AI u medicini

Praktični primjer: otkrivanje artefakata u EKG signalu pomoću Edge AI

Đurković Jovan – MECOnet – 19.1.2026

Uvod - AI u medicini

- Vještačka inteligencija sve češće se koristi u medicinskoj dijagnostici
- Analiza biosignala (EKG, EEG, EMG)
- Problem šuma i artefakata u realnim mjerenjima
- Edge AI omogućava obradu podataka direktno na uređaju

Problem koji rješavamo

- EKG signal često sadrži anomalije
- Uzrok anomalija može biti:
  - stvarni srčani poremećaj
  - fizičko pomjeranje elektroda
- Cilj: razlikovati artefakte uzrokovane pokretom od stvarnih EKG anomalija

Hardverska platforma

- **Arduino Nano 33 BLE Sense**
- Ugrađeni senzori: 3-osni akcelerometar i žiroskop
- Mala potrošnja energije
- Pogodan za nosive i medicinske uređaje

Koncept rješenja

- Istovremeno snimanje:
  - EKG signala
  - Signala akcelerometra
- AI model procjenjuje:
  - da li je pacijent u mirovanju
  - da li postoji fizičko pomjeranje
- Na osnovu toga se tumače anomalije EKG-a

Edge Impulse platforma

- Platforma za razvoj Edge AI modela
- Omogućava:
  - prikupljanje podataka
  - ekstrakciju karakteristika
  - treniranje i testiranje modela
- Direktna optimizacija za embedded uređaje

Prikupljanje podataka

- Snimanje akcelerometarskih podataka
- Definisane 3 klase:
  - Mirovanje – bez pomjeranja
  - Jaki pokreti – nasumično pomjeranje u svim pravcima
  - Blagi pokreti – pomjeranje u jednom pravcu
- Podjela skupa podataka:
  - 68% trening
  - 32% testiranje

