

Využití telemedicíny v arytmologii

Veronika Bulková^{1,2}, Jakub Pindor¹, Filip Plešinger^{1,3}, Ivo Višcora³, Martin Fiala^{1,2}

¹MDT – Mezinárodní centrum pro telemedicínu, Medical Data Transfer, Brno

²Centrum kardiovaskulární péče, Neuron Medical, Brno

³Ústav přístrojové techniky AV ČR, Brno

Telemedicínu lze definovat jako zdravotnickou službu, která zejména v oblasti diagnostiky využívá technologie současného vzdáleného přenosu velkého objemu dat od velkého množství pacientů. Tato data jsou následně centrálně zpracována a poskytována velkému množství zdravotnických subjektů, které si telemedicínskou službu po své pacienty zadávají na národní i mezinárodní úrovni. V arytmologii je telemedicína využívána zejména při dlouhodobém monitorování EKG v diagnostice arytmií a ke kontrole léčby pomocí externích záznamníků, chytrých hodinek a implantabilních přístrojů. Zpracování obrovského objemu telemedicínských dat stále více využívá umělou inteligenci.

Klíčová slova: telemedicína, arytmologie, monitorování EKG, umělá inteligence.

Telemedicine in arrhythmology

Telemedicine can be defined as a health care service that, specifically in the field of diagnostics, employs remote transfer of a large volume of data from a large number of subjects at the same time. This data is subsequently processed on a central basis and returned to a large number of health care providers by whom the service was ordered on national or international level. In arrhythmology, telemedicine is used particularly in long-term ECG monitoring to diagnose arrhythmias and check out treatment outcome via external recorders, smart watch, and implantable devices. To facilitate analysis of large telemedicine data volume, artificial intelligence is being increasingly exploited.

Key words: telemedicine, arrhythmology, ECG monitoring, artificial intelligence.

Úvod

Arytmologie využívá možnosti telemedicíny více než dvacet let. Indikace se rozvíjely od 24hodinové monitorace EKG, přes kontroly implantabilních kardiostimulátorů/defibrilátorů až ke komplexnímu kontinuálnímu sledování pacientů s chronickým srdečním selháním.

Nejčastěji využívanou telemedicínskou metodou je dlouhodobá EKG monitorace.

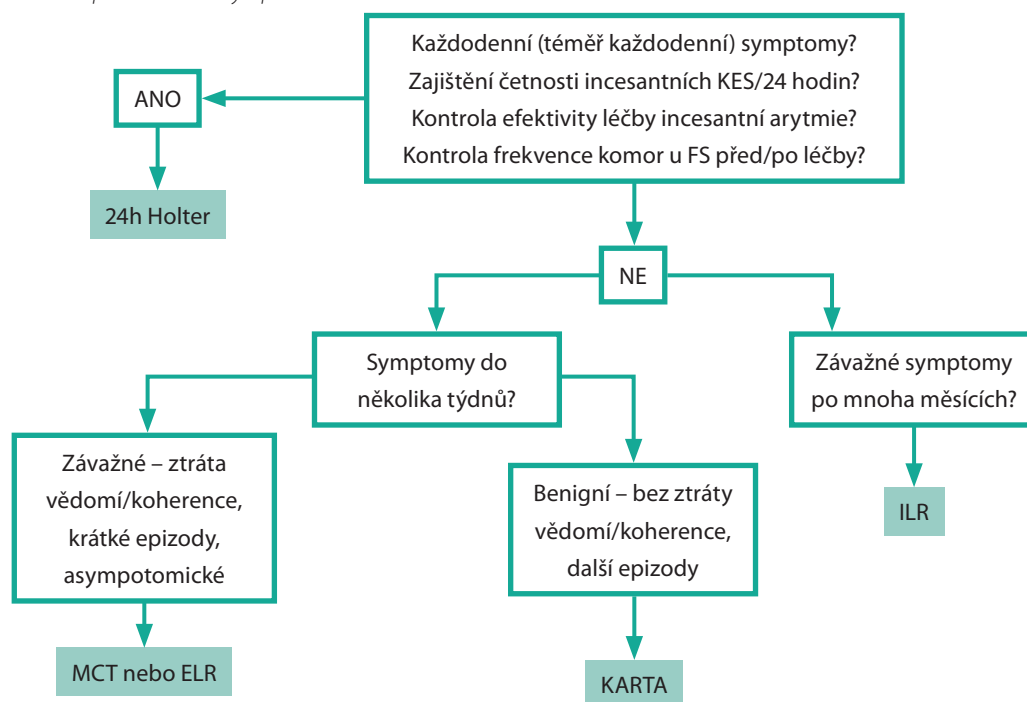
Základní charakteristikou telemedicíny je vzdálený zisk a přenos medicínských dat pacientů, většinou transtelefonní cestou, aniž by pacient musel navštívit zdravotnické zařízení.

