

Bakalářská práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra počítačů

Zpracování a vizualizace aktigrafických a behaviorálních dat

Lukáš Sláma

Vedoucí: doc. Ing. Daniel Novák Ph.D.

Obor: Software

Studijní program: Otevřená informatika

Srpen 2021

Poděkování

Děkuji svému vedoucímu Danielu Novákovi za pomoc, rady a vedení při přípravě této bakalářské práce.

Děkuji Jakubu Schneiderovi za cenné rady při zpracovávání dat a kolegům Martinu Lukešovi, Michalu Kubinovi, Ericu Žílovi a Ondreji Sakačimu za příjemnou spolupráci.

Děkuji také Jiřímu Wildovi za pomoc při nasazování a při správě platformy LAMP.

Děkuji svojí mamince Janě za pomoc při práci a svému bratrovi Tomášovi za cenné rady a komentáře.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze, 12. srpna 2021

Abstrakt

Cílem této bakalářské práce bylo prozkoumat nový vědecký obor digitální fenotypizace a jeho možné využití v praxi. Digitální fenotypizace je multidisciplinární obor vědy, který se dá definovat jako "*sledování lidského fenotypu/lidských vlastností za použití digitálních zařízení*".

Pro sběr digitálních fenotypizačních dat existuje několik platform. Zabýval jsem se popisem a zkušenostmi s dvěma takovými platformami - LAMP a Beiwe.

V poslední části této práce popisuji pilotní studii, kterou jsme s kolegy uskutečnili. Pomocí fenotypizačních dat získaných v této studii ověřuji dvě hypotézy ohledně mentálního zdraví. Hypotézy jsou založeny na předpokladech, že se člověk cítí lépe, když tráví čas pohybem a hůře, když tráví značné množství času na svém mobilním telefonu. Tyto hypotézy jsou ověřeny pomocí lineární regrese a statistická významnost výsledků je ověřena pomocí multivariační analýzy rozptylu.

Naše studie ukazuje, že existuje statisticky signifikantní vztah mezi náladou, pohybem a časem stráveným na telefonu.

Klíčová slova: digitální fenotypizace, aktigrafie, klasifikace, behaviorální analýza

Vedoucí: doc. Ing. Daniel Novák Ph.D.

Abstract

The aim of this bachelor thesis was to explore the new scientific field of digital phenotyping and its possible application in practice. Digital phenotyping is a multidisciplinary field of science that can be defined as "*monitoring the human phenotype/human characteristics using digital devices*".

Several platforms exist for collecting digital phenotyping data. In my thesis I provide a description and experience with two such platforms - LAMP and Beiwe.

In the last section of this paper, I describe a pilot study that my colleagues and I conducted. Using the phenotyping data collected in that study, I test two hypotheses regarding mental health. The hypotheses are based on the assumptions that people feel better when they spend time on physical activity and worse when they spend a significant amount of time on their mobile phones. These hypotheses are tested using linear regression and the statistical significance of the results is tested using multivariate analysis of variance.

Our study shows that there is a statistically significant relationship between mood, movement and time spent on the phone.

Keywords: digital phenotyping, actigraphy, classification, behavioral analysis

Title translation: Processing and visualisation of actigraphical and behavioral data

Obsah

1 Úvod	1	6 Diskuze	31
1.1 Pohyb	1	6.1 Sběr dat	31
1.2 Čas u obrazovky	1	6.1.1 Aktivní data	31
2 Digitální fenotypizace	3	6.1.2 Pasivní data	32
2.1 Definice a úvod	3	6.1.3 Možné řešení výzev	32
2.1.1 Aktivní data	3	6.1.4 Zkušenosti se sběrem dat - platforma Beiwe	32
2.1.2 Pasivní data	3	6.1.5 Zkušenosti se sběrem dat - platforma LAMP	33
2.1.3 Zařízení pro sběr dat	4	6.2 Srovnání platforem	35
2.2 Využití digitální fenotypizace	4	6.2.1 Úvod	35
2.2.1 Bipolární porucha	5	6.2.2 Nasazení	35
2.2.2 Schizofrenie	6	6.2.3 Správa	35
2.2.3 Další využití	6	6.2.4 Data	36
2.2.4 Využití v praxi	7	6.2.5 Mobilní aplikace	36
2.3 Etické otázky a ochrana osobních údajů	8	6.3 Shrnutí	37
2.3.1 Osobní data	8	6.4 Výsledky	37
2.3.2 Varovný příklad	8	7 Závěr	39
2.4 Shrnutí	8	A Literatura	41
3 Platformy pro sběr dat	11	B Zadání práce	45
3.1 Úvod	11		
3.2 Beiwe	11		
3.2.1 Popis a úvod	11		
3.2.2 Důvod vzniku	11		
3.2.3 Sbíraná aktivní data	11		
3.2.4 Sbíraná pasivní data	12		
3.3 LAMP	13		
3.3.1 Popis a úvod	13		
3.3.2 Důvod vzniku	13		
3.3.3 Sbíraná aktivní data	13		
4 Pilotní studie	17		
4.1 Úvod	17		
4.2 Popis	17		
4.2.1 Délka a účastníci	17		
4.2.2 Postup registrace	18		
4.2.3 Sběr dat	19		
5 Zpracování dat	21		
5.1 Úvod	21		
5.2 Příprava dat	21		
5.2.1 Aktivní data	22		
5.2.2 Pasivní data	22		
5.3 Lineární regrese	22		
5.3.1 Souhrnné výsledky	22		
5.3.2 Individuální výsledky	23		

Obrázky

2.1 "Roustoucí trend v používání digitální fenotypizace v oblasti mentálního zdraví"[LZZ19]	4
5.1 Graf lineární regrese mezi časem stráveným na telefonu a náladou, vnitřním pocitem a energií - odpovědi všech účastníků dohromady	25
5.2 Graf lineární regrese mezi počtem zapnutí displeje telefonu a náladou, vnitřním pocitem a energií - odpovědi všech účastníků dohromady	26
5.3 Graf lineární regrese mezi pohybem a náladou, vnitřním pocitem a energií - odpovědi všech účastníků dohromady	27
5.4 Graf lineární regrese mezi časem stráveným na telefonu a náladou, vnitřním pocitem a energií - účastník BA018	28
5.5 Graf lineární regrese mezi počtem zapnutí displeje telefonu a náladou, vnitřním pocitem a energií - účastník BA018	28
5.6 Graf lineární regrese mezi časem stráveným na telefonu a náladou, vnitřním pocitem a energií - účastník BA006	29
5.7 Graf lineární regrese mezi pohybem a náladou, vnitřním pocitem a energií - účastník BA013	29

Tabulky

5.1 Výsledné tabulky multivariačních analýz rozptylu	23
5.2 Výsledky lineární regrese mezi časem stráveným na telefonu, počtem zapnutí obrazovky u telefonu a pohybem předchozí den a náladou, vnitřním pocitem a energií (<i>spád průmek vynásobený konstantou 10^3 u času u obrazovky a u pohybu a 10^2 u počtu zapnutí displeje pro lepší čitelnost</i>)	24

Kapitola 1

Úvod

1.1 Pohyb

S vývojem civilizace se postupně mění každodenní život lidí. Především za posledních sto let došlo k razantní změně běžného života (nejenom lidí) na zemi. Lidský organismus byl evolucí přizpůsoben na způsob života, kterého se mu již dnes nedostává. Každodenní fyzická aktivita je něco, na co je naše tělo stavěné a co vyžaduje. Naše fyziologie a biochemie funguje optimálně s pravidelnou dávkou fyzické aktivity. Současná moderní civilizace je ale uzpůsobená pro sedavý životní styl, který je v naší společnosti pro některá zaměstnání vyžadován - např. práce v kanceláři, práce řidiče atd. [EE03]

Lidé žijící sedavým životním stylem jsou více náchylní k různým chronickým onemocněním - např. ateroskleróza, obezita, časté zlomeniny, cukrovka a další [EE03]. I když z dostupných dat stále není jasné, jaké je ideální množství fyzické aktivity za den, jedno je zcela zřejmé: jakákoliv aktivita je lepší než žádná [Hid12]. Vzhledem k tomu, že je fyzické a psychické zdraví úzce spojeno, chronické somatické nemoci mohou způsobit, či zhoršit psychické nemoci, např. depresi [Hid12]. Na téma fyzické aktivity a nálady jsem se zaměřil v první části mé práce.

1.2 Čas u obrazovky

Kromě sedavého životního stylu trpí moderní populace nedostatkem slunečního světla, nedostatkem spánku a sociální izolací [Hid12]. Jeden z důvodů pro tyto problémy může být čas strávený u obrazovky, například čas strávený na telefonu.

Používání aktivních technologických zařízení (např. počítač/telefon) hodinu před spaním je v moderní době velice časté, především u mladých lidí a oproti pasivním technologickým zařízením (např. televize, hudební přehrávač) způsobuje větší problémy s usínáním a s kvalitou spánku [GWH⁺13]. Špatný spánek je u adolescentů asociovaný se zhoršením psychického zdraví a zvýšením úzkosti a deprese [ZPL⁺17]. A naopak intervence v podobě kognitivně-behaviorální terapie (KBT) zaměřené na spánek může zlepšit psychické zdraví člověka [FSG⁺17].

Kromě zhoršení spánku mohou dle Jeste a kol. moderní technologie zhoršit samotu a sociální izolaci [JLC20]. Podle Scotta a kol. může mít přílišné vázání na technologie za následek snížení sociálních schopností, motivace a emoční inteligence a zvýšit riziko deprese u mladších populací [SVS16]. Proto jsem se ve druhé části své práce zaměřil na vztah mezi časem stráveným u telefonu a náladou.

Kapitola 2

Digitální fenotypizace

2.1 Definice a úvod

Digitální fenotypizace (anglicky "*digital phenotyping*") je multidisciplinární obor vědy, který byl v roce 2016 definován jako "*moment-by-moment quantification of the individual-level human phenotype in situ using data from personal digital devices*" [TKLO16]. Tato definice by se dala volně přeložit jako "*sledování lidského fenotypu/lidských vlastností za použití digitálních zařízení*". Za použití digitální fenotypizace je možné sbírat dva hlavní typy dat: aktivní a pasivní.


2.1.1 Aktivní data

Aktivní data jsou taková, která musí uživatel aktivně vytvářet. Může se jednat např. o dotazník nálady či dotazník ohledně fyzické aktivity apod.

2.1.2 Pasivní data

Pasivní data v digitální fenotypizaci představují data, která jsou generována pasivně, tzn. bez uživatelského vstupu. Pokud je pro sběr dat použitý např. chytrý telefon, může se jednat o data ze senzorů GPS, akcelerometru, bluetooth, gyroskopu apod. Kromě dat ze senzorů patří mezi pasivní data i statistiky o používání telefonu, např. počet a délka telefonních hovorů, styl psaní na klávesnici (rychlost psaní, přesnost), počet a frekvence přijatých/odeslaných SMS zpráv, počet hodin strávených na telefonu apod.

Vzhledem k obrovskému množství senzorů, které je možné pro sběr dat využít, je zapotřebí vhodné naplánování studie a následné zpracování dat. Data jsou sbírána jako surová data, bez jakéhokoliv zpracování. Například z dat o telefonních hovorech je možné získat informace o délce a frekvenci telefonních hovorů, ale je také možné telefonní hovory nahrávat a z různých parametrů hlasu (např. intonace/rychlost) odhadnout náladu subjektu [FJBF⁺16]. Témata týkající se etiky a ochrany osobních údajů budou dále rozvedeny v sekci 2.3.



