



Biosignal Challenge 2024

Detekce spánkové apnoe

Spánková apnoe, charakterizovaná opakujícími se cykly přerušného dýchání postihuje přibližně 10 % dospělých ve středním věku, zejména muže s nadváhou nebo obezitou. Téměř 80 % lidí s touto poruchou však zůstává nedignostikovaných a neléčených.

Onemocnění nevede pouze k zastavení přísunu kyslíku a tím pádem poklesu saturace, ale také k výraznému poklesu kvality spánku a celkového zdraví pacienta. Ten se po probuzení často cítí unavený, a to i po celonočním spánku.

Rozlišují se dva základní typy apnoe, někteří pacienti trpí kombinací obou typů.

- **Obstrukční spánková apnoe**
 - Anatomické příčiny, je vyvolána mechanickým uzavřením dýchacích cest (hltanu) během spánku.
- **Centrální spánková apnoe**
 - Příčina v centrálním nervovém systému, dýchací cesty jsou v pořádku, ale chybí dýchací úsilí, mozek nedává správný signál dýchací soustavě.
- **Smíšená spánková apnoe**
 - Začíná jako centrální (chybí dýchací úsilí), ale končí jako obstrukční (v průběhu dojde k obnovení dýchacího úsilí).

K častým příznakům patří hlasité chrápání, náhlé probouzení doprovázené dušností, velká denní spavost nebo problémy s pozorností a podrážděnost.

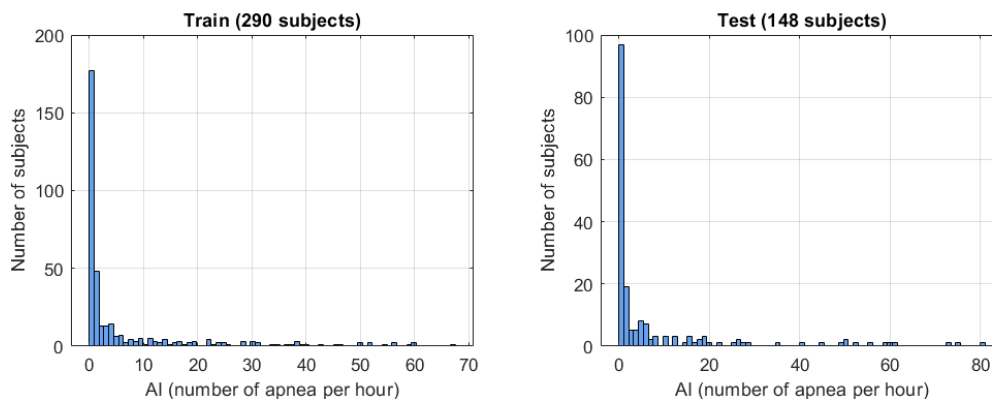
Podle Americké akademie spánkové medicíny (AASM) se apnoe u dospělých hodnotí, pokud dojde k poklesu signálu o ≥ 90 % výchozí hodnoty před událostí pomocí oronazálního tepelného senzoru (diagnostické studie), průtoku zařízení PAP (titrační studie) nebo alternativního senzoru apnoe po dobu ≥ 10 sekund ve spojení s ≥ 3 % arteriální desaturací kyslíku nebo změnou spánkové fáze.

Biosignal Challenge 2024 si klade za cíl vytvořit algoritmus pro detekci spánkové apnoe s využitím moderních výpočetních prostředků a anotovaných signálů EKG, průtoku vzduchu a okysličení. Robustně navržený a spolehlivě fungující algoritmus by výrazně urychlil práci lékařů, kteří musí manuálně procházet několikahodinové záznamy a ručně zaznamenávat apnoické epizody.

Anotovaná databáze spánkových apnoí NÚDZ


Data pochází z anotované databáze několikahodinových nahrávek pacientů z Národního ústavu duševního zdraví, Topolová 748, 250 67 Klecany. Data byla nahrána pro vědecké účely s informovaným souhlasem pacientů. Pacienti byli podle počtu apnoických epizod rozděleni do 4 skupin:

- minimální počet apnoických epizod ($<q_{0.25}$)
- nízký počet apnoických epizod ($q_{0.25} - q_{0.5}$)
- střední počet apnoických epizod ($q_{0.5} - q_{0.75}$)
- vysoký počet apnoických epizod ($>q_{0.75}$)



Obrázek 1: Histogram počtu apnoí (za hodinu) jednotlivých pacientů v trénovacím a testovacím datasetu.


