sum_{i=1}^{l-3} ADD_i. \quad (6)$$

Then this mean value is subtracted from all values of ADD and ADD be row vector of length $l - 3$. Let ADD_i be the value in i -th row of this vector. Then

$$ADD_i = ADD_i - M2. \quad (7)$$

Let $ADCS$ be a row vector of length $l - 3$ and $ADCS_1 = ADD_1$. Then for i -th row of $ADCS$, $i > 1$, following formula holds

$$ADCS_i = ADD_{i-1} + ADD_i. \quad (8)$$

Let $M1$ be mean value of values of vector $ADCS$, i.e.

$$M1 = \frac{1}{l-3} \sum_{i=1}^{l-3} ADCS_i. \quad (9)$$

Then this mean value is subtracted from all values of $ADCS$. Let ADI be row vector of length $l - 3$ and $ADI_1 = ADCS_1$. Then for i -th row of ADI , $i > 1$, following formula holds

$$ADI_i = ADCS_i - M1. \quad (10)$$

Let ACS be a row vector of length $l - 3$ and $ACS_1 = ADl_1$. Then for i -th row of ACS , $i > 1$, following formula holds

$$ACS_i = ADl_{i-1} + ADl_i, \quad (11)$$

where ACS is detrended euclidean arc length.

Because the approach deals with real-world signals, several noise sources always affect the measured signals. The two most important noise sources are electric hum from sockets, which in the Czech Republic is of frequency 50 Hz, and mechanical noise related to involuntary movements of measured persons. In order to smooth ACS to get rid of these noises, three different filters are used. The parameters of these filters are found empirically. In order to describe the calculation algorithm of these filters, there is a need to define the moving average filter and its properties along the borders of the signal.

Let Y be a row vector of length k representing arbitrary measured discrete signal with k sampling points. Let v be the number of points over which the filter will be averaging. Let Z be the row vector of length k , which is a result of applying a moving average filter at signal Y over v number of points. Let Y_i denotes value at i -th row of Y and Z_i denotes value at i -th row of Z . Then following formulas hold in the assumption that v is odd:

$$\begin{aligned} Z_i &= \frac{1}{2i-1} \sum_{j=1}^{2i-1} Y_j, i \geq 1 \wedge i \leq \frac{v-1}{2} \\ Z_i &= \frac{1}{v} \sum_{j=i-\frac{v-1}{2}}^{i+\frac{v-1}{2}} Y_j, i > \frac{v-1}{2} \wedge i < k - \frac{v-1}{2} \\ Z_i &= \frac{1}{2(k-i)+1} \sum_{j=2i-k}^k Y_j, i \geq k - \frac{v-1}{2} \wedge i \leq k. \end{aligned} \quad (12)$$

For even v , $v > 0$ it is used $\tilde{v} = v - 1$ in above described formula.

Let $Z = F(Y, v)$, i.e. let vector Z be the same size as vector Y where the above-mentioned algorithm is used to calculate Z by applying moving average filter on vector Y over v points.

Now three separate filters are applied in the following order. The first moving average of vector ACS is calculated over 1000 sampling points, so $ACS_1 = F(ACS, 1000)$. Let ACS_1 be the value in i -th row of this vector. Let $ACS1M$ be a row vector of length $l - 3$. Let $ACS1M_i$ be the value in the i -th row of this vector. Let $ACS1M_i = ACS_i - ACS_1$. One second moving average filtered detrended euclidean arc length is subtracted from the original detrended euclidean arc length. Then moving average of vector $ACS1M$ is calculated over 100 sampling points, so $ACS2 = F(ACS1M, 100)$. The moving average of vector $ACS2$ is calculated over 33 sampling points so $ACS3 = F(ACS2, 33)$. Next, the sign of all the values of $ACS3$ is change. Let AF be a row vector of length $l - 3$. Let AF_i be the value in i -th row of this vector and $AF3S_i$ be the value in i -th row of this vector. Then $AF_i = -AF3S_i$ and AF is a row vector of length $l - 3$ called monitoring function.

Now, the local maxima of AF can be used as a relevant mechanical trigger for extracting the Cartan curvature of the signal. It is natural to discuss the different lengths of the input matrix C and the output vector M . However, the difference in the lengths is three sampling points, which means the added inaccuracy is only in the order of 3 milliseconds. Moreover, it is a systematic inaccuracy, which means it is constant among all the measurements, thus it can be neglected with respect to the results.

The typical shape of the monitoring function is in Fig. 4. QRS complex together with T wave is indicated, so it is possible to distinguish separate parts of the signal. The decision to use the maxima of a monitoring function to be the trigger for our pre-processing sequence is made. This maxima corresponds with the end of the rapid ejection phase, which then translates into a reduced ejection. The distance between the mechanical trigger and R wave varies through time as it is dependent on various physiological phenomena and thoracic pressure. On average, the distance is $160 \text{ ms} \pm 40 \text{ ms}$.

The main advantage of this approach is complete unobtrusiveness since no ECG signal is needed as a trigger for cardiac cycle detection to obtain information about the pulse arrival time using Cartan curvatures. In most relevant cited papers, the ECG is the main and only source for the classifier in cases where sensors are not implemented on or directly below the human body. Our method does not need any ECG signal which is only possible to be obtained via obtrusive methods.

2.2. Classifier input preparation

The preprocessing of raw data for CNN is done in the following way. First, there is a need for raw data measure for an adequate period of time. Since we work on the scale of individual heartbeats and individual breaths, at least 15 seconds are needed. It means that the required time for problem detection is between 1 and 15 heart beats where information is included. The data is measured with sampling frequency 1 kHz so n -seconds of data will produce $1000n$ rows and 12 columns representing 12 force sensors. So the input is in the form of a matrix $1000n \times 12$. The first moving average filter is applied and described above with 10 points averaging on each of the columns individually to cut down potential 50 Hz electrical noise. Then the Cartan curvatures and monitoring function is calculated from the data using the above-described method. After that, all peaks in the monitoring function are founded and marked as a trigger for each heartbeat. Thus the vector B of size mn is extracted, where mn is the number of detected heartbeats, where each point represents the index of a local maximum in monitoring function. Then the first Cartan curvature is taken and create mn vectors CC_b , each of them of size 450 where $CC_{b,i} = C_{B_b-50...B_b+400}$.

2.3. Data description

The BCG samples used in this work were collected from the public Mendeley database [30] and measured in the laboratory of the University of Hradec Kralove. This database contains raw data without any preprocessing or normalization. The BCG sensor dataset is obtained from 11 men aged 23 to 33 years and nine women aged 24 to 65 years. It includes 9 with 7 minutes in duration recordings and 11 with 12 minutes in duration recordings of humans with normal and disordered breathing sequences. In sum, by using 15 sequential parts by the mechanical trigger, we collected 2281 disordered and 5130 normal breathing samples. Although it is possible to obtain the weight of the subjects, it was not necessary. The weight does affect the raw signal data, however, all used equations are based on derivations of the signals, and consecutive calculations are based on time differences and time locations of maxima in the processed signals. So the approach is independent of the BMI.

2.4. Model architecture

The CNN architecture consists of three main layers types: convolutional, pooling, and fully connected [2]. The convolutional layer contains several filters, also called kernels. These filters slide over the input from the previous layer, or input data in the case of the first layer of architecture, to generate several feature maps [31]. The convolution process often occurs at the same time as the pooling process. The pooling layer reduces the number of neurons from the previous layer. At the end of the structure, fully-connected layers are implemented for final feature analysis. The last fully-connected layer contains as many neurons as classes for the classifier prediction.

The architecture in the presented paper is shown in Fig. 5. Input to the network is represented by 15 Cartan curvatures which are downsampled from size 450 to 200 because of optimization

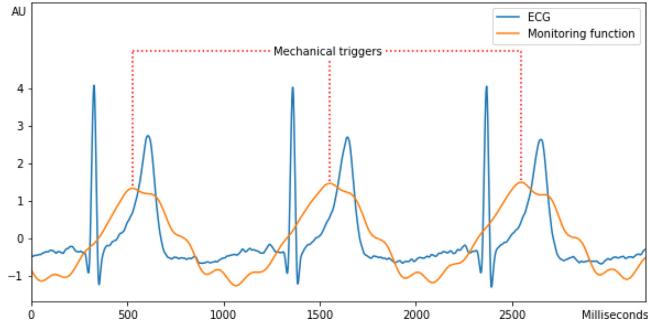


Fig. 4. Example of ECG.

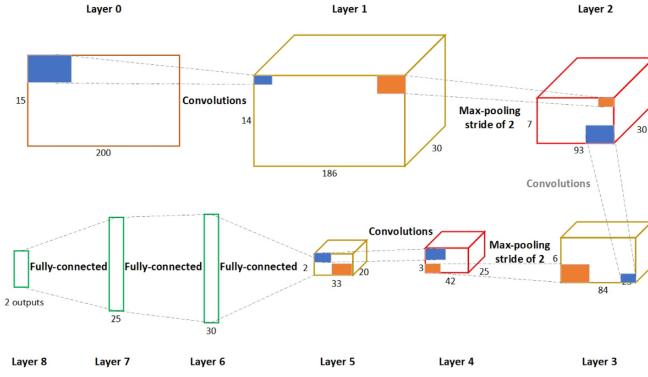


Fig. 5. Architecture of CNN model.

of architecture complexity. In the beginning, the first four layers constitute two combinations of convolutional and max-pooling layers. Convolutional layers kernels have a 2-dimensional resolution. The first dimension corresponds to the number of vectors with mechanical information fused by Cartan curvatures, which is always made with value 2. The second dimension corresponds to the length of each vector and is set on values 15 and 10, respectively. All max-pooling layers have the kernel with a resolution of 2×2 . Because of the resolution of features, architecture continues with a convolutional layer of kernel size 2×10 without max-pooling operation. After that, two fully-connected layers, which analyze features from previous layers, are implemented with 30 and 25 neurons. In the end, the last fully-connected layer with two neurons corresponding to classes of normal and disordered breathing predicts the result by a softmax activation function. It normalizes the result of architecture to a suitable form on the value between 0 and 1 with a threshold of 0.5 for prediction. Moreover, mechanisms for over-fitting prevention, which have important impact on process of model training [31], are applied too. Concrete, it is a rectifier linear unit (Relu) layers between all pairs of convolution and max-pooling and dropout layer with a drop parameter of 0.3 between first and second fully-connected layers.

3. Results

3.1. Training and testing

The input dataset is first divided by stratified 10-fold cross-validation strategy [7]. It is a common method to prove model performance because of the training and testing of classifiers on non-redundant data. The methodology consists of data separation into the same equally large ten groups. For each fold, one group, which is not used in the previous fold, is a tested data subset for the validation of the model, and the rest nine groups are a trained data subset fine-tune of model inner parameters. Training and testing parts are percentages divided as 70% and 30%, respectively. In the training process, 75 epochs is used, which means that each training sample is used 75 times for the model parameters modification to get feasible results.

Further, the learning rate value, which represents the size of the step towards minimizing the cost function of the model, is variable for the training process depends on the number of the current epoch. The parameter on $1 \cdot 10^{-3}$ has been selected for first 25 epochs, $2 \cdot 10^{-4}$ has been selected for next 25 epochs, and $4 \cdot 10^{-5}$ for the last 25 epochs. The reason why the value of the learning rate is changed after every 25 epochs are related to the training

Table 1
Optimization hyperparameters used for training the model.

Input Size	Optimizer	Learning rate	Learning rate schedule	Learning rate drop	Mini batch size	Epochs
200x15	Adam	1e-3	Step decay	2e-1	32	75

Table 2
Overall classification.

O/P	Normal	Disordered	Acc (%)	PPV (%)	Sen (%)	Spec (%)
Normal	2109	172	96.37	95.60	92.46	98.11
Disordered	97	5033	96.37	96.70	98.11	92.46

accuracy stuck. It relates to gradient descent for finding a local minimum. After several epochs, the gradient is very close to a minimum too much, and a high value of learning rate will cause the performance of the model will not increase in rest epochs [25]. Because of that, it is appropriate to decrease the value of the learning rate for further training tasks. The hyperparameter cast-off for the optimization of model used for training and learning are tabularized in **Table 1**.

3.2. Results of the experiments

There are three fusion processes in this paper. The first one is the fusion of multivariate time series into one parameter - euclidean arc length. The inputs are fused from 12 sensors into one parameter, which can be used to detect the mechanical triggers, which is called a monitoring function and is derived directly from euclidean arc length. The second fusion is the fusion of multivariate time series into the second independent parameter - Cartan curvature. The inputs are fused from 12 sensors into one parameter, which can be used to detect pulse arrival time in the human cardiovascular system. The third fusion process is the fusion of mechanical trigger together with methods of differential geometry. By the implementation of the mechanical trigger and Cartan curvatures, it is possible to extract precious information about the pulse arrival time for each of the heartbeats.

Our proposed method can also be used in other kinds of data. Thanks to the mathematical independence of differential geometry invariants, it is irrelevant how many sensors are used. Our proposed method can work even with one sensor. However, the more sensors are used, the better precision of the system is achieved. The solution also works with BCG signals measured by other standard methods, not only tensometers, e.g. piezoelectric foils, accelerometers, etc.

The classification results of the proposed system are shown in **Table 2**, represented by the confusion matrix with three basic metrics: accuracy, sensitivity, and specificity. Accuracy is the proportion of correct results and all predictions in a testing population. It measures the degree of veracity of a diagnostic test on a condition. Sensitivity is the proportion of true positives that are correctly predicted by the classifier. It shows how good the test is at disorder detections. Specificity is the proportion of the true negatives correctly predicted by the classifier. It presents how good the test is at predicting normal (negative) breath[42].

The sensitivity and specificity are the main performance parameters, especially in cases like this with an unbalanced proportion of detected classes. If one class contains several times more samples than the other, the high accuracy value pointing to high performance. But with low specificity or sensitivity, depends on the low number of positive or negative samples, represents poor-quality of the model. In the worst case, it is predicting all inputs as one class. In the presented approach, sensitivity and specificity were achieved on the values of 92.46% and 98.11%.

4. Discussion

Our presented model for the detection of breathing disorders has several advantages, which together form a strong tool. First of all, it is completely unobtrusive, so it does not need anything to be directly attached to the patient. It also does not rely on any form of EM radiation, so it is completely safe. Then the system uses invariant mathematical tools to preprocess the data thus another advantage is that the system works with patients lying on the bed in any position, and these were already tested in the presented paper. In principle, the patient lies down on the bed, and that is all that is needed from the measured person, so the practical applicability of this system is very strong since it has no need for special preparation of the patient or from the medical personnel. This is unlike other papers cited in this work since they either need to use ECG, nasal sound, EM radiation or they cannot achieve precision in all positions of the patient on the bed. Two disadvantages, which can affect the performance of the proposed system, need to be mentioned. Because the core of the measurement rest in the mechanical micromovements of the body, the system can measure only a person who does not move significantly. For example, when the person turns from left side to right side, the system is put to a halt for a short period until the person calms. The second disadvantage is that the system cannot measure more than one person lies in bed or when another person is leaning on the bed since this will again create too much mechanical noise.

Our main achievement was in the completely novel algorithm for trigger detection of studied phenomena, which enabled complete unobtrusiveness of the system. Our proposed method based on mechanical trigger detection of individual heartbeats has never been published before. It consists of detection of the rapid ejection phase of the heartbeat, which is precise enough to provide information about changes in pulse arrival time, which is directly dependent on breathing cycles and disorders. The system can detect these changes purely from mechanical data without the need for ECG. The only construction disadvantage of our system is the need for tensometers to be embedded in the measuring bed. However, this could be done by implementing tensometric sensors in the legs of any ordinary bed.

There are three fusion processes in this paper. The first one is the fusion of multivariate time series into one parameter - euclidean arc length. The inputs are fused from 12 sensors into one parameter, which can be used to detect the mechanical triggers, which is called a monitoring function and is derived directly from euclidean arc length. The second fusion is the fusion of multivariate time series into the second independent parameter - Cartan curvature. The inputs are fused from 12 sensors into one parameter, which can be used to detect pulse arrival time in the human cardiovascular system. The third fusion process is the fusion of mechanical trigger together with methods of differential geometry. By the implementation of the mechanical trigger and Cartan curvatures, it is possible to extract precious information about the pulse arrival time for each of the heartbeats.

Table 3
Selected studies of an detection of breathing disorders.

Author	Approach	Used dataset	Classification	Performance (%)
Current	Cartan curvatures with Euclidean length trigger	[30]	CNN	Acc = 96.37 Sen = 92.46 Spec = 98.11
[6]	Cartan curvatures with normalization	[30]	CNN	Acc = 98.00 Sen = 94.26 Spec = 99.22
[5]	Cartan curvatures with CWT on pulse arrival	[30]	CNN	Acc = 89.35 Sen = 86.35 Spec = 91.22
[26]	Adaptive thresholding	Proprietary experimental data	Statistically	Sen = 24.24 Spec = 85.88
[20] [41]	Threshold-based division STC-Min	Proprietary BCG dataset Proprietary data from home environment	BPNN SVM	Acc = 94.6 Acc = 90.46
[39]	Locally Projective Noise Reduction	Proprietary clinical data	Heuristic	Acc = 92.7 Sen = 99.5
[36]	Wavelet decomposition	[35]	Physio_ICSS	Acc = 97.57 Sen = 91.44 Spec = 98.01

Table 4
Comparison with well-known implementation of advanced CNN models.

Model	No. of parameters	Acc (%)	Sen (%)	Spec (%)
Current	97,247	96.37	92.46	98.11
ResNet50 [11]	25,636,712	97.03	94.75	98.05
DenseNet121 [14]	8,062,504	96.76	98.69	95.91
MobileNetV2 [13]	3,538,984	95.01	85.15	100
Xception [4]	22,910,480	92.85	91.27	93.57
NASNetMobile [44]	5,326,716	94.88	83.01	95.71

Our proposed method can also be used in other kinds of data. Thanks to the mathematical independence of differential geometry invariants, it is irrelevant how many sensors are used. Our proposed method can work even with one sensor. However, the more sensors are used, the better precision of the system is achieved. The solution also works with BCG signals measured by other standard methods, not only tensometers, e.g. piezoelectric foils, accelerometers, etc.

A comparison of system performance with other articles based on BCG sensors is shown in Table 3. The results point to the fact that the presented approach ranks as one of the strongest tools for breathing disorders detection. Moreover, other articles measured auxiliary data in an obtrusive way or are dependent on the position of sensors against the human body.

CNN architecture in principal is classical feed-forward neural network (FFNN) extended by convolutional operations. Convolutional operations are handy in cases where adjacent inputs are in some relations such as creation of a predicted class shape. For that reason, CNN architectures are appropriate for image or signal classification tasks. Besides that, there are many other types of neural networks. One of them is neural networks with a time twist like Recurrent Neural Network, Long / Short Term Memory, or Gated Recurrent Units. These networks work with recurrency linked not only to forwarding layers. It is appropriate for cases where the necessary relations are not on neighbor values but in the time domain, like in text classification tasks.

As CNN is an extended version of FFNN, there were developed several versions of extended CNN for better classification, mainly with a focus on image tasks. CNN architectures are supplemented by new approaches like depthwise separable convolutions [4], residual connections to skip layers [11], or a "collective knowledge" from all preceding layers [14]. In Table 4, there is a comparison of the well-known implementation of advanced CNN models implemented in the Keras Applications module with the same set-

ting of hyperparameters as in our presented model. It is obvious that new techniques implemented in models do not bring significant performance raise. Moreover, well-known tested classifiers are in principle prepared on a wide area of image classifications and include millions of trainable parameters, unlike the current model with less than 100 000. It leads to the more appropriate deployment of the presented model in a real case usage without the need for unnecessarily high performance on the computing device.

5. Conclusion

In this study, a novel methodology for the unobtrusive triggering of vital data for breathing disorders detection was developed. The system worked with four ballistocardiography sensors embedded on the corners of a measuring bed. The proposed solution depends on Euclidean length computation from the fusion of 12-dimensional ballistocardiography signal information. After data fusion and trigger, an 8-layer deep CNN model is designed to recognize breathing problems from Cartan Curvatures sequence signals of 15 heartbeats. The achieved accuracy, sensitivity, and specificity are of 96.37%, 92.46%, and 98.11%, respectively.

The main contribution of the paper is novel methodology and algorithms for beat detection by an unobtrusive mechanical trigger. This trigger is used for the recognition of breathing disorders without the need to attach any sensor to the measured person. Because of the fully unobtrusive form of data measuring, the proposed solution can effectively be deployed in all clinical or home environments. The system can work without professional staff, who have to implement the devices in every moment of new data collection and analysis for healthcare problem prediction. The importance of this paper also rests in the proof of the functionality of the mathematical methods on the BCG signals. Thanks to this, it is opening the whole unexplored area, which can contain more physiological information of the human body. These data can be examined with corresponding eventual diseases, which are successfully detected with obtrusive approaches. It leads to our main goal to create a complex system based on one data collection instead of many time-consuming clinical testing.

Declaration of competing interest

We declare that we do have no commercial or associative interests that represent a conflict of interests in connection with this manuscript. There are no professional or other personal interests that can inappropriately influence our submitted work.

Acknowledgements

Financial support from the Faculty of Science University of Hradec Kralove is gratefully acknowledged. Part of this study is supported by JSPS/Japan KAKENHI (Grants-in-Aid for Scientific Research) #JP20K11955.