Telemedicínské centrum je charakterizováno tím, že disponuje veškerými technologiemi pro zajištění vzdáleného přenosu a zpracování dat pro velké množství subjektů současně na národní, respektive mezinárodní úrovni. Díky telemedicině a organizaci příslušných činností

v telemedicínském centru odpadá nutnost nákupu drahých technologií do každé jednotlivé ambulance. Nároky na technické zabezpečení jsou značené, od SIM karet do EKG zařízení, přes zajištění datového přenosu transtelefonní či jinou cestou, až po datová centra, či náklady na hardwarovou připravenost a kybernetickou bezpečnost.

Dlouhodobá monitorace EKG

Dokumentace EKG křivky je základní diagnostickou metodou poruch srdečního rytmu. Dlouhodobější monitorace EKG se používá především k odhalení arytmií, které se nepodařilo zachytit pomocí standardního 12svodového EKG záznamu nebo 24–48hodinového EKG Holteru. Dokumentace arytmií na EKG je předpokladem další cílené léčby. Absence arytmií na EKG v době výskytu příznaků je také diagnosticky cenná, neboť arytmií v zásadě vylučuje a umožňuje nasměrovat

Obr. 1. Výběr typu monitorace EKG podle četnosti symptomů

další vyšetřování jiným směrem. Nejdůležitější v denní praxi lékaře je rozhodnutí, jakou metodu monitorace EKG – především na základě četnosti obtíží – zvolí (Obr. 1). Mezinárodní telemedicínské centrum MDT (Medical Data Transfer) funguje od roku 2008 a ročně sleduje více než 35 000 pacientů v ČR, SR a dalších zemích EU. Specializuje se především na hodnocení dlouhodobých EKG záznamů a sledování pacientů se srdečním selháním. Telemedicínské centrum poskytuje 24hodinovou technickou podporu pacientům a jejich rodinným příslušníkům.

Transtelefonní ambulantní telemetrie – MCT, epizodní záznamníky EKG, EKG Holter

Nejvyužívanější metodou je tzv. transtelefonní ambulantní telemetrie, která umožňuje přenos kontinuálních EKG záznamů pomocí datového přenosu na server telemedicínského centra. Tím, že je k dispozici úplný EKG záznam, je možné se vyjádřit k četnosti jednotlivých arytmií a procentuálně vyčíslit jejich časovou zátěž. Velkou výhodou je přesné označení symptomů v časové korelaci s EKG záznamem. Tyto záznamníky umožňují registraci jedno- až tří-svodového EKG, což je většinou indikací diagnosticky zcela dostačující. S výhodou se tato monitorace využívá u pacientů vyšetřovaných pro kryptogenní CMP s neurodeficitem a u starších pacientů. Nevýhodou zůstávají velké časové nároky na zpracování úplného EKG záznamu, avšak s využitím umělé inteligence (AI) je možné čas zpracování zkrátit. Využití AI nyní umožňuje takto v telemedicínském centru sledovat on-line zhruba 1300 pacientů denně.

Dále se využívají epizodní záznamníky EKG a 7–30denní (off-line) EKG Holtery, kterými je vyšetřováno přibližně dalších 500 pacientů denně. Průměrná délka monitorace činí 14 ± 9 dní. Distribuce jednotlivých indikací k monitoraci EKG je následující: 30 % pacientů s palpitacemi, 8 % pacientů s (pre)synkopou, 15 % pacientů ke kontrole výsledku katetrizační ablace, 34 % pacientů po kryptogenní CMP/TIA a 13 % pacientů

s jinou indikací. Celková diagnostická výtěžnost činí 32% záchyt dosud nedokumentovaných arytmií. Naopak 27 % představují nálezy, kdy má pacient při palpitacích či jiných symptomech zachycen sinusový rytmus nebo ojedinělé klinicky benigní extrasystoly.

„Chytré“ hodinky s měřením EKG a SpO₂

Chytré hodinky mohou představovat budoucnost pro obor arytmologie. Jednoduchost a dostupnost umožňuje rychlejší diagnostiku pacientů s palpitacemi či asymptomatickou fibrilací síní. Snižování ceny těchto zařízení do budoucna umožní tento typ monitorace zařadit jako základní screening.