Do trénovacího dataset byly zařazeny přibližně $\frac{2}{3}$ všech dostupných nahrávek, do testovacího datasetu zbylá $\frac{1}{3}$. Obě skupiny obsahují podobný podíl nahrávek z jednotlivých skupin, trénovací dataset je tedy proporcčně reprezentativní datasetu testovacímu. Ke každému subjektu jsou k dispozici tři signály: druhý svod EKG (ECG), průtok vzduchu (flow) a okysličení krve (SpO_2).



Obrázek 2: Označená apnoická epizoda na signálech ECG (nahore), flow (uprostřed) a SpO_2 (dole).

Data pochází z klinického prostředí a nejsou nijak upravena. Je potřeba počítat s tím, že jsou zašumělá a také obsahují množství artefaktů. Jedná se o artefakty pohybové,

kdy se subjekt pohne na lůžku, ale také artefakty technické, kdy dojde k chvilkovému odpojení senzoru nebo přerušení signálu kvůli odchodu subjektu na toaletu. Součástí vhodného řešení musí tedy být také vhodná filtrace dat a rozpoznávání artefaktů.



Obrázek 3: Pohybový artefakt na signálech ECG (nahore), flow (uprostřed) a SpO₂ (dole). Senzor okysličení je v tomto časovém úseku odpojený (záporná hodnota signálu SpO₂).

Trénovací množina obsahuje 290 nahrávek apnoických pacientů (označení ap_XXX.mat). Testovací množina obsahuje 148 nahrávek apnoických pacientů.

Metody detekce

Účastníci mohou využít pokročilé metody zpracování signálů, strojového učení i umělé inteligence v programovém prostředí MATLAB. Není však dovoleno využívat předtrénované modely. Neuronové sítě je nutné navrhnout od začátku, není dovoleno stáhnout již natrénované váhy. K trénování algoritmů je možné využívat poskytnutá data, ale také kterékoliv veřejné databáze s fyziologickými signály (např. <https://physionet.org/about/database/>).

Při využití pokročilých technik strojového učení je dobré si uvědomit, že dataset je silně nevyvážený. Segmenty, které neobsahují žádnou apnoickou událost výrazně početně převyšují segmenty, které apnoickou událost zachycují.

Kritéria hodnocení soutěže

Výkon jednotlivých algoritmů je stanoven skupinou parametrů, které vycházejí z porovnání expertního hodnocení a výsledků detekce. Ačkoliv je expertní hodnocení považováno za referenční, nelze očekávat neomylnost v označování apnoických epizod. Vzhledem k délce záznamů nebo subjektivnímu pohledu hodnotitele lze očekávat občasné nepřesné označení apnoických epizod. Od algoritmů tedy neočekáváme totožné výsledky, ale svými výkony by se měly referenci co nejvíce blížit. Algoritmy budou hodnoceny z hlediska robustnosti a přesnosti. Důležité pro finální hodnocení budou tři skupiny detekcí podle správnosti.

- TP (true positive) – správně zdetekovaný vzorek z apnoické epizody
- FP (false positive) – špatně zdetekovaný vzorek mimo apnoickou epizodu
- FN (false negative) – nezachycený vzorek apnoické epizody

Úspěšnost algoritmů bude hodnocena podle následujících metrik:

1. Plocha pod P-R (precision-recall) křivkou na testovací množině (40 %)

Pro každý práh (threshold), neboli každou hodnotu pravděpodobnosti na výstupu klasifikátoru, budou vypočteny metriky precision a recall. Jako první hodnotící kritérium pak bude brána plocha pod vzniklou P-R křivkou.

$$precision = \frac{tp}{tp + fp} \quad recall = \frac{tp}{tp + fn}$$

2. F1-skóre na testovací množině (40 %)

Pro každý práh bude vypočteno F1-skóre podle následujícího vzorce:

$$F1 = \frac{2 \cdot precision \cdot recall}{precision + recall}$$

Výsledná hodnota bude brána jako maximum všech hodnot F1-skóre přes různé prahy, pomocí kterých byla tvořena P-R křivka.