Prikupljanje podataka

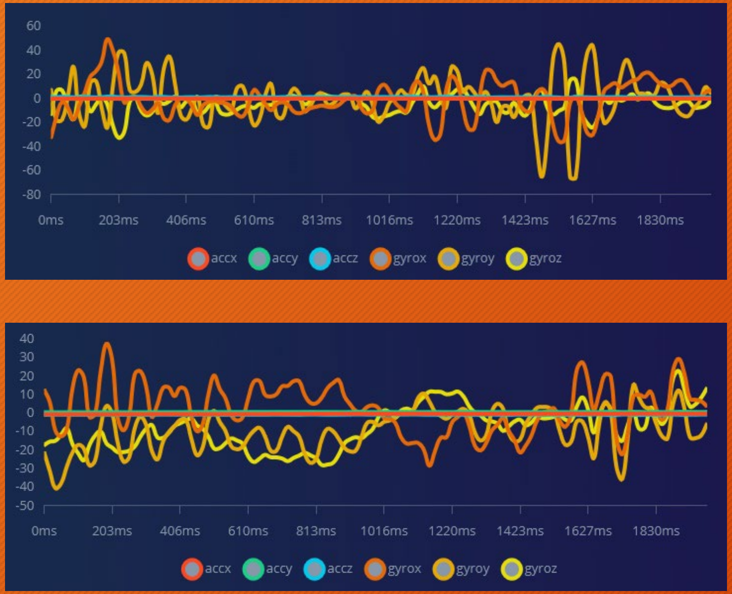

1. Blago pomjeranje

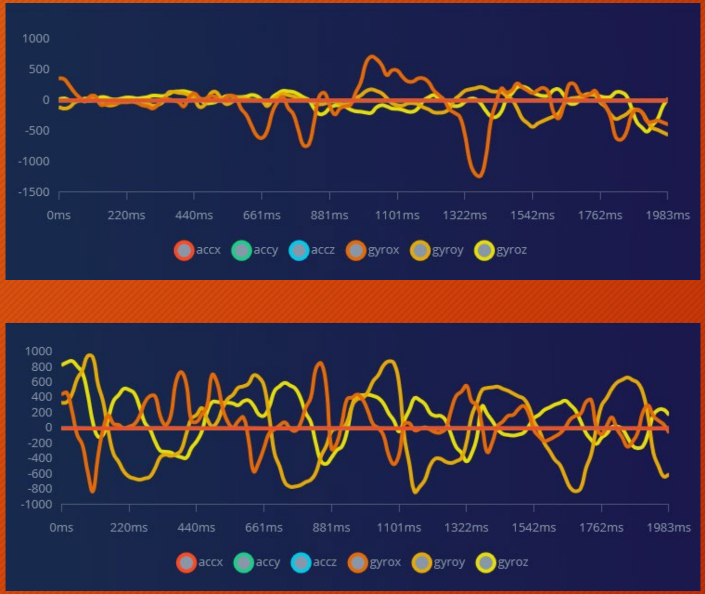

2. Jako pomjeranje

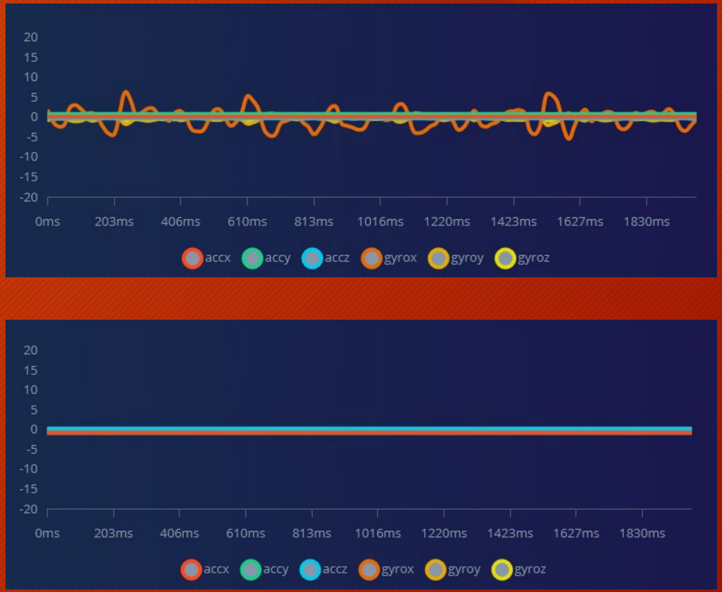

3. Mirovanje

Obrada signala

- Korišćen je **Spectral Analysis blok**
- FFT analiza signala:
  - izdvajanje frekvencijskih karakteristika
- Parametri:
  - FFT dužina: 16
  - logaritamska skala spektra