References

- [1] S. Akhter, U.R. Abeyratne, V. Swarnkar, C. Hukins, Snore sound analysis can detect the presence of obstructive sleep apnea specific to nrem or rem sleep, *Journal of Clinical Sleep Medicine* 14 (6) (2018) 991–1003.
- [2] S. Aljawi, T.A. Mohammed, S. Al-Zawi, Understanding of a convolutional neural network, in: 2017 International Conference on Engineering and Technology (ICET), IEEE, 2017, pp. 1–6.
- [3] F.T. Bennett, K.R. Bennett, A.K. Markov, Einthoven's triangle: lead errors and an algorithm for solution, *Am. J. Med. Sci.* 329 (2) (2005) 71–77.
- [4] F. Chollet, Xception: Deep learning with depthwise separable convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp. 1251–1258.
- [5] D. Cimr, F. Studnicka, Automatic detection of breathing disorder from ballistocardiography signals, *Knowl. Based Syst.* (2019) 104973.
- [6] D. Cimr, F. Studnicka, H. Fujita, H. Tomaskova, R. Cimler, J. Kuhnova, J. Siegr, Computer aided detection of breathing disorder from ballistocardiography signal using convolutional neural network, *Inf. Sci. (Ny)* (2020).
- [7] R.O. Duda, P.E. Hart, D.G. Stork, et al., Pattern classification, *Int. J. Comput. Intell. Appl.* 1 (2001) 335–339.
- [8] M. Ferrando, D. Bagnasco, V. Roustan, G.W. Canonica, F. Braido, I. Baiardi, Sleep complaints and sleep breathing disorders in upper and lower obstructive lung diseases, *J. Thorac. Dis.* 8 (8) (2016) E716.
- [9] H. Fujita, D. Cimr, Computer aided detection for fibrillations and flutters using deep convolutional neural network, *Inf. Sci. (Ny)* 486 (2019) 231–239.
- [10] A.R. Hassan, Computer-aided obstructive sleep apnea detection using normal inverse gaussian parameters and adaptive boosting, *Biomed. Signal Process. Control* 29 (2016) 22–30.
- [11] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770–778.
- [12] J.R. Hebert, M.M. Manago, Reliability and validity of the computerized dynamic posturography sensory organization test in people with multiple sclerosis, *Int. J. MS Care* 19 (3) (2017) 151–157.
- [13] A.G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam, Mobilenets: efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv:1704.04861* (2017).
- [14] G. Huang, Z. Liu, L. Van Der Maaten, K.Q. Weinberger, Densely connected convolutional networks, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp. 4700–4708.
- [15] S. Jayalakshmy, G.F. Sudha, Scalogram based prediction model for respiratory disorders using optimized convolutional neural networks, *Artif. Intell. Med.* 103 (2020) 101809.
- [16] M. Kagawa, H. Tojima, T. Matsui, Non-contact diagnostic system for sleep apnea-hypopnea syndrome based on amplitude and phase analysis of thoracic and abdominal doppler radars, *Medical & biological engineering & computing* 54 (5) (2016) 789–798.
- [17] E. Kaimakamis, V. Tsara, C. Bratsas, L. Sichletidis, C. Karvounis, N. Maglaveras, Evaluation of a decision support system for obstructive sleep apnea with nonlinear analysis of respiratory signals, *PLoS ONE* 11 (3) (2016) e0150163.
- [18] J. Kfiz, P. Šeba, Force plate monitoring of human hemodynamics, *Nonlinear Biomed. Phys.* 2 (1) (2008) 1.
- [19] H. Lee, J. Park, H. Kim, K.-J. Lee, New rule-based algorithm for real-time detecting sleep apnea and hypopnea events using a nasal pressure signal, *J. Med. Syst.* 40 (12) (2016) 282.
- [20] F. Liu, X. Zhou, Z. Wang, T. Wang, H. Ni, J. Yang, Identifying obstructive sleep apnea by exploiting fine-grained bkg features based on event phase segmentation, in: Bioinformatics and Biengineering (BIBE), 2016 IEEE 16th International Conference on, IEEE, 2016, pp. 293–300.
- [21] S.S. Mostafa, D. Baptista, A.G. Ravelo-Garcia, G. Juliá-Serdá, F. Morgado-Dias, Greedy based convolutional neural network optimization for detecting apnea, *Comput. Methods Programs Biomed.* 197 (2020) 105640.
- [22] H. Nakano, T. Furukawa, T. Tanigawa, Tracheal sound analysis using a deep neural network to detect sleep apnea, *Journal of Clinical Sleep Medicine* 15 (8) (2019) 1125–1133.
- [23] B.B. Rekha, A. Kandaswamy, R. Ramanathan, Ensemble classification approach for screening of obstructive sleep apnoea using ecg, *Int. J. Biomed. Eng. Technol.* 27 (1–2) (2018) 139–150.
- [24] R.E. Rolón, L.D. Larraategui, L.E. Di Persia, R.D. Spies, H.L. Rufiner, Discriminative methods based on spars representations of pulse oximetry signals for sleep apnea-hypopnea detection, *Biomed. Signal Process. Control* 33 (2017) 358–367.
- [25] S. Ruder, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747* (2016).
- [26] I. Sadek, E. Seet, J. Biswas, B. Abdulrazak, M. Mokhtari, Nonintrusive vital signs monitoring for sleep apnea patients: a preliminary study, *IEEE Access* 6 (2018) 2506–2514.
- [27] M. Sidikova, R. Martinek, A. Kawala-Sterniuk, M. Ladrova, R. Jaros, L. Danys, P. Simonit, Vital sign monitoring in car seats based on electrocardiography, ballistocardiography and seismocardiography: a review, *Sensors* 20 (19) (2020) 5699.
- [28] M.E. Silverman, J. Willis Hurst, Willem einthoven the father of electrocardiography, *Clin. Cardiol.* 15 (10) (1992) 785–787.
- [29] C. Song, K. Liu, X. Zhang, L. Chen, X. Xian, An obstructive sleep apnea detection approach using a discriminative hidden markov model from ecg signals, *IEEE Trans. Biomed. Eng.* 63 (7) (2015) 1532–1542.
- [30] F. Studnicka, Ballistocardiography with breathing disorders, 2020, (????). Mendeley Data, v1, <https://data.mendeley.com/datasets/9fmfnfk7/1>.
- [31] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1–9.
- [32] C.M. Travieso, J.B. Alonso, M. Del Pozo, J.R. Ticay, G. Castellanos-Domínguez, Building a cepstrum-hmm kernel for apnea identification, *Neurocomputing* 132 (2014) 159–165.
- [33] M. Uddin, C. Chow, S. Su, Classification methods to detect sleep apnea in adults based on respiratory and oximetry signals: a systematic review, *Physiol. Meas.* 39 (3) (2018) 03TR01.
- [34] S.C. Veasey, I.M. Rosen, Obstructive sleep apnea in adults, *N. Engl. J. Med.* 380 (15) (2019) 1442–1449.
- [35] Z. Wang, Assessing the severity of sleep apnea syndrome based on ballistocardiogram (bcg), 2017, (????). Figshare Data, v3, <https://doi.org/10.6084/m9.figshare.4868102.v3>.
- [36] Z. Wang, X. Zhou, W. Zhao, F. Liu, H. Ni, Z. Yu, Assessing the severity of sleep apnea syndrome based on ballistocardiogram, *PLOS ONE* 12 (4) (2017) e0175351.
- [37] H. Williams, Geometric methods and applications for computer science and engineering, by jean gallier, pp. 572.E 44.50. 2001. isbn 0 387 95044 3 (springer-verlag), *The Mathematical Gazette* 86 (507) (2002) 564–565.
- [38] Q. Yao, R. Wang, X. Fan, J. Liu, Y. Li, Multi-class arrhythmia detection from 12-lead varied-length ecg using attention-based time-incremental convolutional neural network, *Information Fusion* 53 (2020) 174–182.
- [39] Y. Yao, C. Brüsler, U. Pietrzyk, S. Leonhardt, S. van Waesken, M. Schieck, Modular-based separation of a non-linear separation scheme for ballistocardiography, *IEEE J. Biomed. Health Inform.* 18 (1) (2014) 174–182.
- [40] J. Zhang, R. Yao, W. Ge, J. Gao, Orthogonal convolutional neural networks for automatic sleep stage classification based on single-channel eeg, *Comput. Methods Programs Biomed.* 183 (2020) 105089.
- [41] W. Zhao, H. Ni, X. Zhou, Y. Song, T. Wang, Identifying sleep apnea syndrome using heart rate and breathing effort variation analysis based on ballistocardiography, in: Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE, IEEE, 2015, pp. 4536–4539.
- [42] W. Zhu, N. Zeng, N. Wang, et al., Sensitivity, specificity, accuracy, associated confidence interval and roc analysis with practical sas implementations, NE-SUG proceedings: health care and life sciences, Baltimore, Maryland 19 (2010) 67.
- [43] M.D. Zink, C. Brüsler, B.-O. Stüben, A. Napp, R. Stöhr, S. Leonhardt, N. Marx, K. Mischke, J.B. Schulz, J. Schiefer, Unobtrusive nocturnal heartbeat monitoring by a ballistocardiographic sensor in patients with sleep disordered breathing, *Sci. Rep.* 7 (1) (2017) 13175.
- [44] B. Zoph, V. Vasudevan, J. Shlens, Q.V. Le, Learning transferable architectures for scalable image recognition, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2018, pp. 8697–8710.



Classification of health deterioration by geometric invariants

Dalibor Cimr^a, Damian Busovsky^a, Hamido Fujita^{b,c,d,e,*}, Filip Studnicka^a, Richard Cimler^a, Toshitaka Hayashi^a

^a Faculty of Science, University of Hradec Kralove, Rokitanskeho 62, Hradec Kralove 50003, Czech Republic

^b Faculty of Information Technology, HUTECH University, Ho Chi Minh City 700000, Vietnam

^c Malaysia-Japan International Institute of Technology (MJIT), Universiti Teknologi Malaysia, Kuala Lumpur 54100, Malaysia

^d DaSCI Andalusian Institute of Data Science and Computational Intelligence, University of Granada, Granada, Spain

^e Regional Research Center, Iwate Prefectural University, Iwate 0200611, Japan

ARTICLE INFO

Article history:

Received 28 March 2023

Revised 18 May 2023

Accepted 24 May 2023

Keywords:

Deterioration detection

Ballistocardiography

Cartan curvature

Convolutional neural network

Piezoelectric sensor

ABSTRACT

Background and Objectives: Prediction of patient deterioration is essential in medical care, and its automation may reduce the risk of patient death. The precise monitoring of a patient's medical state requires devices placed on the body, which may cause discomfort. Our approach is based on the processing of long-term ballistocardiography data, which were measured using a sensory pad placed under the patient's mattress.

Methods: The investigated dataset was obtained via long-term measurements in retirement homes and intensive care units (ICU). Data were measured unobtrusively using a measuring pad equipped with piezoelectric sensors. The proposed approach focused on the processing methods of the measured ballistocardiographic signals, Cartan curvature (CC), and Euclidean arc length (EAL).

Results: For analysis, 218,979 normal and 216,259 aberrant 2-second samples were collected and classified using a convolutional neural network. Experiments using cross-validation with expert threshold and data length revealed the accuracy, sensitivity, and specificity of the proposed method to be 86.51.

Conclusions: The proposed method provides a unique approach for an early detection of health concerns in an unobtrusive manner. In addition, the suitability of EAL over the CC was determined.

© 2023 The Author(s). Published by Elsevier B.V.
This is an open access article under the CC BY-NC-ND license
(<http://creativecommons.org/licenses/by-nc-nd/4.0/>)

1. Introduction

Patient deterioration is the significant degradation of the physical state of a hospitalized patient, which can often result in morbidity and/or mortality [23]. The symptoms of deterioration may vary. Some patients may experience a decreased cardiac index followed by decreased blood pressure, tachycardia, and reduced blood flow [8]. As mentioned in [28], before the loss of the electrocardiogram (ECG) signal of dying elderly patients, the P-wave was undetectable in the majority of the observed cases. Prolongation of the corrected time interval between the Q and T peaks of the ECG (QTc) is associated with an increased risk of sudden cardiac death (SCD) [34]. Here the QTc interval is a number calculated via different formulae using heart rate or RR intervals, i.e. time intervals between two successive R peaks in an ECG [14]. Addition-

ally, phenomena associated with breathing such as apnea periods, Cheyne-Stokes breathing, and respiration with mandibular movement are also observed [21,24,28]. Moreover, article [21] states that the death rattle and pulselessness of the radial artery are other physical signs that signal impending death.

Recently, various methods have been developed to predict whether a patient's critical condition will worsen. A reliable approach can prevent patient deterioration. This requirement is not only related to the elderly population [28], but also adults [18,29,32] and pediatric patients [7,22]. The predictive methods for this phenomenon differ in terms of input data and processing. Several studies have investigated the changes in ECG of patients. ECG is a non-invasive method for monitoring heart activity over a period. In recent years, the number of portable ECG-measuring devices has increased significantly. Therefore, focusing on processing data of this type is desirable [20]. Acharya et al. [2] first extracted nonlinear features from second-level discrete wavelet transform decomposed ECG signals and subsequently ranked them

* Corresponding author.

E-mail addresses: h.fujita@hutech.edu.vn, H.Fujita-799@acm.org (H. Fujita).

using their *t*-value. Subsequently, the authors formulated and employed an integrated SCD index using highly ranked features to effectively predict SCD four minutes before onset. This research was expanded by Fujita et al [16], who introduced a novel methodology to automatically classify the heart rate variability (HRV) signals of normal and SCD-risk patients. In a study by Acharya et al., ECG signals were used [1]. Herein, the authors used an eleven-layer convolutional neural network model to process 2-second ECG segments to distinguish shockable and non-shockable ventricular arrhythmias. This phenomenon is crucial for increasing the efficacy of defibrillation via automated external defibrillators. Another study by Ebrahimzadeh et al. [15] extracted HRV parameters from ECG to predict SCD. Both nonlinear and time-frequency HRV features were determined. Subsequently, the dimension of the feature space was reduced using feature selection with healthy and SCD-risk patient classification using a multilayer perceptron and K-nearest neighbor neural network. Brufau et al. [6] employed machine learning to create a model to predict patient deterioration. This study aimed to process the laboratory test results, nursing assessments, vital signs, and demographics of patients hospitalized in general care beds, resulting in the development of a specific early warning score (EWS) that accurately predicts acute deterioration. Kirkland et al. [25] investigated the values of the Braden Scale, oxygen saturation, respiratory rate, and shock index using a multivariate regression analysis to determine the clinical variables statistically associated with patient deterioration.

A review of EWSs by Gerry et al. [19] stated that EWSs are widely used as prediction models for patient deterioration. This review noted that many EWSs have methodological weaknesses that may have detrimental effects on patient care. Another review by Mann et al. [27] focused on tools for predicting patient deterioration. It included results from 46 publications, concluding that the literature has not shown that the implementation of the reviewed tools is reproducibly associated with improvements in patient outcomes. Finally, Blackwell [5] studied statistical models for the early detection of patient deterioration in patients hospitalized in cardiac and cardiac surgery wards. This study concluded that no model could be relied upon in all situations.

In branch of deep learning-based disease diagnosis, Muezzinoglu et al. [31] discussed the use of convolutional neural networks (CNNs) for automated brain tumor classification. The authors propose a patch-based deep feature engineering model called PatchResNet to improve classification performance. The model uses three types of patches of different sizes and two layers of a pretrained ResNet50 as feature extractors. Three selectors were used to obtain 18 final feature vectors, and k nearest neighbors and iterative hard majority voting were used for classification. In other brain problematics, Baygin et al. [4] describes a hand-crafted model for accurately detecting schizophrenia using EEG signals. The model generates features using a carbon chain pattern (CCP) and an iterative decomposition model, and extracts subbands of the EEG signal using an iterative tunable q-factor wavelet transform (ITQWT) technique. The clinically significant features are selected using iterative neighborhood component analysis (INCA) and classified using k nearest neighbor (kNN) with a 10-fold cross-validation strategy. The iterative weighted majority method is used to obtain the results in multiple channels. Moreover, Kuluozturk et al. [26] presented a study on cough-based disease detection using machine learning. The authors collected a large cough sound dataset comprising four diagnostic categories (Covid-19, heart failure, acute asthma, and healthy), and trained, validated, and tested a novel model for automatic detection. The model includes four components: feature generation using a specifically directed knight pattern (DKP), signal decomposition using four pooling methods, feature selection using iterative neighborhood analysis (INCA), and classification using the k-nearest neighbor (kNN)

classifier with ten-fold cross-validation. The study resulted in the selection of ten best feature vectors and elimination of redundant feature vectors using misclassification rates, followed by feature selection using INCA and input to a kNN classifier.

The proposed approach is based on processing the ballistocardiographic (BCG) data obtained from long-term measurements using a sensory pad equipped with piezoceramic sensors placed under the patient's mattress. BCG is an unobtrusive method for studying the vital functions of a subject by recording the recoil movement of the subject's body. The measured movement appears due to the mechanical activity of the heart and large arteries ensuring blood circulation, and in the case of this study, the mechanical activity of the respiratory system. Both phenomena cause the human body to vibrate slightly. These micro-vibrations then reach the sensors placed directly under/on the body of the subject or propagate through the mattress and bed to reach the sensors. BCG investigations may be used to assess the state of the cardiovascular system of a subject. Starr and Wood [33] conducted a study on a group of 211 healthy persons. Investigation of their ballistocardiograms (BCGm) showed considerable variation in amplitude. The authors interpreted this to be due to the differences in the force exerted by the heart during contraction. Subjects with lower exerted heart force later suffered significantly more from cardiac disability, chiefly coronary heart disease and death, than those with higher exerted heart force. Cimr et al. [13] examined the ability of BCG data to detect various breathing disorders using a 9-layer deep convolutional neural network (CNN) with an ECG R-peak as a trigger. This model achieved an accuracy, sensitivity, and specificity of 96.21%, 88.31%, and 98.69%, respectively, highlighting the possibility of it being used as an early warning system for long-term impending problems. In [3], Baker et al. reported a study focusing on their BCGm examination of coronary heart disease. This study found that abnormalities in BCGm appeared more often in subjects with coronary heart disease. Theorell and Rahe [35] examined the medical and psychological data of 36 people who either experienced myocardial infarction and survived or died from it. These data included their ultralow-frequency BCGm. Here, the mean I-J amplitude served as a rough estimate of the maximal force exerted by the heart during contraction. In the case of subjects dying from myocardial infarction, a significant increase in the mean I-J amplitude appeared approximately six months before their death. However, it is imperative to emphasize that the existing literature does not encompass any research that specifically addresses the management of BCG records for terminally ill individuals. Therefore, this article serves to contribute novel insights to this field of study. By delving into previously unexplored territory, it sheds light on an important aspect that has thus far been overlooked by researchers.

Existing literature prior to [11,13] focused on processing differential geometric invariants. The preprocessing of the examined BCG input in terms of calculating its (first) Cartan curvature (CC) preceded the classification. The dataset can be investigated as a set of 12-dimensional discrete time-parameterized curves in Euclidean space (the BCGm were obtained by deploying four triaxial tensometers) using the Frenet–Serret theory [17]. CCs are uniform functions describing the local properties of curves derived from the derivatives of the vectors of the Frenet frame, that is, a group of *n* orthogonal normalized vectors in the case of a *n*-dimensional curve (in the case of *n* = 3, the vectors are tangent, normal, and binormal) [17]. The main reason for processing CC is its invariance to isometric transformations (translations, rotations, and reflections) of the Euclidean group $\mathbb{E}(n)$, where CC is independent of the position of the person on the bed. In [12], another differential invariant in BCG data examination, the Euclidean arc length (EAL), was also included in the data processing. The EAL of a time series in a window of a given length is computed as the sum of the lengths of all segments connecting two successive points in that window of

concrete length [17]. It was first used as a trigger for the unobtrusive detection of respiratory disorders. However, subsequent data processing showed that EAL is not only a useful trigger but also a valuable source of information on the vital state of the measured subject. This led us to include both invariants in this study.

Each method of detection or prediction of patient deterioration listed previously has its own weaknesses. Most research on this topic is based on the processing of ECG data. Precise ECG recording requires the attachment of electrodes to specific locations on the patient's body. Usually, these electrodes are connected to the recording device by a wire, making the measurement obtrusive and difficult to perform in the long term, despite wireless ECG recording devices being available. Otherwise, the processing of clinical or demographic data may be burdened by the late provision of information, resulting in a late warning. A literature review shows that there has been no published research examining BCG data a few hours before death, impending patient deterioration, or during death. Therefore, the outcomes of the current study are unprecedented. In continuation of this article, we also present the distinctive BCG dataset that we have collected and analyzed. This dataset comprises death records of 16 subjects, providing valuable and specific information for further investigation. By sharing this dataset, we aim to facilitate future research in this domain, enabling researchers to delve deeper into the implications and insights derived from these records. The inclusion of this dataset contributes to the overall comprehensiveness and reliability of the findings.

In this study, a novel approach for achieving mechanical triggers of patient deterioration is proposed. The core hypothesis is that deterioration causes significant changes in a BCG signal. Death records of the elderly were collected during long-term BCG data collection using measuring pads equipped with piezoceramic sensors. When these data were examined using expert estimates, deterioration was discovered several hours prior to death. While annotating the trigger in the processed dataset, the expert considered the changes in hemodynamics and respiration effort. The literature shows that these phenomena change before death. BCG cannot be described as easily as ECG because BCG does not have a standardized measurement and strongly depends on the position of the patient or the sensor on the bed. Accordingly, the experts used differential geometric invariants (CC and EAL) to annotate the significant changes. These invariants have proven to be robust tools for searching for changes in BCG data. Obtaining CC and EAL while measuring BCG is completely unobtrusive and may be performed in the long term, even in home care. The calculations of CC and EAL and their further processing are described in the following sections.

2. Methods

In the present study, data measurement and preprocessing were germane. The processed dataset was obtained using measuring pads equipped with piezoceramic sensors placed under the patient's mattress, as shown in Fig. 1.

In the case of a 4-sensor pad, the sensors were placed as follows: (i) approximately under the heart, (ii) under the right lunge, on the same level as sensor (i), (iii) under the left hip approximately, at the level of the patient's centroid, and (iv) on the same level under the right hip. By contrast, in 2-sensor pads, only sensors (i) and (iii) were deployed. The person lying on the bed was not connected to any device, and both sensors were placed directly on the measuring pad, making the measurement unobtrusive. The body recoil movement propagated through the mattress, and the measuring pad reached the piezoceramic sensor. The number of sensors used depended on the type of institution. The beds in retirement homes were equipped with only two sensors because the

aim of their data processing was to focus on bed presence and client positioning. In contrast, in the ICU, pads with four sensors were installed to record the vital state of the patient more accurately. In the presented approach, the output signals were considered as 2-dimensional discrete curves parameterized by time, in terms of the timestamp of the recorded data, and 4-dimensional discrete curves in the case of the ICU. This perspective allows for the calculation of the differential invariants of the obtained data.

2.1. Data description

The BCG data, whose processing results are presented in this study, consisted of 16 death records. Data were obtained from the piezoceramic sensors used for body microvibration data collection. The sensor sampling frequency was 330 Hz. The lengths of the records differed owing to the different time intervals from the onset of deterioration to death; a detailed explanation is provided in the next section. The patients' sex, age, height, weight, and other descriptors were unknown; however, none significantly affected the differential invariants used for our purposes.

