

Rozpoznávání ischemické choroby srdeční pomocí skrytých Markovových modelů

Jana Bardoňová, Ivo Provazník

Ústav biomedicínského inženýrství, Fakulta elektrotechniky a informatiky, VUT v Brně

Souhrn:


Při ischemické chorobě srdeční je možné vysledovat změny v průběhu diskretizovaného EKG signálu. V našem případě sledujeme změny mezi vlnami Q a J. Proces rozpoznávání mezi ischemickým a normálním průběhem je realizován pomocí Markovových modelů s diskrétním rozložením. Parametry těchto modelů jsou zjištěny na základě naměřených dat. Pro popis signálu je použita vlnková transformace. Celý proces rozpoznávání se skládá z těchto po sobě jdoucích procesů: určení průběhu mezi Q a J vlnou, vlnková transformace pro popis signálů, výpočet kódové knihy, vektorové kvantizace, učení Markovových modelů a rozpoznávání.

Úvod:

Skryté Markovovy modely lze použít pro rozpoznávání řeči a zpracování biologických signálů. Jsou to matematické modely, které umožňují pracovat s průběhy signálů s různou délkou trvání. Pro rozpoznávání časových signálů je tato vlastnost velmi cenná. V tomto případě jde o rozpoznávání ischemického průběhu EKG. Jsou sledovány pouze změny mezi vlnami Q a J. Byly využity reálné průběhy EKG naměřené ve třech ortogonálních směrech (x,y,z).

Vlnková transformace:

Běžně používaným nástrojem časově frekvenční analýzy je krátkodobá Fourierova transformace (STFT). STFT je aplikovaná na oknem omezenou část signálu, přičemž se okno posouvá v čase. Konstantní šířka okna způsobí malé časové rozlišení v různých frekvenčních pásmech. Tato nevýhoda může být odstraněna pomocí vlnkové transformace (WT). WT používá základní funkci dvou parametrů, časový posun a časovou dilataci. Jsou počítány projekce každé dilatační bázové funkce (vlnky). WT je definována jako korelace signálu $x(t)$ a vlnky $g^*[(t-\tau)/\lambda]$, kde τ je časový posun, λ je časová dilatace, a $*$ reprezentuje komplexní sdruženost. Je použita komplexní vlnka typu Kingsbury. Výsledkem této transformace je časově – frekvenční spektrum, frekvence jsou v rozsahu 0.01-250 Hz pro vzorkovací frekvenci 500 Hz. Frekvenční spektrum pro konkrétní čas je zvoleno jako charakteristický vektor. Tyto vektory jsou použity pro popis stavů Markovova modelu, který je popsán dále.



obr. 1 (a) analyzovaný QRS-komplex, (b) časově - frekvenční spektrum, komplexní vlnka typu Kingsbury.

Návrh kódové knihy a vektorová kvantizace:

Vektory příznaků popisující EKG signál, jsou definovány jako hodnoty frekvenčního spektra, které je určeno pro daný časový okamžik pomocí vlnkové transformace. Ze souboru všech možných vektorů příznaků je vytvořena kódová kniha. Ve skutečnosti je takových charakteristických vektorů nekonečně mnoho, ale pro jednodušší práci s Markovovými modely je jejich počet omezen.

Pro práci s modely převádíme průběhy signálů na posloupnosti indexů pomocí vektorové kvantizace. Tímto procesem postupně všechny vektory příznaků popisujících daný signál nahradíme


indexy (pořadí) vektorů z kódové knihy podle určitého kritéria. V tomto případě je kritériem minimum vzdáleností daného vektoru od všech kódových vektorů.

Skryté Markovovy modely:

Skrytý markovův model (HMM) je pravděpodobnostní model popisující posloupnost stavů, který je tvořen uzly a přechody mezi nimi. Vnitřní vazby mezi uzly jsou popsány pomocí matice pravděpodobností přechodů N . Přechody mezi jednotlivými uzly vyjadřují, s jakými pravděpodobnostmi se může model z určitého uzlu dostat do jiných uzlů. Hodnoty jednotlivých uzlů jsou popsány pomocí matice pravděpodobností generovaných vzorů M . Každý uzel může nabývat hodnoty jednoho ze stavů popsaných dříve definovanou kódovou knihou. Tedy počet možných stavů jednoho uzlu je dán počtem kódových vektorů. Počáteční stav modelu je určen vektorem pravděpodobností počátečních stavů π . Ve většině případů je počátkem první stav. Markovův model s diskrétním rozložením je matematicky popsán těmito soubory parametrů: $\lambda = (N, M, \pi)$.

V obecném Markovově modelu jsou uvažovány všechny možné přechody mezi uzly. Pro časové průběhy signálu se používají tzv. levo-pravé modely (obr. 2), které uvažují přechody z jednoho uzlu do téhož uzlu nebo do kteréhokoliv následujícího uzlu. Vychází se z časové plynulosti a proto se nepředpokládají zpětné vazby v modelech.