Obrázek 2.1: "Růstující trend v používání digitální fenotypizace v oblasti mentálního zdraví"[LZZ19]

2.1.3 Zařízení pro sběr dat

Pro sběr pasivních dat je nejčastěji využíván chytrý telefon, a to proto, že ho většina lidí vlastní (v USA v roce 2013 56% dospělých osob [Smi13]) a obsahuje velké množství senzorů. Kromě chytrých telefonů je ale možné pro sběr dat využít i jiné zařízení, např. chytré hodinky/náramky. Důležitou vlastností všech zařízení pro sběr pasivních dat je, aby je uživatel měl neustále u sebe nebo na sobě, jelikož data jsou sbírána nepřetržitě.

Pro sběr aktivních dat se většinou používá smartphone či jiné elektronické zařízení, např. počítač, protože pro vyplňování dotazníků je tento způsob nejjednodušší. Pro větší přesnost aktivních dat je možné využít osobního pohovoru se zaškolenou osobou. Nevýhodou tohoto přístupu jsou větší náklady a větší časová náročnost. To většinou vede k nižší frekvenci získávání dat.

2.2 Využití digitální fenotypizace

I přesto, že je digitální fenotypizace poměrně nový pojem, využití v oblasti mentálního zdraví neustále stoupá - viz 2.1. Z grafu je vidět, že roční objem nových článků je stále poměrně nízký a zaměřený především na poruchy autistického spektra (anglicky "*ASD - Autism spectrum disorder*") a na depresi. Digitální fenotypizace byla ale také využita pro studium pacientů trpících bipolární afektivní poruchou (viz 2.2.1) a schizofrenií (viz 2.2.2).

Například u depresivních pacientů, je možné za pomoci sběru aktivních a pasivních dat, a jejich následného zpracování, zjistit, jak se mění pacientova nálada s ohledem např. na počet navštívených míst za den, nebo na délce pobytu na určitých místech (domov, kancelář, restaurace apod.) [OR16].

■ 2.2.1 Bipolární porucha

■ Definice

Bipolární afektivní porucha je psychické onemocnění, které se vyznačuje opakujícími se epizodami zvýšené nálady (mánie) a deprese. Bipolární porucha I. typu je charakterizována silnými epizodami zvýšené nálady. U bipolární poruchy II. typu je mánie méně silná a nazývá se "hypománie". [AHS12]

■ Význam digitální fenotypizace

Pro pacienty trpící bipolární poruchou je důležité, aby se pokud možno zabránilo epizodám mánie či deprese, jelikož jsou tyto epizody nebezpečné jak pro pacienta, tak pro okolí. Akutní stav mánie může způsobit dezinhibici a násilné chování, které může mít za následek sociopatologické jevy. Nejlepším způsobem, jak zmírnit dopad stavů mánie či deprese, je jim předcházet. Toho by bylo možné dosáhnout pomocí digitální fenotypizace. Pokud by byla nalezena souvislost např. se zvýšenou aktivitou a příchodem manické epizody, bylo by možné pacienta včas informovat, případně změnit medikaci a tím pádem vzniku epizody zabránit. [AHS12]

U bipolárních pacientů nám pasivní data ohledně telefonní komunikace mohou ukázat, jak často a jak dlouho pacient komunikuje se svým sociálním kruhem. Z těchto dat je možné detekovat změnu pacientova chování, např. v počtu a v délce telefonních hovorů, a odhalit tak možný začátek depresivního či manického stavu. U pacientů s neurologickou poruchou, která způsobuje problémy s komunikací a vyjadřováním, je podle nahrávek hlasu možné rozpoznat, jak postupuje pacientova léčba. [OR16]

Ve studii Zuluety a kol. je popsána korelace mezi náladovými stavy pacientů trpících bipolární poruchou a specifickými změnami v používání mobilního telefonu [ZPR⁺18].

Ze studie Ebner-Priemera a kol. vyplývá, že pro úspěšnou predikci stavů mánie či deprese bude pravděpodobně nutné sledování celé škály různých latentních příznaků oproti specifickým změnám chování (např. snížený počet příchozích hovorů) [EPMN⁺20].

V roce 2014 proběhla studie na 12 pacientech s bipolární poruchou, při které se autorům povedlo pomocí pasivních dat z GPS a akcelerometru detekovat manické a depresivní stavy s přesností od 66 do 92 procent, dle pacienta [GOB⁺14].

V roce 2017 proběhla studie s 22 bipolárními pacienty a 14 zdravými lidmi, která ukázala silnou vazbu mezi geografickým pohybem pacientů a depresí [PTS⁺17].

Dle Faurholt-Jepsena a kol. je možné klasifikovat depresivní a manické stavy pomocí nahrávek hlasu z telefonu [FJBF⁺16].

Cao a kol. ukazuje, že je možné s vysokou přesností okolo 90 procent klasifikovat depresi u bipolárních pacientů pomocí pasivních dat získaných z klávesnice telefonu [CZZ⁺17].

2.2.2 Schizofrenie

Definice

Schizofrenie je závažná psychická nemoc charakterizovaná různými příznaky, např. bludy a halucinacemi. Příznaky se dělí na dva hlavní typy, "pozitivní příznaky" a "negativní příznaky". Mezi pozitivní příznaky patří již zmíněné bludy a halucinace, obecně se jedná o příznaky, které způsobují pacientovo odloučení od reality. Mezi negativní příznaky patří různorodé nepříjemné symptomy, například snížená motivace, snížená spontánní řeč, sociální izolace, snížená kognice apod. Kvůli výrazným symptomům a léčbě, která nemusí být vždy efektivní (např. přes 50 procent pacientů má přerušované, ale dlouhodobé psychiatrické problémy, a okolo 20 procent pacientů má chronické příznaky a invaliditu), má schizofrenie ohromný dopad na pacienty i společnost. [OSM16]

Význam digitální fenotypizace

Podobně jako u bipolární poruchy, predikce relapsu psychotických příznaků by velice pomohla při léčbě pacientů se schizofrenií. Vzhledem k tomu, že až 40 procent pacientů, kteří jsou propuštěni z léčebny, mají relaps příznaků během jednoho roku i přes vhodnou léčbu, je jeho predikce velice důležitá. Relapsem se v tomto případě rozumí psychiatrická hospitalizace, a nebo zvýšení psychiatrické péče pacienta [BTS⁺18]

Podle Barnetta a kol. může sledování změn ve způsobu používání telefonu u pacientů se schizofrenií pomoci předpovědět relaps, a tím pádem snížit utrpení pacientů vhodnou intervencí [BTS⁺18].

Digitální fenotypizace nám může dát lepší přehled o tom, které činnosti zvyšují či snižují příznaky u pacientů trpící schizofrenií. Například ve studii [HBKT20] byla popsána negativní korelace mezi reportovanou úzkostí, depresí, psychózou a špatným spánkem u pacientů se schizofrenií, ale u zdravé populace nikoliv.

2.2.3 Další využití

Kromě bipolární poruchy a schizofrenie má digitální fenotypizace široké využití. Kromě mentálního zdraví, kde je možné ji využít např. u predikce symptomů deprese a posttraumatická stresové poruchy (PTSP či PTSD z anglického "*Posttraumatic Stress Disorder*" [PBHR⁺17]), je ji možné využít v následujících oborech:

Předávkování opioidy

Při předávkování opioidy dochází k celkovému utlumení lidského organismu, přičemž utlumení může být tak silné, že předávkovaný pacient přestane dýchat a umře. Většina úmrtí z předávkování opioidů je neúmyslná a dá se jim předcházet podáním účinného antidota *naloxonu*, který funguje na principu blokování opioidových receptorů [Nes09]. Proto je velice důležité včas

rozpoznat příznaky předávkování a podat naloxon. Nové řešení na detekci dýchacích potíží, které jsou s předávkováním spojené, již existuje a k detekci používá chytrý telefon. [HVC19]

■ Nebezpečná konzumace alkoholu

Kromě toho, že se digitální fenotypizace může zaměřit na jednotlivce, je ji také možné použít k detekování různých vzorců chování pro celé skupiny lidí. Například je možné použít data z chytrých telefonů mladých lidí a detekovat vzorce chování, které nastávají při konzumaci alkoholu. Z těchto modelů chování je poté možné identifikovat rizikové oblasti pro konzumaci alkoholu nezletilými jedinci a za pomoci vhodné intervence (např. důsledné kontroly dodržování zákonů ohledně prodeje alkoholu nezletilým osobám) nevhodné konzumaci zabránit. [HVC19]

■ Identifikace rizika sebevraždy

Sebevražda je velký problém především u mladých lidí a dospívajících, kde představuje hlavní příčinu úmrtí. K pokusům o sebevraždu často dochází ještě před prvním kontaktem se zdravotnickými pracovníky, a proto je velice důležité jí předcházet. Technologie na automatické zpracování příspěvků na sociálních sítích již byla použita k určení, zda je člověk v psychické tísní a zda vykazuje známky zvýšeného rizika pro sebepoškozování nebo sebevraždu. Fenotypizační data z chytrých telefonů je možné u rizikových skupin použít k identifikaci zvýšeného rizika sebevraždy. [HVC19]

■ 2.2.4 Využití v praxi

Kromě studií se digitální fenotypizace začíná dostávat do běžných spotřebitelských produktů. Např. americká společnost Apple prodává chytré hodinky Apple Watch, které pravidelně monitorují uživatelův tep, a mohou poté uživatele upozornit na srdeční arytmiie. V roce 2019 Perez a kol. zveřejnili studii na zhodnocení přesnosti měření chytrými hodinkami Apple Watch, které se zúčastnilo přes 400 000 účastníků bez diagnostikované fibrilace síní. Ze studie vyplývá, že 84 procent notifikací se shodovalo s fibrilací síní. [PMH⁺19]

Kromě použití digitální fenotypizace v chytrých hodinkách se společnost Apple rozhodla tento vědecký postup implementovat ve své nové aktualizaci operačního systému iOS 15. Tato aktualizace přináší novou funkci, kterou si uživatel může zapnout v aplikaci Zdraví. Po zapnutí začne iPhone sbírat data ohledně chůze - délku kroku, dvouoporovou fázi chůze a rychlost chůze. Tato data použije k výpočtu asymetrie chůze, která může pomoci upozornit na zvýšené riziko pádu. Vzhledem k tomu, že iOS 15 je k červenci 2021 v beta verzi, nejsou ještě publikované studie o efektivitě této nové funkce, ale oceňují, že se digitální fenotypizace začíná dostávat do běžných spotřebitelských produktů.