2.2. Classifier input preparation

After an expert qualitative examination of data from several cases, the deterioration of the patient was found to be readable in the measured data by observing a linear decreasing trend in amplitude and irregularities in vital signs. First, the sliding mean of the Euclidean arc length (SEAL) difference with a window length of 1 h was derived to automate the identification of amplitude drop occurrence. SEAL then served as input data for the sliding least square method (SLSM) with a window length of 30 min and an overlap between adjoining segments of 10 min to examine the trend of the signals' amplitude. In contrast, continuous wavelet transform (CWT) was used to evaluate the data in terms of anomalies in vital signs. The expert subsequently examined sections of the measured data, characterized by a negative trend of SLSM approximation lines, a low difference in the slopes of these lines, a relatively low error of SLSM, and less readable frequencies of vital functions in the output of CWT to annotate the start of deterioration. The SEAL and SLSM lines of a recorded death are shown in Fig. 2a. The parameters examined by annotating the start of the deterioration with respect to the decrease in amplitude corresponding to this particular case are presented in Fig. 2b-d. In these figures, death is observed the moment after which our data no longer recorded a legible trace of heart activity. The outputs of the CWT before and after deterioration are shown in Fig. 3a and b.

However, there is a concern that expert annotations are subjective. To address this issue, expert annotation was evaluated using a CNN by analyzing the required trainable parameters to decrease the computational complexity of the system for future applications [10]. The core hypothesis is that the machine-learning model can classify before and after the threshold with high accuracy. For this purpose, the signal is split into training and testing data, as shown in Fig. 4, where the parts near the threshold are used as testing data, and those before (normal) and after (deterioration) are used as training data. This split was created to achieve the same class balance.

Regarding the threshold, 20% of the shorter vectors represented the testing dataset, and the remaining 80% represented the training dataset. An exact-length dataset was created for the second class. Subsequently, the data were separated into vectors of 660 values, which corresponded to a 2-second sample of 330 Hz frequency.

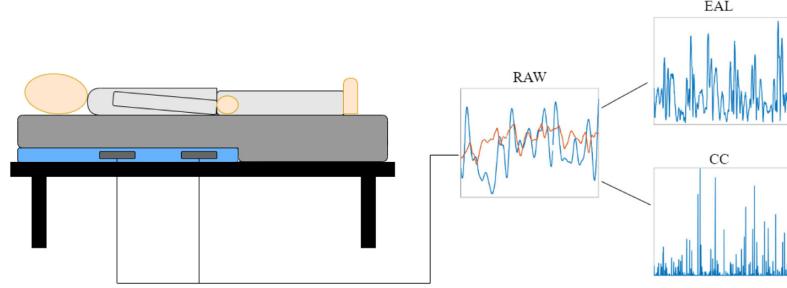


Fig. 1. System architecture.

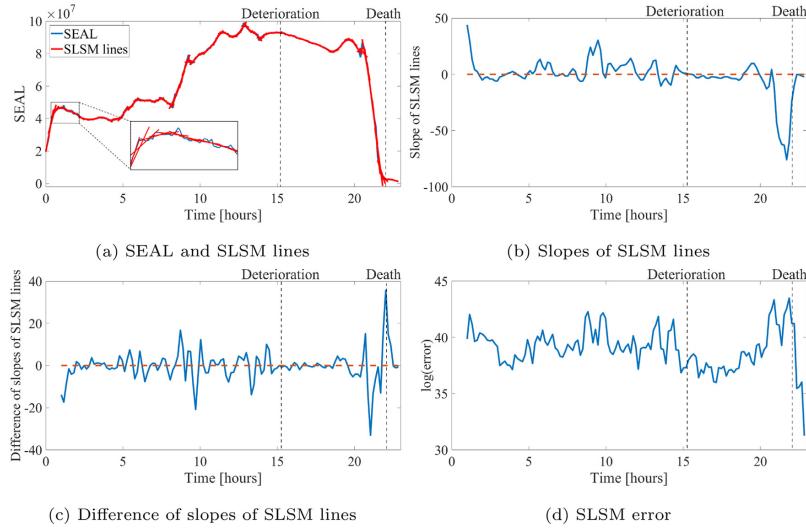


Fig. 2. Expert thresholding.

2.3. Preprocessing

The Euclidean differential invariants are preserved under the actions of the Euclidean group $\mathbb{E}(n)$, rendering them invariant to the position of the person lying on the bed. This is because the cardiovascular system of the person does not change significantly in different positions while lying. Let \mathbf{C} be a matrix whose columns correspond to the signals measured by individual sensors, C_i be the i th row of \mathbf{C} , that is, the vector of measured data corresponding to timestamp $t = t_i$, and $C_{i,j}$ be the element of \mathbf{C} in the i th row and j th column. The n th difference of \mathbf{C}_i can be defined as

$$d^n \mathbf{C}_i = \sum_{k=0}^n (-1)^k \binom{n}{n-k} \mathbf{C}_{i+(n-k)}. \quad (1)$$

Moreover, the first difference of the element $C_{i,j}$ is given by

$$dC_{i,j} = C_{i+1,j} - C_{i,j}. \quad (2)$$

The EAL of an n -dimensional discrete curve parameterized by time is calculated using the following equation

$$s_m = \sum_{i=1}^m \sqrt{\sum_{j=1}^n (dC_{i,j})^2}. \quad (3)$$

In (3), s_m represents the EAL of the polyline connecting successive points, starting at the point corresponding to the initial timestamp $t = t_1$ and ending at the point corresponding to the timestamp $t = t_{m+1}$. The elements s_m are stored in the vector \mathbf{s} , and the difference \mathbf{ds} is used for further data processing. However, when calculating the CCs of the processed n -dimensional discrete signal at a given time corresponding to timestamp $t = t_i$, the n orthonormal vectors \mathbf{e}^q and $q \in \{1, 2, \dots, n\}$ of the relevant Frenet frame must be determined first. This can be achieved using the Gram-Schmidt process [30]. Let the q th vector of the Frenet frame corresponding to the i th row of \mathbf{C} be denoted by \mathbf{e}_i^q . Using this notation,

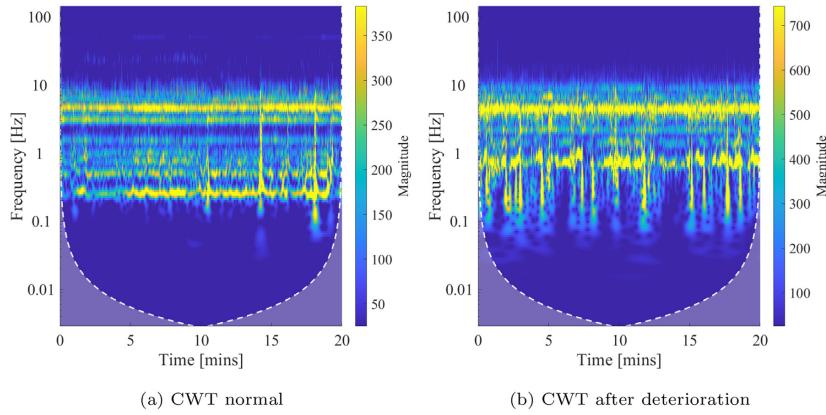


Fig. 3. CWT.

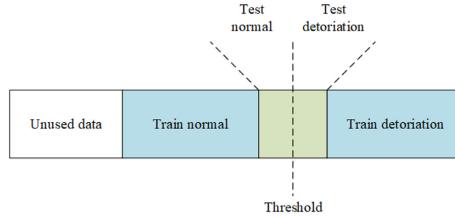


Fig. 4. Data split.

all Frenet frame vectors can be determined as follows:

$$\mathbf{e}_i^1 = \frac{\mathbf{dC}_i}{\|\mathbf{dC}_i\|}, \quad (4)$$

$$\mathbf{e}_i^k = \frac{\mathbf{d}^k \mathbf{C}_i - \sum_{j=1}^{k-1} \langle \mathbf{d}^k \mathbf{C}_i, \mathbf{e}_i^j \rangle \mathbf{e}_i^j}{\| \mathbf{d}^k \mathbf{C}_i - \sum_{j=1}^{k-1} \langle \mathbf{d}^k \mathbf{C}_i, \mathbf{e}_i^j \rangle \mathbf{e}_i^j \|}, \quad \text{for } k = 2, 3, \dots, n-1, \quad (5)$$

$$\mathbf{e}_i^n = \mathbf{e}_i^1 \times \mathbf{e}_i^2 \times \cdots \times \mathbf{e}_i^{n-1}. \quad (6)$$

Here $\|\mathbf{v}\|$ stands for the Euclidean norm of a vector \mathbf{v} , $\langle \mathbf{u}, \mathbf{v} \rangle$ for the dot product of vectors \mathbf{u} and \mathbf{v} , and $\mathbf{u} \times \mathbf{v}$ for the cross product of vectors \mathbf{u} and \mathbf{v} . Let

$$\mathbf{de}_i^q = \mathbf{e}_{i+1}^q - \mathbf{e}_i^q, \quad \text{for } q = 1, 2, \dots, n, \quad (7)$$

then, the first CC of the n -dimensional discrete curve at the time corresponding to timestamp $t = t_i$ is given by

$$\kappa_i = \frac{\langle d\mathbf{e}_i^1, \mathbf{e}_i^2 \rangle}{\|d\mathbf{C}_i\|}. \quad (8)$$

This prescription clearly indicates that an n -dimensional discrete curve may include points for which the first CC cannot be defined owing to division by zero. In our case, this situation occurs when none of the n signals change their values for two consecutive timestamps. From the differential geometry theory perspective, this curve is not *regular*. However, if all sensor values change minimally for two consecutive timestamps, the software used to calculate the CC values may return infinity. In both cases, CC was

Table 1
The details of the CNN structure with n classes depend on the used dataset.

Layers	Type	No. of output neurons	Kernel size	Stride
0-1	convolution	642 x 30	19	1
1-2	max-pooling	321 x 30	2	2
2-3	convolution	303 x 30	19	1
3-4	max-pooling	151 x 30	2	2
4-5	convolution	141 x 30	11	1
5-6	max-pooling	70 x 30	2	2
6-7	fully connected	30	-	-
6-7	fully connected	20	-	-
7-8	fully connected	2	-	-

assigned a value of zero. Two additional facts regarding the introduced invariants must be stated for further processing. First, the denominator in the final prescription of the first CC equals the i th element of difference in the EAL. Second, EAL is more sensitive to signal segments with larger differences and CC, compared to those where the signal locally deviates from the signal's tangents at the previous points. This relates the invariants in a form similar to inverse proportion.

2.4. Model architecture

A unique CNN architecture was developed for classification. The architecture comprised layer blocks formed by convolutional and max-pooling layers. Both block layers slid the input of the previous layer through window filter defined by the kernel size and stride. Three blocks were provided in the proposed model to obtain the required features from the input data. In all the max-pooling layers, the kernel size for the sliding data was determined by throwing two values with a stride step of two. The first two blocks of the convolutional layers contained a kernel filter comprising 19 vector values, followed by a layer with a filter size of 11. Thirty filters were used in the convolutional layers to determine the patterns with a stride step of one. The design was completed using three successive fully connected layers with 30, 20, and two neurons representing the normal and abnormal classes, as shown in Table 1. The entire architecture contained 91,352 trainable parameters, indicating that an unnecessarily complex model was not required, even for such a large dataset. To avoid overfitting, rectified linear unit layers were added after each convolutional layer.

and a dropout layer was added between the first and second fully connected layers, all with a value of 0.3. Toward the end of the architecture, a softmax exponential function was used to normalize the findings.

2.5. Limitations and benefits of the approach

Utilizing the 4-sensor BCG pads enables us to acquire long-term measurements for subsequent processing. The data collection procedure itself is non-invasive and non-disruptive to the patients. Simultaneously, the employed measurement method is susceptible to bed movements unrelated to the patient's cardiac activity. Numerous beds in retirement homes are equipped with anti-decubitus mattresses, which induce periodic bed frame movements. However, this signal noise can be easily extracted due to its predictable periodicity. Conversely, movements originating from the patient's skeletal muscles are indistinguishable from the measured data and can introduce inaccuracies in the data classification. Each human body constitutes a unique biological system, and the manifestations of health deterioration may exhibit variations. In this study, a total of 16 death records have been analyzed, which represents a relatively small sample size necessitating expansion for future research endeavors.

The utilization of geometric invariants as an approach in this study is exemplary and builds upon the previous works conducted by the authors. By aggregating the four measured BCG signals into a single time series, we are able to employ the aforementioned Convolutional Neural Network (CNN) described earlier. This technique allows for a comprehensive analysis of the combined data, taking advantage of the rich information encoded in the merged signals. The integration of the geometric invariants and the CNN model enhances the robustness and effectiveness of the analysis, enabling us to extract meaningful insights from the BCG measurements.

2.6. Data availability

The raw BCG data supporting the findings of this study are available in from Mendeley-doi:10.17632/4wrk4fr69w.2. [9].

2.7. Ethics and informed consent

This research was approved by the Committee for Research Ethics of the University of Hradec Králové. The experimental procedure was conducted in accordance with the Ethical Research Framework of the Ministry of Education, Youth, and Sports of the Czech Republic and the ethical requirements of the research. All the participants provided written informed consent to participate in this study.

3. Results

3.1. Experimental setup

As described in Fig. 4, 20% of the shorter vectors around threshold were used as the testing dataset, while the remaining 80% represented the training dataset. The data were separated into vectors of 660 values, which corresponded to a 2-second sample of 330 Hz frequency. An exact-length dataset was created for the second class. The training dataset was then divided into training and validation data by a split of 70% and 30%, respectively. During the training process, 100 epochs were repeated with an early stopping callback when the validation accuracy stopped improving.

Adam optimizer were used to adapt the model attributes. Moreover, the learning rate (LR) value, which represents the size of a

Table 2
Optimization hyperparameters used for training the model.

Input	Optimizer	LR	Patience	Factor	Mini batch	Epochs
660x1	Adam	$1 \cdot 10^{-3}$	$1 \cdot 10^{-5}$	$2 \cdot 10^{-1}$	32	100

Table 3
Confusion matrix description.

O/P	Normal	Abnormal	Acc (%)	Sen (%)	Spec (%)
Normal	TP	FN	$\frac{TP+TN}{TP+TN+FP+FN}$	$\frac{TP}{TP+FN}$	$\frac{TN}{TN+FP}$
Abnormal	FP	TN	$\frac{TP+TN}{TP+TN+FP+FN}$	$\frac{TN}{TP+FN}$	$\frac{TP}{TP+FP}$

Table 4
Overall classification of EAL.

Person	Single input			Voting			
	ID	Acc (%)	Sen (%)	Spec (%)	Acc (%)	Sen (%)	Spec (%)
0	96.56	94.73	98.55	98.91	97.89	100	
1	95.77	97.27	94.36	97.02	100	94.31	
2	63.36	70.47	59.91	65.03	80.85	58.62	
3	76.80	73.33	81.48	85.71	80.88	92.41	
4	80.08	79.76	80.40	90.20	92.55	87.94	
5	72.55	94.39	50.71	75	95.18	53.79	
6	98.10	96.98	99.28	100	100	100	
7	61.44	58.56	67.26	67.31	58.66	90.90	
8	95.55	93.80	97.44	99.36	99.69	99.03	
9	96.56	94.70	98.59	98.92	97.91	100	
10	81.65	91.57	75.55	83.73	95.60	76.66	
11	78.39	59.92	96.85	83.21	69.12	97.67	
12	72.69	70.17	75.93	87.12	80.00	97.56	
13	67.32	65.26	70.03	77.33	75.95	79.09	
14	86.20	88.34	84.28	92.00	98.23	86.86	
15	74.88	70.16	82.46	83.33	76.74	94.23	
Total	81.12	81.21	82.06	86.51	87.45	88.06	

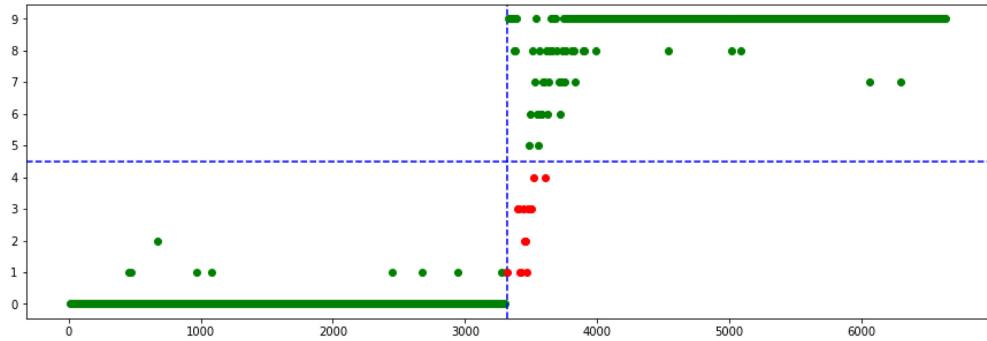
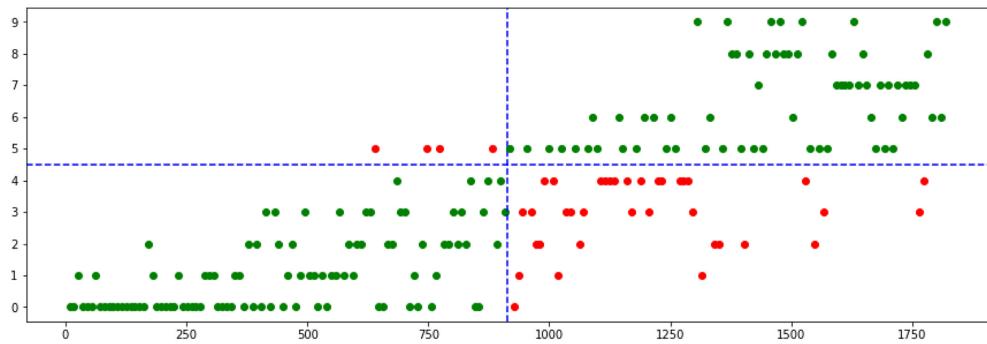
step towards minimizing the cost function of a model, was variably reduced for the training process with a patience of five for no decrease in validation loss by a factor of $2 \cdot 10^{-1}$ until the minimum value of $1 \cdot 10^{-5}$. Table 2 summarizes the hyperparameters of the proposed CNN model.

At the end, each individual were analyzed on testing dataset to evaluate expert annotations and model performance in deterioration detection. Classification results are evaluated using a tool called a confusion matrix. This matrix tabulates the number of true positives (TP), true negatives (TN), false positives (FP), and false negatives (FN), tabulated in Table 3 with equations for accuracy (Acc), sensitivity (Sen), and specificity (Spec). TP and TN indicate correctly classified normal and abnormal signals, respectively, whereas FP and FN represent the incorrect decisions made by the model.

3.2. Results of the experiments

Table 4 presents the EAL classification results for the proposed system in terms of accuracy, sensitivity, and specificity. The fraction of correct outcomes and all predictions in a testing population is defined as accuracy. It evaluates the dependability of a diagnostic test under given conditions. The proportion of true positives correctly predicted by the classifier is referred to as the sensitivity. It represents the ability of a test to detect a disease. Specificity is defined as the proportion of true negatives correctly predicted by a classifier. This demonstrates the accuracy of a test for predicting normal data.

Each data point around the expert-defined threshold was evaluated separately. Furthermore, sample sequence voting was supplied to improve the system performance, and it succeeded in most cases, except for that of the person with ID 11. Example details for a person with ID 0 are shown in Fig. 5. The green dots represent voting results that result in true-positive or true-negative

**Fig. 5.** Testing example for individual patient with ID 0.**Fig. 6.** Testing example for individual patient with ID 12.

decisions, whereas the red dots represent false-positive or false-negative categories. An important aspect of the observation is that most errors are close to the threshold where the patient's condition worsens, without early or late false positives or false negatives. The overall accuracy, sensitivity, and specificity of the proposed technique were 86.51%, 87.45%, and 88.06%, respectively.

Table 5 presents the CC classification results. The differences between individual results with EAL were negligible in terms accuracy, sensitivity, and specificity. However, the sensitivity and specificity for individuals were not balanced. A possible reason is that some CCs were infinite or undefined; these were subsequently replaced with zero. Moreover, the threshold from [Section 2.2](#) was computed from EAL; thus, computing both approaches was not necessary.

4. Discussion

The results presented in **Tables 4** and **5** are similar owing to the nature of EAL and CC, which was described at the end of [Section 2.3](#). The results of the expert estimation for IDs 0, 1, 6, 8, 9, and 10 indicated immediate health deterioration with high accuracy. This suggests that the system can accurately detect critical patient conditions. However, in case 10, there was a short-term state deterioration in the pre-threshold region, causing the classi-

Table 5
Overall classification of CC.

Person ID	Single input			Voting		
	Acc (%)	Sen (%)	Spec (%)	Acc (%)	Sen (%)	Spec (%)
0	97.09	99.54	94.63	97.55	99.72	95.36
1	95.46	93.65	97.62	97.02	95.81	98.22
2	59.86	53.67	66.05	61.57	55.37	67.76
3	78.81	89.37	68.24	85.72	93.16	77.64
4	82.52	80.01	85.04	89.97	88.45	91.46
5	69.16	95.55	42.77	66.35	94.91	39.52
6	97.78	99.08	96.49	100	100	100
7	57.23	17.68	96.78	53.81	15.94	95.96
8	97.89	97.95	97.82	99.21	99.21	99.21
9	98.03	99.77	96.28	98.98	99.88	98.07
10	78.52	72.24	84.80	79.63	73.54	85.68
11	79.86	64.93	94.78	85.81	73.92	96.45
12	75.82	83.99	67.65	82.18	88.46	75.51
13	67.45	77.63	57.27	74.73	83.25	65.61
14	86.18	83.09	89.26	92.2	90.24	94.09
15	76.34	86.14	66.53	82.67	90.21	74.62
Total	81.15	80.89	81.37	84.21	83.87	84.69

fication accuracy to be lower than that of the other cases with an instantaneous state change.

