

## Distribuovaná inteligence a její aplikace pro monitoring diabetického pacienta

Jakub Klimeš<sup>1</sup>

### 1 Úvod

Nemoc diabetes mellitus se projevuje zhoršenou, nebo zcela ztracenou schopností slinivky pacienta regulovat koncentraci glukózy v krvi. Především pacienti z druhé zmíněné skupiny jsou tak nuceni si injektováním inzulinu regulovat glukózu sami, případně za pomoci inzulinové pumpy, často spojené se systémem pro kontinuální měření koncentrace glukózy (CGM).

Inzulinová pumpa je kromě samotné pumpy tvořena také výpočetní jednotkou a je možné ji tedy obdařit určitou inteligencí ve formě modelu lidského metabolismu, díky čemuž by teoreticky dokázala koncentraci glukózy v krvi předvídat a inzulin dávkovat zcela automaticky. Aby toho bylo ale možné docílit, je potřeba model identifikovat, tj. přiřadit jeho parametrům konkrétní hodnoty, zpravidla odlišné pro různé pacienty.

Toho bychom chtěli dokázat ideálně z dat nasbíraných během běžného života pacienta a v důledku zcela nahradit lidskou slinivku.

### 2 Východiska

Identifikace není triviální proces – analytický způsob řešení neznáme, a je proto nutné využít numerické postupy. Metaheuristiky jsou skupinou takových optimalizačních algoritmů, které sice zpravidla nedokáží nalézt optimální řešení, na druhou stranu poskytnuté řešení dosahuje dostatečných kvalit a zároveň je získáno v přijatelném čase.

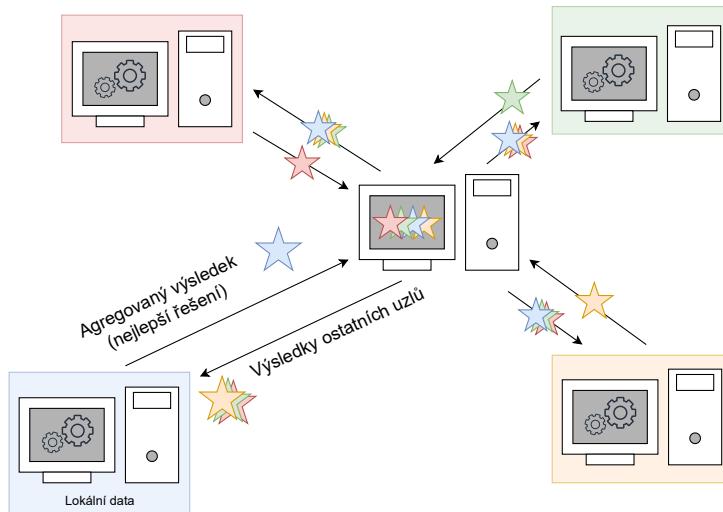
Cenou jsou ale netriviální výpočetní nároky. Obecně lze metaheuristiky přirovnat spíše k inteligentnějšímu prohledávání stavového prostoru hrubou silou, což znevýhodňuje zařízení se slabším výpočetním výkonem – jakými jsou právě inzulinové pumpy, zamýšlené pro co nejdélší výdrž na baterii, než rychlosť výpočtu.

Identifikace modelu na inzulinové pumpě by měla některé výhody. V první řadě by nebylo potřeba nikam přenášet citlivá medicínská data potřebná pro optimalizaci. Důsledkem je snažší ochrana dat proti zneužití a úspora přenosových linek. Druhou výhodou je využití hardwaru, který pacient s velkou pravděpodobností tak jako tak vlastní a není plně využitý.

Nedostatky inzulinových pump z hlediska výpočetního výkonu by šlo negovat jejich spojením do výpočetního clusteru, ve kterém by docházelo k výměně agregovaných dat o postupu optimalizace na jednotlivých pumpách. Tím by byla zachována žádoucí vlastnost trvalé lokality dat a zároveň by tím mohlo být dosaženo zvýšení kvality nalezených řešení, jelikož lze očekávat větší množství spolupracujících pump a tedy i větší společný výpočetní výkon. Přestože každý pacient a tedy optimalizační problém je jiný, stále se jedná o shodný metaproblém a přenesené znalosti mezi pumpami nemusí ztratit na smysluplnosti.

Tento přístup, typicky navíc s koordinujícím centrálním prvkem, je v literatuře (např.

<sup>1</sup> student navazujícího studijního programu Distribuované výpočetní systémy, specializace Výpočetní technika, e-mail: klimesja@students.zcu.cz



**Obrázek 1:** Grafické naznačení konceptu federated learning.

Kairouz et al. (2021)) označován pojmem *federated learning*. Graficky princip zachycuje obrázek 1.

### 3 Implementace a výsledky

V rámci práce byly implementovány dva optimalizační algoritmy ve formě solverů, určených pro framework SmartCGMS: genetická evoluce a particle swarm optimization. Tyto solver v určitých chvílích komunikují s paralelně běžicími instancemi v Internetu s cílem výměny dosavadních nejlepších parametrů. Dále byl implementován server sloužící pro udržování adres participujících solevrů, takže není potřeba provádět objevování sítě.

Navržené solverby byly otestovány na Raspberry Pi Zero, představující platformu vlastnostmi blízkou inzulinovým pumpám. Výsledky naznačují, že výměna parametrů během optimalizace může přinést zlepšení kvality výsledků. Výstupy algoritmu particle swarm byly přitom obecně lepší, než v případě genetické evoluce. Část naměřených výsledků právě pro particle swarm zachycuje tabulka 1.

	Průměrná chyba [%]		
	Bez sdílení, stejný pacient	Se sdílením, stejný pacient	Se sdílením, různí pacienti
Pumpa 1	19,94	12,48	12,75
Pumpa 2	19,94	12,48	39,59
Pumpa 3	-	12,48	15,25
Pumpa 4	-	12,48	35,93

**Tabulka 1:** Vyňatek z naměřených výsledků algoritmu particle swarm.

### Literatura

Kairouz, Peter et al. (2021) Advances and Open Problems in Federated Learning. Dostupné z arXiv: 1912.04977.

Koutny, T., Ubl, M. (2020), SmartCGMS as a Testbed for a Blood-Glucose Level Prediction and/or Control Challenge with (an FDA-Accited) Diabetic Patient Simulation, *Procedia Computer Science*, Volume 177, pp. 354-362