

Detekce infarktu myokardu s využitím vektorkardiografických záznamů

Jaroslav Vondrak¹, Marek Penhaker¹, František Jurek²

¹ Fakulta elektrotechniky a informatiky, Katedra kybernetiky a biomedicínského inženýrství, VSB-Technická univerzita Ostrava, Ostrava 708 33, Czech Republic

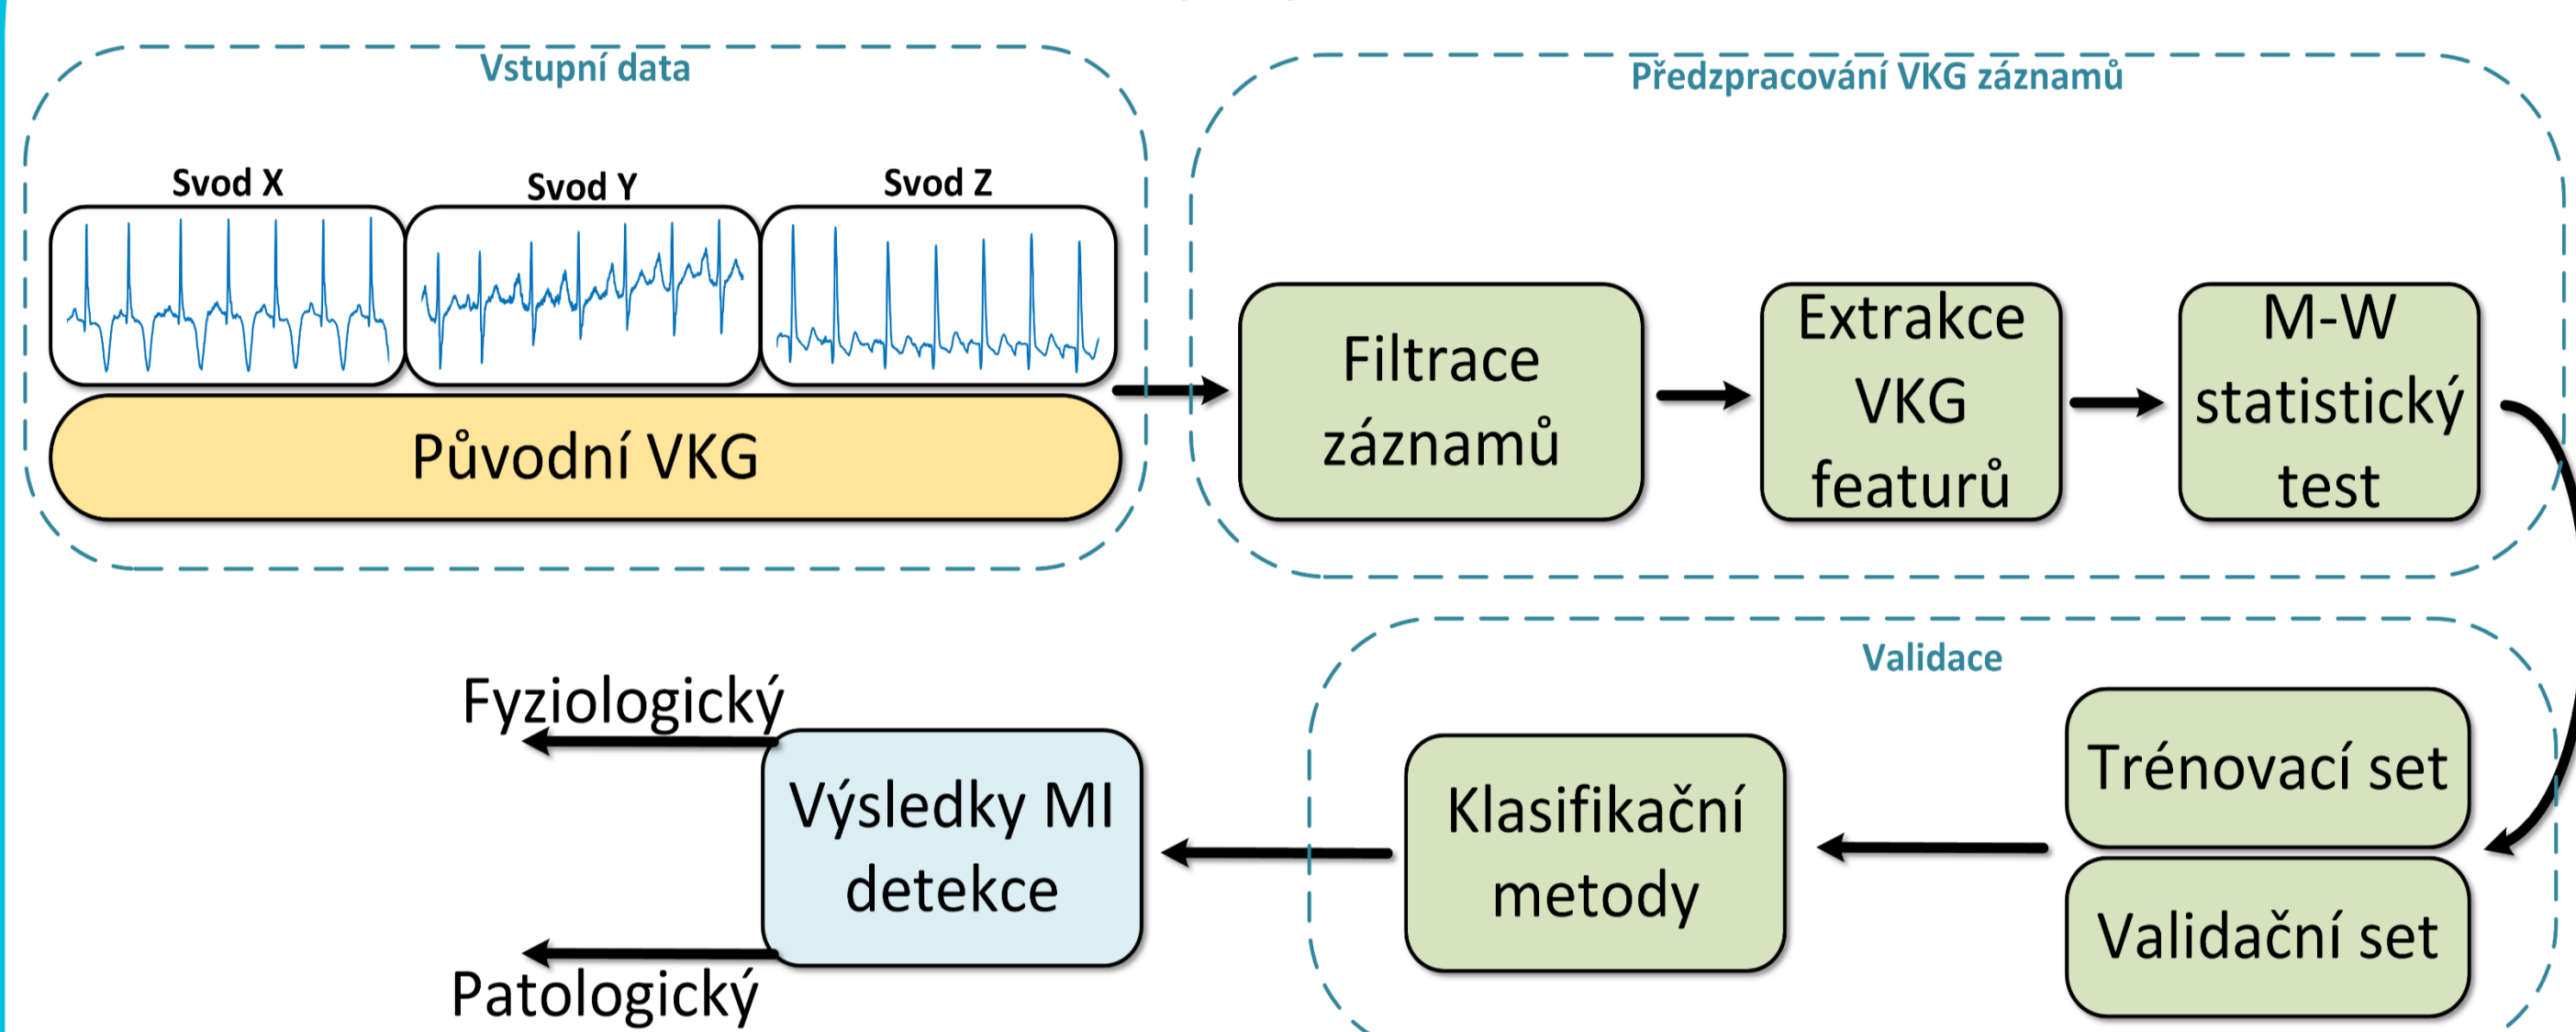
² Kardiologická ordinace, Městská nemocnice Ostrava, Ostrava 728 80, Czech Republic