2.3 Etické otázky a ochrana osobních údajů

2.3.1 Osobní data

Vzhledem k obrovskému množství dat, které digitální fenotypizace schromažďuje a následně zpracovává, vyvstává důležitá otázka ohledně etiky a ochrany osobních údajů. Data získaná pro účely digitální fenotypizace se dají rozdělit na dva hlavní druhy. Prvním druhem jsou data "obsahově bohatá" a druhým data "obsahově prázdná". Obsahově bohatá data obsahují soukromé osobní informace o pacientovi. Může se jednat například o historii vyhledávání na internetu, hlasové nahrávky, či textové zprávy. Obsahově prázdná data obsahují zdánlivě neškodná data bez citlivých osobních údajů. Jedná se například o data z klávesnice telefonu (ovšem pouze frekvence a styl psaní, nesmí se uchovávat např. použité znaky) nebo informace ohledně "scrollování" na internetových stránkách (např. rychlost posouvání či frekvence posouvání apod.). [MMID⁺18]

Problém ovšem nastává, když si uvědomíme, že ze zdánlivě obsahově prázdných dat můžeme pomocí jejich zpracování získat osobní informace o pacientovi. Například ve studii [BTS⁺18] byly schromažďovány pasivní data z GPS, akcelerometru, anonymizované protokoly o hovorech a textových zprávách, čas zapnuté/vypnuté obrazovky telefonu a stav nabití telefonu. Na první pohled se jedná o neškodná data, ze kterých je ale možné díky jejich zpracování získat osobní informace ohledně nálady a psychického zdraví pacienta. [MMID⁺18]

Z těchto důvodů je podle mého názoru nesmírně důležité důkladně seznámit pacienty/uživatelé s tím, jaká data budou sbírána a jak se s nimi bude zacházet, případně jaké informace z těchto dat bude možné po jejich zpracování získat.

2.3.2 Varovný příklad

I přesto, že si to mnoho lidí v dnešní době neuvědomuje, aplikace podobné digitální fenotypizaci je možné využít bez velkých následků (viz aféra Facebook a Cambridge Analytica [CGH18] [Ber18]) na všech uživateli internetových služeb. Internetové stránky mohou sledovat chování uživatelů a snažit se ho předpovědět, či změnit. Může se jednat například o nabídnutí relevantní reklamy za účelem přesvědčení uživatele o nákupu daného produktu, či o udržení uživatelské pozornosti za účelem získání co největšího zisku ze zobrazené reklamy. Kromě pozornosti je možné změnit uživatelské přesvědčení [MKNS17], například za účelem získání politické moci.

2.4 Shrnutí

Digitální fenotypizace je moderní vědecký obor, který má velký potenciál změnit zdravotnictví budoucnosti. Pilotní studie ukazují, že najde využití především v oblasti mentálního zdraví, například u pacientů trpících depresí, poruchami autistického spektra, bipolární poruchou či schizofrenií. Kromě

mentálního zdraví existují studie zaměřující se na použití digitální fenotypizace při detekci předávkování opioidy nebo zvýšené psychické tísně a možného rizika ublížení na zdraví či sebevraždě.

Kromě vědeckých studií se digitální fenotypizace začíná dostávat do běžných spotřebitelských produktů, především společnost Apple již digitální fenotypizaci implementovala pro detekci fibrilace síní ve svých chytrých hodinkách Apple Watch a ve své nové aktualizaci mobilního operačního systému iOS 15 pro predikci pádů.

Digitální fenotypizace je moderní vědecký obor s obrovským potenciálem, který si podle mého názoru zaslouží hloubější prozkoumání, i přes své nedostatky.

Kapitola 3

Platformy pro sběr dat

3.1 Úvod

Pro sběr dat používaných pro digitální fenotypizaci existují dvě hlavní platformy, které jsou volně dostupné a jednoduché na instalaci a použití. Jedná se o platformy "Beiwe" a "LAMP". V naší pilotní studii jsme spolu s kolegy obě platformy nasadili a otestovali. Naše zkušenosti s oběma platformami rozvedu níže.

3.2 Beiwe

3.2.1 Popis a úvod

Platforma Beiwe vznikla v roce 2016 v Laboratoři Onnela na Harvardově univerzitě. Platforma obsahuje aplikaci pro chytré telefony s operačním systémem Android a iOS a back-end pro AWS (*Amazon Web Services*), který obsahuje studijní portál, databázi a nástroje pro zpracování a vizualizaci surových dat. Celá platforma je vyvíjena pod licencí BSD-3 a zdrojový kód je volně dostupný na internetových stránkách <https://github.com/onnela-lab>.

3.2.2 Důvod vzniku

Torous a kol. udává hlavní důvod pro vznik této platformy možnost k přístupu k surovým datům získaným v rámci studií. Přesto, že v době vzniku Platformy Beiwe již existovaly různé komerční platformy, nedovolovaly autorům studie přístup k surovým datům. To má podle Torouse a kol. značnou nevýhodu - nereprodukovatelnost výsledků studií. Pokud by totiž platforma povolovala přístup k surovým datům, mohli by statistické výpočty ověřit ostatní členové vědecké komunity, a tím pádem zvýšit validitu výsledků studie. [TKLO16]

3.2.3 Sbíraná aktivní data

Všechna aktivní data, která je možné sbírat přes platformu Beiwe jsou dostupné na operačních systémech iOS i Android. Přes platformu Beiwe je možné sbírat následující aktivní data:

■ 3.3 LAMP

■ 3.3.1 Popis a úvod

Platforma LAMP (Learn Assess Manage and Prevent, česky "Poznat, Zhodnotit, Spravovat a Předcházet") byla zveřejněna v roce 2019 týmem *The Division of Digital Psychiatry*, který sídlí na Harvardově univerzitě v Massachusetts. Platforma obsahuje mobilní aplikaci pro chytré telefony s operačním systémem iOS a Android a back-end se studijním portálem. Stejně jako platforma Beiwe je platforma LAMP vyvíjena pod licencí BSD-3 a zdrojový kód je volně dostupný na adrese <https://github.com/BIDMCDigitalPsychiatry>.

■ 3.3.2 Důvod vzniku

Podle Torouse a kol. je hlavním důvodem vzniku platformy LAMP několik nezaplněných potřeb v oblasti digitálního duševního zdraví. Jedná se především o absenci platformy, která by byla otevřená, znovupoužitelná pro velký rozsah využití a obsahovala komponenty pro sběr fenotypizačních dat mnoha druhů - se speciálním zaměřením na data z externích senzorů. Kromě samotných aktivních a pasivních dat, které je možné přes platformu LAMP sbírat, je také možné získat metadata. Mezi metadata patří například čas, za který pacient vyplnil dotazník apod. Obecně se jedná o data, která poskytnou informace o tom, jak daný pacient vyplnil dotazník nebo kognitivní test (platforma LAMP nabízí kromě dotazníků též kognitivní testy). Tato data se můžou zdát na první pohled zbytečná, při bližším zkoumání se ale ukazuje, že mohou mít obrovskou výpovědní hodnotu. Torous a kol. uvádí následující příklad: Pokud pacient vyplňuje dotazník o svém duševním zdraví, a u otázky ohledně suicidality váhá s odpovědí po dobu jedné minuty, předá tím více informací než samotnou odpovědí. [TWB⁺19]

■ 3.3.3 Sbíraná aktivní data

Všechna aktivní data, která je možné sbírat přes platformu LAMP jsou dostupné na operačních systémech iOS i Android. Přes platformu LAMP je možné sbírat následující aktivní data:

- Průzkum s výběrem z několika možností
- Průzkum s možností vlastní textové odpovědi
- Hra "Spatial Span"
- Hra "Cats and Dogs"
- Hra "Jewels Trial A&B"

Je nutné podotknout, že hry na platformě LAMP neslouží k vytvoření kratochvíle, ale jedná se o testy kognice, které je možné využít např. u pacientů se schizofrenií.

■ **Sbíraná pasivní data**

Různé typy pasivních dat je možné sbírat na různých mobilních operačních systémech, přičemž naprostou většinu dat je možné sbírat na obou operačních systémech. Přes platformu LAMP je možné sbírat následující pasivní data:

- **Akcelerometr** - Dostupné na iOS i Android
Akcelerometr měří lineární a úhlové zrychlení.
- **GPS** - Dostupné na iOS i Android
Používá se k zjištění polohy.
- **Stav napájení** - Dostupné na iOS i Android
Změny ve stavu napájení (např. zapojení/vypojení nabíječky) a displeje (vypnutí/zapnutí).
- **Gyroskop** - Dostupné na iOS i Android
Používá se k orientaci zařízení v 3D prostoru.
- **Magnetometr** - Dostupné na iOS i Android
Magnetometr měří velikost a směr magnetické indukce.
- **Pohyb zařízení** - Dostupné na iOS i Android
Používá data z akcelerometru, magnetometru a z gyroskopu k získání informací ohledně pohybu zařízení.
- **WiFi** - Dostupné na iOS i Android
Data o WiFi routerech se kterými může zařízení komunikovat.
- **Telefonní hovory** - Dostupné pouze na iOS
Informace o délce a frekvenci telefonních hovorů.
- **Ušlá vzdálenost** - Dostupné pouze na iOS
- **Krevní tlak** - Dostupné na iOS i Android - Nutné externí monitorovací zařízení
- **Dechová frekvence** - Dostupné na iOS i Android - Nutné externí monitorovací zařízení
- **Srdeční tep** - Dostupné na iOS i Android - Nutné externí monitorovací zařízení
- **Tréninkový segment** - Dostupné na iOS i Android - Nutné externí monitorovací zařízení
Doba trvání tréninku.
- **Spánek** - Dostupné na iOS i Android - Nutné externí monitorovací zařízení
Doba trvání spánku.
- **Váha** - Dostupné na iOS i Android - Nutné externí monitorovací zařízení

- Kroky - Dostupné na iOS i Android - Nutné externí monitorovací zařízení
Počet kroků za den.

Kapitola 4

Pilotní studie

4.1 Úvod

Mým hlavním cílem naší studie bylo ověřit dvě hypotézy ohledně mentálního zdraví. První hypotéza se týká pohybu a nálady. Chtěl jsem ověřit, zda se člověk cítí lépe, pokud sportuje, a pokud ano, do jaké míry se člověku nálada zlepší. Druhá hypotéza je založená na předpokladu, že se člověk cítí hůře, čím více používá svůj mobilní telefon. Tuto hypotézu jsem se pokusil ověřit pomocí sledování dvou metrik o používání telefonu. První z nich je počet zapnutí (případně odemknutí) displeje telefonu za den, a druhá je celkový počet minut strávených na telefonu za den.

Sekundárním cílem studie bylo seznámit se s tím, co organizací studie v oboru digitální fenotypizace prakticky obnáší, např. komunikace s účastníky, tvorba protokolu, sběr dat apod. a s možnými problémy, které mohou během jejího průběhu nastat. Dalším sekundárním cílem bylo důkladně otestovat platformu Beiwe, kterou jsme po krátké zkušební době obou platforem zvolili, větším počtem účastníků.

4.2 Popis

4.2.1 Délka a účastníci

Naše studie probíhala celkem ve dvou kolech, přičemž první kolo trvalo 11 týdnů (22.2. - 9.5.2021) a druhé kolo 7 týdnů (17.5. - 4.7.2021). V prvním kole se zúčastnilo 20 dobrovolníků a v druhém kole 17, z toho 16 bylo i v prvním kole. Původně jsme měli v plánu studii po prvním kole ukončit, ale vzhledem k tomu, že jsme pro naše práce chtěli mít dostatek dat, a měli jsme možnost pracovat v dobrém kolektivu, rozhodli jsme se spustit druhé kolo studie.

Studie se zúčastnili dobrovolníci ve věkovém rozmezí 19-64 let, průměr věků byl 31 let a medián 24 let. Dvě třetiny dobrovolníků byly mužského pohlaví, 16 účastníků bylo během studie zaměstnaných a 13 studovalo.