The condition of patients with IDs 3, 4, and 14 worsened rapidly, although not immediately, within 10 min. This caused

more frequent mispredictions in the near-threshold region, indicating that the system is particularly vulnerable to errors in this area. Therefore, these cases must be focused upon to improve the overall accuracy and reliability of the system. In addition, case 3 was found to have random false positives, which reduced the sensitivity of the system. This is a serious concern because false positives can lead to unnecessary interventions. Such issues must be identified and addressed to optimize the system and minimize the occurrence of false positives while maintaining high sensitivity and accuracy.

Certain findings, however, appeared dubious for persons with IDs 12, 13, and 15, where the model appeared to be ineffective in step threshold cases. Specifically, for ID 12, a detailed qualitative study of the associated RAW data using SEAL, SLSM, and CWT, revealed that the patient's deterioration progressed over a period of 7 h, with accelerated deterioration during the last 2 h. However, an additional examination indicates that a specific trend results in an improvement in the distance from the threshold decision. It may be seen in Fig. 6, the Y-axis shows the number of voting results, indicating that the condition is not acceptable, and the X-axis represents the number of testing samples. This leads to the conclusion that status changes should be gradual rather than stepwise and explains why voting post-processing improved the final prediction. Furthermore, accuracies of 56.45% and 53.48% for the single-input evaluation were unsatisfactory for the situations of IDs 5 and 11, respectively. Examination of the findings revealed a tendency for gradual condition change in distinct timesteps, requiring a double-check of expert design thresholds and performance improvement. Moreover, the individuals with IDs 2 and 7 showed unsatisfactory results. However, after these patients first experienced health-state deteriorations, their SEAL, SLSM, and CWT results improved. After an hour-long increasing trend for SEAL and gradually readable vital function signs in the CWT results, the patients' condition deteriorated again, which culminated in their deaths within approximately 1 h.

Overall, these findings suggest that the system has the potential to accurately detect critical conditions in patients; however, its performance and reliability may be improved.

5. Conclusion

This paper presents a classification model for health deterioration based on geometric invariants. The system operated via BCG sensors placed unobtrusively by measuring pads placed under the patient's mattress. The proposed solution was classified based on CC and EAL preprocessing mechanisms, with data labeling as normal or abnormal based on the SLSM algorithm and CWT. The classifier was designed as an 8-layer deep CNN model for predicting health deterioration. A voting post-processing technique was deployed to improve model performance. Experiments employing cross-validation with an expert threshold and data length demonstrated that the accuracy, sensitivity, and specificity were 86.51%, 87.45%, and 88.06%, respectively.

In future work, the plan is to persist in the collection of long-term BCG data primarily from retirement homes situated in the Czech Republic. The objective is to gather a larger number of death cases for subsequent analysis. Differential geometry provides additional geometric invariants that hold promise for the classification of the measured data, such as affine differential invariants (such as affine arc length and affine curvatures). Furthermore, there is a plan to develop a more resilient algorithm for detecting the threshold of health deterioration. By enhancing the algorithm's robustness, we can improve the accuracy and reliability of identifying critical health changes. These proposed future directions aim to further enhance the understanding and applica-

tion of BCG measurements in monitoring and predicting health outcomes.

Declaration of Competing Interest

The authors declare no conflicts of interest.

CREDIT authorship contribution statement

Dalibor Cimr: Conceptualization, Writing – original draft, Investigation, Data curation, Software. **Damian Busovsky:** Writing – original draft, Investigation, Data curation. **Hamido Fujita:** Writing – review & editing, Supervision. **Filip Studnicka:** Writing – original draft, Investigation, Data curation. **Richard Cimler:** Writing – review & editing, Project administration. **Toshitaka Hayashi:** Conceptualization, Methodology, Writing – original draft, Investigation, Software.

Acknowledgments

The authors are grateful to the Operational Programme "Development of the Internal Grant Agency of the University of Hradec Králové", reg. no. CZ.02.2.69/0.0/0.0/19_073/0016949, project no. IGRA-TYM-2021008 (investigators: Damian Busovsky and Katerina Voglova).

This study was also possible thanks to the project TP01010032 "The Centre of Creative Activities and Knowledge Transfer at University Hradec Králové." This project was co-financed by the state budget of the Technology Agency of the Czech Republic under the GAMA 2 Programme.

Furthermore, the authors are grateful to the Excellence project PřF UHK 2215/2023-2024 for its financial support.

References

- [1] U.R. Acharya, H. Fujita, S.L. Oh, U. Raghavendra, J.H. Tan, M. Adam, A. Gerlich, Y. Hagiwara, Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network, Future Gener. Comput. Syst. 79 (2018) 952–959.
- [2] U.R. Acharya, H. Fujita, V.K. Sudarshan, V.S. Subbhuraam, L.W.J. Eugenio, D.N. Ghista, R.S. Tan, An integrated index for detection of sudden cardiac death using discrete wavelet transform and nonlinear features, Knowl. Based Syst. 83 (2015) 149–158.
- [3] B.M. Baker, Ballistocardiography: predictor of coronary heart disease, Circulation 37 (1) (1968) 1–3.
- [4] M. Baygin, P.D. Barua, S. Chakraborty, I. Tuncer, S. Dogan, E.E. Palmer, T. Tuncer, A.P. Kamath, E.J. Ciacco, U.R. Acharya, CCPNet136: automated detection of schizophrenia using carbon chain pattern and iterative TQWT technique with EEG signals, Physiol. Meas. (2023).
- [5] J.N. Blackwell, J. Keim-Malpass, M.T. Clark, R.L. Kowalski, S.N. Najjar, J.M. Bourque, D.E. Lake, J.R. Moorman, Early detection of in-patient deterioration: one prediction model does not fit all, Crit. Care Explor. 2 (5) (2020).
- [6] S. Romero-Brutau, D. Whittford, M.G. Johnson, J. Hickman, B.W. Morlan, T. Therneau, J. Naessens, J.M. Huddleston, Using machine learning to improve the accuracy of patient deterioration predictions: Mayo clinic early warning score (MC-EWS), J. Am. Med. Inform. Assoc. 28 (6) (2021) 1207–1215.
- [7] S.M. Chapman, J. Wray, K. Oulton, M.J. Peters, Systematic review of paediatric track and trigger systems for hospitalised children, Resuscitation 109 (2016) 87–109.
- [8] L.-C. Chien, J.O.K. Liu, C.C.J. Wo, W.C. Shoemaker, Hemodynamic patterns preceding circulatory deterioration and death after trauma, J. Trauma 62 (4) (2007) 928–932.
- [9] D. Cimr, D. Bušovský, F. Studnička, H. Fujita, R. Cimler, T. Hayashi, Bag - patient deterioration impending death, 2023a, Mendeley Data, v2, doi:10.17632/4wrk4fr69wv2.
- [10] D. Cimr, H. Fujita, H. Tomaskova, R. Cimler, A. Selamat, Automatic seizure detection by convolutional neural networks with computational complexity analysis, Comput. Methods Programs Biomed. 229 (2023) 107277.
- [11] D. Cimr, F. Studnička, Automatic detection of breathing disorder from ballistocardiography signals, Knowl. Based Syst. 188 (2020) 104973.
- [12] D. Cimr, F. Studnička, H. Fujita, R. Cimler, J. Šlégr, Application of mechanical trigger for unobtrusive detection of respiratory disorders from body recoil micro-movements, Comput. Methods Programs Biomed. 207 (106149) (2021) 71–86.
- [13] D. Cimr, F. Studnička, H. Fujita, H. Tomášková, R. Cimler, J. Kühnová, J. Šlégr, Computer aided detection of breathing disorder from ballistocardiography signal using convolutional neural network, Inf. Sci. (Ny) 541 (2020) 207–217.

- [14] P. Dahlberg, U.-B. Diamant, T. Gilljam, A. Rydberg, L. Bergfeldt, QT correction using Bazett's formula remains preferable in long QT syndrome type 1 and 2, *Ann. Noninvasive Electrocardiol.* 26 (1) (2021).
- [15] E. Ebrahimbazeh, F. Fayaz, F. Ahmadi, M.R. Dolatabad, Linear and nonlinear analyses for detection of sudden cardiac death (SCD) using ecg and HRV signals, *Trends Res.* 1 (2018).
- [16] H. Fujita, U.R. Acharya, V.K. Sudarshan, D.N. Ghista, V.S. Subbhuraam, L.W.J. Eugene, J.E.W. Koh, Sudden cardiac death (SCD) prediction based on nonlinear heart rate variability features and SCD index, *Appl. Soft Comput.* 43 (2016) 510–519.
- [17] J. Gallier, *Geometric Methods and Applications: For Computer Science and Engineering*, second ed., Springer, 2011.
- [18] H. Gao, A. McDonell, D.A. Harrison, T. Moore, S. Adam, K. Daly, L. Esmonde, D.R. Goldhill, G. Parry, A. Rashidian, C.P. Subbe, S. Harvey, Systematic review and evaluation of physiological track and trigger warning systems for identifying at-risk patients on the ward, *Intensive Care Med.* 33 (4) (2007) 667–679.
- [19] S. Gerry, T. Bonnici, J. Birks, S. Kirtley, P.S. Virdee, P.J. Watkinson, G.S. Collins, Early warning scores for detecting deterioration in adult hospital patients: systematic review and critical appraisal of methodology, *BMJ* 369 (2020) m1501.
- [20] S. Hong, Y. Zhao, J. Shang, C. Xiao, J. Sun, Opportunities and challenges of deep learning methods for electrocardiogram data: a systematic review, *Comput. Biol. Med.* 122 (2020) 103801.
- [21] D. Hui, R. dos Santos, G.B. Chisholm, S. Bansal, T.B. Silva, K. Kilgore, C.d.S. Crovador, X. Yu, M.D. Swartz, P.E. Perez-Cruz, R.d.A. Leite, M.S.d.A. Nascimento, S. Reddy, F. Seriaco, S. Yennu, C.E. Paiva, R. Dev, S. Hall, J. Fajardo, E. Bruera, Clinical signs of impending death in cancer patients, *Oncologist* 19 (6) (2014) 681–687.
- [22] N. Jacob, Y. Moriarty, A. Lloyd, M. Mann, L. Tume, G. Sefton, C. Powell, D. Roland, R. Trubey, K. Hood, D. Allen, Optimising paediatric afferent component early warning systems: a hermeneutic systematic literature review and model development, *BMJ Open* 9 (2019) e028796.
- [23] D. Jones, I. Mitchell, K. Hillman, D. Story, Defining clinical deterioration, *Resuscitation* 84 (8) (2013) 1029–1034.
- [24] K.A. Kehl, J. Kowalkowski, A systematic review of the prevalence of signs of impending death and symptoms in the last 2 weeks of life, *Am. J. Hospice Palliative Med.* 30 (6) (2013) 601–616.
- [25] L.L. Kirkland, M. Malinchoc, M.O. O'Byrne, J.T. Benson, D. Kashiwagi, M.C. Burton, P. Varkey, T.I. Morgenthaler, A clinical deterioration prediction tool for internal medicine patients, *Am. J. Med. Qual.* 28 (2) (2013) 135–142.
- [26] M. Kuluozturk, M.A. Kobat, P.D. Barua, S. Dogan, T. Tuncer, R.-S. Tan, E.J. Ciacio, U.R. Acharya, DKPNNet41: directed knight pattern network-based cough sound classification model for automatic disease diagnosis, *Med. Eng. Phys.* 110 (2022) 103870.
- [27] K. Mann, N. Good, F. Fatehi, S. Khanna, V. Campbell, R. Conway, C.M. Sullivan, A. Stalb, C. Joyce, D.A. Cook, Predicting patient deterioration: a review of tools in the digital setting, *J. Med. Internet Res.* 23 (9) (2021) e28209.
- [28] K. Matsunami, K. Tomita, H. Touge, H. Sakai, A. Yamasaki, E. Shimizu, Physical signs and clinical findings before death in ill elderly patients, *Am. J. Hospice Palliative Med.* 35 (4) (2018) 712–717.
- [29] J. McGaughey, F. Alderdice, R. Fowler, A. Kapila, A. Mayhew, M. Moutray, Outreach and early warning systems (EWS) for the prevention of intensive care admission and death of critically ill adult patients on general hospital wards (review), *Cochrane Database of Syst. Rev.* (2007) CD005529.
- [30] F. Milano, The frenet frame as a generalization of the park transform, *IEEE Trans. Circuits Syst. I Regul. Pap.* (2022) 1–11.
- [31] T. Muezzinoglu, N. Baygin, I. Tuncer, P.D. Barua, M. Baygin, S. Dogan, T. Tuncer, E.E. Palmer, K.H. Cheong, U.R. Acharya, PatchResNet: multiple patch division-based deep feature fusion framework for brain tumor classification using MRI images, *J. Digit. Imaging* (2023) 1–15.
- [32] M.E.B. Smith, J.C. Chivaro, M.E. O'Neil, D. Kansagara, A.R. Quinenos, M. Freeman, M. Motuapuaka, C. Slatore, Early warning system scores for clinical deterioration in hospitalized patients: a systematic review, *Ann. Am. Thorac. Soc.* 11 (9) (2014) 1454–1465.
- [33] I. Starr, F.C. Wood, Twenty-year studies with the ballistocardiograph, *Circulation* 23 (5) (1961) 714–732.
- [34] S.M.J.M. Straus, J.A. Kors, M.L.D. Bruin, C.S.v.d. Hooft, A. Hofman, J. Heeringa, J.W. Deckers, J.H. Kingma, M.C.J.M. Sturkenboom, B.H.C. Sticker, J.C.M. Witteman, Prolonged QTc interval and risk of sudden cardiac death in a population of older adults, *J. Am. Coll. Cardiol.* 47 (2) (2006) 362–367.
- [35] T. Theorell, C.R. Rahe, Life change events, ballistocardiography and coronary death, *J. Human Stress.* 1 (3) (1975) 18–24.

Příloha B – Vybrané publikované patenty a užitné vzory

V této příloze jsou uvedeny nejvýznamnější patenty a užitné vzory autora, komentované v habilitační práci.

UŽITNÝ VZOR

(19) ČESKÁ REPUBLIKA 	(21) Číslo přihlášky: 13.08.2019 (22) Přihlášeno: 20.12.2019 (47) Zapsáno:	2019-36515 20.12.2019	(11) Číslo dokumentu: 33 574 (13) Druh dokumentu: U1 (51) Int. Cl.: <i>G01H 11/08</i> (2006.01) <i>A61B 5/0245</i> (2006.01) <i>A61B 5/08</i> (2006.01)
ÚŘAD PRŮMYSLOVÉHO VLASTNICTVÍ			

- (73) Majitel:
Univerzita Hradec Králové, Hradec Králové, CZ
- (72) Původce:
Ing. Richard Cimler, Ph.D., Chrudim, Chrudim IV,
CZ
RNDr. Filip Studnička, Ph.D., Hradec Králové,
Slezské Předměstí, CZ
RNDr. Jan Šlégr, Ph.D., Litomyšl, Litomyšl-Město,
CZ
Ing. Jan Štěpán, Dobruška, CZ
Ing. Jan Matýška, Hradec Králové, Nový Hradec
Králové, CZ
RNDr. Jitka Kühnová, Ph.D., Hradec Králové,
Nový Hradec Králové, CZ
Ing. David Šec, Pravy, CZ
prof. RNDr. Petr Šeba, DrSc., Bartošovice v
Orlických horách, CZ
- (74) Zástupce:
PatentEnter s.r.o., Koliště 1965/13a, 602 00 Brno,
Černá Pole

- (54) Název užitného vzoru:
**Zařízení pro sledování mikropohybů živých
organismů**

CZ 33574 U1

Úřad průmyslového vlastnictví v zápisném řízení nezjišťuje, zda předmět užitného vzoru
splňuje podmínky způsobilosti k ochraně podle § 1 zák. č. 478/1992 Sb.

Zařízení pro sledování mikropohybů živých organismů

Oblast techniky

5

Předkládané technické řešení se týká zařízení vhodných pro neinvazivní sledování mikropohybů živých organismů, zejména lidí.

10 Dosavadní stav techniky

V současnosti lze monitorovat mechanickou aktivitu vnitřních orgánů a struktur (srdce, plíce, cévní systém, svaly) na základě sledování jejich mikropohybů s charakteristickými frekvencemi. V publikaci „Unobtrusive Vital Sign Monitoring in Automotive Environments - A Review“ autorů Leonhardt a kol. (Sensors 2018, 18(9), 3080; <https://doi.org/10.3390/s18093080>) jsou shrnutы způsoby sledování vitálních funkcí lidského těla ve vozidle. Mezi způsoby na základě mechanických změn patří distanční monitorování ultrazvukem, radarem nebo mikrovlnami, video monitorování, balistokardiografie (BCG) nebo seismokardiografie (SCG). Zejména balistokardiografická měření poskytují data o vibracích způsobených srdeční a plícní aktivitou pomocí nezbytného mechanického kontaktu měřícího zařízení se sledovaným organismem. Důležitým aspektem monitorování fyziologických parametrů je i poloha těla (ve stojí, v sedě, v lehu na zádech/bříchu/boku apod.) Popsaná měřící zařízení mohou zahrnovat piezoelektrický element, feroelektrickou vrstvu, tenzometrické či tlakové senzory umístěné ve váze, v postelních sloupech, nebo v matraci.

25

Nevýhodou těchto zařízení je jak jejich nepřesnost, způsobená nízkou vzorkovací frekvencí, tak nízká životnost a robustnost využití.

30 Podstata technického řešení

Cílem předkládaného technického řešení je poskytnout zařízení pro sledování mikropohybů živých organismů, zejména lidí, s dostatečnou přesností a robustností použití.

35

Výše uvedené nedostatky stavu techniky do jisté míry odstraňuje zařízení pro sledování mikropohybů živých organismů, jehož podstata spočívá v tom, že zahrnuje pouzdro zahrnující dve klapky s přítlačnou částí, dva piezoelektrické elementy, nábojový zesilovač, AD převodník a řídící jednotku. Každá klapka je uchycena v pouzdru kyně pomocí čepu a držáku a její přítlačná část vyčnívající ze spodní strany klapky je mechanicky spojena s piezoelektrickým elementem uvnitř pouzdra. Každý piezoelektrický element je dále vodivě spojen přes nábojový zesilovač a AD převodník s řídící jednotkou, umístěnou na desce plošných spojů. Řídící jednotka dále zahrnuje napájecí konektor a alespoň jeden datový konektor.

45

Funkce zařízení je popsána následovně. Po mechanickém zatížení klapky mikropohybem sledovaného živého organismu je tento pohyb přenesen její přítlačnou částí na piezoelektrický element. Mechanická deformace piezoelektrických elementů je převedena na elektrický náboj, který je zesílen nábojovým zesilovačem, a výsledné napětí je pro řídící jednotku digitalizováno AD převodníkem. Z digitálních dat jsou pomocí řídící jednotky vypočteny data fyziologických hodnot. Výsledky lze dále zpracovat, interpretovat a zobrazit na počítači.

50

Ve výhodném provedení je piezoelektrický element z keramického nebo organického materiálu. Dále může pouzdro zahrnovat odnímatelný kryt, např. podepřený dvěma stojinami uvnitř pouzdra, který spolu s klapkou chrání vnitřní součástky zařízení.

- Výhodně jsou sledovány mikropohyby s frekvencemi 0,1 až 10 Hz. Jedná se o mikropohyby způsobené zejména dechovou aktivitou (frekvence cca 0,1 až 0,5 Hz) a tepovou aktivitou (cca 0,8 až 5 Hz) a o jednorázové změny způsobené změnami polohy měřeného subjektu. Výstupem zařízení (řídící jednotky) jsou tedy naměřená fyziologická data o tepové frekvenci, dechové frekvenci, úrovni stresu a/nebo únavy. Vysoká vztorkovací frekvence zařízení (300 až 350 Hz) a rozlišení AD převodníku poskytuje minimálně každou sekundu fyziologická data (tep/dech/úroveň stresu), tedy např. tepovou frekvenci s přesností na každý srdeční úder, oproti známým řešením, která zobrazují různě průměrované hodnoty. Získaná data můžou dále být přeposlána pomocí datových konektorů do počítače, kde jsou vyhodnocena a zobrazena. Získaná data můžou však být využita inteligentním systémem pro úpravu prostředí, který může měnit teplotu, osvětlení (intenzitu či barvu), hudbu a další parametry prostředí na základě naměřených fyziologických parametrů v reálném čase, např. s cílem uklidnit rozrušeného člověka, nebo doporučit přestávku sedícího pracovníka v kanceláři. Počítač může s tímto systémem komunikovat prostřednictvím rozhraní API. Dále mohou být získaná data přenesena přes internet (např. technologiemi Ethernet, Wifi nebo Bluetooth) do vybraných zařízení, např. uzpůsobených k upozornění vybraných osob (např. ošetřujícího personálu nebo rodinného příslušníka) do mobilní aplikace v případě překročení určité hranice tepové či dechové frekvence monitorované osoby.
- Zařízení může být výhodně integrováno do sedáku, opěradla nebo ložní plochy, např. do židle, křesla, gauče, posteče, invalidního vozíku apod.
- Dalším aspektem technického řešení je i použití předkládaného zařízení při sledování tepové frekvence, dechové frekvence, úrovni stresu a/nebo únavy živého organismu.
- Objasnění výkresů**
- Podstata technického řešení je dále objasněna na příkladech jeho uskutečnění, které jsou popsány s využitím připojených výkresů, kde:
- obr. 1 znázorňuje perspektivní pohled na otevřené zařízení bez klapek a krytu;
 - obr. 2 znázorňuje vrchní pohled na otevřené zařízení bez klapek a krytu;
 - obr. 3 znázorňuje perspektivní pohled na klapku;
 - obr. 4 znázorňuje boční pohled na klapku a její přitlačnou část;
 - obr. 5 znázorňuje perspektivní pohled na kryt; a
 - obr. 6 znázorňuje blokové schéma zapojení jednotlivých součástek zařízení.