Zpracování elektrické aktivity srdce


- Vektorkardiografie (VKG) je alternativní formou 12 svodového EKG pro měření elektrické aktivity srdce.
- Měření probíhá ve třech navzájem kolmých anatomických rovinách a to: frontální, horizontální a sagitální.
- V určitých případech dosahuje Vektorkardiografie vyšší sensitivity v porovnání s konvenčním EKG, např. v diagnostice zvětšení síní, hypertrofie pravé komory či detekce posteriorního infarktu myokardu.
- V posledních letech je pozornost věnována do oblasti automatizovaného zpracování EKG a VKG záznamů pro podporu diagnostiky.
- Cílem této studie bylo vyhodnotit skutečnou informativní hodnotu VKG záznamů v časové oblasti v rámci automatizovaného zpracování pro detekci infarktových stavů.

Použité metody

- Použito celkem 368 infarktových a 80 fyziologických VKG záznamů z databáze PTB physionet.



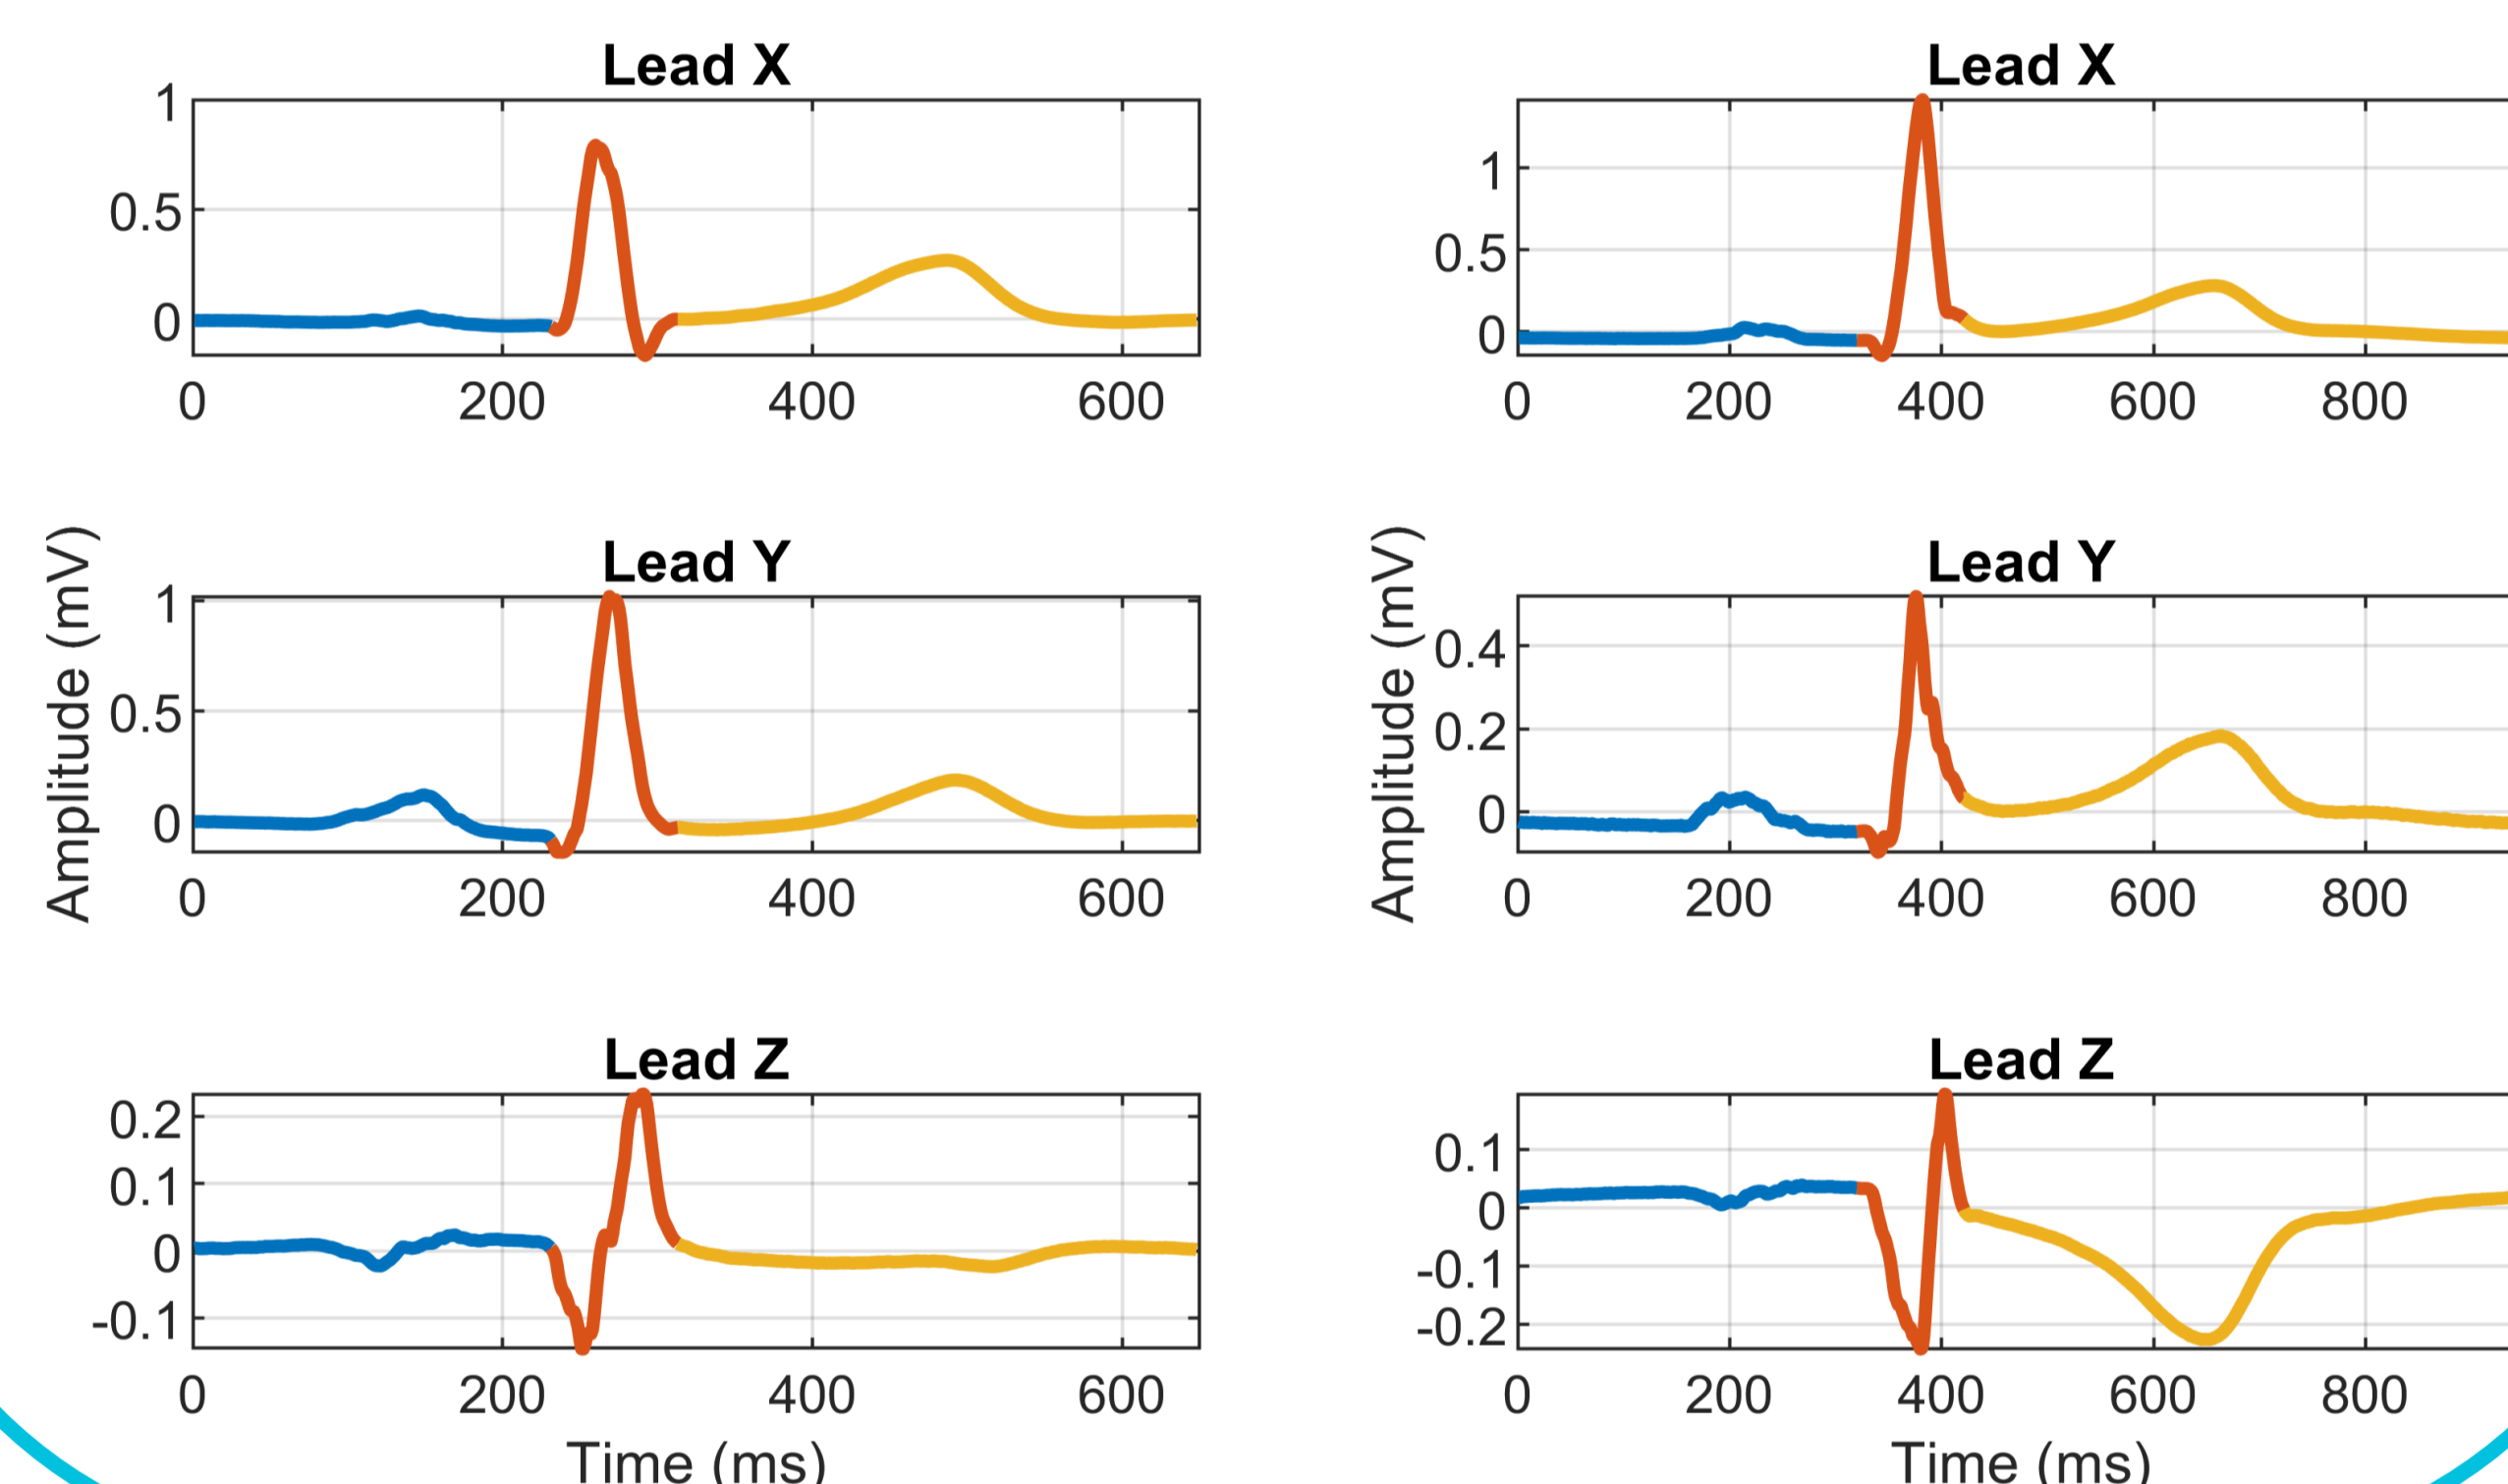
- Morfologické změny VKG smyček analyzovány pomocí VKG příznaků.
- Extrahováno celkem 12 VKG příznaků, z toho 7 založených na morfologii smyčky QRS a 5 založených na morfologii smyčky T:
 - Plocha QRS, max rychlost QRS, mean rychlost QRS, std rychlost QRS, vzdálenost od těžiště QRS, max vektor QRS, délka QRS
 - Plocha T, max rychlost T, mean rychlost T, std rychlost T, max vektor T