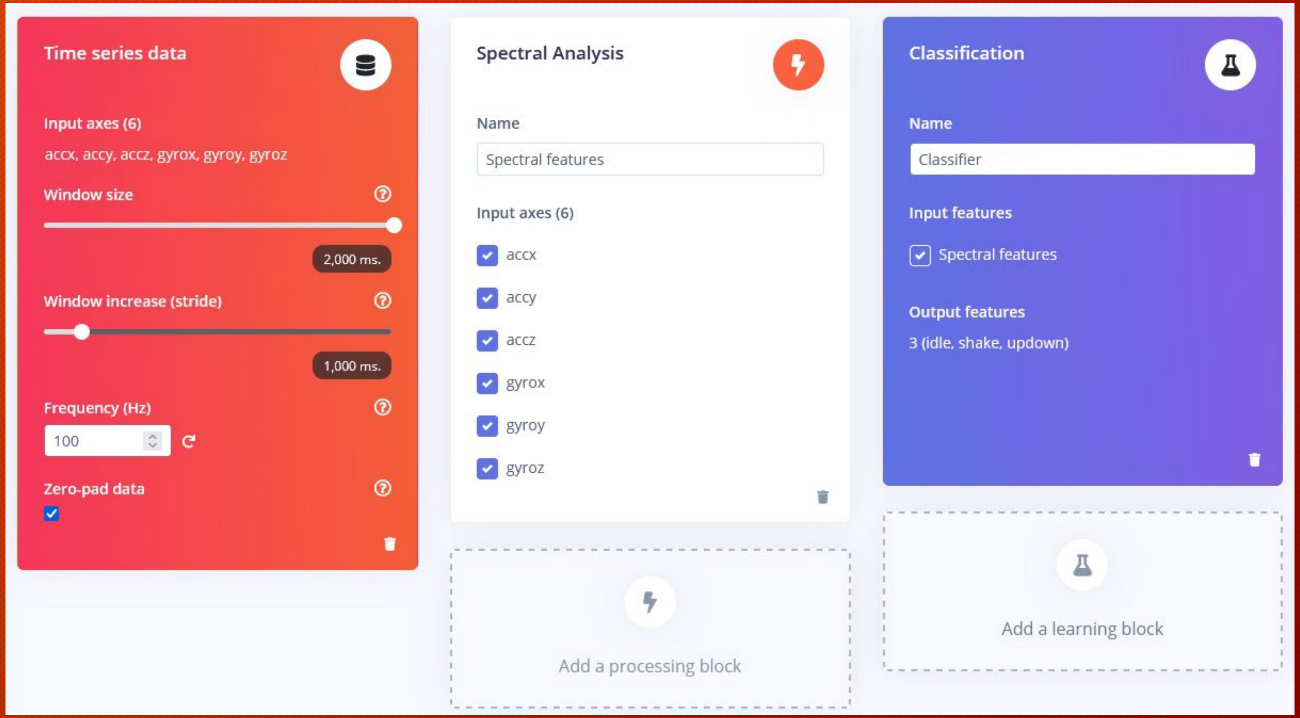

Obrada signala

Arhitektura neuronske mreže

- Tip: Fully Connected Neural Network
- Slojevi:
  - 3 Dense sloja (256 neurona)
  - Dropout za smanjenje overfittinga
- Aktivacija:
  - ReLU (skriveni slojevi)
  - Softmax (izlazni sloj)

```
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, InputLayer, Dropout, Conv1D, Conv2D, Flatten, Reshape, MaxPooling1D, MaxPooling2D,
AveragePooling2D, BatchNormalization, Permute, ReLU, Softmax, Activation
from tensorflow.keras.optimizers.legacy import Adam

EPOCHS = args.epochs or 40
LEARNING_RATE = args.learning_rate or 0.005
# If True, non-deterministic functions (e.g. shuffling batches) are not used.
# This is False by default.
ENSURE_DETERMINISM = args.ensure_determinism
# this controls the batch size, or you can manipulate the tf.data.Dataset objects yourself
BATCH_SIZE = args.batch_size or 32
if not ENSURE_DETERMINISM:
    train_dataset = train_dataset.shuffle(buffer_size=BATCH_SIZE*4)
train_dataset=train_dataset.batch(BATCH_SIZE, drop_remainder=False)
validation_dataset = validation_dataset.batch(BATCH_SIZE, drop_remainder=False)

# model architecture
model = Sequential()
model.add(Dense(256, activation='relu',
    activity_regularizer=tf.keras.regularizers.l1(0.00001)))
model.add(Dropout(0.2))
model.add(Dense(256, activation='relu',
    activity_regularizer=tf.keras.regularizers.l1(0.00001)))
model.add(Dropout(0.2))
model.add(Dense(256, activation='relu',
    activity_regularizer=tf.keras.regularizers.l1(0.00001)))
model.add(Dropout(0.2))
model.add(Dense(classes, name='y_pred', activation='softmax'))

# this controls the learning rate
opt = Adam(learning_rate=LEARNING_RATE, beta_1=0.9, beta_2=0.999)
callbacks.append(BatchLoggerCallback(BATCH_SIZE, train_sample_count, epochs=EPOCHS,
ensure_determinism=ENSURE_DETERMINISM))

# train the neural network
model.compile(loss='categorical_crossentropy', optimizer=opt, metrics=['accuracy'])
model.fit(train_dataset, epochs=EPOCHS, validation_data=validation_dataset, verbose=2, callbacks=callbacks)

# Use this flag to disable per-channel quantization for a model.
# This can reduce RAM usage for convolutional models, but may have
# an impact on accuracy.
disable_per_channel_quantization = False
```