3. Plocha pod P-R křivkou na trénovací množině (5 %)

4. F1-skóre na trénovací množině (5 %)

5. Rozdíl výsledků na trénovací a testovací množině (10 %)

Pro ověření robustnosti algoritmů bude porovnávána úspěšnost algoritmu na trénovací a testovací množině podle následujícího vzorce:

$$DC = 1 - \frac{\|(F_{train}, AUPRC_{train}) - (F_{test}, AUPRC_{test})\|_2}{\sqrt{2}}$$

Podmínky soutěže

- Soutěž je určena vysokoškolským studentům v České republice.
- Řešitelské týmy mohou mít od 1 do 3 členů.
- Všechny algoritmy musí být implementovány v prostředí MATLAB.
- Každý tým se musí registrovat na <https://bsch.fel.cvut.cz>.
- Řešení je nutné odevzdat na <https://bsch.fel.cvut.cz> do 17. května 2024.
- Řešení musí zahrnovat:
 - Hlavní funkci: apnoe_detekce.m
 - Všechny další soubory a data nezbytná ke spuštění hlavní funkce.
 - Zprávu ve formátu PDF obsahující jméno, univerzitu, počet členů týmu, použitou verzi MATLABu, popis použitých metod, výsledky na trénovací databázi a seznam použité literatury.

Přístup k datům

Jeden člen týmu se musí registrovat na <https://bsch.fel.cvut.cz>. Po registraci je nutné se na stejné adrese přihlásit a odevzdat vyplněné přihlášky od všech členů týmu. Poté bude týmu schválena registrace a povolen přístup k datům.

Odevzdaný algoritmus

Je třeba odevzdat hlavní funkci **apnoe_detekce.m** a všechny ostatní funkce, na kterých je hlavní funkce závislá. Pokud budete trénovat pokročilé algoritmy umělé inteligence, které jsou závislé na naučených vahách, přidejte také trénovací skripty.

Vstup

Soubory z trénovací i testovací množiny mají podobu struktury file.xxx, kde xxx reprezentuje následující položky:

- filename Název souboru
- ecg Signál EKG, rozměr: [počet vzorků, 1]
- flow Průtok vzduchu, rozměr: [počet vzorků, 1]
- spo2 Okysličení, rozměr: [počet vzorků, 1]
- gt_segments... Indexy intervalů (ve vzorcích) obsahujících apnoe – formát: [začátek apnoe, konec apnoe], rozměr: [počet apnoí, 2]
 - není součástí testovacího datasetu
- fs ... Vzorkovací frekvence (250 Hz)

Name ^	Size	Bytes	Class
ecg	7231820x1	28927280	single
filename	1x1	166	string
flow	7231820x1	28927280	single
fs	1x1	4	int32
gt_segments	206x2	1648	int32
spo2	7231820x1	28927280	single

Obrázek 4: Struktura dat, která jsou k dispozici pro trénink algoritmů.

Vstupem do funkce apnoe_detekce.m je načtená struktura bez proměnné gt_segments.

Výstup

Na výstupu funkce apnoe_detekce.m požadujeme strukturu, ve které jsou zaznamenány detekce pro jednotlivé soubory. Jedná se o vnořenou strukturu DET.detection.xxx. kde xxx reprezentuje následující položky:

- filename ... název souboru (string)
- score ... výstup klasifikátoru obsahující pravděpodobnost (0-1), že daný vzorek bude klasifikován jako apnoe, rozměr [počet vzorků, 1]

Literatura

- Baguet, J.-P., Barone-Rochette, G., Tamisier, R., Levy, P., & Pepin, J.-L. (2012). Mechanisms of cardiac dysfunction in obstructive sleep apnea. *Nature Reviews Cardiology*, 9(12), 679.
- Hassan, A. R., & Haque, M. A. (2016). Computer-aided obstructive sleep apnea screening from single-lead electrocardiogram using statistical and spectral features and bootstrap aggregating. *Biocybernetics and Biomedical Engineering*, 36(1), 256–266.
- Jin, J., & Sanchez-Sinencio, E. (2015). A home sleep apnea screening device with time-domain signal processing and autonomous scoring capability. *IEEE transactions on biomedical circuits and systems*, 9(1), 96-104.
- Bartoň, M. (2020). Event detection in polysomnographic recordings by using machine learning techniques. Kladno. Master's thesis. Faculty of Biomedical Engineering CTU.

Ceny pro vítěze

- 1. místo: 15.000,- Kč
- 2. místo: 9.000,- Kč
- 3. místo: 6.000,- Kč

Partneři a sponzoři