Chytré hodinky využívají princip měření EKG založený na dvou elektrodách, z nichž jedna je umístěna na rubu hodinek na ruce a druhá je na boku hodinek (nebo v řemínku) a přikládá se na ni prst. Měření trvá 30 vteřin a získaný EKG signál se vyhodnotí přímo v hodinkách. Algoritmus umí rozpoznat sinusový rytmus a fibrilaci síní. Na základě vlastních zkušeností MDT, kdy pojištěnci OZP zasílají své záznamy k analýze, je důležité upozornit na fakt, že algoritmus umí posoudit pouze fibrilaci síní. Jakmile hodinky např. naměří hodnotu tepové frekvence pod 50/min nebo 150/min, majitel obdrží upozornění, že má kontaktovat lékaře. Při síňových či komorových extrasystolách bývá opět výsledek EKG nejednoznačný. Do budoucna s velkým počtem zapojených pacientů může potenciálně nastat problém s tím, že lékaři budou zahlcení různými záznamy ve svých emailových schránkách. Na základě 3letých zkušeností, ať už z telemedicínského centra či z arytmologických ambulancí, jsme se rozhodli vytvořit další pomocnou aplikaci, která by zlepšila identifikaci dalších nálezů. Ve spolupráci s UPT jsme vytvořili mobilní aplikaci pro odeslání nejednoznačného záznamu s využitím AI. Pomocí aplikace v mobilním telefonu je možné odeslat EKG záznam k posouzení do telemedicínského centra či ošetřujícímu lékaři, takže všechny EKG pacienta jsou shromážděny ve složce pacienta a dostupné kdykoliv lékaři či pacientovi (Obr. 2).

Kontrola EKG křivek lékařem či biomedicínským technikem zůstává důležitá, protože z praxe je evidentní, že zhruba 20 % EKG záznamů, které ke zhodnocení obdrží telemedicínské centrum, obsahuje nějakou algoritmem nerozpoznanou abnormalitu srdečního rytmu.

Dálkové monitorování srdečních implantátů založené na aplikaci v chytrém telefonu

Další nejvyužívanější metodou telemedicíny v kardiologii je dálkové monitorování implantabilních přístrojů. Dálkové monitorování umožňuje arytmiologickým centřům přístup k diagnostickým datům pacientů a dálkové načtení paměti implantabilních přístrojů. Časný přístup k datům z trvalých kardiostimulátorů a implantabilních kardioverter-defibrilátorů (TKS, ICD) usnadňuje monitorování stavu pacienta a umožňuje optimální nastavení léčby arytmií, kontrolu kardiální kompenzace a kontrolu technického stavu implantátu. Mezi perspektivní sledované parametry lze zahrnout:

- Pravidelné sledování poklesu kapacity baterie, čímž lze odstranit četné ambulantní kontroly před dosažením doporučené výměny implantátů.
- Časné zachycení malfunkce implantátu, které může eliminovat život ohrožující stavy, jako jsou poškození stimulační elektrody u dependentního pacienta nebo poškození defibrilační elektrody vedoucí k neadekvátní terapii.
- Prevence progresu onemocnění, např. detekce asymptomatických benigních, ale i maligních arytmií může vést k časnějšímu klinickému řešení.

Spolehlivost a efektivita dálkového monitorace byla prokázána v klinické studii TRUST (1). Studie CONNECT se zaměřila především na klinické přínosy – zkrácení reakce na klinickou událost z 22 na 4,6 dne ($p < 0,001$) a zkrácení doby hospitalizace pro kardiovaskulární příčinu ze 4,0 na 3,3 dne ($p < 0,002$) (2). Opodstatnění dálkové monitorace byla také ověřena ve studii COMPAS v rámci detekce asymptomatických paroxysmů fibrilace síní, jako častou příčinu kardioembolizační cévní mozkové příhody (3). Ve skupině pacientů se srdečním selháním (NYHA II-III) s implantovaným ICD studie IN-TIME prokázala snížení celkové mortality 3,4 % oproti kontrolní skupině 8,7 % ($p < 0,004$) (4).