■ 4.2.2 Postup registrace

Před zařazením do studie byli dobrovolníci seznámeni se studií jako takovou, a s tím, co účast ve studii obnáší. Poté dobrovolníci podepsali informovaný souhlas, souhlas se zpracováním osobních údajů a následně prošli vstupním dotazníkem zaměřeným na duševní zdraví dobrovolníka. Účastníkům byla také přidělena zodpovědná osoba, která měla na starosti komunikaci s dobrovolníkem. Zpravidla se jednalo o vědeckého pracovníka studie, který danému dobrovolníkovi navrhl účast ve studii.

Pro vstupní dotazník jsme použili modifikovaný M.I.N.I. - Mini International Neuropsychiatric Interview (česky "Mini Mezinárodní Neuropsychiatrické Interview) dotazník [LSW⁺97]. Z dotazníku jsme použili následující sekce, které pro nás byly důležité:

- Velká depresivní epizoda
- Velká depresivní epizoda s melancholickými rysy
- Dystymie
- Suicidalita
- (Hypo) Manická epizoda

Kromě těchto sekcí jsme do dotazníku přidali několik vlastních otázek ohledně životního stylu:

- Sportujete? Pokud ano, kolikrát týdně?
- Užíváte pravidelně tabákové výrobky?
- Užíváte alkoholické výrobky? Pokud ano kolikrát týdně?
- Užíváte návykových látek? Pokud ano, v jaké formě, množství a jak často?
- Pracujete? Pokud ano, na plný úvazek, poloviční úvazek, více prací apod.? jaká je forma vaší práce? Manuální, v kanceláři, jiná?
- Studujete? Pokud ano, v jaké formě? Jaký obor studia?
- Jaké je Vaše nejvyšší dosažené vzdělání?
- Má někdo z blízké rodiny diagnostikovanou bipolární poruchu, deprese, anebo jinou duševní poruchu?

Poté, co dobrovolník podepsal potřební dokumenty a prošel vstupním dotazníkem, byla mu přidělena zodpovědná osoba, která mu pomohla s instalací aplikací pro sběr dat. Každý dobrovolník také dostal aktigrafický náramek, který přes vnitřní gyroskop měřil míru pohybu. Každému dobrovolníkovi byl vygenerován náhodný kód ve tvaru BA0X, kde X je číslo od 1 do 21. Toto kódování slouží k pseudonymizaci účastníků.

■ 4.2.3 Sběr dat

Pro sběr pasivních fenotypizačních dat byla použita platforma Beiwe s mobilní aplikací Beiwe2. Jelikož každý ze členů týmu potřeboval sběr jiného typu dat, sbírali jsme všechny typy dat, které platforma Beiwe podporuje (více v sekci 3.2.4). Pro sběr aktivních dat jsme využili mobilní aplikaci Mindpax.me, která byla použita také pro sběr dat z aktigrafického náramku. Jednou denně jsme sbírali následující aktivní fenotypizační data:

- Začátek spánku
- Konec spánku
- Nálada
 - Uvedte vaši náladu na škále od -1 do 1, kde -1 značí nejsmutnější náladu a 1 nejšťastnější
- Vnitřní pocit
 - Uvedte váš vnitřní pocit na škále od -1 do 1, kde -1 značí nejvíce úzkostný pocit a 1 nejvíce relaxovaný
- Energie
 - Uvedte míru vaší energie na škále od -1 do 1, kde -1 značí nejsilnější pocit únavy a 1 nejvyšší množství energie
- Typ dne
 - Možnost z výběru:
 - Práce/studium z domova
 - Práce/studium z kanceláře/školy
 - Kombinace práce z domova a z kanceláře/Studium z domova a školy
 - Volný den
- Čas strávený sportovní aktivitou předchozí den v minutách

Kromě každodenního dotazníku nálady bylo zapotřebí vyplnit i týdenní dotazník. Otázky pokládané v týdenním dotazníku vypadaly takto:

- Nic mě nebaví/netěší
- Jsem bez energie
- Budoucnost vidím temně a pesimisticky
- Cítím se neobvykle dobře, optimisticky
- Mám nadmíru energie
- Myslí mi to příliš rychle, ostatní mě nestíhají
- Potřebuji spát méně než obvykle

- Cítím neklid/napětí
- Nemůžu se soustředit

Na každou z otázek z dotazníku bylo možné odpovědět následujícím způsobem:

- Nesouhlasím
- Spíše nesouhlasím
- Spíše souhlasím
- Souhlasím
- Naprosto souhlasím

Kapitola 5

Zpracování dat

5.1 Úvod

Jak bylo zmíněno v kapitole 4, cílem studie bylo ověřit dvě hypotézy ohledně lidského duševního zdraví.

Vzhledem k tomu, že na platformě Beiwe nebylo možné, v době kdy probíhala naše studie, nastavit automatické zpracování a vizualizaci dat, bylo nutné surová data zpracovat ručně. Zpracování surových dat je sice časově velice náročné, poskytuje ale možnost se s daty lépe seznámit a nechává otevřené možnosti ohledně metod pro jejich zpracování. Osobně jsem se rozhodl pro přípravu a zpracování dat použít program *MATLAB*, který poskytuje velkou databázi předpřipravených funkcí pro různé vědecké obory [Mat21].

5.2 Příprava dat

Před samotným zpracováním a vizualizací dat je zapotřebí data na zpracování připravit. Při přípravě dat jsem surová data importoval a uložil do vhodných objektů, například do objektů typu *struct* (česky struktura). Poté jsem do jedné struktury spároval aktivní a pasivní data podle datumu a vadná data odstranil. Vadná data vznikala především výpadky nebo různými chybami serveru.

Aktivní data již byla v použitelném formátu a nepotřebovala žádnou další úpravu. Z pasivních dat jsem použil informace o displeji telefonu, konkrétně kdy ho účastník zapnul/vypnul. Z těchto údajů je poté možné spočítat celkový čas strávený na telefonu za nějaký úsek času, pro svoji analýzu jsem použil minuty strávené na telefonu za den. Spočítat počet zapnutí obrazovky telefonu za den už bylo lehké.

Celkem jsem po přípravě dat a po odstranění nepoužitelných odpovědí měl od všech účastníků dohromady za obě kola studie 976 vyplněných dotazníků pro hypotézu ohledně pohybu a nálady a 600 vyplněných dotazníků s pasivními daty pro hypotézu ohledně používání telefonu a nálady. Průměrně se tedy jedná o zhruba 46.5 vyplněných dotazníků na účastníka pro první hypotézu a zhruba 28.5 vyplněných dotazníků na účastníka pro druhou hypotézu.

■ 5.2.1 Aktivní data

Aktivní data z aplikace Mindpax.me byla v jednotlivých CSV (Comma-separated values, česky *hodnoty oddělené čárkami*) souborech, přičemž každý účastník měl všechna aktivní data za celou dobu studie v jednom CSV souboru. Odpovědi na dotazníky byly ve formátu JSON (JavaScript Object Notation, česky *JavaScriptový objektový zápis*).

■ 5.2.2 Pasivní data

Pasivní data z platformy Beiwe byla rozdělena do velkého množství CSV souborů (v řádu stovek až tisíců souborů na účastníka). Pasivní data byla obsažena jako prostý text v jednotlivých CSV souborech, nebyla tedy zakódována jako aktivní data ve formátu JSON. Toto rozdělování do velkého množství dat vidím jako nevýhodu platformy Beiwe, jelikož načtení (v našem případě) desítek tisíc souborů je časově náročné a některé operační systémy (např. Windows) mohou mít problémy s indexováním takto velkého počtu souborů. Tyto problémy se mohou projevit například vysokým vytížením procesoru počítače při indexování nebo úbytkem volného místa na disku kvůli objemnému souboru *Windows.edb*, který při indexování vznikne. V mém případě se jedná o soubor o velikosti několika desítek GB.

■ 5.3 Lineární regrese

Pro vyhodnocení mých dat jsem použil lineární regresi. Je to matematická metoda, při které se body v grafu prokládají přímkou metodou nejmenších čtverců. Tato poměrně základní metoda nám může ukázat korelaci mezi daty.

■ 5.3.1 Souhrnné výsledky

Jak je vidět ze souhrnných výsledků lineární regrese na grafech 5.1, 5.2 a 5.3 čas strávený na telefonu měl u našich účastníků tendenci zhoršovat náladu, úzkost a energii následující den. Počet zapnutí obrazovky snižoval energii a pocit relaxace, ale zvyšoval náladu a pohyb u našich účastníků zvyšoval náladu, relaxovanost a množství energie následující den.

Pro zjištění signifikance těchto výsledků jsem použil multivariační analýzu rozptylu (MANOVA), která určí hladinu statistické významnosti mých výsledků. Data jsem rozdělil do čtyř kategorií. U času u obrazovky jsem kategorie rozdělil po 200 minutách strávených na telefonu, počet zapnutí obrazovky po 50 zapnutí a čas strávený pohybem po 60 minutách. V tabulkách 5.1 jsou zaznamenány statisticky signifikantní výsledky u nálady ve všech 3 skupinách. Z průměru nálad v každé skupině můžeme vidět, že se nálada zhoršuje s množstvím času stráveném na telefonu. Nálada se ale zlepšuje s rostoucím počtem zapnutí displeje telefonu a s rostoucím množstvím času věnovanému pohybu. Výsledky ohledně vnitřního pocitu a energie nejsou statisticky signifikantní, možné důvody rozvádím v kapitole 6.

Čas u obrazovky (min)			
Kategorie	Nálada (průměr; p = 0,02)	Vnitřní pocit (průměr; p = 0,63)	Energie (průměr; p = 0,78)
>600	0,08	-0,05	-0,03
400-600	0,18	0,08	0,06
200-400	0,19	0,10	0,02
<200	0,26	0,17	0,13

Počet zapnutí displeje (n)			
Kategorie	Nálada (průměr; p < 0,001)	Vnitřní pocit (průměr; p = 0,4)	Energie (průměr; p = 0,93)
>150	0,43	0,24	0,05
100-150	0,28	0,07	-0,07
50-100	0,22	0,11	0,05
<50	0,21	0,16	0,14

Čas strávený pohybem (min)			
Kategorie	Nálada (průměr; p < 0,001)	Vnitřní pocit (průměr; p = 0,65)	Energie (průměr; p = 0,97)
>180	0,29	0,26	0,21
120-180	0,28	0,24	0,10
60-120	0,26	0,21	0,15
<60	0,19	0,08	0,02

Tabulka 5.1: Výsledné tabulky multivariačních analýz rozptylu

5.3.2 Individuální výsledky

Z individuálních výsledků je možné zjistit, jak časté a silné jsou pozitivní/negativní korelace u jednotlivých účastníků.

Tabulky 5.2 ukazuje výsledky lineární regrese mezi časem stráveným u telefonu, počtem zapnutí obrazovky u telefonu a pohybem předchozí den a náladou. Červená políčka značí silnou pozitivní korelaci a modrá políčka značí silnou negativní korelaci. Čím je políčko sytější, tím je korelace větší. Bílá políčka vyznačují nulovou míru korelace. Pro lepší představu o významu těchto dat přikládám dva grafy lineární regrese účastníka BA018 - výrazná pozitivní korelace u času u obrazovky (5.4) a počtem zapnutí displeje (5.5), graf účastníka BA006 - výrazná negativní korelace u času u obrazovky (5.6) a jeden graf účastníka BA013 - mix pozitivních a negativních korelací u pohybu (5.7).