- Každý z příznaků byl testován o ověření výpovědní hodnoty s využitím statistického testování – využití Manova-Whitneyova statistického testu.
- Vybrány VKG příznaky dle p-hodnoty, které vykazují statisticky významnou separaci.

Metody strojového učení pro detekci infarktu myokardu

- Analyzováno celkem pět různých metod strojového učení
 - K-nejbližších sousedů (KNN)
 - Metoda podpurných vektorů (SVM)
 - Rozhodovací stromy (DT)
 - Diskriminační analýza (LDA)
 - Neuronové sítě (ANN)
- Metody byly analyzovány s experimentálně nastavenými hyperparametry s využitím 10-foldové křížové validace.



Dosažené výsledky a budoucí směry

- Z testovaných metod strojového učení dosahuje nej přesnějších výsledků metoda SVM.

Klasifikační metoda	Sensitivita (%)	Specifická (%)	Přesnost (%)	PPV (%)	NPV (%)
KNN	92.98	74.10	88.90	92.87	73.12
SVM	94.80	75.30	90.80	93.72	76.93
DT	92.46	77.54	89.30	94.82	71.88
DA	94.58	69.75	89.80	92.38	76.24
ANN	92.45	74.00	88.50	93.54	71.46

- Použitá metodika může být přínosná v rámci automatizovaného zpracování záznamů pro podporu diagnostiky.
- Možnost využití také na transformované VKG záznamy.

Závěr

- Výsledky získané v této práci mohou být užitečné pro podporu diagnostiky v rámci automatizované detekce infarktu myokardu.
- Analyzované VKG příznaky v této práci lze rozšířit o extrakci dalších jak v časové, tak frekvenční oblasti (fourier, wavelet transformace), které mohou být přínosné pro zlepšení přesnosti detekce.
- V klinické praxi jsou využívány záznamy 12 svodového EKG, které lze pomocí transformačních metod převést na odvozené VKG svody.
- Možnost využití navržené metodiky na transformované VKG záznamy z 12 svodového EKG.

- Tato práce vznikla za finanční podpory Evropské unie v rámci projektu LERCO CZ.10.03.01/00/22_003/0000003 prostřednictvím Operačního programu spravedlivá transformace.
- Práce a příspěvky byly podpořeny projektem SV4500X21/2101, SP2021/112 'Biomedical Engineering systems XVII'.