Za celou dobu si svým vývojem prošly jak implantabilní přístroje, tak technologie jejich sledování. Modernizace komunikačních technologií otevřela novou dimenzi dálkového sledování implantabilních přístrojů, která přináší spolehlivost, efektivitu a ekonomický přínos. V České republice dlouhodobě nabízí služby dálkového monitorování přední výrobci implantabilních přístrojů (Abbott, Medtronic, Biotronik, Boston Scientific). Základem byla původně patientská jednotka zprostředkovávající zabezpečený přenos dat z implantátu na zabezpečený server (5). Dnešní koncept spoléhá na technickou gramotnost populace, cenovou dostupnost moderních technologií a nové Bluetooth komunikační rozhraní v implantabilních přístrojích. Patientské jednotky jsou nahrazeny mobilní bránou, kterou představují chytré telefony vybavené kompatibilními aplikacemi, které jsou i volně stažitelné např. z Google play store či Apple store. Pro komunikaci s implantabilním přístrojem se využívá protokol Bluetooth Low Energy, používaný pro pomalejší pře-

nosy s nižším objemem přenášených dat a umožňující dvoutřetinovou spotřebu energie oproti původnímu řešení komunikace (6).

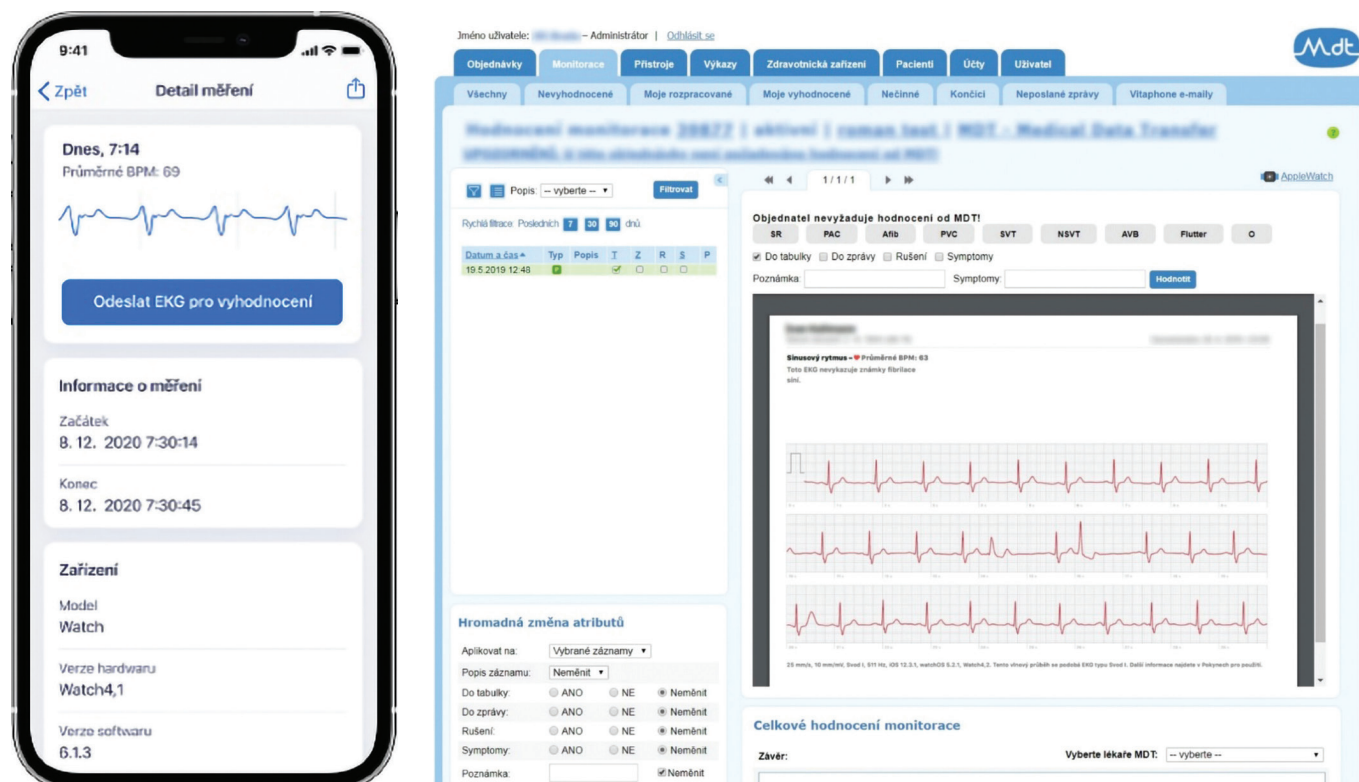
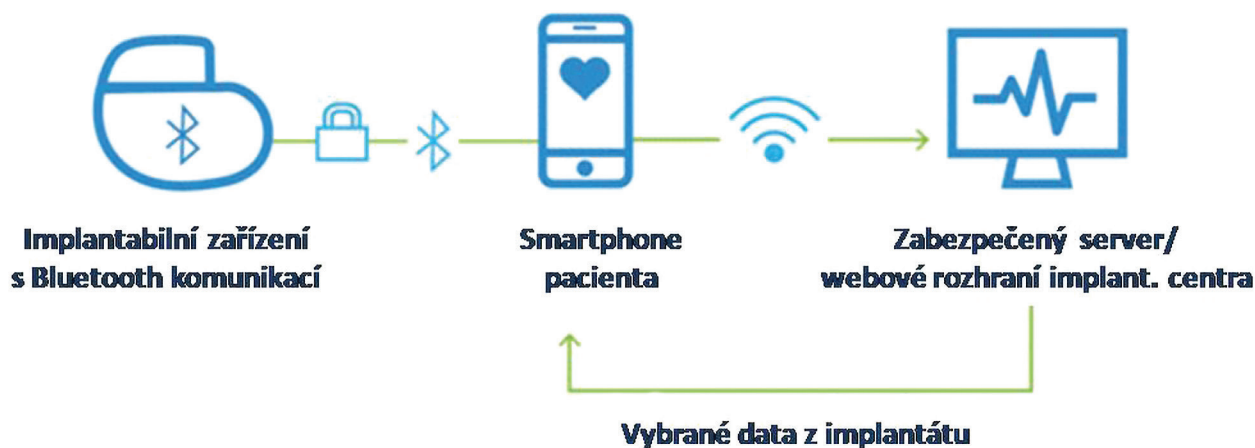
