

APRENDIZADO DE MÁQUINA PARA SAÚDE

Deep Learning II: Transformers e a pulsação dos dados

Atenção, séries temporais e sinais fisiológicos em ambientes clínicos

APOSTILA TÉCNICA · ENCONTRO 08

Prof. Flávio Luiz Seixas
Pós-graduação em Computação

Sumário

Sumário	2
Introdução	3
1. Sinal, tempo e contexto	3
2. Recorrência e memória	3
3. Atenção e Transformers	4
4. Multimodalidade, alarmes e explicação	4
Síntese do encontro.....	4
Referências	4

Introdução

Sinais fisiológicos são sequências amostradas por dispositivos, sujeitas a ruído, artefatos, frequências diferentes e mudanças de contexto. O desafio computacional é preservar temporalidade e relacionar padrões locais, dependências longas e estado clínico. [1]

O encontro compara redes recorrentes e Transformers e discute como essas arquiteturas podem transformar séries em representações e previsões, mantendo atenção a sincronização, alarmes e explicações. [1]



Figura 1 — Processamento recorrente e atenção paralela. Fonte: elaboração própria com base em [2].

1. Sinal, tempo e contexto

Sistemas de monitoramento adquirem ECG, pressão, oximetria e outros sinais, realizam processamento e os apresentam de modo integrado. Artefatos, perdas de conexão, diferenças de amostragem e limites de alarme afetam a informação que chega ao algoritmo [1].

A entrada de um modelo temporal pode ser uma janela multivariada; a saída pode ser uma classe, evento, risco ou sequência prevista. A definição do horizonte separa detecção do presente de previsão de um evento futuro [2].

CONCEITO-CHAVE

Sistemas de monitoramento adquirem ECG, pressão, oximetria e outros sinais, realizam processamento e os apresentam de modo integrado.

2. Recorrência e memória

RNNs atualizam um estado conforme percorrem a sequência. LSTM e GRU introduzem mecanismos que favorecem retenção e esquecimento de informação, respondendo a dificuldades de dependências longas. O processamento sequencial, contudo, limita paralelismo e pode tornar relações distantes difíceis de aprender [2].

3. Atenção e Transformers

Transformers usam unidades de atenção para relacionar posições da sequência. Em vez de depender apenas de um estado propagado passo a passo, cada posição pode ponderar outras posições relevantes. A representação precisa conservar informação de ordem, pois atenção isolada não fornece temporalidade [2].

Para sinais, segmentos ou amostras são transformados em representações, combinados com posição e processados por blocos de atenção. A saída pode ser agregada para classificação ou preservada ao longo do tempo para detecção e previsão [2].

4. Multimodalidade, alarmes e explicação

Sinais com frequências diferentes exigem alinhamento e tratamento explícito de lacunas. Na UTI, uma previsão deve ser comparada com limiares convencionais e integrada à capacidade de resposta. Alarmes em excesso reduzem efetividade e podem levar a altas taxas de sobreposição [1].

Uma explicação temporal pode indicar segmentos, canais e contexto associados ao resultado, mas pesos de atenção não devem ser automaticamente tratados como explicação causal. A avaliação deve incluir estabilidade, utilidade para o usuário e comportamento em ruído ou artefatos [3].

LIMITAÇÃO DOCUMENTAL

Os PDFs locais dão suporte conceitual a Transformers e sinais, mas não reproduzem todas as arquiteturas e estudos indicados nos slides.

Síntese do encontro

Sinal, tempo e contexto: sistemas de monitoramento adquirem ecg, pressão, oximetria e outros sinais, realizam processamento e os apresentam de modo integrado.

Recorrência e memória: rnns atualizam um estado conforme percorrem a sequência.

Atenção e Transformers: transformers usam unidades de atenção para relacionar posições da sequência.

Multimodalidade, alarmes e explicação: sinais com frequências diferentes exigem alinhamento e tratamento explícito de lacunas.

Referências

[1] Herasevich, V. et al. Patient Monitoring Systems. In: Biomedical Informatics. Springer, 2021.

[2] Bellazzi, R.; Dagliati, A.; Nicora, G. Predicting Medical Outcomes. In: Intelligent Systems in Medicine and Health. Springer, 2022.

[3] Li, R. C. et al. Explainability in Medical AI. In: Intelligent Systems in Medicine and Health. Springer, 2022.