Treniranje modela

- Procesor: CPU
- Learning rate: 0.005
- Batch size: 32
- Model kvantizovan (int8)
- Optimizovan za rad na uređaju

Rezultati – tačnost

- Ukupna tačnost: 96.9%
- Loss: 0.07
- AUC ROC: 1.00
- F1 score (prosjek): 0.97

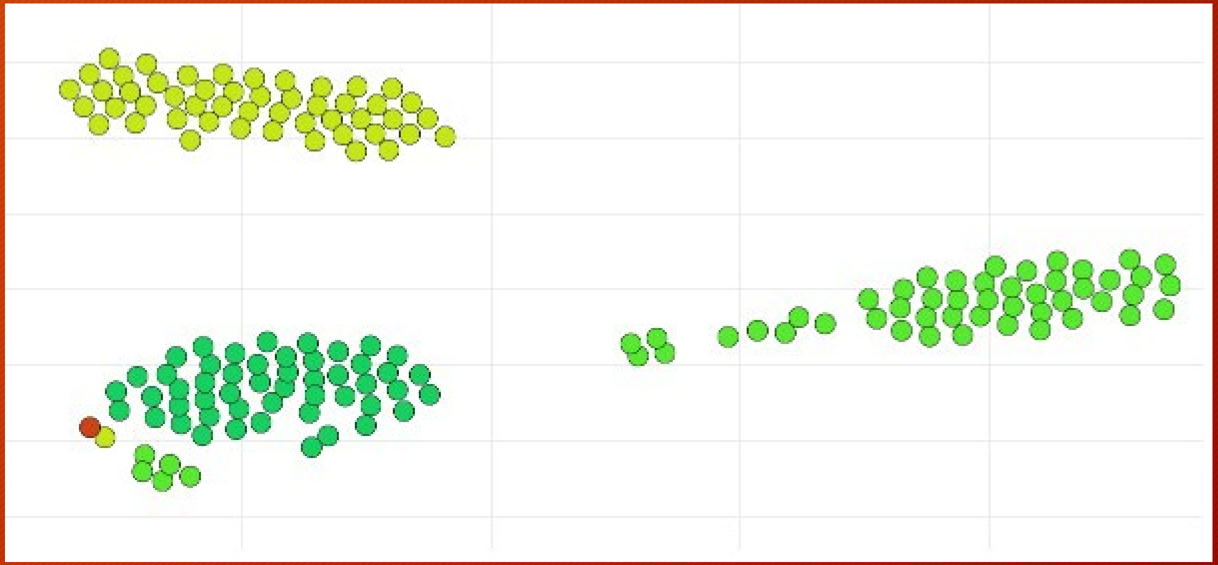

Rad na uređaju (On-device performance)