Implantabilní přístroje jsou přímo propojeny prostřednictvím aplikace s „chytrým“ zařízením (smartphone, tablet) pacienta (Obr. 3). Patientské zařízení pak přenáší data z implantabilních přístrojů prostřednictvím mobilní sítě (příp. wifi sítě) na zabezpečený server, odkud jsou data distribuována arytmiologickým či telemedicínským centřům. Vybrané informace jsou následně zaslány zpět do zařízení pacienta, kde jsou k dispozici pacientovi jako zpětná vazba (informace o úspěšnosti přenosu, varování a upozornění). Tento systém vyžaduje otevření aplikace na pozadí pacientova telefonu, aby mohla nepřetržitě probíhat komunikace, umožňující pasivní přenos dat v naplánovaných intervalech, respektive při detekci závažné události. Plán přenosů řídí implantační centrum prostřednictvím sítě serveru poskytovatele (výrobce implantabilního zařízení). Pokud má být proveden plánovaný přenos a pacient nemá otevřenou aplikaci, jsou automaticky odesílána upozornění pacientovi k aktivaci aplikace. Samozřejmostí aplikace je možnost aktivního přenosu, vyžadující interakci pacienta. Pacient může zaznamenat svůj zdravotní stav a označit případné příznaky (významné u implantabilních záznamníků). V aplikaci v závislosti na výrobci mohou být k dispozici přídatné funkce jako vzdělávací rozcestníky a také základní údaje o pacientově implantátu, které mohou sloužit jako jeho identifikační karta (Obr. 4) (7).

Kombinace funkcí obslužné aplikace ve spojení s přenositelným telefonem tvoří novou generaci monitorování implantabilních přístrojů, která by mohla zlepšit adherenci pacienta ke své léčbě, což povede k snížení počtů rehospitalizací a nákladů na zdravotní péči (8). Právě průzkum, jak pacienti rozumí používání aplikace a jaký je potenciál ovlivnění jejich léčby, byl náplní prospektivní mezinárodní multicentrické studie BlueSync Field Evaluation. Hodnocení ukázalo, že úspěšnost plánovaných přenosů pomocí aplikace v pacientově telefonu nebo tabletu byla 94,6 % a předčila tradiční přenosy bez závislosti na věku, typu zařízení a pohlaví (9).

Využití umělé inteligence (AI) v arytmologii

Úskalím telemedicíny může být extrémní navyšování objemu dat a informací, které nemůže lékař sledovat na denní bázi. Dnešní doba však přináší nové pokročilé metody analýzy dat, přičemž jednou z nich je umělá inteligence. Umělá inteligence je obecné označení pro metody, které napodobují lidské uvažování. Umělou inteligencí se rozumí především strojové učení, resp. jeho podskupina – hluboké učení.

Strojové učení dokáže z expertem připravených příznaků vytvořit tzv. výpočtový model (různé složitý vzorec nebo program). K jeho sestavení jsou potřeba vstupy (zde příznaky, např. směrodatná odchylka RR intervalů, korelace po sobě jdoucích T-Q oblastí (10) atd.) a výstupy (např. informace, že je v dané oblasti fibrilace síní či nikoliv). Pokud existuje dostatečné množství takových párů vstup-výstup, lze model tzv. trénovat. Dostatečné množství dat se odvíjí od použité metody a počtu příznaků. Zatímco např. logistická regrese může být spolehlivá u vyšších desítek případů, tak např. na Random Forest modely je již potřeba stovek nebo lépe tisíců případů. Pro představu – v soutěži PhysioNet/CinC Challenge 2017 (11) (úloha – klasifikace záznamu do

Obr. 2. Mobilní aplikace pro zaslání EKG z chytrých hodinek do telemedicínského centra**Obr. 3.** Dálková monitorace implantabilního zařízení prostřednictvím mobilní aplikace

Použití technologie Bluetooth Low Energy, s minimalizací spotřeby baterie implantátu



Zvýšené zabezpečení dat šifrováním

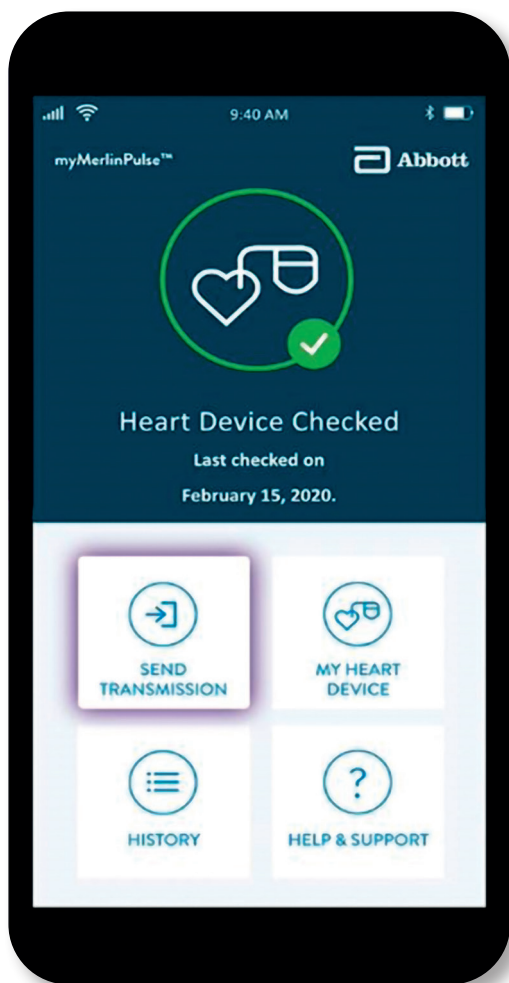


Doživotní možnost upgradu Pacientského zařízení



Automatická upozornění informují pacienty o stavu přenosu

Obr. 4. Aplikace firmy Abbott v telefonu pro komunikaci s implantabilním zařízením



jedné ze tříd fibrilace síní, sinusový rytmus, jiná arytmie, nečitelný signál) bylo k dispozici přes 8500 záznamů. Nejvýkonnější metody z této soutěže využívaly expertní příznaky (8), nebo je kombinovaly s hlubokým učením (12, 13).

Hluboké učení již nepotřebuje expertem připravené příznaky, nachází si je samo, obvykle pomocí tzv. konvolučních vrstev. Tyto konvoluční vrstvy jsou schopny se naučit tvary a společně s dalšími druhy vrstev bývají zřetězeny za sebou či vedle sebe a to různými způsoby. Výsledná architektura, pokud se osvědčí, je užívána pod specifickým názvem (ResNet, UNet (14) atd.). Do sítí hlubokého učení tedy vstupuje surový nebo nějak