Účastníka BA008 jsem musel vyloučit kvůli špatné kvalitě dat a účastník BA017 nemá výsledky v tabulkách u času stráveného u obrazovky a u počtu zapnutí displeje kvůli chybějícím datům.

Čas u obrazovky																					
Účastník	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
Nálada	0,03	1,64	0,3	-0,03	-0,21	-0,96	-0,35	NaN	0,02	-1,13	-0,27	-0,9	-0,08	0,78	-0,06	0,03	NaN	7,7	0,24	0,38	-0,52
Vnitřní pocit	0,08	0,06	-0,05	0,05	0,79	-1,72	-0,68	NaN	0,02	1,76	-0,29	-0,86	-0,41	-0,8	0,12	0	NaN	6,7	0,47	-0,06	-0,63
Energie	0,21	1,3	0,11	-0,14	-2,34	-2,42	-0,09	NaN	-0,06	0,1	-0,17	-0,51	0,27	0,68	-0,2	-0,04	NaN	6,66	-0,39	0,09	-0,61


Počet zapnutí displeje																					
Účastník	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
Nálada	0	-0,04	0,31	-0,06	-0,1	-0,1	-0,03	NaN	0,24	0,54	-0,09	-0,08	-0,07	0,02	0,2	0,03	NaN	1,86	-0,02	0,05	-0,12
Vnitřní pocit	-0,04	-0,19	0,15	-0,03	0,38	-0,13	-0,02	NaN	0,25	1,8	-0,23	-0,1	-1,09	0,14	0,43	0,05	NaN	1,5	0,06	-0,02	-0,25
Energie	-0,1	-0,26	0,05	-0,02	-0,13	-0,23	-0,09	NaN	0,15	1,28	-0,28	-0,09	-1,14	0,4	0,09	0,04	NaN	1,71	-0,05	-0,17	0,01

Pohyb																					
Účastník	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
Nálada	-0,43	-0,32	0	0,18	0,7	0	0,87	NaN	0,37	-0,62	0,01	0,31	0,62	0,31	1,63	0,7	0,82	0,2	-0,22	-0,16	-0,12
Vnitřní pocit	-0,32	0,46	0	0,25	0,77	0	-0,71	NaN	0,34	-0,66	0,19	-0,67	-0,71	1,09	2,81	0,75	0,29	0,73	-0,05	0,08	0,03
Energie	0,51	-0,2	0	0,11	0,43	0	0,14	NaN	0,38	-0,54	0,12	-0,07	-4,61	-0,32	3,22	0,95	1,45	1,14	-0,02	-1	0,13


Tabulka 5.2: Výsledky lineární regrese mezi časem stráveným na telefonu, počtem zapnutí obrazovky u telefonu a pohybem předchozí den a náladou, vnitřním pocitem a energií (*spád přímek vynásobený konstantou 10^3 u času u obrazovky a u pohybu a 10^2 u počtu zapnutí displeje pro lepší čitelnost*)



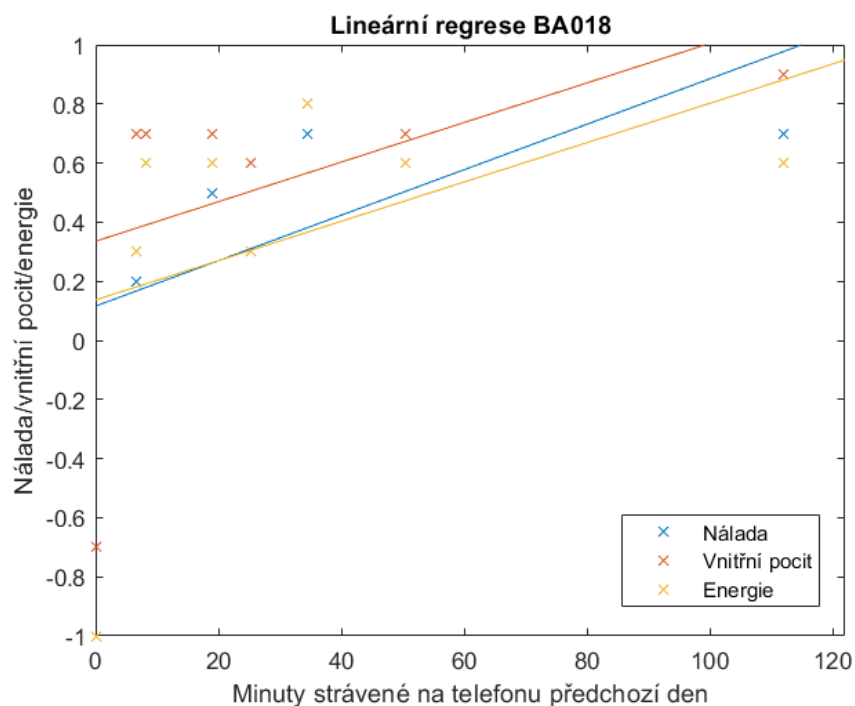
Obrázek 5.1: Graf lineární regrese mezi časem stráveným na telefonu a náladou, vnitřním pocitem a energií - odpovědi všech účastníků dohromady



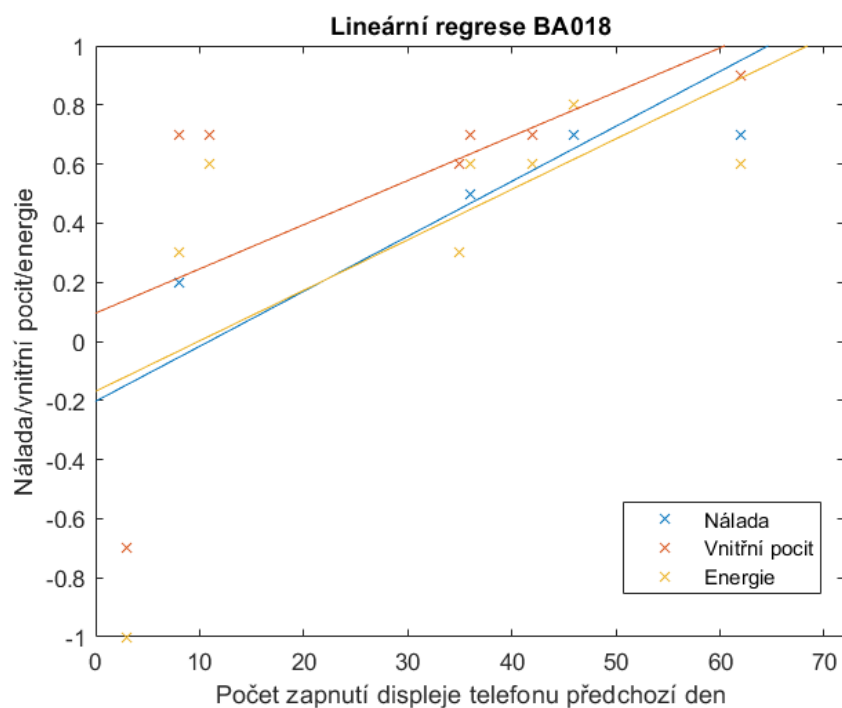
Obrázek 5.2: Graf lineární regrese mezi počtem zapnutí displeje telefonu a náladou, vnitřním pocitem a energií - odpovědi všech účastníků dohromady



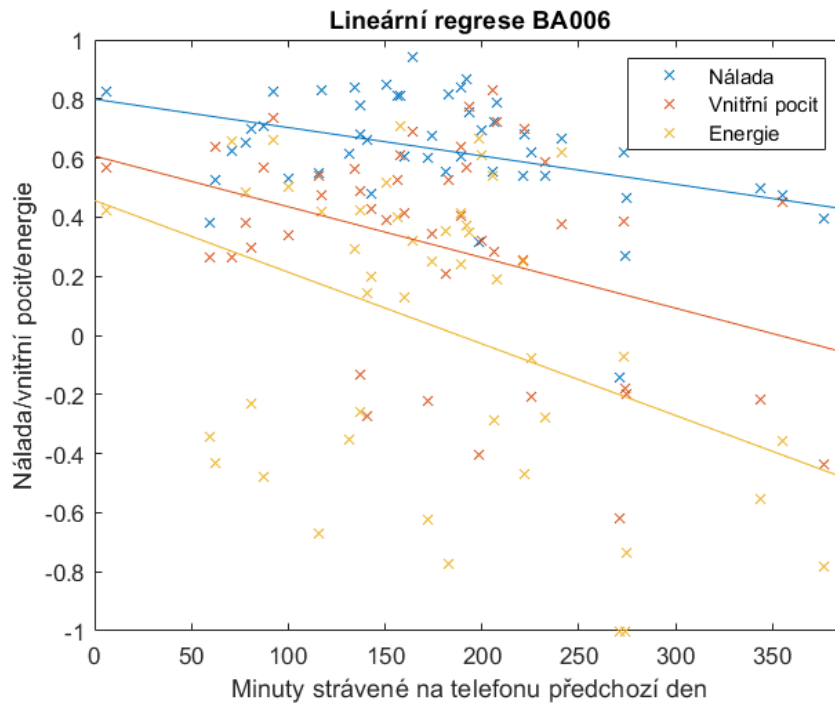
Obrázek 5.3: Graf lineární regrese mezi pohybem a náladou, vnitřním pocitem a energií - odpovědi všech účastníků dohromady



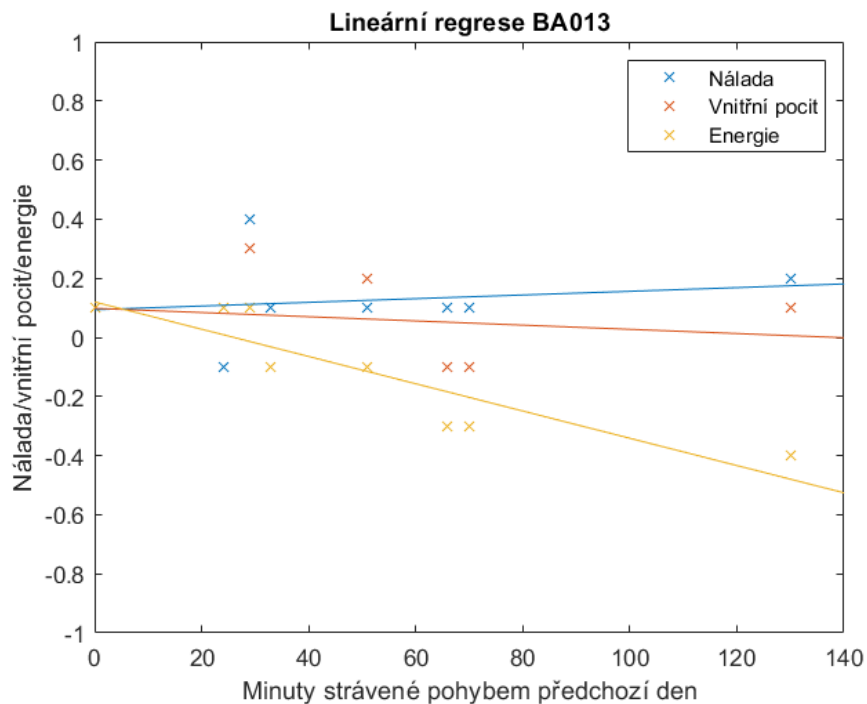
Obrázek 5.4: Graf lineární regrese mezi časem stráveným na telefonu a náladou, vnitřním pocitem a energií - účastník BA018



Obrázek 5.5: Graf lineární regrese mezi počtem zapnutí displeje telefonu a náladou, vnitřním pocitem a energií - účastník BA018



Obrázek 5.6: Graf lineární regrese mezi časem stráveným na telefonu a náladou, vnitřním pocitem a energií - účastník BA006



Obrázek 5.7: Graf lineární regrese mezi pohybem a náladou, vnitřním pocitem a energií - účastník BA013

Kapitola 6

Diskuze

6.1 Sběr dat

Vzhledem k tomu, že je digitální fenotypizace nový vědecký obor, existuje i několik problémů, se kterými se potýká. Jedná se hlavně o problémy při sběru dat a při motivaci uživatelů k vyplňování dotazníků, které slouží ke sběru aktivních dat. Dále je problém ve variabilitě senzorů v mobilních zařízeních, které se používají pro sběr pasivních dat. Chytré mobilní telefony nebyly stavěné na nepřetržitý sběr dat ze svých senzorů, a proto se vyskytují problémy především s životností baterie. Tomuto problému je ovšem možné předejít vhodným nastavením aplikace pro sběr dat, např. snížením frekvence sběru dat ze senzorů.