EKG Mirovanje Jače pomjeranje Slabije pomjeranje

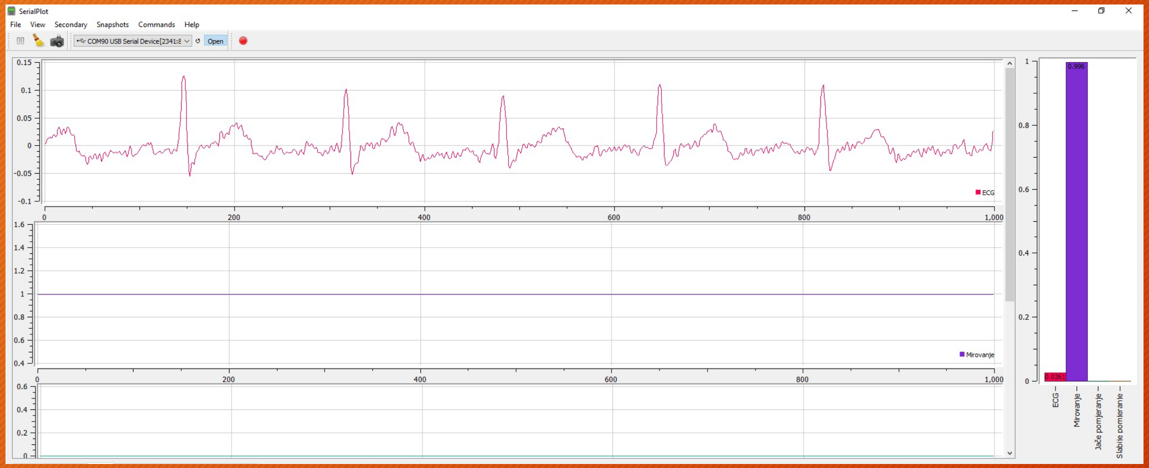

Mirovanje: stabilni EKG signal

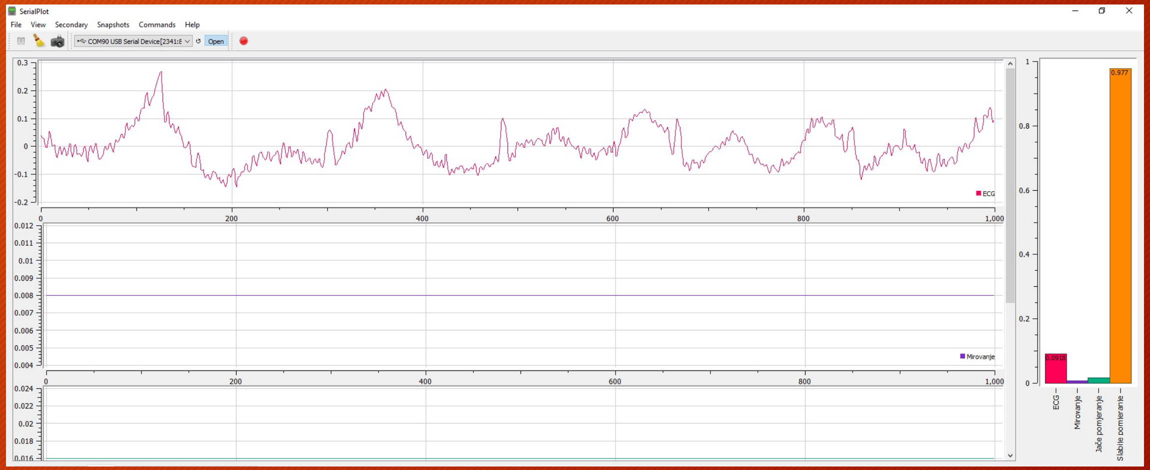

Pomjeranje: prisutni artefakti

- Vrijeme obrade: 62 ms
- Potrošnja RAM-a: 6 KB
- Pogodno za real-time medicinske aplikacije

Rad na uređaju (On-device performance)

Elektrode za EKG

EKG Mirovanje Jače pomjeranje Slabije pomjeranje

Prednosti rješenja

- Obrada podataka lokalno (Edge AI)
- Nisko kašnjenje
- Povećana tačnost interpretacije EKG-a
- Moguća primjena u:
  - holter monitorima
  - nosivim medicinskim uređajima

Zaključak

- AI značajno poboljšava analizu biosignala
- Kombinacija senzora i ML modela daje pouzdane rezultate
- Edge Impulse omogućava brz razvoj embedded AI rješenja
- Veliki potencijal za primjenu u medicini

Hvala na pažnji!

Pitanja?

jovan@meconet.me