transformovaný (filtrovaný) signál. V oblasti telemedicíny to je obvykle blok EKG signálu (v řádu jednotek či desítek sekund) a pro natrénování modelu je opět potřeba znát výstupy pro tyto EKG bloky. Dostatečné počty případů jsou u hlubokého učení výrazně vyšší a jedná se nejméně o desítky/stovky tisíc případů. Pro představu, v soutěži PhysioNet/CinC Challenge 2021 (15) (detekce 25 patologií v EKG) bylo pro trénink k dispozici přibližně 100 000 případů. Nejvýkonnější metoda (16) využívala soubor pěti modelů typu ResNet, které rozhodovaly o patologii pomocí konsensu. Typické pro metody hlubokého učení je, že v těchto kvantech dat stroj dokáže najít souvislosti, které zůstávají pro člověka skryté, nebo běžným výpočtem nedosažitelné. Pokud jsou správně navrženy, naučené a ověřené, dosahují lepší výkonnosti než běžné metody strojového učení. Např. klasifikátor a detektor QRS komplexů naučený na více než 700 000 případech se dokáže vypořádat s nepříjemnými případy typickými pro signály z telemedicíny, jako na obrázku 5.


Kolik tyto výhody stojí

Co tedy musíme „zaplatit“ za komfort, který nám sítě hlubokého učení mohou dodat? Ekonomicky nejdražší je lidský čas, potřebný ke sběru a označení potřebného množství dat. K naučení složitých modelů je třeba také silný výpočetní výkon, ale to už se dá řešit lokálními či cloudovými akcelerátory. Při samotném použití již natrénovaných modelů (tzv. inferenci) jsou požadavky na výkon výrazně menší a vystačíme si s běžným hardware. Např. systém J.O.S.E.P.H., který vyvíjí MDT, s. r. o., s ÚPT AV ČR, v. v. i., ve společném projektu, dosahuje výpočetní kapacity kolem 800 hodin EKG záznamů za 1 hodinu skutečného času při společném běhu na třech lokálních počítačích (dva z toho navíc virtualizované). Samotný proces tréninku (učení) modelu QRS detektoru pro systém J.O.S.E.P.H. trvá na specializovaném serveru s osmi grafickými kartami (ÚPT AV ČR) přibližně 10 hodin. Inferenci již naučených modelů je možné dnes provádět i na mobilních zařízeních, případně přímo na vybraných mikročipech.

Kde jsou rizika umělé inteligence

Modely strojového učení dělají pouze to, k čemu jsou naučeny během procesu učení. Technicky se jedná velké množství o výpočetní vztahů, které i specialista musí od určité komplexity akceptovat jako tzv. black-box. Pro člověka totiž není reálné udělat jasný závěr např. z desítek milionů koeficientů, které si síť v průběhu svého učení zafixovala, i když určité postupy aspoň pro nějaký vhled do „uvažování“ sítí existují, a to

Obr. 5. Závěr běhu supraventrikulární tachykardie s přechodem do sinusového rytmu, zaznamenaný pomocí nositelné elektroniky (zde hodinky Apple Watch 6). Vertikály označují QRS komplexy detekované autonomním systémem J.O.S.E.P.H. ze společného projektu MDT, s.r.o., a ÚPT AV ČR. Detekční model byl trénován na datech z jiného akvizičního hardware



především pro obrazová data (17, 18). Zde se tedy nejedná o riziko spíše jako o nepříjemný fakt. Skutečným rizikem jsou chyby, které se odvíjí od návrhu celého procesu učení a dat – tedy od člověka. Prakticky nejjednodušší chybou může být přetřénování, ke kterému může dojít například tak, že je využita neadekvátně komplexní metoda vzhledem k objemu trénovacích dat. Nebo že model není testován a trénován na datech od jiných pacientů. Následkem bude např. model s teoretickou výkonností F1 0.98 v reálné situaci dosahovat výkonnosti F1 0.75 (F1 je tzv. F-skóre, což je běžná metrika pro úlohy strojového učení v nevyvážených datasetech).

K čemu AI v telemedicině tedy může pomoci

Využití AI a především hlubokého učení je efektivní, protože umožňuje výpočetně zpracovávat (modelovat) velmi variabilní jevy. AI v telemedicině využíváme již od zmíněné detekce patologií či klasifikace

QRS komplexů po např. třídění velkého množství dat, kdy metody shlukování mohou rozčlenit nějakou patologii na předem neznámé podskupiny. Analogicky jsme takový postup využili např. pro analýzu, zda se v množině desítek tisíc záznamů označených jako signál poškozený rušením neobjevují podskupiny ukazující na specifické poruchy hardware. A neméně zajímavé mohou být i regresní modely, které na výstupu neukážou pravděpodobnost určitého stavu (je fibrilace síní/ není fibrilace síní), ale spojitou veličinu – například odhad arteriálního krevního tlaku přímo z EKG (19). Záleží jen na tom, zda máme k úloze dostatek dat, zda se podaří daný model trénovat a jak zodpovědně provedeme jeho objektivní a nejlépe multicentrické testování.

