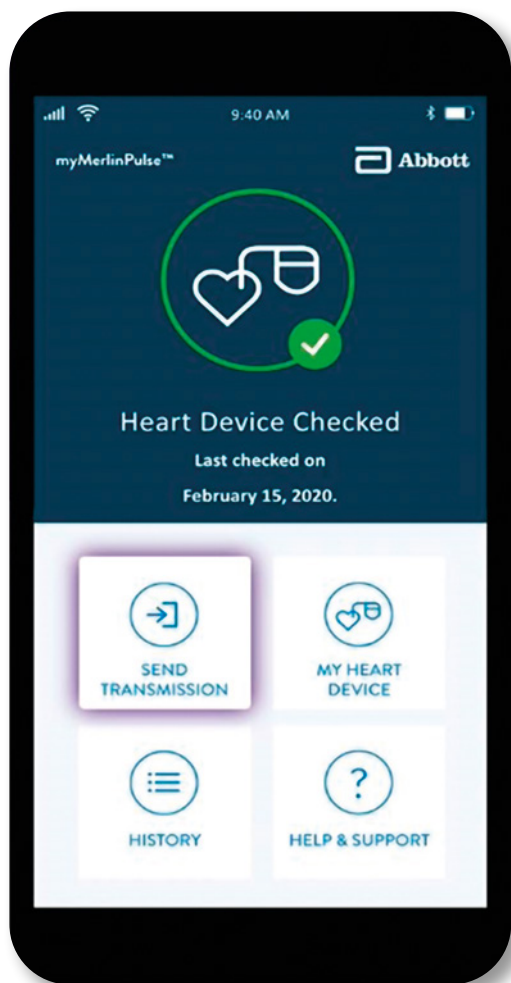


Obr. 4. Aplikace firmy Abbott v telefonu pro komunikaci s implantabilním zařízením



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 100000 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 700000 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