6.1.1 Aktivní data

Hlavní výzva, se kterou jsme se potýkali v naší pilotní studii (viz sekce 4), se sběrem aktivních dat byla neochota našich subjektů pravidelně vyplňovat dotazníky ohledně jejich životního stylu a nálady. Bohužel na operačním systému iOS nefungují v aplikaci Mindpax.me notifikace, a proto na vyplňování dobrovolníci často zapomínali. Problém jsme vyřešili tím způsobem, že jeden z členů našeho týmu pravidelně kontroloval získané odpovědi z dotazníků, a pokud zaznamenal chybějící odpověď, upozornil na to zodpovědnou osobu účastníka studie, která následně upozornila účastníka.

Několik účastníků mělo problém s vyplňováním dotazníku téměř každý den, proto jsme v průběhu studie aplikovali automatizované SMS notifikace těmto účastníkům, které byli zasílány jednou denně. Ze začátku byly tyto notifikace efektivní, postupem času je ale účastníci začali ignorovat. Nejúčinnější tedy zůstal přímý kontakt účastníka a zodpovědné osoby.

Kromě nízké míry vyplněnosti dotazníků nastává problém v subjektivitě některých otázek, především otázek týkajících se nálady. Tento problém je ale podle mého názoru neřešitelný, jelikož nálada je subjektivní vždy a neexistuje objektivní způsob jejího měření. I když není možné s velkou objektivitou měřit náladu, je možné měřit trendy v náladě a její změny, které jsou podle mého názoru důležitější, např. při evaluaci efektivnosti nějaké léčby. Důležité je podle mě to, že se pacient za poslední den/týden/měsíc cítí průměrně lépe

než dříve, což je něco, co je možné pomocí digitální fenotypizace určit.

■ 6.1.2 Pasivní data

V naší pilotní studii (viz sekce 4) byl problém v různorodosti mobilních zařízení, která pacienti používali. Kvalita (množství a rozlišení) pasivních dat se velice lišila mezi různými chytrými telefony. Jedno z řešení je při vstupu do studie všem účastníkům přidělit stejný, erární chytrý telefon. To samozřejmě zvyšuje náklady na studii a navíc vzniká nový problém. Účastníci pravděpodobně nebudou erární telefon používat stejným způsobem jako svůj osobní. Především, pokud budou tímto nuceni přejít na nový operační systém telefonu, se kterým nemají předchozí zkušenosti.

Další problém ve sběru pasivních dat je ve způsobu, jakým jsou data z telefonu získávána. Nainstalovaná aplikace pro sběr dat musí požádat operační systém telefonu o přístup k datům daného senzoru (např. GPS nebo akcelerometru) a následně data zaznamenat. Každý senzor má určitou frekvenci, se kterou je schopný data získávat. Pokud senzor využívá nějaká aplikace (např. navigace může využít GPS senzor), záleží na operačním systému telefonu, aby rozhodl, která aplikace bude mít k senzoru, a k jeho datům, v danou chvíli přístup. Toto může mít za následek snížené množství získaných dat.

Některé senzory také mohou při neustálém sběru dat spotřebovávat velké množství elektrické energie, a tím pádem snižovat stav nabití baterie. Kromě frustrace ze strany účastníků studie dojde také ke změně jejich chování - častější nabíjení telefonu, která může způsobit zkreslení sbíraných dat.

■ 6.1.3 Možné řešení výzev

Hlavní problémy s notifikacemi by bylo možné vyřešit plnou automatizací notifikací. Tento přístup by byl ze začátku časově náročný na implementaci, ale v průběhu studie by ušetřil velké množství času, především u studií s větším počtem účastníků. Tento systém by pravděpodobně musel frekvenci notifikací časem zvyšovat, jelikož jak jsme zjistili u našeho automatizovaného systému SMS notifikací, účastníci si postupem času na notifikace zvykají a začínají je ignorovat. Pokud by ovšem systém notifikoval příliš často, mohlo by to vést k frustraci ze strany účastníků, a tyto emoce by se mohli promítnout do odpovědí v dotazníku.

■ 6.1.4 Zkušenosti se sběrem dat - platforma Beiwe

Vzhledem k tomu, že jsme s kolegy v naší pilotní studii měli různorodá mobilní zařízení pro sběr dat, mohli jsme otestovat, jak se liší kvalita dat na různých operačních systémech. Zjistili jsme také, že se kvalita získaných dat liší nejenom podle operačního systému chytrého telefonu, ale také podle značky výrobce.

■ iOS

Nejlepší zkušenosti jsme měli s operačním systémem iOS, který byl v naší pilotní studii zastoupený zařízeními Apple iPhone 12, iPhone 11 Pro, iPhone 11, iPhone Xr a iPhone 8 Plus. Data získaná z mobilní aplikace *Beiwe2* byla robustní a bez výpadků. Aplikace na pozadí fungovala dobře a nebylo za potřeby s ní jakkoliv interagovat (např. nebyl zapotřebí restart aplikace nebo odhlášení a opětovné přihlášení do studie). Jelikož jsme aktivní fenotypizační data získávali pomocí jiné aplikace, otestovali jsme pouze kvalitu pasivních dat. S aktivními daty obvykle není problém, jelikož se jedná především o dotazníky, hlavní problémy nastávají u pasivních dat.

■ Android

U operačního systému Android jsme se potýkali s problémy při sběru pasivních dat. Operační systém Android byl v naší pilotní studii zastoupen zařízeními Samsung S8+, S+, Galaxy A52; Xiaomi Redmi Note 7, Redmi 7A, Mi A3; Realme 7 Pro; OnePlus 6. Některá zařízení (např. Samsung Galaxy A52) přestala posílat data na server jen několik desítek minut po přihlášení do studie, poté bylo nutné buď aplikaci přinstalovat, nebo se ze studie odhlásit a opět zpět přihlásit. Neustálá interakce s aplikací každých několik desítek minut samozřejmě není přijatelná, a proto jsme tato zařízení museli ze studie vyřadit.

Kromě problémů s některými zařízeními bylo z Androidu obecně získáno méně pasivních dat oproti iOS. Tuto zkušenost jsme měli ve všech z 18 týdnů, kdy naše pilotní studie probíhala. Několik dní před ukončením naší studie byla vydána nová aktualizace aplikace *Beiwe2* pro operační systém Android. Tuto novou verzi jsme mohli z časových důvodů testovat pouze několik dní, z těchto předběžných testů ovšem vyšlo najevo, že na některých zařízeních (např. Samsung S8+) byl problém s nedostatkem získaných dat vyřešen a množství některých typů dat (např. z akcelerometru) bylo ještě větší, než u zařízeních s operačním systémem iOS. Bylo by však vhodné tyto předběžné výsledky ověřit delším testováním, aby se lépe ověřila stabilita odesánní dat této aktualizace.

■ 6.1.5 Zkušenosti se sběrem dat - platforma LAMP

Platformu LAMP jsme otestovali na totožných zařízeních jako platformu *Beiwe*. V našem testování byly se sběrem dat na platformě LAMP oproti platformě *Beiwe* poměrně velké problémy, především s kvalitou a konzistencí dat. Jeden z hlavních důvodů je podle mého názoru absence cachování na platformě LAMP. Cachování umožňuje ukládat data do telefonu na pozdější použití. To se hodí například v případě, kdy dané zařízení není připojeno k internetu. Data se uloží na telefon a po připojení k internetu se odešlou na server. Platforma LAMP touto funkcionalitou bohužel nedisponuje, a proto jsme zaznamenali rozsáhlé výpadky dat.

Kromě výpadků dat jsme na platformě LAMP zaznamenali velkou spotřebu

baterie, na některých zařízeních v až řádu desítek procent za den. Tím se podle mého názoru stává platforma pro uživatele nepoužitelná, protože zkrácení životnosti baterie až na polovinu povede k frustraci ze strany uživatele a ke změně chování, která může ovlivnit získaná data. Jedním řešením tohoto problému by bylo změnit frekvenci získávání dat ze senzorů. Bohužel ani tuto funkcionalitu zatím platforma LAMP neobsahuje, proto tento problém zůstává momentálně bez řešení.

■ iOS

Dalo by se čekat, že data získaná ze zařízení od firmy Apple budou konzistentní mezi sebou. V našem testování tomu tak ovšem nebylo. Problémy s daty jsme zaznamenali u následujících senzorů:

Akcelerometr. U akcelerometru jsme zaznamenali velké rozdíly napříč různými zařízeními. Například u iPhone 8+ je frekvence získávání dat velice malá a u iPhone 11 Pro jsou rozsáhlé výpadky dat. Jediný model iPhone Xr sbíral data se srovnatelnou kvalitou jako na platformě Beiwu.

GPS. Kromě rozdílné frekvence získávání dat napříč zařízeními jsme se setkali s extenzivními výpadky dat. Tyto výpadky mohou být vysvětleny absencí připojení k internetu, především, pokud daný uživatel nemá mobilní internet.

Stav napájení. Podle mého názoru je nejzásadnější problém s daty ohledně stavu napájení. Data jsou naprosto nekonzistentní, a proto téměř nepoužitelná. Setkávali jsme se s daty, podle kterých uživatelé několikrát po sobě vypnuli nebo zapnuli displej. To ovšem není možné. Vypnutý displej již není možné znovu vypnout. Abych mohl displej vypnout, musím ho nejdříve zapnout a naopak.

■ Android

Podobně jako u operačního systému iOS jsme se u Androidu potýkali s výpadky a s nekonzistencí dat u následujících senzorů:

Akcelerometr. Robustní data z tohoto senzoru nám poskytl pouze Samsung S8+. U zařízení od značky Xiaomi byly výpadky tak rozsáhlé, že se jejich data stala nepoužitelnými.

GPS. Stejně problémy jako u iOS, frekvence se na zařízeních liší a značné výpadky dat kvůli absenci cachování učinily data nepoužitelnými.

Stav napájení. Podobně jako u iOS zapříčinila naprostá nekonzistence dat jejich nepoužitelnost.