Práce byla částečně podpořena projektem České technologické agentury (TAČR) č. FW01010305

LITERATURA

1. Varma N. Rationale and design of a prospective study of the efficacy of a remote monitoring system used in implantable cardioverter defibrillator follow-up: the Lumos-T Reduces Routine Office Device Follow-Up Study (TRUST) study. *Am Heart J.* 2007;154:1029-1034.
2. Crossley GH, Boyle A, Vitense H et al. The CONNECT (Clinical Evaluation of Remote Notification to Reduce Time to Clinical Decision) trial: The value of wireless remote monitoring with automatic clinician alerts. *J Am Coll Cardiol.* 2011;57:1181-1189.
3. Mabo P, Victor F, Bazin P et al. A randomized trial of long-term remote monitoring of pacemaker recipients (The COMPAS trial). *Eur Heart J.* 2012;33:1105-1111.
4. Saxon LA, Gates DL, Gilliam PA et al. Long-term outcome after ICD and CRT implantation and influence of remote device follow-up: the ALTITUDE survival study. *Circulation.* 2010;122:2359-2367.
5. Hutten H, Schreier G, Kastner P. Cardiac telemonitoring using pacemakers and the Internet. *Medical & Biological Engineering & Computing.* 1999;35 (Suppl 2):1295
6. Roberts PR, El Refai MH. The Use of App-based Follow-up of Cardiac Implantable Electronic Devices. *Card Fail Rev.* 2020;6:e03.
7. Tilz, Roland R et al. „Real-world Adoption of Smartphone-based Remote Monitoring Using the ConfirmRx™ Insertable Cardiac Monitor.“ *The Journal of innovations in cardiac rhythm management* vol. 12:84613-4620.
8. Varma N, Piccini JP, Snell J, Fischer A, Dalal N, Mittal S. Relation ship between Level of Adherence to Automatic Wireless Remote Monitoring and Survival in Pacemaker and Defibrillator Patients. *J Am Coll Cardiol.* June 23, 2015;65(24):2601-2610.
9. Tarakji KG, Vives CA, Patel AS, Fagan DH, Sims JJ, Varma N. Success of pacemaker remote monitoring using app-based technology: Does patient age matter? *Pacing Clin Electrophysiol.* 2018 Oct; 41(10):1329-1335.
10. Plesinger F, Andrla P, Viscor I, Bulkova V, Jurak P. „Shape Analysis of Consecutive Beats May Help in the Automated Detection of Atrial Fibrillation,“ in *Computing in Cardiology*, 2018.
11. Clifford GD et al. AF Classification from a Short Single Lead ECG Recording: The Physionet Computing in Cardiology Challenge 2017. In *Comput Cardiol. (Rennes IEEE)*, 2017:1-4.
12. Datta S et al. Identifying Normal, AF and other Abnormal ECG Rhythms using a Cascaded Binary Classifier. In *Comput Cardiol (Rennes IEEE).* 2017;44:1-4.
13. Hong S et al. ENCASE: an ENsemble CIASsifiEr for ECG Classification Using Expert Features and Deep Neural Networks. In *Comput Cardiol (Rennes IEEE)*, 2017, vol. 44, 1-4.
14. Teijeiro T, García CA, Castro D, Félix P. Arrhythmia Classification from the Abductive Interpretation of Short Single-Lead ECG Records. In *Comput Cardiol (Rennes IEEE)*, 2017, vol. 44, 1-4.
15. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics).* 2015;9351:234-241.
16. Reyna MA et al. Will Two Do? Varying Dimensions in Electrocardiography: The Physionet/Computing in Cardiology Challenge 2021.
17. Nejedlý P, Ivora A, Viscor I, Halamek J, Jurak P, Plesinger F. Utilization of Residual CNN-GRU With Attention Mechanism for Classification of 12-lead ECG.
18. Vaswani A et al. Attention is all you need. In *Advances in Neural Information Processing Systems.* 2017; Decem. 2017:5999-6009.
19. Baltruschat IM, Nickisch H, Grass M, Knopp T, Saalbach A. Comparison of Deep Learning Approaches for Multi-Label Chest X-Ray Classification. *Sci. Reports.* 2019; Apr. 2019:1-10.