Příklady uskutečnění technického řešení

- Uvedená uskutečnění znázorňují příkladné varianty provedení technického řešení, která však nemají z hlediska rozsahu ochrany žádný omezuječí vliv.
- Jak je znázorněno na obr. 1, 2 a 5, předkládané zařízení pro sledování mikropohybů živých organismů zahrnuje pouzdro 1 zahrnující odnímatelný kryt 2, dvě klapky 3 s přitlačnou částí 4, dva piezoelektrické elementy 5, nábojový zesilovač 6, AD převodník 7 a řídící jednotku 8 na desce plošných spojů 16. Každá klapka 3 je uchycena v pouzdru 1 kyvně pomocí čepu 9 a držáků 10, viz obr. 3, a její přitlačná část 4 je mechanicky spojena s piezoelektrickým elementem 5 uvnitř pouzdra 1, viz obr. 4. Klapka 3 detekuje mikropohyby způsobené srdeční, dechovou

aktivitou nebo určitým stupněm únavy či stresu sledovaného organismu s frekvencí 0,1 až 10 Hz a její mechanický pohyb je mechanicky přes přítlačnou část 4 přenesen na piezoelektrický element 5. Každý piezoelektrický element 5 (např. z keramického materiálu) je dále vodivě spojen přes nábojový zesilovač 6 a AD převodník 7 s řídící jednotkou 8, umístěnou na desce plošných spojů 16. Řídící jednotka 8 dále zahrnuje napájecí konektor 11 a alespoň jeden datový konektor 12 pro spojení s externím počítačem 13. Jak je znázorněno na obr. 1 a 5, odnímatelný kryt 2 je podepřený dvěma stojinami 14 uvnitř pouzdra 1 a je fixován vruty přes fixační otvory 15.

Obr. 6 znázorňuje blokové schéma přenosu elektrického signálu z piezoelektrického elementu 5 po jeho mechanické deformaci přítlačnou částí 4. Signál z piezoelektrického elementu 5 se vzorkovací frekvencí např. 330 Hz je přenesen do nábojového zesilovače 6, např. v podobě operačního zesilovače. Výstupní napětí je se vzorkovací frekvencí až 660 Hz digitalizováno AD převodníkem 7, např. šestnáctibitový sigma-delta AD převodníkem, který komunikuje s řídící jednotkou 8, která umožňuje vyhodnocovat data a předat signál dále do počítače 13 po digitálním rozhraní RS485 pomocí datových konektorů 12. Signál může rovněž být přenesen přes internet (Ethernet, Wifi, Bluetooth) do dalších zařízení.

20 Průmyslová využitelnost

Výše popsané zařízení pro sledování mikropohybů živých organismů lze využít v židlích, křeslech, gaučích, postelích nebo invalidních vozících apod., a to jak v domácím prostředí, v kancelářích, v domovech duchodců nebo ve veřejných prostorách (letiště, atria, čekárny, salonky).

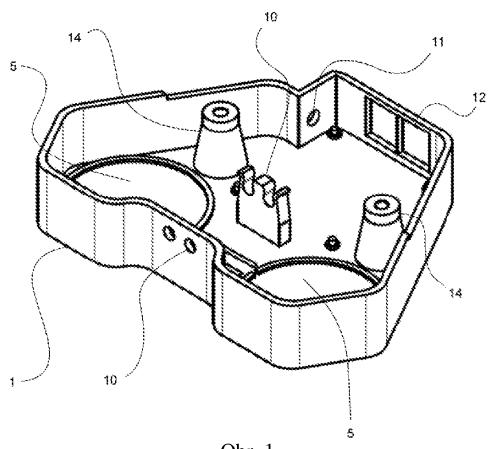
NÁROKY NA OCHRANU

- 5 1. Zařízení pro sledování mikropohybů živých organismů, **vyznačující se tím**, že zahrnuje pouzdro (1) zahrnující dvě klapky (3) s přitlačnou částí, dva piezoelektrické elementy (5), nábojový zesilovač (6), AD převodník (7) a řídící jednotku (8), přičemž každá klapka (3) je uchycena v pouzdru (1) kyvně a její přitlačná část je mechanicky spojena s piezoelektrickým elementem (5) uvnitř pouzdra (1), přičemž každý piezoelektrický element (5) je dále vodivě spojen přes nábojový zesilovač (6) a AD převodník (7) s řídící jednotkou (8), která dále zahrnuje napájecí konektor (11) a alespoň jeden datový konektor (12).
- 10 2. Zařízení podle nároku 1, **vyznačující se tím**, že piezoelektrickým elementem (5) je keramický nebo organický piezoelektrický element.
- 15 3. Zařízení podle nároku 1 nebo 2, **vyznačující se tím**, že pouzdro (1) zahrnuje odnímatelný kryt (2).
- 20 4. Zařízení podle kteréhokoliv z předchozích nároků, **vyznačující se tím**, že vzorkovací frekvence zařízení je 300 až 350 Hz.
- 25 5. Zařízení podle kteréhokoliv z předchozích nároků, **vyznačující se tím**, že řídící jednotka (8) je uzpůsobená k poskytování dat o tepové frekvenci, dechové frekvenci, úrovni stresu a/nebo únavy.
6. Zařízení podle kteréhokoliv z předchozích nároků, **vyznačující se tím**, že je integrováno do sedáku, opěradla nebo ložní plochy.

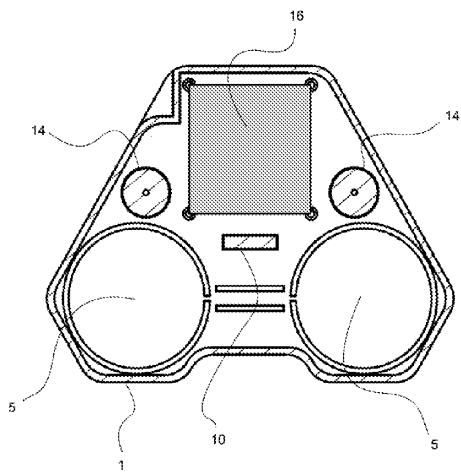
3 výkresy

Seznam vztahových značek:

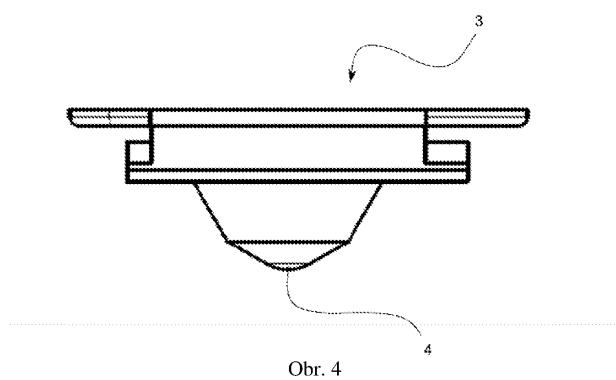
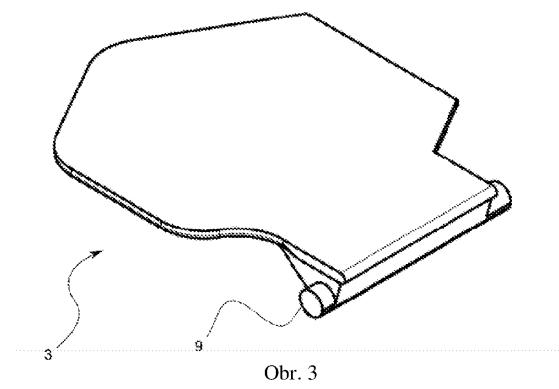
- 1 Pouzdro
- 2 Odnímatelný kryt
- 3 Klapka
- 4 Přítláčná část
- 5 Piezoelektrický element
- 6 Nábojový zesilovač
- 7 AD převodník
- 8 Řídicí jednotka
- 9 Čep klapky
- 10 Držák klapky
- 11 Napájeci konektor
- 12 Datový konektor
- 13 Externí počítač
- 14 Stojina
- 15 Fixační otvor
- 16 Deska plošných spojů.



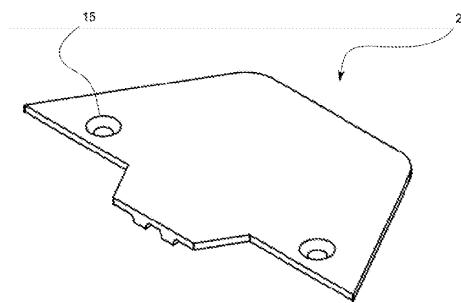
Obr. 1



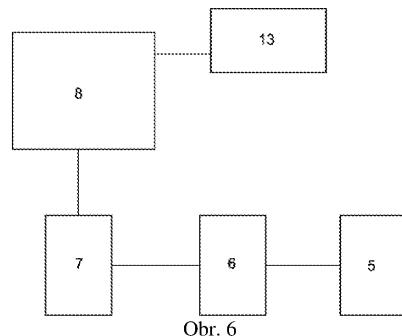
Obr. 2



CZ 33574 U1



Obr. 5



(12) INTERNATIONAL APPLICATION PUBLISHED UNDER THE PATENT COOPERATION TREATY (PCT)

(19) World Intellectual Property Organization
International Bureau



(43) International Publication Date
02 February 2023 (02.02.2023)

(10) International Publication Number
WO 2023/006134 A1

(51) International Patent Classification:

A61B 5/11 (2006.01) *A61B 5/00* (2006.01)
A61B 5/021 (2006.01)

AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ,

(21) International Application Number:

PCT/CZ2022/050069

CA, CH, CL, CN, CO, CR, CU, CV, CZ, DE, DJ, DK, DM,
DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT,
HN, HR, HU, ID, IL, IN, IQ, IR, IS, IT, JM, JO, JP, KE,
KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU,
LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA,
NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO,
RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH,
TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS,
ZA, ZM, ZW.

(22) International Filing Date:

01 August 2022 (01.08.2022)

(84) Designated States (unless otherwise indicated, for every kind of regional protection available): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), Eurasian (AM, AZ, BY, KG, KZ, RU, TJ, TM), European (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

(25) Filing Language:

English

(26) Publication Language:

English

(30) Priority Data:

PV 2021-361 30 July 2021 (30.07.2021) CZ

(71) Applicant: UNIVERZITA HRADEC KRÁLOVÉ [CZ/CZ]; Rokitanského 62/26, 50003 Hradec Králové (CZ).

(72) Inventors: STUDNIČKA, Filip; Severní 771/26, 50003 Hradec Králové (CZ); ŠLÉGR, Jan; Miru 686, 57001 Litomyšl (CZ); ŠEBA, Petr; Neratov 14, 53341 Neratov (CZ).

(74) Agent: PATENTENTER; Koliště 1965/13a, 60200 Brno (CZ).

(81) Designated States (unless otherwise indicated, for every kind of national protection available): AE, AG, AL, AM,

(54) Title: METHOD OF MONITORING PERISTALSIS OF ORGANS OF THE GASTROINTESTINAL TRACT AND A DEVICE FOR MONITORING PERISTALSIS

(57) Abstract: The object of the invention is a method of operation of a system (1) for monitoring peristaltic movement of organs of the gastrointestinal tract. The system comprises a pair of sensors that monitor mechanical excitations and heart parameters. The sensors (3, 4) are placed on the body of the patient (2), the first in the upper half of the body, the second in the region below the abdominal bifurcation. After detection of mechanical excitations and parameters of the aorta, a time parameter describing the relationship between the mechanical excitations and parameters is determined. By further processing of the time parameter by the computing unit, movement of fetus in utero is detected. The movement of the GIT organs compresses the aorta of the patient (2), which affects the dynamics of blood flow in the body. As a result, the time parameter does not have a constant value and by studying it and processing its values over a longer period of time it is possible to detect peristaltic movement of the GIT organs. The system may include an alert unit that will alert the medical personnel if an arrest of the peristaltic movements is detected.

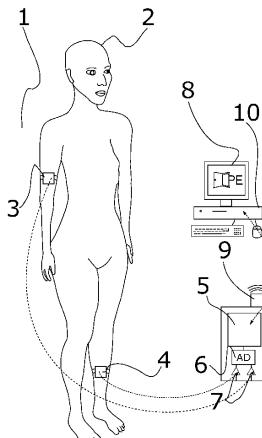


Fig. 1

WO 2023/006134 A1

[Continued on next page]



Published:

- *with international search report (Art. 21(3))*
- *with amended claims (Art. 19(1))*
- *in black and white; the international application as filed contained color or greyscale and is available for download from PATENTSCOPE*

Method of monitoring peristalsis of organs of the gastrointestinal tract and a device for monitoring peristalsis

Technical Field

The invention relates to a diagnostic device for monitoring peristalsis of organs of
5 the gastrointestinal tract or movement of fetus in utero.

Background of the Invention

Heart pulse or pressure is a frequently used source of physiological data, the analysis of which can be used to diagnose a patient's condition or to evaluate the effect of treatment. One of the most common methods is listening to the heart with a
10 phonendoscope, which can be used to determine the heart rate. Blood pressure is determined by a tonometer. Heart rate can also be measured non-invasively using a finger oximeter. More detailed information about the heart activity provides, for example, the ECG method.

The document US 10,335,050 B2 describes a device for determining the
15 propagation velocity of a cardiac pulse wave. The device comprises at least two pulse wave sensors, where one sensor is placed on a finger of the hand and the other sensor is placed on a toe of the foot of the patient, and a computing unit adapted to determine the time at which a given pulse wave arrives to the finger of the hand and to the toe of the foot of the patient. The computing unit works with the time difference measured
20 between pulse wave detections, which is then used to determine the risk of a cardiac event using the patient's height and age. The document does not describe the methodology of data processing that would allow for monitoring of peristalsis of the patient's gastrointestinal tract or movement of fetus in utero.

The document JP09081047 describes a device measuring an R wave signal using an ECG placed above the level of the abdomen of the patient being monitored, and a pulse wave signal on a finger of the hand. By processing the measurements it is possible to obtain information about the transition time of the pulse wave of the aorta. However,

5 without a sensor placed on the lower body, it is not possible to determine the degree of peristalsis of the patient's gastrointestinal tract.

Summary of the Invention

The above shortcomings of the state of the art are at least partially eliminated by a method of operation of a device for monitoring peristalsis of organs of the

10 gastrointestinal tract. The device comprises a first sensor adapted to be placed in the region of the upper half of the body, a second sensor adapted to be placed in the region below the abdominal bifurcation, and a computing unit communicatively connected to the first sensor and the second sensor. The method of operation of the device comprises the following steps:

- 15 - detection of at least one mechanical parameter of the aorta by the first sensor;
- detection of mechanical excitation of the aorta by the second sensor, where the mechanical parameter measured detected by the first sensor and the mechanical excitation detected by the second sensor correspond to the same heartbeat;
- 20 - and determination of the time parameter describing the time relationship between the mechanical parameter and the mechanical excitation by the computing unit.

The advantage of the present method lies in the accurate detection of the peristaltic movements of the gastrointestinal tract based on the processing of the time parameter.

25 Preferably, the second sensor is embodied as a piezoelectric sensor or strain gauge and detects the pulse wave of the aorta, which is a mechanical excitation of the aorta. The first sensor is embodied as an electrocardiograph, where the mechanical

parameter of the aorta is its QRS complex. The time parameter is the time difference between the detection of the R wave by the first sensor and the detection of the pulse wave of the aorta by the second sensor.

Alternatively, the first sensor can be embodied as a piezoelectric sensor or strain gauge, wherein the mechanical parameter of the aorta is its pulse wave. The time parameter is then the time difference between the detection of the pulse wave of the aorta by the first sensor and the second sensor.

Preferably, the method is performed for 30–1800 s, therefore, the present method of operation of the device for monitoring the peristalsis of the GIT organs does not restrict the patient during the measurement in the long term and does not represent a significant interference with their comfort.

The method further preferably comprises steps performed by the computing unit:

- creation of a time series of the time parameter values,
- determination of the spectral density of the time parameter values
- 15 - and indication of the peristaltic movement of the GIT organs.

These steps have the advantage of automatically indicating the arrest of the GIT peristaltic movements. This can be further monitored by an alert mechanism that alerts the attending staff in the event of detection of an arrest of the GIT peristaltic movements.

The above shortcomings of the state of the art are at least partially eliminated by a device for monitoring peristalsis of organs of the gastrointestinal tract. The device comprises a first sensor adapted to be placed in the region of the upper half of the body, a second sensor adapted to be placed in the region below the abdominal bifurcation, and a computing unit communicatively connected to the first sensor and the second sensor. The first sensor is adapted to detect at least one mechanical parameter of the aorta by the first sensor. The second sensor is adapted to detect mechanical excitation of the aorta. The computing unit is then adapted to determine the time parameter, which describes the time relationship between the mechanical parameter and the mechanical excitation. The advantage of the present device lies in the accurate detection of the peristaltic movements of the gastrointestinal tract based on the processing of the time parameter.

The first sensor is embodied as an electrocardiograph, or together with the second sensor it is embodied as a piezoelectric sensor or a strain gauge.

The device further comprises an AD converter electrically connected to the first and second sensors and the computing unit. Preferably the signal is amplified by an 5 amplifier before processing.

The device further preferably comprises an alert mechanism and a communication peripheral communicatively connected to the alert mechanism, where the alert mechanism is adapted to alert medical personnel in the event of detection of arrest of the peristaltic movements of the GIT organs.

10 Description of Drawings

A summary of the invention is further clarified using exemplary embodiments thereof, which are described with reference to the accompanying drawings, in which:

Fig. 1 – shows a device for monitoring peristalsis of organs of the gastrointestinal tract;

15 Fig. 2 – shows QRS complex of the aorta;

Fig. 3 and 4 – show the waveform of signals measured by the first and second sensor;

Fig. 5 and 6 – the spectral dependence of the processed signal is plotted.

Exemplary Embodiments of the Invention

The invention will be further clarified using exemplary embodiments with reference to the respective drawings, which, however, have no limiting effect on the scope of protection.

5 In the first exemplary embodiment shown in Fig. 1 a device 1 for monitoring peristalsis of organs of the gastrointestinal tract comprises a first sensor 3 adapted to be placed in the region of the upper half of the body of the patient 2 above the level of the heart, for example, on the hand, arm, fingers, in the neck region, or on the head, and a second sensor 4 adapted to be placed in the region of the lower half of the body of the
10 patient 2 below the level of the heart, for example, behind the abdominal bifurcation in the direction of blood flow through the arteries, e.g. on the thigh, calf, foot, or toes, and a computing unit 5 electrically connected to the first and second sensors 3, 4.

The first sensor 3 is adapted to detect a mechanical parameter of the aorta. The second sensor 4 is adapted to detect a mechanical excitation of the aorta or induced by
15 the aorta or the pulse wave of the aorta. The pulse wave of the aorta corresponds to a single heartbeat, during which blood is displaced from the heart into the aorta and then into the individual arteries and other vessels. The displacement and transport of blood are associated with an increase in blood pressure in the vessels, which decreases in the second phase of the cardiac cycle. The peak of the pulse wave corresponds to the highest
20 value of pressure reached, while the minimum of the pulse wave corresponds to the lowest value of blood pressure. In the same way, mechanical excitations occur during the heart pulse and propagate through the individual vessels. The first sensor 3 is embodied either as a mechanical sensor of the excitation caused by the pulse wave of the aorta, or in an alternative embodiment the first sensor 3 is embodied as an electrocardiograph.
25 The second sensor 4 is embodied as a mechanical sensor of the excitation caused by the pulse wave of the aorta. In case of mechanical embodiment of the sensors 3, 4, the sensors 3, 4 may be in the form of a piezoelectric sensor, where the pulse waveform causes deformation of the crystal in the sensor and thus generates electrical voltage. Another option for a mechanical sensor embodiment is to use a strain gauge.

30 As an example, the device 1 for monitoring peristalsis of organs further comprises a first amplifier 7 electrically connected to the first sensor 3, and a second amplifier 7

electrically connected to the second sensor 4. The amplifiers 7 are used to amplify the output signals obtained by the first and second sensors 3, 4. The device 1 for monitoring peristalsis of organs further comprises at least one AD converter 6 for converting the analogue signal obtained by the first and second sensors 3, 4 into a digital signal. The 5 AD converter 6 is electrically connected to the computing unit 5 to which it sends the converted digital signal. Alternatively, two AD converters 6 can be used, one for each sensor 3, 4.

In an exemplary embodiment, where the first sensor 3 is embodied as an electrocardiograph, the mechanical parameter of the aorta is the QRS complex shown in 10 Fig. 2, which describes the contraction of the ventricular musculature of the heart. The duration of the signal corresponding to the QRS complex ranges from 75–105 ms. The monitored parameter is then the R wave, which is the highest positive wave recorded on the electrocardiograph and corresponds to the pulse of the aorta.

The amplified and converted signal obtained by the first and second sensors 3, 4 15 corresponds to the pulse waveform of the aorta, where both waveforms, or the waveform measured by the first sensor 3 and the second sensor 4, belong to the same heartbeat. The amplified and converted signal is then processed by the computing unit 5. Both signals have a similar waveform, as can be seen in Fig. 3, however, they are slightly delayed to each other, which is due to the placement of the first and second sensors 3, 20 4, which are usually at different distances from the heart. Alternatively, it is possible to work only with the detection of the pulse wave itself instead of sensing entire waveform thereof. In this case, the pulse corresponding to the same heartbeat is detected by one sensor at a certain time and the other sensor detects this pulse with a certain time delay.

The signals corresponding to the pulse waveform are then processed by the 25 computing unit 5. In Fig. 3 and 4, the waveform of signals measured by the first sensor 3 (blue) and the second sensor 4 (orange) is shown in an exemplary embodiment, in which both sensors 3, 4 are embodied as mechanical sensors. The waveform of the signals corresponds to the mechanical excitation induced by the pulse wave of the aorta. In Fig. 3 and 4, it is clear that both signals have a very similar trend, however, they show a slight 30 delay with respect to each other. Signal processing means determination of time parameter describing time relationship between the mechanical parameter of the aorta and the mechanical excitation of the aorta by subtracting the pulse waveforms detected by the first sensor 3 and the second sensor 4, the signal processing subsequently results

in obtaining a time difference between the detections of pulse wave by the first sensor 3 and the second sensor 4 in an embodiment where both sensors 3, 4 are embodied as mechanical sensors. In an exemplary embodiment, where the electrocardiograph is used as the first sensor 3, the time parameter describing the time relationship between the 5 mechanical parameter of the aorta monitored by the first sensor 3 and the mechanical excitation of the aorta monitored by the second sensor 4 is the time difference between the detection of the R wave in the QRS complex of the electrocardiogram and the detection of the pulse wave by the second sensor 4. The time differences obtained in this way would have a virtually constant value throughout the entire measurement period in 10 case of absolute rest of the patient. Patient movement may affect the values obtained, however, this irregularity can be detected and can be handled and eliminated by the computing unit 5.

The organs of the gastrointestinal tract lie close to the aorta. The GIT organs perform constant peristaltic and other movements. Due to their movement and change in 15 shape, they exert a force on the aorta, compressing it or, on the contrary, relieving the pressure on it. Similarly, the fetus in utero performs its own movements, by which it compresses other organs in the woman's body, or it can affect the aorta itself, similar to the peristaltic movements of the GIT organs. Thus, the fetus in utero can compress the aorta in various ways or, on the contrary, relieve the pressure on it. These forces affect 20 the hemodynamics of the blood flowing through the aorta and thus delay or accelerate the pulse waveform of the aorta and the pulse is recorded by the second sensor 4 with a delay. Delays caused by peristaltic movements of the organs or movement of the fetus will affect the recorded pulse waveform of the aorta or pulse detection time. If the GIT 25 organs do not perform peristaltic movements or the fetus is not moving in utero at that moment, the time difference of the pulse wave detection by the first sensor 3 and the second sensor 4 acquires the first value. In case of peristaltic movement of the GIT or movement of the fetus, the time difference of the pulse wave detection by the first sensor 3 and the second sensor 4 acquires a second value different from the first value.

In an exemplary embodiment, detection of peristaltic movements of the GIT organs 30 or movement of the fetus in utero is performed as follows. The second sensor 4 is placed on the male patient 2 or female patient 2 in the region behind the abdominal bifurcation in the direction of blood flow in the artery from the heart towards the legs. If the first sensor 3 is embodied as a mechanical sensor, it is placed in the upper half of the body, for

example on the hand or arm. In an alternative embodiment, the first sensor 3 is embodied as an ECG. Subsequently, the pulse waveform of the aorta is measured or the time of the pulse detection, so-called *pulse arrival time*, is measured. The signal from the first and second sensors 3, 4 is processed by the computing unit 5 for at least 30 seconds.

- 5 The upper value of the measurement time is practically unlimited and can be chosen with regard to the male or female patient's comfort, time possibilities, and practical purpose, or it can be monitored permanently. For example, the upper value of the measurement by the first and second sensors 3, 4 is 1800 s. The computing unit 5 determines a series of values of differences of the pulse detection by the first sensor 3 and the second sensor
- 10 4. The male patient 2 or female patient 2 is at rest and lying down throughout the measurement. If the movement performed by the GIT organs or the fetus in utero is minimal or has almost no value, the time difference of pulse detections by the first sensor 3 and the second sensor 4 acquires first values, the set of first values is the same with respect to the measurement statistics, the mean value, and the standard deviation. When
- 15 the GIT organs or the fetus in utero begin to make movements, these movements exert a force on the aorta. Exertion of force means in particular the compression or relaxation of the aorta. This exertion of force results in different blood flow at the compressed or relaxed site, which affects the pulse wave detection time by the second sensor 4 and the pulse waveform measured by the second sensor 4. The time difference of pulse
- 20 detections by the first sensor 3 and the second sensor 4 thus acquires second values that are different from the first values. The second value denotes a set of second values that do not have to be of the same size. The value of this difference is determined by the rate of movement of the GIT organs or the fetus in utero.

- From the set of computed values, the spectral density of the signal corresponding to the number of frequencies contained in this signal is determined by the computing unit 5 by the following procedure — a time series composed of a series of values of pulse detection differences in the measurement time interval is created, then the spectral density of the signal is computed from this series by determining an arbitrary frequency, for example 4 Hz. In an exemplary embodiment, the computing unit 5 is connected to a display unit 8, for example a monitor or other display, on which the obtained dependency is displayed. For example, it is shown in the form of a graph, where the X-axis shows the values of the signal frequencies, and the Y-axis shows their values over time. Fig. 5 shows this dependence obtained in an experiment on a pig in which the blood supply to

the intestines was cut off during embolization, stopping peristalsis thereof. The values on the Y-axis are in minutes. Yellow vertical bars with decreasing intensity can be observed on the graph. The first bar on the left indicates the fundamental frequency, the other vertical yellow bars indicate higher harmonic components of the fundamental frequency

- 5 or contain additional information. Green vertical bars indicate signal attenuation. The state before embolization, when the peristaltic movements of the intestines were performed naturally, is shown in the upper part of the figure; after embolization, when the peristaltic movements ceased, there is an observable deviation marking the interruption of the peristaltic movements at a time of about 95 min.

10 The assessment of cessation of the peristaltic movement of the GIT organs or movement of the fetus in utero is determined by a trained medical professional from the graphical representation shown on the display unit 8 or from a list of values. Alternatively, the computing unit 5 is adapted to detect abnormalities corresponding to the cessation of the peristaltic movement of the GIT organs or movement of the fetus in utero. The
15 detection can be implemented by an algorithm that monitors sudden fluctuations in the spectral density of frequencies, wherein an abnormality is detected if the fluctuation in values has a longer duration to avoid detection of false fluctuations caused by e.g., sudden movement of the patient, noise, random interference with surrounding electronics, etc. The detection may also be performed using artificial intelligence, in
20 particular neural networks with a trained classifier adapted to detect abnormalities in the measured values, where the abnormalities correspond to the cessation of the peristaltic movements of the GIT organs or movement of the fetus in utero. The detected abnormality is displayed in a list of spectral density values directly in the graphical representation for easier orientation of the medical personnel. One exemplary
25 embodiment of the device 1 for monitoring the peristalsis of the GIT organs or movement of the fetus in utero further comprises an alert mechanism 9 which, in the event of detection of an anomaly in the measured values by the computing unit 5, alerts medical personnel that immediate medical intervention is required. The alert may be acoustic, e.g.
30 by triggering an alarm mechanism similar to a *code blue* situation, by lighting up an indicator light placed on the device for monitoring the peristaltic movements of the GIT organs or movement of the fetus in utero, or the alert mechanism 9 may communicate with an internal server and send an alert to a computer, cell phone, pager, or other

communication peripheral 10, thereby alerting medical personnel who may immediately provide the necessary medical care to the patient.

Using the device 1 for monitoring the movement of the fetus in utero according to the previous embodiments of the invention, it was possible to perform a series of experiments proving the practicability of the presented invention. The total of 28 patients were monitored using the device 1 for monitoring the movement of the fetus in utero for the time duration of approximately 30-60 minutes. The heart activity of the fetus was measured using the cardiotocography which produces an actogram. The movements, microvibrations, of the patient and the fetus were also simultaneously measured using a plurality of sensors 3, 4. The operational frequency of the sensors 3, 4 was set to 330 Hz. Data obtained by the sensors 3, 4 was further processed by the computing unit 5, and the first Cartan curvature was calculated. The first Cartan curvature carries information about the change of the parameters of a pulse wave reflected in the organism. Afterwards, the selected values were processed using the continuous wavelet transformation which provides information about the frequency characteristics of the given processed signal, in this case the Cartan curvature. Number of frequencies present in the results of the continuous wave transformation was then studied. Given the properties of the signal appropriate threshold value was determined for a selected interval of frequencies, in this case 0,5-1 Hz. If the average amplitude of the signal in the given interval of frequencies exceeded the threshold value, the moment was determined as a moment of a significant fetal movement. This measurement was realized with sampling frequency of 1 s. By this process, it was possible to obtain two time series. The first time series displays the timestamps of fetal movement registered by the actogram, the second time series displays the timestamps of fetal movement registered by the described algorithm of calculating the CWT from the first cartan curvature. By comparing the reference values obtained by the actogram and the measured values obtained by the sensors 3, 4, the sensitivity of the method was determined as 88%, and the specificity of the method was determined as 70%. The first time series with the movement of the fetus marked by black rectangles is depicted in the Fig. 7. The output of the CWT method applied to the first Cartan curvature of the processed signal is depicted in the Fig. 8, where the horizontal axis symbolizes time values, and the vertical axis symbolizes a magnitude of the signal. Fetal movements are easily determined from the Fig. 8.

Industrial Applicability

The invention finds application in medicine, it can be used to monitor peristaltic movements of organs of the gastrointestinal tract or the fetus in utero. The device for monitoring peristalsis of the GIT organs or movement of fetus in utero forms a monitoring device that monitors the health condition of the patient.

List of Reference Numbers

- 1 – device for monitoring peristalsis of the GIT organs
- 2 – patient
- 3 – first sensor
- 5 4 – second sensor
- 5 – computing unit
- 6 – AD converter
- 7 – amplifier
- 8 – display unit
- 10 9 – alert mechanism
- 10 – communication peripheral

CLAIMS

1. A device (1) for monitoring peristalsis of organs of the gastrointestinal tract comprising a first sensor (3) adapted to be placed in the region of the upper half of the body, a second sensor (4) adapted to be placed in the region of the lower half of the body, and a computing unit (5) electrically connected to the first and second sensors (4), **characterized in that** the first sensor (3) is adapted to detect a mechanical parameter of the aorta, wherein the mechanical parameter is the pulse wave of the aorta, QRS complex, or R wave, and the second sensor (4) is adapted to detect mechanical excitation of the aorta, wherein the mechanical excitation is the pulse wave of the aorta, wherein the computing unit (5) is adapted to determine a time parameter, wherein the time parameter is a time difference between the detection of the mechanical parameter of the aorta by the first sensor (3) and the detection of mechanical excitation of the aorta by the second sensor (4), and to process the time parameter values by generating a time series of time parameter values and determining the spectral density of the time parameter values for an arbitrary signal frequency and to indicate an arrest of the GIT peristaltic movements.
5
2. The device for monitoring peristalsis of claim 1, **characterized in that** the first sensor (3) is an electrocardiograph.
20
3. The device for monitoring peristalsis of claim 1, **characterized in that** the sensors (3, 4) are embodied as piezoelectric sensors or strain gauges.
25
4. The device for monitoring peristalsis of any one of the preceding claims 1 to 3, **characterized in that** it further comprises an AD converter (6) electrically connected to the first sensor (3), the second sensor (4), and the computing unit (5).
30
5. The device for monitoring peristalsis of any one of the preceding claims 1 to 4, **characterized in that** it further comprises a signal amplifier (7) of signal detected by the first sensor (3) and the second sensor (4).

6. The device for monitoring peristalsis of any one of the preceding claims 1 to 5, **characterized in that** it further comprises an alert mechanism (9) and a communication peripheral (10) communicating with the alert mechanism (9), wherein the alert mechanism (9) is adapted to alert the medical personnel.

5 7. A method of monitoring peristalsis of organs of the gastrointestinal tract using the device of any one of claims 1 to 6, **characterized in that** it comprises the following steps:

10 - detection of at least one mechanical parameter of the aorta by the first sensor (3), wherein the mechanical parameter is a pulse wave of the aorta, QRS complex, or R wave;

15 - detection of mechanical excitation of the aorta by the second sensor (4), wherein the mechanical excitation is a pulse wave of the aorta;

15 o wherein the mechanical parameter detected by the first sensor (3) and the mechanical excitation detected by the second sensor (4) correspond to the same heartbeat;

20 - determination of the time parameter by the computing unit (5), wherein the time parameter is the time difference between the detection of the mechanical parameter of the aorta by the first sensor (3) and the detection of the mechanical excitation of the aorta by the second sensor (4)

20 - and it further comprises the steps performed by the computing unit (5):

25 o creation of a time series of the time parameter values,

25 o determination of the spectral density of the time parameter values for arbitrary signal frequency

25 - and indication of an arrest of the GIT peristaltic movements by detecting deviations in the spectral density values.

30 8. The method of monitoring peristalsis of organs of the gastrointestinal tract of claim 7, **characterized in that** the second sensor (4) is embodied as a piezoelectric sensor or strain gauge.

9. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 and 8, **characterized in that** the first sensor (3) is embodied as an electrocardiograph.

5 10. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 and 8, **characterized in that** the first sensor (3) is embodied as a piezoelectric sensor or strain gauge.

10 11. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 to 10, **characterized in that** it is performed in a time range of 30–1800 s.

15 12. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 to 11, **characterized in that** the cessation of the peristaltic movements is indicated by the alert mechanism (9).

AMENDED CLAIMS
received by the International Bureau on 13 January 2023 (13.01.2023)

CLAIMS

1. A device (1) for monitoring peristalsis of organs of the gastrointestinal tract comprising a first sensor (3) adapted to be placed in the region of the upper half of the body, a second sensor (4) adapted to be placed in the region of the lower half of the body, and a computing unit (5) electrically connected to the first and second sensors (4), **characterized in that** the first sensor (3) is adapted to detect a mechanical parameter of the aorta, wherein the mechanical parameter is the pulse wave of the aorta, QRS complex, or R wave, and the second sensor (4) is adapted to detect mechanical excitation of the aorta, wherein the mechanical excitation is the pulse wave of the aorta, wherein the computing unit (5) is adapted to determine a time parameter, wherein the time parameter is a time difference between the detection of the mechanical parameter of the aorta by the first sensor (3) and the detection of mechanical excitation of the aorta by the second sensor (4), and to process the time parameter values by generating a time series of time parameter values and determining the spectral density of the time parameter values for an arbitrary signal frequency and to indicate an arrest of the GIT peristaltic movements by detecting deviations in the spectral density values.
5
2. The device for monitoring peristalsis of claim 1, **characterized in that** the first sensor (3) is an electrocardiograph.
10
3. The device for monitoring peristalsis of claim 1, **characterized in that** the sensors (3, 4) are embodied as piezoelectric sensors or strain gauges.
15
4. The device for monitoring peristalsis of any one of the preceding claims 1 to 3, **characterized in that** it further comprises an AD converter (6) electrically connected to the first sensor (3), the second sensor (4), and the computing unit (5).
20
5. The device for monitoring peristalsis of any one of the preceding claims 1 to 4, **characterized in that** it further comprises a signal amplifier (7) of signal detected by the first sensor (3) and the second sensor (4).
25
30

AMENDED SHEET (ARTICLE 19)

6. The device for monitoring peristalsis of any one of the preceding claims 1 to 5, **characterized in that** it further comprises an alert mechanism (9) and a communication peripheral (10) communicating with the alert mechanism (9),
5 wherein the alert mechanism (9) is adapted to alert the medical personnel.

7. A method of monitoring peristalsis of organs of the gastrointestinal tract using the device of any one of claims 1 to 6, **characterized in that** it comprises the following steps:
10

- detection of at least one mechanical parameter of the aorta by the first sensor (3), wherein the mechanical parameter is a pulse wave of the aorta, QRS complex, or R wave;

- detection of mechanical excitation of the aorta by the second sensor (4), wherein the mechanical excitation is a pulse wave of the aorta;
15

o wherein the mechanical parameter detected by the first sensor (3) and the mechanical excitation detected by the second sensor (4) correspond to the same heartbeat;

- determination of the time parameter by the computing unit (5), wherein the time parameter is the time difference between the detection of the mechanical parameter of the aorta by the first sensor (3) and the detection of the mechanical excitation of the aorta by the second sensor (4)
20

- and it further comprises the steps performed by the computing unit (5):

o creation of a time series of the time parameter values,

o determination of the spectral density of the time parameter values for arbitrary signal frequency
25

- and indication of an arrest of the GIT peristaltic movements by detecting deviations in the spectral density values.

30 8. The method of monitoring peristalsis of organs of the gastrointestinal tract of claim 7, **characterized in that** the second sensor (4) is embodied as a piezoelectric sensor or strain gauge.

AMENDED SHEET (ARTICLE 19)

9. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 and 8, **characterized in that** the first sensor (3) is embodied as an electrocardiograph.
- 5 10. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 and 8, **characterized in that** the first sensor (3) is embodied as a piezoelectric sensor or strain gauge.
- 10 11. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 to 10, **characterized in that** it is performed in a time range of 30–1800 s.
- 15 12. The method of monitoring peristalsis of organs of the gastrointestinal tract of any one of claims 7 to 11, **characterized in that** the cessation of the peristaltic movements is indicated by the alert mechanism (9).

AMENDED SHEET (ARTICLE 19)

1/5

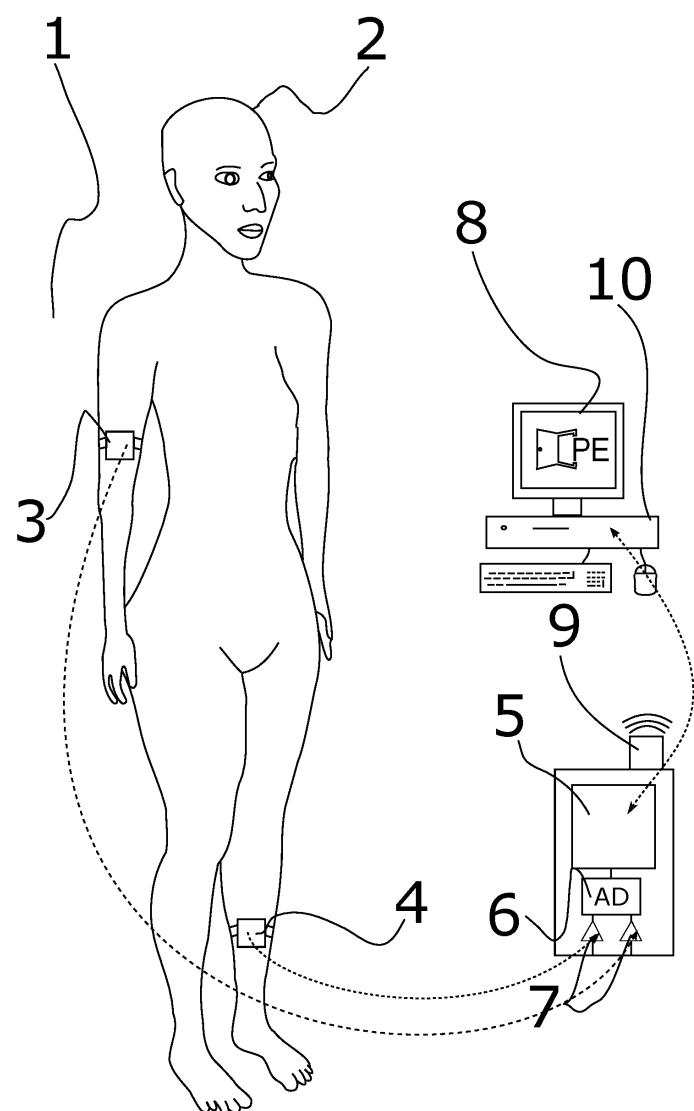


Fig. 1

2/5

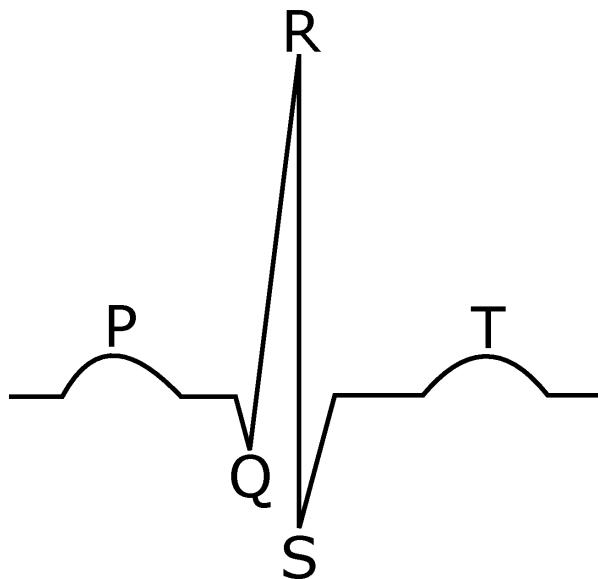


Fig. 2

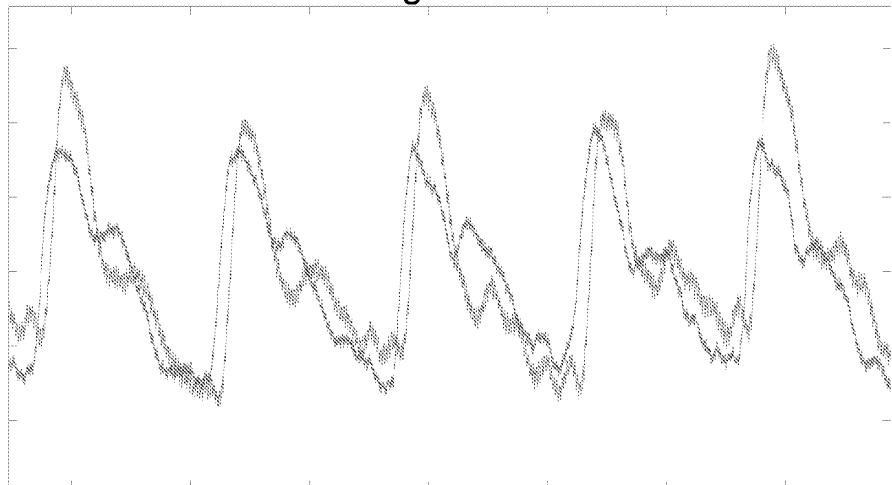


Fig. 3

3/5

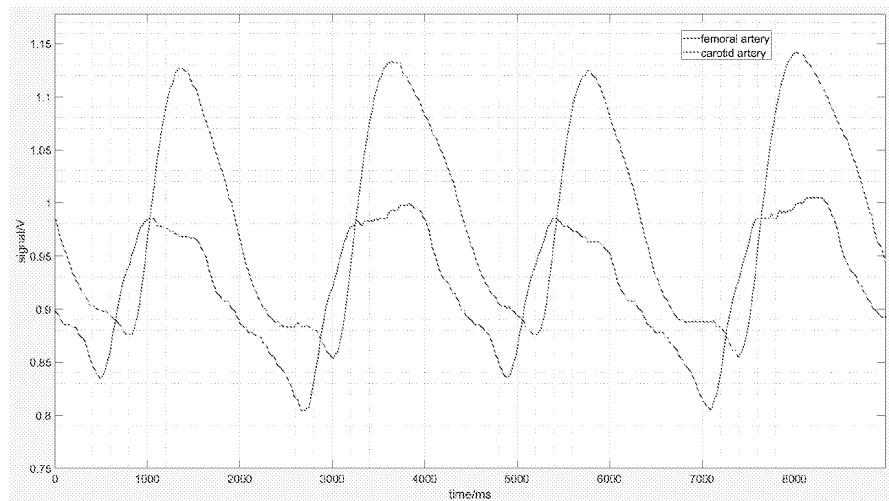


Fig. 4

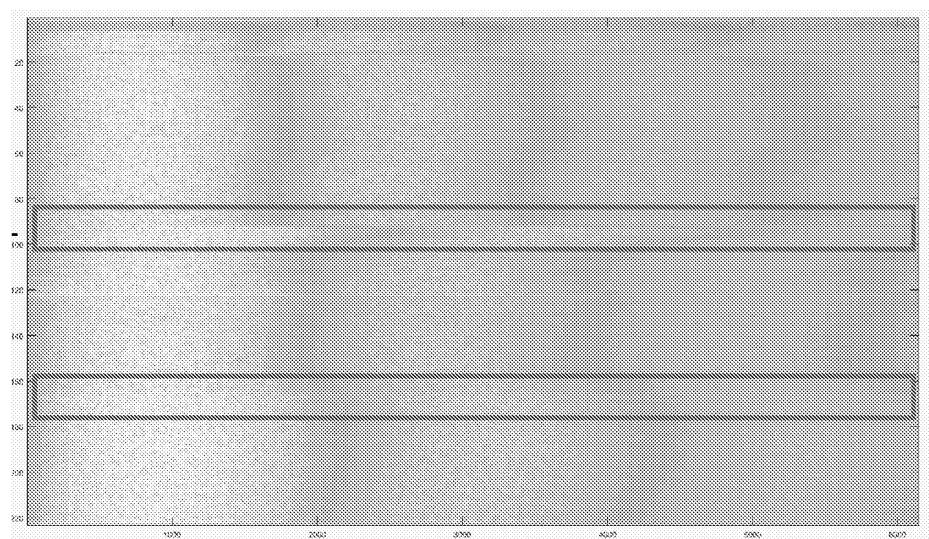


Fig. 5

4/5

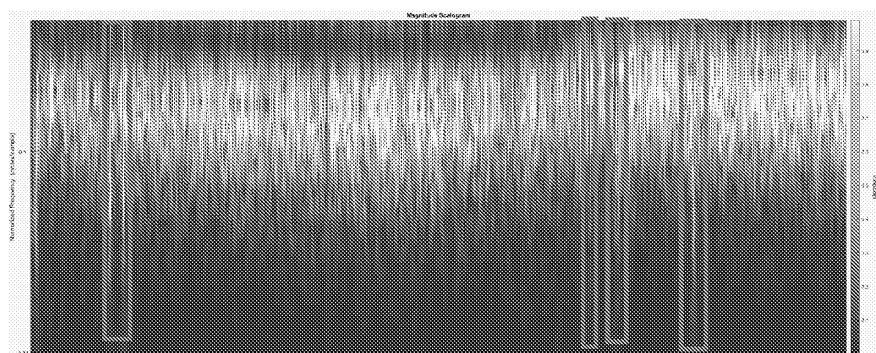


Fig. 6

5/5

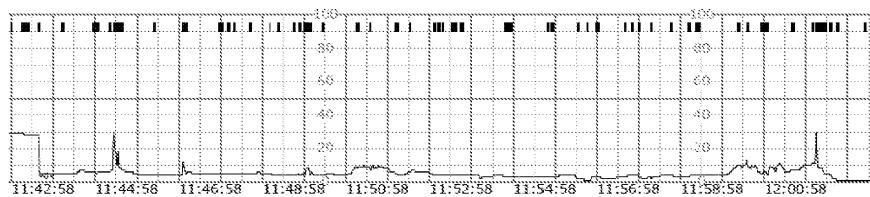


Fig. 7

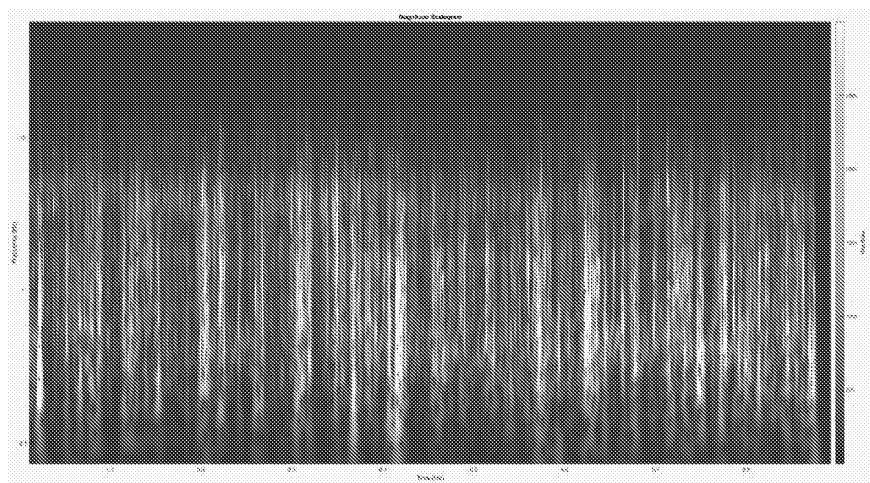


Fig. 8

INTERNATIONAL SEARCH REPORT

International application No PCT/CZ2022/050069	
--	--

A. CLASSIFICATION OF SUBJECT MATTER INV. A61B5/11 ADD. A61B5/021 A61B5/00		
According to International Patent Classification (IPC) or to both national classification and IPC		
B. FIELDS SEARCHED Minimum documentation searched (classification system followed by classification symbols) A61B		
Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched		
Electronic data base consulted during the international search (name of data base and, where practicable, search terms used) EPO-Internal		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
X	JP 6 521345 B1 (M COOPERS CO LTD; REMEDIA KK; TERUOKA MASAKI; YOSHIKAWA TOSHIICHI) 29 May 2019 (2019-05-29)	1-6
A	paragraphs [0008] - [0024], [0049] - [0050], [0083] -----	7
A	US 2021/169361 A1 (BAKER STEVEN D [US] ET AL) 10 June 2021 (2021-06-10) paragraphs [0007], [0067] - [0074], [0082] - [0083] -----	1, 7
A	CN 102 170 830 A (GLAXO GROUP LTD) 31 August 2011 (2011-08-31) figure 7 ----- -/-	1, 7
<input checked="" type="checkbox"/> Further documents are listed in the continuation of Box C.		<input checked="" type="checkbox"/> See patent family annex.
<p>* Special categories of cited documents :</p> <p>"A" document defining the general state of the art which is not considered to be of particular relevance</p> <p>"E" earlier application or patent but published on or after the international filing date</p> <p>"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)</p> <p>"O" document referring to an oral disclosure, use, exhibition or other means</p> <p>"P" document published prior to the international filing date but later than the priority date claimed</p> <p>"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention</p> <p>"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone</p> <p>"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art</p> <p>"&" document member of the same patent family</p>		
Date of the actual completion of the international search 2 November 2022	Date of mailing of the international search report 15/11/2022	
Name and mailing address of the ISA/ European Patent Office, P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Fax: (+31-70) 340-3016	Authorized officer Kronberger, Raphael	

Form PCT/ISA/210 (second sheet) (April 2005)

page 1 of 2

INTERNATIONAL SEARCH REPORT

International application No
PCT/CZ2022/050069

C(Continuation). DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	<p>MA H T ET AL: "Spectral Analysis of Pulse Transit Time Variability and Its Coherence with Other Cardiovascular Variabilities", CONFERENCE PROCEEDINGS. ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (IEEE CAT. NO. 06CH37748); 30 AUG.-3 SEPT. 2006; NEW YORK, NY, USA, IEEE, PISCATAWAY, NJ, USA, 30 August 2006 (2006-08-30), pages 6442-6445, XP031390832, ISBN: 978-1-4244-0032-4 the whole document</p> <p>-----</p> <p>US 2021/228098 A1 (ZHUANG SHAOCHUN [CN] ET AL) 29 July 2021 (2021-07-29) the whole document</p> <p>-----</p> <p>US 2016/095522 A1 (WIARD RICHARD M [US] ET AL) 7 April 2016 (2016-04-07) the whole document</p> <p>-----</p>	1, 7
A		1, 7
A		1, 7

Form PCT/ISA/210 (continuation of second sheet) (April 2005)

page 2 of 2

INTERNATIONAL SEARCH REPORT

Information on patent family members

International application No PCT/CZ2022/050069	
--	--

Patent document cited in search report		Publication date		Patent family member(s)		Publication date
JP 6521345	B1	29-05-2019	JP	6521345 B1	29-05-2019	
			JP	2020089502 A	11-06-2020	
US 2021169361	A1	10-06-2021	EP	3834722 A1	16-06-2021	
			US	2021169361 A1	10-06-2021	
CN 102170830	A	31-08-2011	CA	2723680 A1	12-11-2009	
			CN	102170830 A	31-08-2011	
			EP	2273924 A1	19-01-2011	
			JP	2011519663 A	14-07-2011	
			KR	20110011666 A	08-02-2011	
			WO	2009136930 A1	12-11-2009	
			ZA	201008241 B	24-04-2013	
US 2021228098	A1	29-07-2021	JP	7138363 B2	16-09-2022	
			JP	2021521963 A	30-08-2021	
			US	2021228098 A1	29-07-2021	
			WO	2019205174 A1	31-10-2019	
US 2016095522	A1	07-04-2016	AU	2012211300 A1	09-05-2013	
			CA	2825405 A1	02-08-2012	
			EP	2667769 A2	04-12-2013	
			JP	5955341 B2	20-07-2016	
			JP	6130474 B2	17-05-2017	
			JP	2014507213 A	27-03-2014	
			JP	2016101504 A	02-06-2016	
			US	2013310700 A1	21-11-2013	
			US	2015282718 A1	08-10-2015	
			US	2016095522 A1	07-04-2016	
			WO	2012103296 A2	02-08-2012	

Form PCT/ISA/210 (patent family annex) (April 2005)

UŽITNÝ VZOR

<p>(19) ČESKÁ REPUBLIKA</p>  <p>ÚŘAD PRŮMYSLOVÉHO VLASTNICTVÍ</p>	<p>(21) Číslo přihlášky: 2022-40594 (22) Přihlášeno: 20.12.2022 (47) Zapsáno: 07.02.2023</p>	<p>(11) Číslo dokumentu: 36 821</p> <p>(13) Druh dokumentu: U1 (51) Int. Cl.: <i>A61B 5/11</i> (2006.01) <i>G16H 50/80</i> (2018.01) <i>A61B 5/02</i> (2006.01)</p>
--	---	---

- (73) Majitel:
Univerzita Hradec Králové, Hradec Králové, CZ
- (72) Původce:
RNDr. Filip Studnička, Ph.D., Hradec Králové,
Slezské Předměstí, CZ
Ing. Richard Cimler, Ph.D., Chrudim, Chrudim IV,
CZ
Mgr. Jitka Kühnová, Ph.D., Hradec Králové, Nový
Hradec Králové, CZ
Ing. Jan Matyska, Hradec Králové, Nový Hradec
Králové, CZ
Ing. Jan Štěpán, Ph.D., Dobruška, CZ
doc. RNDr. Jan Šlégr, Ph.D., Litomyšl, Litomyšl-
Město, CZ
- (74) Zástupec:
PatentEnter s.r.o., Koliště 1965/13a, 602 00 Brno,
Černá Pole

- (54) Název užitného vzoru:
**Systém pro monitorování pohybové aktivity
a vitálních funkcí zvířete**

CZ 36821 U1

Úřad průmyslového vlastnictví v zápisném řízení nezjišťuje, zda předmět užitného vzoru splňuje podmínky způsobilosti k ochraně podle § 1 zák. č. 478/1992 Sb.

Systém pro monitorování pohybové aktivity a vitálních funkcí zvířete

Oblast techniky

5

Technické řešení se týká systému pro monitorování pohybové aktivity a vitálních funkcí zvířete, jako je například variabilita srdečního tepu. Konkrétněji se řešení týká podložky, kterou lze použít např. pro monitorování pohybových aktivit a vitálních funkcí zvířat v kotcích na veterinárních klinikách.

10

Dosavadní stav techniky

15

Pro hospitalizaci zvířecích pacientů po operaci existují v současné době na veterinárních klinikách kotce, v nichž jsou tato zvířata umístěna. Lékař pak nad daným zvířete dohlíží, případně mu podává léky, přičemž tato může být časově velmi náročná, a navíc se jí lékař vzhledem k ostatním povinnostem nemůže věnovat naplno. V některých případech je navíc potřeba kontrolovat zdravotní či psychický stav zvířete kontinuálně, tzn. také v noci.

20

V současné době je možné monitorovat vitální funkce zvířat, případně jejich pohybovou aktivitu, pomocí senzorů, které má dané zvíře na sobě. Taková řešení nicméně omezují komfort zvířete a ovlivňují jeho psychický stav, čímž do značné míry zkreslují také výsledky měření. Problematické může být také upevnění senzorů ke zvířeti, obzvláště pokud je stav zvířete po zátku vážnější a je potřeba s ním manipulovat opatrně, nebo pokud je zvíře neklidné a aplikaci senzorů se brání. Navíc může dojít také k tomu, že si zvíře senzory strhne, čímž znemožní sbírání výsledků.

25

Bylo by proto vhodné přijít s řešením, které by umožňovalo kontinuální monitorování pohybové aktivity zvířete, ale také jeho vitálních funkcí, jako je tepová či dechová frekvence, a to bez nutnosti nošení speciálního monitorovacího přístroje či různých senzorů připevněných k tělu zvířete.

Podstata technického řešení

30

Výše uvedené nedostatky do jisté míry odstraňuje systém pro monitorování pohybové aktivity a vitálních funkcí zvířete zahrnující alespoň jednu podložku, řídící jednotku a modul pro analýzu dat. Podstata systému dle předkládaného technického řešení spočívá v tom, že podložka zahrnuje alespoň jeden senzor vibrací upevněný k podložce a spojený s řídící jednotkou, přičemž řídící jednotka zahrnuje komunikační modul pro přenos dat.

35

Výhoda takového systému spočívá v tom, že umožňuje monitorování pohybové aktivity zvířete a také monitorování jeho vitálních funkcí, jako je tepová či dechová frekvence. Nijak přitom není omezeno pohodlí monitorovaného zvířete, neboť není nutné, aby na sobě mělo jakýkoliv přístroj či senzor. Díky systému s podložkou dle předkládaného technického řešení také odpadají časté fyzické kontroly, neboť zdravotní a psychický stav zvířete je monitorován kontinuálně 24 hodin denně, 7 dní v týdnu, respektive po celou dobu, kdy se zvíře nachází v kotci, kde je podložka umístěna.

40

Systém dále výhodně zahrnuje alespoň jeden zesilovač signálu, přičemž alespoň jeden zesilovač signálu je na svém vstupu spojený s alespoň jedním senzorem vibrací a na svém výstupu je spojený s řídící jednotkou. Pomocí zesilovače lze zesílit signál naměřený senzorem vibrací, a tím lépe odlišit užitečný signál senzoru odpovídající vibracím podložky od okolního šumu.

45

Senzorem vibrací je výhodně tenzometrický senzor. Tento typ senzoru je obzvláště vhodný, neboť je dostatečně citlivý pro měření mikrovibrací, způsobených vitálními funkcemi zvířete přítomného

na podložce, ale zároveň umožňuje měření vibrací způsobených makroskopickými jevy, jako je pohybová aktivity (např. chůze) na podložce. Při použití vysoké snímkovací frekvence (např. 1 kHz) lze získat dat s milisekundovou přesností.

- 5 Řídící jednotka výhodně zahrnuje analogově digitální převodník. Tento převodník převede analogový signál ze senzoru vibrací na digitální signál, který je již možné zpracovat běžně dostupnými výpočetními jednotkami, např. mikropočítačem, nebo jej snáze zaslat do jiné části systému, např. bezdrátovým spojením na vzdálený server.
- 10 Podložka výhodně zahrnuje rám a podpěrnou desku uspořádanou na vrchní straně rámu, přičemž senzor vibrací je upevněn k rámu a je v kontaktu s podkladem, díky čemuž může senzor vibrací měřit vibrace podložky. Uvedená konstrukce umožňuje také jednoduchou instalaci podložky, zaručuje její dobrou stabilitu a vyznačuje se dobrou odolností vůči mechanickému poškození. Podpěrná deska může být od rámu případně také odejmouta, např. odmontována, čímž je umožněn přístup k senzoru vibrací, pokud by např. došlo k jeho poruše a bylo by potřeba jej vyměnit či opravit. Podkladem je zde mírněna např. podlaha kotce či dno zvířecího pelíšku.
- 15 Modulem pro analýzu dat je výhodně server spojený s řídicí jednotkou, přičemž server je spojený s komunikačním modulem pro přenos dat mezi řídící jednotkou a serverem. V tomto provedení není nutné mít výkonnější, a tudíž nákladnější, řídící jednotku, neboť řídící jednotka neprovádí detailní analýzu naměřeného signálu, ale tento signál zasílá pro další zpracování (tj. provedení výpočtu) na server. Server může poskytovat taky uživatelsky přívětivější a přehlednější výstup.
- 20 Modul pro analýzu dat je výhodně součástí řídící jednotky a je spojený s komunikačním modulem, přičemž systém dále zahrnuje displej spojený s komunikačním modulem pro přenos dat mezi modulem pro analýzu dat a displejem. V tomto provedení není potřeba žádné připojení řídící jednotky k externímu serveru, přičemž všechny výpočty potřebné pro analýzu naměřeného signálu provádí řídící jednotka. Je proto potřeba, aby tato jednotka zahrnovala dostatečně výkonný počítač s dostatečnou operační pamětí, případně musí být zajistěno, aby nedošlo k jeho přehřívání.
- 25
- 30

Objasnění výkresů

Podsta technického řešení je dále objasněna na příkladech jeho uskutečnění, které jsou popsány s využitím připojených výkresů, kde na:

- 35 obr. 1 je schematicky znázorněno uspořádání systému dle předkládaného technického řešení v prvním příkladném provedení bez znázornění podpěrné desky podložky,
- 40 obr. 2 je schematicky znázorněno uspořádání řídící jednotky a její spojení s modulem pro analýzu dat v prvním příkladném provedení systému dle předkládaného technického řešení,
- 45 obr. 3 je schematicky znázorněno uspořádání systému dle předkládaného technického řešení ve druhém příkladném provedení bez znázornění podpěrné desky podložky,
- 50 obr. 4 je schematicky znázorněno uspořádání řídící jednotky s displejem ve druhém příkladném provedení systému dle předkládaného technického řešení,
- 55 obr. 5 jsou znázorněny dvě spojené podložky s příslušnými podpěrnými deskami a
- 60 obr. 6 jsou znázorněny dvě spojené podložky se společnou podpěrnou deskou.

Příklady uskutečnění technického řešení

Technické řešení bude dále objasněno na příkladech uskutečnění s odkazem na příslušné výkresy.

- 5 V prvním příkladném provedení systém pro monitorování pohybové aktivity a vitálních funkcí zvítěze zahrnuje alespoň jednu podložku 1, řídící jednotku 3 a modul 4 pro analýzu dat, přičemž v tomto prvním příkladném provedení systému je modulem 4 pro analýzu dat server spojený s řídící jednotkou 3. Pro přenos dat mezi řídící jednotkou 3 a serverem zahrnuje řídící jednotka 3 komunikační modul 7.
- 10 Podložka 1 ve svém prvním příkladném provedení zahrnuje rám 1a a podpěrnou desku 1b uspořádanou na vrchní straně rámu 1a, přičemž rám 1a zajišťuje stabilní polohu podložky 1 na podkladu, na němž je podložka 1 položena, tj. například na podlaze kotce. Jak je vidět na obr. 1, rám 1a zahrnuje čtyři boční profily, které vymezují tvar rámu 1a, a potažmo tedy celé podložky 1, a dále také další profily, které celou konstrukci rámu 1a dodatečně vyztužují. Profily jsou v prvním příkladném provedení provedeny jako hliníkové profily, nicméně alternativně mohou být provedeny také z jiného vhodného materiálu, výhodně z materiálu, který je dostatečně lehký a pevný. V drážkách hliníkových profilů lze navíc vést kabely, např. od zesilovačů 5 k řídící jednotce 3. Ke každému bočnímu profilu podložky 1, konkrétně k jeho vnitřní straně, je dále upewněn senzor 2 vibrací, přičemž senzor 2 vibrací je usporádán tak, aby po položení podložky 1 na podlahu byly tyto senzory 2 vibrací v kontaktu s podlahou, tj. tvoří v podstatě nohy tohoto rámu 1a. Za tímto účelem je spodní strana senzoru 2 vibrací opatřena průmyslovou gumovou nohou. Díky pevnému spojení senzoru 2 vibrací s rámem 1a podložky 1 a uvedenému kontaktu senzoru 2 vibrací s podkladem lze senzorem 2 vibrací měřit vibrace podložky 1 způsobené přítomností či pohybovou aktivitou zvítěze na podpěrné desce 1b. Podpěrná deska 1b je vyrobena z dostatečně pevného materiálu, např. ze dřeva či dřevotřísky, nicméně podložka 1 může být obalena měkčím materiálem pro zajištění většího pohodlí zvítěze. Rozměry podložky 1 mohou být zvoleny podle příslušné aplikace, tj. např. podle rozměrů kotce na veterinární klinice. V takovém případě má rám 1a, a tedy i položka 1, při pohledu shora obecně obdélníkový tvar.
- 15 20 25 30 35 40 45 50 55 Senzor 2 vibrací je v prvním příkladném provedení realizován jako tenzometrický senzor, neboť tento typ senzoru umožnuje dostatečně citlivé měření vibrací. Konkrétně tento typ senzoru umožnuje detektovat nejen vibrace způsobené makroskopickými ději, jako je pohybová aktivita (např. chůze) zvítěze na podpěrné desce 1b, ale také tzv. mikrovibrace, způsobené pouhou přítomností monitorovaného zvítěze na podpěrné desce 1b – právě tyto mikrovibrace jsou pak klíčové pro monitorování vitálních funkcí zvítěze. V prvním příkladném provedení je tenzometrickým senzorem vážící senzor bez převodníku, přičemž byla použita vysoká snímkovací frekvence 1kHz pro získání dat s milisekundovou přesností. Senzor může být váhově dimenzován na konkrétní druh zvítěze, pro které je určen – např. pro psy, kočky nebo mnohem těžší zvířata, jako jsou koně či dobytek. Alternativně může být použit jiný typ, počet či umístění senzorů 2 vibrací, pokud podložka 1 zahrnuje alespoň jeden senzor 2 vibrací dostatečně citlivý pro zaznamenávání vibrací i mikrovibrací podložky 1.
- Alespoň jeden senzor 2 vibrací, v prvním příkladném provedení tedy konkrétně čtyři senzory 2 vibrací, je spojený, respektive jsou spojené, s řídící jednotkou 3. V prvním příkladném provedení dle obr. 1 je však ještě mezi příslušným senzorem 2 vibrací a řídící jednotkou 3 zapojen zesilovač 5 signálu pro zesílení signálu zaznamenaného senzorem 2 vibrací. Analogový, příkladně napěťový, signál ze senzoru 2 vibrací odpovídající vibracím podložky 1 je tedy přiveden na vstup zesilovače 5 signálu a je tímto zesilovačem 5 signálu zesílen. Následně je zesílený signál posán do řídící jednotky 3, kde dochází k jeho převedení na digitální signál pro následné zaslání na server, případně pro jeho další zpracování přímo v této řídící jednotce 3, jak bude přibliženo v rámci druhého příkladného provedení systému v další části textu.
- Řídící jednotka 3 v prvním příkladném provedení systému, jak je schematicky a zjednodušeně znázorněna na obr. 2, zahrnuje analogově digitální převodník 6, který realizuje převod

analogového signálu ze senzoru 2 vibrací (a následně zesíleného zesilovačem 5 signálu) na digitální signál. Alternativně však může být analogově digitální převodník 6 uspořádán např. také mimo řídící jednotku 3, tj. může být zapojen jako samostatná součástka před řídící jednotku 3, přičemž v takovém případě by již řídící jednotka 3 přijímala digitální signál.

- 5 Řídící jednotka 3 dále zahrnuje komunikační modul 7 pro přenos dat, přičemž v prvním příkladném provedení systému je komunikační modul 7 komunikačně spojen s modulem 4 pro analýzu dat, který je proveden jako server a který slouží pro další zpracování a analýzu uvedeného digitálního signálu s cílem monitorovat pohybovou aktivitu, a především také vitální funkce zvýřete. Komunikační spojení mezi komunikačním modulem 7 řídící jednotky 3 a serverem je v prvním příkladném provedení zajištěno pomocí síťového kabelu ethernet. Alternativně může být toto komunikační spojení realizováno také pomocí jiného typu kabelu či může být provedeno jako bezdrátové spojení, např. pomocí technologie Wi-Fi, pokud je takovým provedením spojení zajištěn spolehlivý přenos dat mezi řídící jednotkou 3 a modulem 4 pro analýzu dat, tj. mezi řídící jednotkou 3 a serverem. Serverem je např. vzdálený server, tzv. cloud. Řídící jednotka 3 zahrnuje také mikroprocesor, který řídí přijímání signálů ze senzoru 2 vibrací a dává pokyny komunikačnímu modulu 7 pro komunikaci se serverem. Podobnější bude zpracování dat modulem 4 pro analýzu dat popisováno v další části textu, nebot je jeho princip ve své podstatě totožný pro systém v prvním i ve druhém příkladném provedení, které bude rovněž přibliženo v další části textu.
- 10 15 20

Jak bylo uvedeno výše, systém podle předkládaného technického řešení zahrnuje alespoň jednu podložku 1. Pro využití v praxi však systém může zahrnovat více podložek 1, které jsou spojeny k sobě, např. pro pokrytí větších či netradičně tvarovaných kotců. Jednotlivé podložky 1 lze spojovat např. sešroubováním či jiným spojením jednotlivých rámu 1a k sobě, přičemž v zásadě existují dvě různá provedení podpěrné desky 1b pro překrytí vzájemně spojených rámu 1a. Na příkladu dvou spojených rámu 1a jsou tyto alternativy znázorněny na obr. 5 a obr. 6. Obr. 5 znázorňuje provedení, v němž je na vrchní straně každého rámu 1a uspořádána podpěrná deska 1b, zatímco obr. 6 znázorňuje provedení, v němž jsou všechny rámy 1a překryty jednou podpěrnou deskou 1b společnou pro všechny rámy 1a. Při praktickém použití je pak možné překrýt podpěrnou desku 1b (či právě více podpěrných desek 1b dle obr. 5) např. vrstvou linolea či koberce. Tím dojde především k zakrytí spár, které vznikají mezi podpěrnými deskami 1b v provedení dle obr. 5. Experimenty bylo zjištěno, že provedením dle obr. 5 lze minimalizovat přenos makroskopických vibrací z jedné podložky 1 na druhou. Problém se šířením mikrovibrací (tj. vibrací nesoucích informace o vitálních funkcích zvýřete) z jedné podložky 1 na druhou zjištěn nebyl.

25 30 35

Pokud systém dle předkládaného technického řešení zahrnuje větší počet podložek 1, může zahrnovat také příslušný počet řídících jednotek 3, tzn. jednu řídící jednotku 3 pro každou podložku 1 tak, jak je znázorněno na obr. 1. V takovém provedení je pak každá řídící jednotka 3 komunikačně spojena se serverem a zasílá do něj data získaná ze senzoru 2 vibrací upevněných na dané podložce 1. Alternativně mohou být data z jednotlivých řídících jednotek 3 zaslána do jiné řídící jednotky 3, která je následně zasílá dálé na server pro analýzu. V dalším alternativním provedení zahrnuje celý systém pouze jednu řídící jednotku 3 společnou pro všechny podložky 1, která přijímá signály ze všech senzorů 2 vibrací a zasílá tato data na server.

40 45

Ve druhém příkladném provedení systému, znázorněném na obr. 3 a obr. 4, je modul 4 pro analýzu dat součástí řídící jednotky 3, což znamená, že ke zpracování dat s cílem monitorovat pohybovou aktivitu a vitální funkce zvýřete nedochází na externím serveru, který by byl s řídící jednotkou 3 spojen, ale přímo v řídící jednotce 3. Modul 4 pro analýzu dat tedy zahrnuje výpočetní jednotku, např. mikropočítač, pro provedení výpočtů potřebných pro analýzu dat, které bude přiblížena v další části textu. Řídící jednotka 3 ve druhém provedení systému tedy zahrnuje analogově digitální převodník 6 pro převedení analogového signálu ze senzoru 2 vibrací na digitální signál, který je dále zpracováván modulem 4 pro analýzu dat, a také komunikační modul 7 a displej 8 pro zobrazování vypočítaných hodnot (především tedy vypočítaných hodnot vitálních funkcí, např. srdečního tepu), jak je schematicky a zjednodušeně znázorněno na obr. 4. Displej 8 může být

50 55

zabudován např. ve vrchní straně pouzdra řídící jednotky 3. Komunikační modul 7 tedy ve druhém příkladném provedení systému zajišťuje přenos dat mezi modulem 4 pro analýzu dat a displejem 8. Alternativně není displej 8 součástí řídící jednotky 3, ale je s řídící jednotkou 3 spojen, např. pomocí síťového kabelu ethernet či bezdrátově, nicméně stále platí, že ve druhém příkladném provedení systému jsou data ze senzorů 2 vibrací zpracovávána přímo v řídící jednotce 3.

V následující části bude přiblíženo zpracování dat modulem 4 pro analýzu dat, přičemž zpracování dat je ve své podstatě stejně pro první i druhé provedení systému, jak byla popisována výše.

- 10 Signál získaný pomocí alespoň jednoho senzoru 2 vibrací zahrnuje dvě základní složky – statickou nízkofrekvenční složku a dynamickou vysokofrekvenční složku. Statická nízkofrekvenční složka umožňuje získat informaci o přítomnosti zvěřete na podložce 1 a o jeho pohybové aktivitě (např. chůzi) na podložce 1, zatímco dynamická vysokofrekvenční složka odpovídá změnám zatížení podložky 1 v důsledku dýchání a v důsledku srdeční činnosti. Právě tyto dynamické signály tak lze použít pro výpočet srdeční frekvence nebo dechové frekvence.
- 20 Monitorování přítomnosti zvěřete na podložce 1 je prováděno sledováním statických signálů, přičemž při vstupu zvěřete na podložku 1 dojde ke skokovému nárustu těchto statických nízkofrekvenčních signálů. Pro monitorování přítomnosti zvěřete, ale také pro monitorování pohybové aktivity (např. chůze) zvěřete na podložce 1 je dále definován parametr nazvaný „aktivita“ odpovídající míře pohybu na podložce 1. Tento parametr je příkladně definován jako diference velikostí po sobě jdoucích vektorů tvořených v každém časovém okamžiku aktuálními hodnotami ze senzorů 2 vibrací. Tento parametr je nízký, pokud je na podložce 1 klid, a vysoký, pokud dochází na podložce 1 k pohybu. Zároveň pokud je aktivita menší než zvolená minimální prahová hodnota, lze usuzovat na to, že je podložka 1 nezatížená zvěřetem. Naměřená minimální hodnota aktivity tak odpovídá okolnímu šumu. Z tohoto důvodu je algoritmus využíváný modulem 4 pro analýzu dat upraven tak, aby došlo k potlačení tohoto šumu a ke zvýšení přesnosti monitorování. Např. je provedena filtrace signálu.
- 30 Pro monitorování vitálních funkcí zvěřete slouží dynamické vysokofrekvenční signály, přičemž pro hledání projevů vitálních funkcí v naměřeném signálu jsou použity metody balistokardiografie (zkráceně BKG). Při těchto metodách je snímán pohyb těla v důsledku činnosti srdece zvěřete. Konkrétně jsou měřené pohyby těla způsobeny zrychlením krve při jejím pohybu uvnitř velkých cév. Náraz krve na aortální oblouk způsobuje pohyb těla vzhůru a při sestupu krve dochází naopak k pohybu těla dolů. Pomocí těchto metod jsou vypočítány např. dechová frekvence či srdeční frekvence, přičemž lze sledovat také variabilitu obou těchto frekvencí, tj. jak se tyto vitální funkce mění v čase, a detektovat tak případné arytmie. Tyto metody jsou ve stavu techniky známé např. z článků Computer aided detection of breathing disorder from ballistocardiography signal using convolutional neural network (D. Cimr et al., 2020), Automatic detection of breathing disorder from ballistocardiography signals (D. Cimr, F. Studnička, 2020), Continuous Monitoring of Heart Rate Using Accelerometric Sensors (F. Studnička et al., 2012) či Analysis of Biomedical Signals Using Differential Geometry Invariants (F. Studnička, 2011).
- 40 Obecně platí, že vitální funkce je možné začít detailně monitorovat při klidu trvajícím déle než 6 sekund, ideálně déle než 20 sekund. Při činnostech, kdy vznikají značné vibrace, jako je například chůze či převalování zvěřete na podložce 1, není možné vitální funkce sledovat. Je možné samozřejmě sledovat přítomnost na určitých podložkách 1 (pokud systém zahrnuje více podložek 1) a míru aktivity.
- 45 Výsledky zpracování dat modulem 4 pro analýzu dat, především tedy hodnoty vypočítaných vitálních funkcí, jsou následně zobrazeny uživateli např. na webu, počítači, mobilním telefonu či jiném vhodném zařízení, případně na displeji 8, pokud se jedná o systém podle druhého příkladného provedení. Je tedy umožněno monitorování přítomnosti, pohybové aktivity a vitálních funkcí zvěřete téměř v reálném čase.

55

Systém podle předkládaného technického řešení umožňuje také detekci pádů, přičemž pro detekci pádů lze použít jak statické signály, tak dynamické signály. Příkladně mohou být dynamické signály nejprve jednou či dvakrát vyhlazeny přes 50 Hz a následně určeny jejich klouzavé rozptyly s oknem 0,5 s. Pro každou z podložek 1 je pak určena maximální hranice rozptylu signálu. Pokud dojde k překročení této hranice, je zaznamenán pád na konkrétní podložce 1. Na základě tohoto překročení může být vydána notifikace a lékař je upozorněn, aby se šel na zvíře podívat.

NÁROKY NA OCHRANU

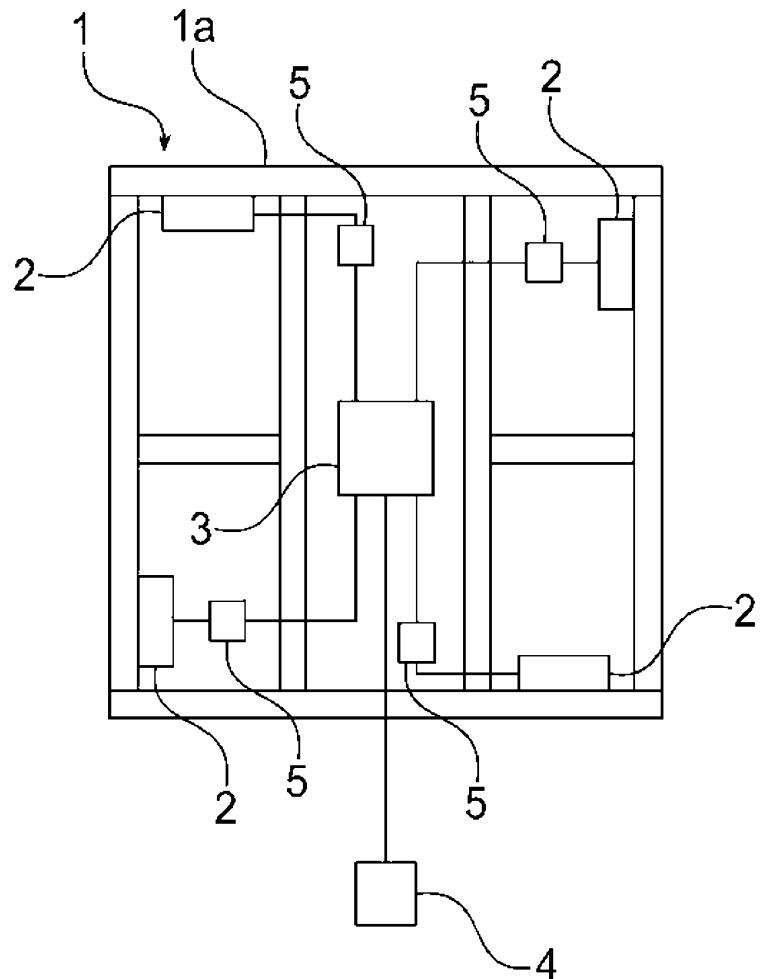
- 5 1. Systém pro monitorování pohybové aktivity a vitálních funkcí zvýšete zahrnující alespoň jednu podložku (1), řídící jednotku (3) a modul (4) pro analýzu dat, **vyznačující se tím**, že podložka (1) zahrnuje alespoň jeden senzor (2) vibrací upevněný k podložce (1) a spojený s řídící jednotkou (3), přičemž řídící jednotka (3) zahrnuje komunikační modul (7) pro přenos dat.
- 10 2. Systém podle nároku 1, **vyznačující se tím**, že dále zahrnuje alespoň jeden zesilovač (5) signálu, přičemž alespoň jeden zesilovač (5) signálu je na svém vstupu spojený s alespoň jedním senzorem (2) vibrací a na svém výstupu je spojený s řídící jednotkou (3).
- 15 3. Systém podle kteréhokoli z nároků 1 a 2, **vyznačující se tím**, že senzorem (2) vibrací je tenzometrický senzor.
4. Systém podle kteréhokoli z předcházejících nároků 1 až 3, **vyznačující se tím**, že řídící jednotka (3) zahrnuje analogově digitální převodník (6).
- 15 5. Systém podle kteréhokoli z předcházejících nároků 1 až 4, **vyznačující se tím**, že podložka (1) zahrnuje rám (1a) a podpěrnou desku (1b) uspořádanou na vrchní straně rámu (1a), přičemž senzor (2) vibrací je upevněn k rámu (1a) a je v kontaktu s podkladem.
- 20 6. Systém podle kteréhokoli z předcházejících nároků 1 až 5, **vyznačující se tím**, že modulem (4) pro analýzu dat je server spojený s řídící jednotkou (3), přičemž server je spojený s komunikačním modulem (7) pro přenos dat mezi řídící jednotkou (3) a serverem.
- 20 7. Systém podle kteréhokoli z předcházejících nároků 1 až 5, **vyznačující se tím**, že modul (4) pro analýzu dat je součástí řídící jednotky (3) a je spojený s komunikačním modulem (7), přičemž systém dále zahrnuje displej (8) spojený s komunikačním modulem (7) pro přenos dat mezi modulem (4) pro analýzu dat a displejem (8).

25

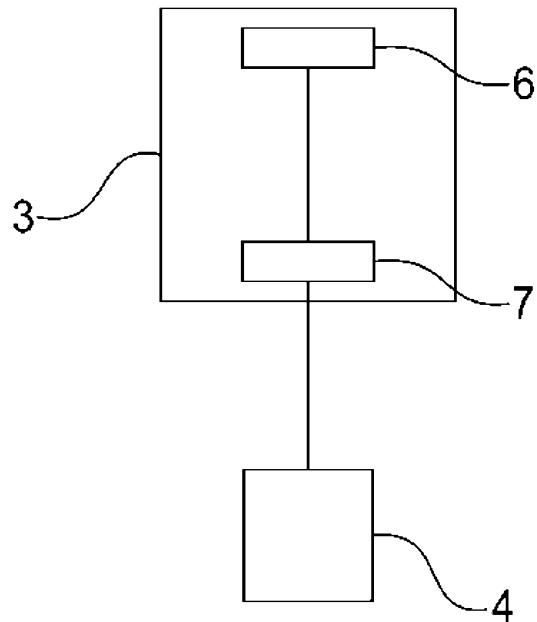
6 výkresů

Seznam vztahových značek:

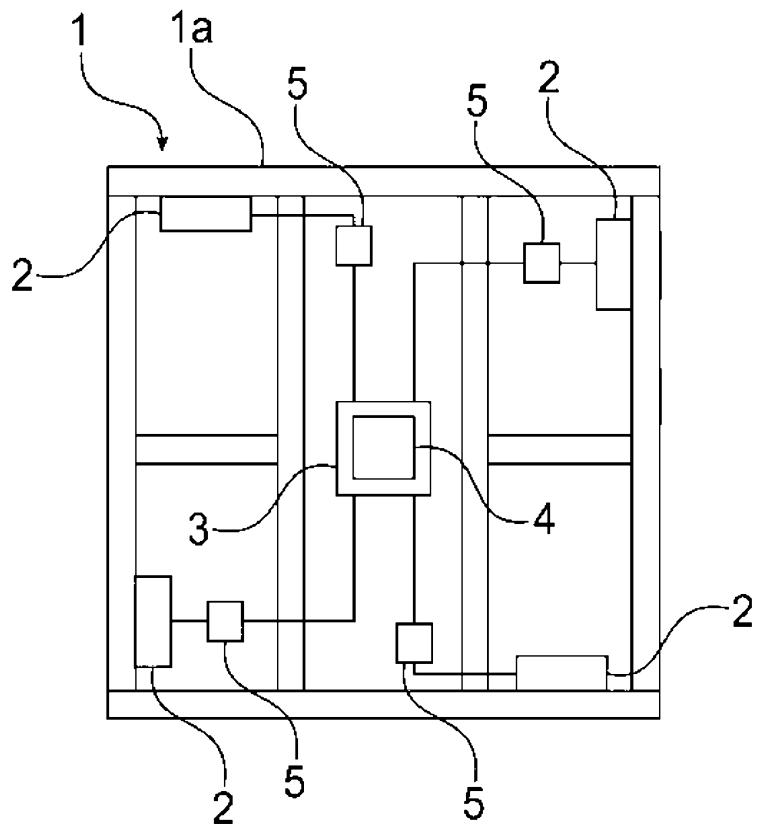
- 1 - podložka
- 1a - rám
- 1b - podpěrná deska
- 2 - senzor vibrací
- 3 - řídící jednotka
- 4 - modul pro analýzu dat
- 5 - zesilovač signálu
- 6 - analogově digitální převodník
- 7 - komunikační modul
- 8 - displej



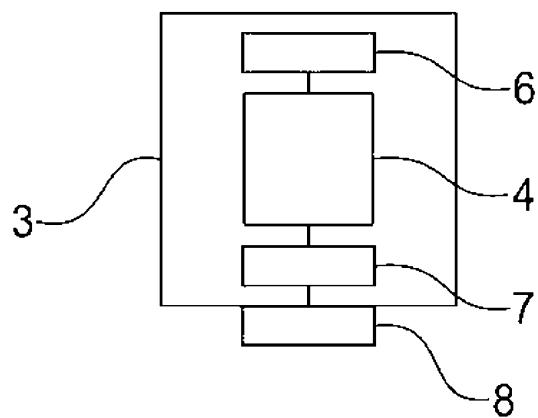
Obr. 1



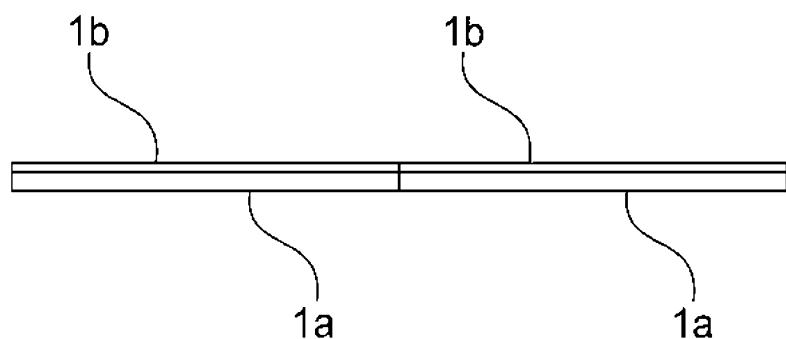
Obr. 2



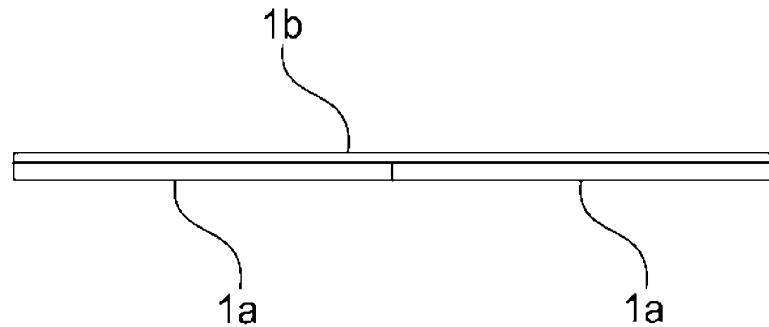
Obr. 3



Obr. 4



Obr. 5



Obr. 6