■ 6.2 Srovnání platformem

■ 6.2.1 Úvod

Vzhledem k tomu, že jsme obě platformy pro sběr data nasadili a otestovali, získali jsme o nich rozsáhlé zkušenosti, od nasazení až po zpracování dat. Obě platformy jsou ale neustále ve vývoji, a je možné, že se v budoucnu budou chovat jinak. Prozatím jsme ale zjistili následující.

■ 6.2.2 Nasazení

■ Beiwe

Platformu Beiwe je možné nasadit přes AWS, není tedy zapotřebí vlastní infrastruktura/server. Cena za AWS se pohybuje zhruba okolo \$100 za 20 uživatelů za měsíc. Nasazení je také kvůli AWS jednodušší a lehce škálovatelné, stačí přenastavit parametry serveru na AWS a platforma je poté připravená pro více uživatelů.

■ LAMP

Platformu LAMP je možné nasadit na vlastní server, nejsou proto nutné žádné další poplatky. Nevýhoda je počáteční investice do serveru, pokud již nějaký není k dispozici. Nasazení na vlastní server je složitější než na AWS, protože každý server je jiný, s rozdílným prostředím, operačním systémem, apod. Škálování je také daleko složitější než na AWS, protože pro upgrade serveru je nutné zakoupit a nainstalovat nové komponenty.

■ 6.2.3 Správa

■ Beiwe

Správa přes AWS je jednoduchá, protože součástí jsou notifikace, které správce upozorní na možné problémy s chodem platformy. Uživatelské prostředí pro správu platformy je graficky poměrně jednoduché, přesto logicky rozložené a plně funkční. Získávání dat je jednoduché a uživatelsky přívětivé. Informace o příchozích datech jsou též přehledné. Ocenil bych ale možnost nastavení notifikace správce (např. emailem) na případný výpadek dat od jednotlivých zařízení.

■ LAMP

Správa je poměrně složitá, protože oproti AWS chybí notifikace o problémech s platformou. Uživatelské prostředí pro správu platformy je graficky hezky zpracované a obsahuje více funkcí oproti platformě Beiwe, bohužel obsahuje také softwarové chyby. Získávání dat je oproti Beiwe náročné, probíhá totiž

přes spustitelný skript, který musí správce správně nastavit/vytvořit. Informace o příchozích datech jsou přehlednější oproti platformě Beiwe, také ale chybí možnost nastavení notifikací.

■ 6.2.4 Data

■ Beiwe

Data z platformy Beiwe jsou z velké části robustní a neobsahují mnoho výpadků díky funkci cachování. Oproti platformě LAMP však Beiwe sbírá menší množství typů dat. Na druhou stranu Beiwe disponuje možností nastavit vzorkovací frekvenci sběru dat, která je poté unifikovaná na všech zařízeních (pokud to senzory zvládnou).

■ LAMP

Data získaná platformou LAMP obsahují velké množství výpadků a jsou nekonzistentní, především kvůli absenci funkce cachování. Platforma LAMP ale disponuje možností sběru velkého množství typů dat, i s možností sběru dat z externích senzorů. Bohužel není možné nastavit vzorkovací frekvenci sběru dat, což značně omezuje správce při vytváření studií.

■ 6.2.5 Mobilní aplikace

■ Beiwe

Mobilní aplikace s názvem *Beiwe2* je dostupná pro operační systémy iOS a Android. Aplikace byla v našem testování stabilní a nebylo zapotřebí s ní po přihlášení do studie nijak interagovat.

Uživatelské rozhraní aplikace je jednoduché, stejně jako získávání aktivních dat (vyplňování dotazníků).

Aplikace v naší pilotní studii spotřebovávala zhruba 5% baterie za den. To sice není zanedbatelné množství, ale je přijatelné co se týče ovlivnění chování uživatelů (častější nabíjení telefonu), které je minimální.

■ LAMP

Stejně jako aplikace *Beiwe2* je mobilní aplikace *mindLAMP 2* k dispozici pro operační systémy iOS a Android. Aplikace byla v našem testování poměrně nestabilní, především na iOS. Chyby v mobilní aplikaci způsobovaly odhlášení účastníků ze studie a přerušení spojení se serverem, které mělo za důsledek výpadky dat. Tyto výpadky dat bylo nutné vyřešit opětovným přihlášením do studie, což zvyšovalo míru frustrace ze strany uživatelů.

Uživatelské rozhraní aplikace je poměrně složité a na první pohled nepřehledné, podobně jako získávání aktivních dat.

Aplikace spotřebovává několik desítek procent baterie za den, což vede k nespokojenosti ze strany uživatelů a ke změně jejich chování (častější nabíjení),

to potom může ovlivnit sbíraná data. Vysoká spotřeba baterie je podle mého názoru způsobena příliš velkou vzorkovací frekvencí sběru dat, kterou ovšem momentálně není možné přenastavit.

6.3 Shrnutí

Dostupné platformy pro sběr digitálních fenotypizačních dat jsou zadarmo k dispozici k nasazení a použití. Jejich nasazení a správa mohou být komplikovanější, časem je ale možné se s nimi naučit efektivně pracovat. Vzhledem k tomu, že jsou obě platformy stále ve vývoji, je možné se setkat s určitými problémy při jejich použití, především u platformy LAMP. Věřím ale, že se funkcionality a stabilita obou platforem bude nadále vylepšovat, především s rozvojem a vyšší adopcí digitální fenotypizace jako takové.

Platforma Beiwe i platforma LAMP dovolují přístup k surovým datům, což vidím jako obrovskou výhodu pro vedoucí studie a pro vědecké pracovníky.

Závěrem je dobré říci, že se platformy poměrně silně liší co se týče kvality získaných dat, jejich konzistence, jednoduchosti nasazení a správy a v uživatelské přívětivosti. Ve všech ohledech je zatím platforma Beiwe lepší, i když se to s postupem času a s vývojem platformy LAMP může změnit.

6.4 Výsledky

U nálady bylo potvrzené signifikantní zlepšení při zvýšení fyzické aktivity a počtu zapnutí displeje telefonu a při snížení času stráveném na telefonu. Výsledky ohledně času stráveného na telefonu jsou srovnatelné s výsledky studie Khouji a kol. [KMT⁺19], kde byla nalezena asociace mezi časem stráveným u obrazovky (konkrétně počítače) a malým zvýšením rizika úzkosti a deprese u mladých lidí. Ze studie Fenga a kol. [FIZD⁺14] vyplývá, že zvýšená fyzická aktivita a snížený čas u obrazovky jsou asociovány s značně sníženým rizikem špatného spánku a deprese u čínských vysokoškoláků.

Výsledky u počtu zapnutí displeje telefonu je možné vysvětlit několika způsoby. Důvodem může být například to, že čím víc člověk zapíná obrazovku telefonu, tím na něm tráví méně času. Pokud displej např. zapne jednou a následně na telefonu stráví několik hodin, promítne se to podle mě do jeho nálady daleko více, než kdyby se vícekrát podíval na telefon a používal ho celkově méně.

Vysvětlení pro statisticky nevýznamné výsledky u vnitřního pocitu a u energie může být hned několik. Největší problém je podle mého názoru už v samotném návrhu studie. Po našich dobrovolnících jsme požadovali vyplnit dotazník, ale nebyla pevně stanovená doba pro vyplnění dotazníku. Proto jsem sledoval změnu v náladě účastníků až další den. Pokud bych sledoval vnitřní pocit a energii ten samý den, narazil bych často na problém, že někteří účastníci vyplňovali dotazník ráno, ještě předtím, než měli čas strávit na telefonu velké množství času (a tím si případně zkazit náladu) nebo si pořádně zacvičit (a tím si jí případně zlepšit).

Pro sledování změny nálady po pohybové aktivitě by bylo vhodné měřit náladu buď večer, a nebo přímo poc cvičení. Poté by byl podle mého názoru rozdíl nejvíce viditelný, jelikož hladina endorfinů v krvi po cvičení během několika hodin upadá [HS84].

Stejně tak u sledování vztahu mezi používáním telefonu a náladou by bylo vhodné měřit náladu účastníků až večer, jelikož spánek může podle mého názoru ovlivnit případnou negativní náladu (úzkost, únavu a radost) získanou intenzivním používáním telefonu.

Myslím si proto, že by úpravou studijního protokolu mohlo dojít k zvýšení signifikantnosti všech výsledků. Dále by podle mého názoru mohl pomoci větší vzorek uživatelů.



Kapitola 7

Závěr

Digitální fenotypizace je moderní, multidisciplinární vědecký obor, který má i přes své nedostatky spoustu využití. Digitální fenotypizace se začíná dostávat do běžných spotřebitelských produktů. Například americká firma Apple používá digitální fenotypizace ve svých chytrých hodinkách Apple Watch pro detekci arytmií, nebo v chytrých telefonech iPhone pro detekci pádů.

Pro sběr fenotypizačních dat existuje mnoho platforem, přičemž dvě platformy - LAMP a Beiwe - jsou volně dostupné, mají otevřený přístup k surovým datům a jejich nasazení je jednoduché. Z našeho testování vyplývá, že platforma Beiwe je v tuto chvíli více vyzpělá a poskytuje lepší kvalitu sbíraných dat.

Naše pilotní studie ukázala, že je možné úspěšné použití platformy Beiwe pro sběr digitálních fenotypizačních dat. Z našich dat vyplývá, že existuje statisticky signifikantní zlepšení nálady se zvýšením času stráveného pohybem předchozí den a se zvýšením počtu zapnutí displeje chytrého telefonu. Naopak při zvýšení času stráveném na telefonu předchozí den následuje statisticky signifikantní zhoršení nálady.

Příloha A

Literatura

- [AHS12] I. M. Anderson, P. M. Haddad, and J. Scott. Bipolar disorder. *BMJ*, 345(dec27 3):e8508–e8508, apr 2012.
- [Ber18] Hal Berghel. Malice domestic: The cambridge analytica dystopia. *Computer*, 51(5):84–89, 2018.
- [BTS⁺18] Ian Barnett, John Torous, Patrick Staples, Luis Sandoval, Matcheri Keshavan, and Jukka-Pekka Onnela. Relapse prediction in schizophrenia through digital phenotyping: a pilot study. *Neuropsychopharmacology*, 43(8):1660–1666, feb 2018.
- [CGH18] Carole Cadwalladr and Emma Graham-Harrison. Revealed: 50 million facebook profiles harvested for cambridge analytica in major data breach. *The guardian*, 17:22, 2018.
- [CZZ⁺17] Bokai Cao, Lei Zheng, Chenwei Zhang, Philip S. Yu, Andrea Piscitello, John Zulueta, Olu Ajilore, Kelly Ryan, and Alex D. Leow. DeepMood. In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, aug 2017.
- [EE03] S.Boyd Eaton and Stanley B. Eaton. An evolutionary perspective on human physical activity: implications for health. *Comparative Biochemistry and Physiology Part A: Molecular & Integrative Physiology*, 136(1):153–159, sep 2003.
- [EPMN⁺20] Ulrich W. Ebner-Priemer, Esther Mühlbauer, Andreas B. Neubauer, Holger Hill, Fabrice Beier, Philip S. Santangelo, Philipp Ritter, Nikolaus Kleindienst, Michael Bauer, Florian Schmiedek, and Emanuel Severus. Digital phenotyping: towards replicable findings with comprehensive assessments and integrative models in bipolar disorders. *International Journal of Bipolar Disorders*, 8(1), nov 2020.
- [FJBF⁺16] M Faurholt-Jepsen, J Busk, M Frost, M Vinberg, E M Christensen, O Winther, J E Bardram, and L V Kessing. Voice analysis as an objective state marker in bipolar disorder. *Translational Psychiatry*, 6(7):e856–e856, jul 2016.