Pro všechny typy průběhů, které se budou při rozpoznávání používat, se vytvoří příslušné modely. Pro neznámý průběh pak budou určeny pravděpodobnosti, že daný průběh O byl generován všemi naučenými modely. Neznámý průběh je určen maximální pravděpodobností. Pro stanovení pravděpodobnosti $P(O|\lambda)$, že neznámý průběh O byl generován modelem λ můžeme využít rekursivního výpočtu odpředu nebo odzadu generované posloupnosti. Také se využívá Viterbiův algoritmus, který tuto pravděpodobnost určuje rekursivně využitím techniky dynamického programování (DTW) nebo modifikovaný Viterbiův algoritmus [6].



obr. 2. levo-pravý markovův model

Proces učení:

Učením Markovova modelu se rozumí přepočítání modelu $\lambda = (N, M, \pi)$ na nový model $\lambda^* = (N^*, M^*, \pi)$ na základě několika průběhů stejného typu EKG signálů. Pro všechny průběhy jsou vypočteny časově – frekvenční spektra, která jsou dále rozdělena na posloupnosti příslušných vektorů a pomocí kódové knihy vektorovou kvantizací převedeny na posloupnost indexů. Pro každý průběh tak získáme vektor indexů kódových vektorů, který nám zobrazuje jednotlivé stavy, podle nichž se určí, kterými uzly a přechody model prochází.

Nejužívanějším iteračním postupem je Baum-Welchův algoritmus, pomocí kterého získáme parametry modelu $\lambda = (N, M, \pi)$ tak, aby $P(O | \lambda)$ byla alespoň lokálně maximalizována [6].

Rozpoznávací proces:

Pro proces rozpoznávání musíme znát kódovou knihu používanou při učení a modely EKG signálů, které se budou rozpoznávat. Pro příchozí neznámý průběh se opět určí časově – frekvenční spektrum, vektory příznaků a pomocí vektorové kvantizace se určí indexy příslušné nejbližším kódovým vektorům. Pro takto vypočtenou posloupnost stavů se vypočtou pravděpodobnosti, že neznámý průběh byl vygenerován všemi naučenými modely. Z maximální pravděpodobnosti rozpoznáme příslušný model.

Výsledky:

Pomocí HMM byly navrženy dva modely o 12 stavech, pro průběh normálního a ischemického EKG měřeného pomocí ortogonálních svodů x, y, z. Byla využita reálná data z několika experimentů. Pro popis těchto průběhů byla použita vlnková transformace s použitím komplexní vlnky typu Kingsbury. Úspěšnost rozpoznávání je uvedena v následující tabulce:

testovaný signál / nejlépe vyhovující model	úspěšnost [%]
x (non-ischemic) / x (non-ischemic)	81.8
x (ischemic) / x (ischemic)	90.9
y (non-ischemic) / y (non-ischemic)	18.2
y (ischemic) / y (ischemic)	90.9
z (non-ischemic) / z (non-ischemic)	63.6
z (ischemic) / z (ischemic)	63.6

Veškeré algoritmy byly naprogramovány v prostředí Matlab. Byly použity knihovny Signal processing a Wavelet. Výsledky byly generovány v grafické podobě s použitím knihoven Matlabu.

Závěr:

Markovův model je obecný model pro popis stochastických procesů. Použití pro rozpoznávání EKG signálů je možné, ale vyžaduje další studium. Pro rozpoznávání řeči se tato metoda osvědčila a dnes se již využívá. Vylepšení této metody je možné v určení konkrétních přechodů v modelech a zefektivnění práce s kódovou knihou.

pozn: Tato práce byla částečně podporována výzkumným záměrem J22/98:262200011.

- [1] LEVINSON, S. E., RABINER, L. R., SONDHI, M. M.: Speaker Independent Isolated Digit Recognition Using Hidden Markov Models. In: Proc. ICASSP 83, Boston 1983, s. 1049-1052
- [2] STROPE B, ALWAN A. A Model Of Dynamic Auditory Perception And Its Application To Robust Word Recognition. IEEE Trans SAP 1997; 5:451-464.
- [3] COAST, D. A., STERN, R. M.: An Approach to Cardiac Arrhythmia Analysis Using Hidden Markov Models, IEEE Transaction on Biomedical Engineering, Vol. 37, No. 9, 1990, s. 826-836
- [4] GOMIS P, JONES D L, et al. Analysis of Abnormal Signals within the QRS Complex of the High-Resolution Electrocardiogram 1997. IEEE Trans BME; 44: 681-93.
- [5] YAKUBO S, OZAWA Y, et al. Intra-QRS High-Frequency ECG Changes with Ischemia. Is It Possible to Evaluate These Changes Using the Signal-Averaged Holter ECG in Dogs? 1995 J Electrocardiol 28(Suppl): 234-8.
- [6] PSUTKA, J.: Komunikace s počítačem mluvenou řečí, Academia, Praha, 1995

kontaktní adresa:

Purkyňova 118, 612 00 Brno, Czech Republic
E-mail: bardona@dbme.fee.vutbr.cz
tel.: (+420 5) 41149 558, fax: (+420 5) 41149 542