- [FIZD⁺14] Qi Feng, Qing le Zhang, Yue Du, Yong ling Ye, and Qi qiang He. Associations of physical activity, screen time with depression, anxiety and sleep quality among chinese college freshmen. *PLoS ONE*, 9(6):e100914, jun 2014.
- [FSG⁺17] Daniel Freeman, Bryony Sheaves, Guy M Goodwin, Ly-Mee Yu, Alecia Nickless, Paul J Harrison, Richard Emsley, Annemarie I Luik, Russell G Foster, Vanashree Wadekar, Christopher Hinds, Andrew Gumley, Ray Jones, Stafford Lightman, Steve Jones, Richard Bentall, Peter Kinderman, Georgina Rowse, Traolach Brugha, Mark Blagrove, Alice M Gregory, Leanne Fleming, Elaine Walklet, Cris Glazebrook, E Bethan Davies, Chris Hollis, Gillian Haddock, Bev John, Mark Coulson, David Fowler, Katherine Pugh, John Cape, Peter Moseley, Gary Brown, Claire Hughes, Marc Obonsawin, Sian Coker, Edward Watkins, Matthias Schwannauer, Kenneth MacMahon, A Niroshan Siriwardena, and Colin A Espie. The effects of improving sleep on mental health (OASIS): a randomised controlled trial with mediation analysis. *The Lancet Psychiatry*, 4(10):749–758, oct 2017.
- [GOB⁺14] Agnes Gruenerbl, Venet Osmani, Gernot Bahle, Jose C. Carrasco, Stefan Oehler, Oscar Mayora, Christian Haring, and Paul Lukowicz. Using smart phone mobility traces for the diagnosis of depressive and manic episodes in bipolar patients. In *Proceedings of the 5th Augmented Human International Conference*. ACM, mar 2014.
- [GWH⁺13] Michael Gradisar, Amy R. Wolfson, Allison G. Harvey, Lauren Hale, Russell Rosenberg, and Charles A. Czeisler. The sleep and technology use of americans: Findings from the national sleep foundation's 2011 sleep in america poll. *Journal of Clinical Sleep Medicine*, 09(12):1291–1299, dec 2013.
- [HBKT20] Philip Henson, Ian Barnett, Matcheri Keshavan, and John Torous. Towards clinically actionable digital phenotyping targets in schizophrenia. *npj Schizophrenia*, 6(1), may 2020.
- [Hid12] Brandon H. Hidaka. Depression as a disease of modernity: Explanations for increasing prevalence. *Journal of Affective Disorders*, 140(3):205–214, nov 2012.
- [HS84] Victoria J. Harber and John R. Sutton. Endorphins and exercise. *Sports Medicine*, 1(2):154–171, 1984.
- [HVC19] Kit Huckvale, Svetha Venkatesh, and Helen Christensen. Toward clinical digital phenotyping: a timely opportunity to consider purpose, quality, and safety. *npj Digital Medicine*, 2(1), sep 2019.

- [JLC20] Dilip V. Jeste, Ellen E. Lee, and Stephanie Cacioppo. Battling the modern behavioral epidemic of loneliness. *JAMA Psychiatry*, 77(6):553, jun 2020.
- [KMT⁺19] Jasmine N. Khouja, Marcus R. Munafò, Kate Tilling, Nicola J. Wiles, Carol Joinson, Peter J. Etchells, Ann John, Fiona M. Hayes, Suzanne H. Gage, and Rosie P. Cornish. Is screen time associated with anxiety or depression in young people? results from a UK birth cohort. *BMC Public Health*, 19(1), jan 2019.
- [LSW⁺97] Y Lecrubier, DV Sheehan, E Weiller, P Amorim, I Bonora, K Harnett Sheehan, J Janavs, and GC Dunbar. The mini international neuropsychiatric interview (MINI). a short diagnostic structured interview: reliability and validity according to the CIDI. *European Psychiatry*, 12(5):224–231, 1997.
- [LZZ19] Yunji Liang, Xiaolong Zheng, and Daniel D. Zeng. A survey on big data-driven digital phenotyping of mental health. *Information Fusion*, 52:290–307, dec 2019.
- [Mat21] The Mathworks, Inc., Natick, Massachusetts. *MATLAB version 9.10.0.1710957 (R2021a) Update 4*, 2021.
- [MKNS17] S. C. Matz, M. Kosinski, G. Nave, and D. J. Stillwell. Psychological targeting as an effective approach to digital mass persuasion. *Proceedings of the National Academy of Sciences*, 114(48):12714–12719, nov 2017.
- [MMID⁺18] Nicole Martinez-Martin, Thomas R. Insel, Paul Dagum, Henry T. Greely, and Mildred K. Cho. Data mining for health: staking out the ethical territory of digital phenotyping. *npj Digital Medicine*, 1(1), dec 2018.
- [Nes09] Eric Nestler. *Molecular neuropharmacology : a foundation for clinical neuroscience*. McGraw-Hill Medical, New York, 2009.
- [OR16] Jukka-Pekka Onnela and Scott L Rauch. Harnessing smartphone-based digital phenotyping to enhance behavioral and mental health. *Neuropsychopharmacology*, 41(7):1691–1696, jan 2016.
- [OSM16] Michael J Owen, Akira Sawa, and Preben B Mortensen. Schizophrenia. *The Lancet*, 388(10039):86–97, jul 2016.
- [PBHR⁺17] Skyler Place, Danielle Blanch-Hartigan, Channah Rubin, Cristina Gorrostieta, Caroline Mead, John Kane, Brian P Marx, Joshua Feast, Thilo Deckersbach, Alex “Sandy” Pentland, Andrew Nierenberg, and Ali Azarbayejani. Behavioral indicators on a mobile sensing platform predict clinically validated psychiatric symptoms of mood and anxiety disorders. *Journal of Medical Internet Research*, 19(3):e75, mar 2017.

- [PMH⁺19] Marco V. Perez, Kenneth W. Mahaffey, Haley Hedlin, John S. Rumsfeld, Ariadna Garcia, Todd Ferris, Vidhya Balasubramanian, Andrea M. Russo, Amol Rajmane, Lauren Cheung, Grace Hung, Justin Lee, Peter Kowey, Nisha Talati, Divya Nag, Santosh E. Gummidi, Alexis Beatty, Mellanie True Hills, Sumbul Desai, Christopher B. Granger, Manisha Desai, and Mintu P. Turakhia. Large-scale assessment of a smartwatch to identify atrial fibrillation. *New England Journal of Medicine*, 381(20):1909–1917, nov 2019.
- [PTS⁺17] N. Palmius, A. Tsanas, K. E. A. Saunders, A. C. Bilderbeck, J. R. Geddes, G. M. Goodwin, and M. De Vos. Detecting bipolar depression from geographic location data. *IEEE Transactions on Biomedical Engineering*, 64(8):1761–1771, aug 2017.
- [Smi13] Aaron Smith. *Smartphone ownership-2013 update*, volume 12. Pew Research Center Washington, DC, 2013.
- [SVS16] David A. Scott, Bart Valley, and Brooke A. Simecka. Mental health concerns in the digital age. *International Journal of Mental Health and Addiction*, 15(3):604–613, jun 2016.
- [TKLO16] John Torous, Mathew V Kiang, Jeanette Lorme, and Jukka-Pekka Onnela. New tools for new research in psychiatry: A scalable and customizable platform to empower data driven smartphone research. *JMIR Mental Health*, 3(2):e16, may 2016.
- [TWB⁺19] John Torous, Hannah Wisniewski, Bruce Bird, Elizabeth Carpenter, Gary David, Eduardo Elejalde, Dan Fulford, Synthia Guimond, Ryan Hays, Philip Henson, Liza Hoffman, Chun Lim, Michael Menon, Valerie Noel, John Pearson, Randy Peterson, Ammu Susheela, Haley Troy, Aditya Vaidyam, Emma Weizenbaum, John A. Naslund, and Matcheri Keshavan. Creating a digital health smartphone app and digital phenotyping platform for mental health and diverse healthcare needs: an interdisciplinary and collaborative approach. *Journal of Technology in Behavioral Science*, 4(2):73–85, apr 2019.
- [ZPL⁺17] Jihui Zhang, Diana Paksarian, Femke Lamers, Ian B. Hickie, Jianping He, and Kathleen Ries Merikangas. Sleep patterns and mental health correlates in US adolescents. *The Journal of Pediatrics*, 182:137–143, mar 2017.
- [ZPR⁺18] John Zulueta, Andrea Piscitello, Mladen Rasic, Rebecca Easter, Pallavi Babu, Scott A Langenecker, Melvin McInnis, Olusola Ajilore, Peter C Nelson, Kelly Ryan, and Alex Leow. Predicting mood disturbance severity with mobile phone keystroke metadata: A BiAffect digital phenotyping study. *Journal of Medical Internet Research*, 20(7):e241, jul 2018.

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Sláma** Jméno: **Lukáš** Osobní číslo: **483749**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra počítačů**
Studijní program: **Otevřená informatika**
Specializace: **Software**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Zpracování a vizualizace aktigrafických a behaviorálních dat

Název bakalářské práce anglicky:

Behavioral and actigraphic data processing and visualization

Pokyny pro vypracování:

V oblasti duševního zdraví jsou aktigrafická data používána k odhadu duševního stavu pacienta. Cílem této práce je prozkoumat užitečnost údajů o chování, které lze ke stejnému účelu sbírat pasivně během používání různých elektronických zařízení.

- 1) Seznamte se s behaviorálním sběrem dat a s digitální fenotypizací.
- 2) Monitorujte 10 dobrovolníků po dobu alespoň 2 týdnů, použijte jednu z mobilních platforem pro sběr behaviorálních dat. Současně sbírejte i aktigrafická data dobrovolníků.
- 3) Proveďte analýzu a vizualizaci behaviorálních a aktigrafických dat.

Seznam doporučené literatury:

1. Gideon John - MOOD STATE PREDICTION FROM SPEECH OF VARYING ACOUSTIC QUALITY FOR INDIVIDUALS WITH BIPOLAR DISORDER - Proc IEEE Int Conf Acoust Speech Signal Process, 2016
2. Soheil Khorram - Recognition of Depression in Bipolar Disorder: Leveraging Cohort and Person-Specific Knowledge – Interspeech, 2016
3. Zahi N Karam - ECOLOGICALLY VALID LONG-TERM MOOD MONITORING OF INDIVIDUALS WITH BIPOLAR DISORDER USING SPEECH - Proc IEEE Int Conf Acoust Speech Signal Process, 2014
4. John Torous - Realizing the potential of mobile mental health: new methods for new data in psychiatry - Curr Psychiatry Rep, 2015

Jméno a pracoviště vedoucí(ho) bakalářské práce:

doc. Ing. Daniel Novák, Ph.D., Analýza a interpretace biomedicínských dat FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **04.03.2021**

Termín odevzdání bakalářské práce: **13.08.2021**

Platnost zadání bakalářské práce: **19.02.2023**

doc. Ing. Daniel Novák, Ph.D.
podpis vedoucí(ho) práce

podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací.
Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta