



Revisão da gestão e diagnóstico do Pneumotórax no contexto pré-hospitalar

ARTIGO DE REVISÃO

Defeitos congênitos desvendados numa emergência

CASO CLÍNICO PEDIATRIA

Os dispositivos mecânicos de compressão torácica na rede de ambulâncias SIV: um imperativo ou uma excentricidade?

ARTIGO DE REVISÃO

Inteligência Artificial identifica PCR em chamada de emergência

LIFESAVING TRENDS

Handwritten signature and date: 22

INTELIGÊNCIA ARTIFICIAL IDENTIFICA PCR EM CHAMADA DE EMERGÊNCIA

Ana Catarina Segundo¹, André Aguiar¹, André Maciel¹, Afonso Eliseu¹

¹Serviço de Anestesiologia, Centro Hospitalar Universitário do Algarve – Unidade de Faro

Um grupo de investigadores Dinamarqueses testaram um modelo de inteligência artificial (IA) para reconhecer a presença de paragem cardiorrespiratória (PCR) em chamadas de emergência médica direcionadas a uma central de emergência médica de Copenhaga.

Mais de 600 000 pessoas por ano sofrem uma paragem cardiorrespiratória (PCR) na Europa e E.U.A..O reconhecimento rápido deste evento, quer seja por uma testemunha presencial ou pelo profissional da central telefónica de emergência médica é um pré-requisito para que se possa iniciar Suporte Básico de Vida (SBV), prestar o melhor atendimento, triagem, aconselhamento, selecção e envio de meios de socorro apropriados. Iniciar SBV antes da chegada da equipa de emergência ao local melhora a sobrevivência, fazendo com que a identificação deste evento durante a chamada se revista de importância fundamental. Porém, a PCR representa uma pequena percentagem (1%) do volume total de chamadas, o que torna difícil o seu reconhecimento. Aproximadamente 1/4 de todas as PCR não são percebidas na primeira

conversa telefónica de emergência. Esta falha no reconhecimento constitui um grande desafio, e a sua melhoria é objectivo da *American Heart Association (AHA)* e da *Global Resuscitation Alliance*, e nesse sentido surge a contribuição da IA através da tecnologia *Machine Learning Framework (MLF)*.

O MLF é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da IA baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões.

A tecnologia de MLF tem-se mostrado promissora e útil no auxílio à decisão clínica e diagnóstico, mas no contexto de emergência pré-hospitalar não tem sido aplicada.

Neste estudo utilizou-se a tecnologia MLF para reconhecer gravações não editadas de chamadas de emergência, com 3 objectivos principais. Primeiro, testar se uma MLF pode melhorar o reconhecimento de PCR comparativamente ao operador da central de emergência. Segundo, perceber se a MLF consegue reconhecer PCR mais rapidamente que o profissional qualificado. Terceiro, identificar

possíveis grupos ou subgrupos que são mais propensos a viés, seja pelo sistema informático ou pelo operador.

Neste caso particular a MLF é uma rede de vários modelos de aprendizagem, que decifram a conversa telefónica de forma similar a um técnico. Quando uma chamada é analisada pelo sistema em tempo real, o ficheiro é processado sem qualquer edição ou transcrição prévia, é transformado em texto e analisado a partir dessa fonte predizendo a probabilidade de PCR.

Para “ensinar a máquina” foram utilizadas gravações catalogadas previamente com a presença ou ausência de PCR. Os dados usados para treino não foram empregues na validação, o que significa que a MLF não foi avaliada nos ficheiros nos quais se “formou”.

Foram incluídas todas as chamadas recebidas pela central de Copenhaga, no espaço de 1 ano. Dos cerca de 110 000 incidentes, aproximadamente 1200 (1%) eram PCR, confirmado posteriormente pelo registo nacional *Danish Cardiac Arrest Registry*.



A performance da MLF foi comparada com a do técnico profissional qualificado, como linha de base. A MLF gera uma predição binária de 0 ou 1 para identificar PCR, correspondendo à probabilidade daquela condição estar presente na chamada. Foram também calculadas sensibilidade e especificidade para caracterizar a performance da MLF. Calculou-se o tempo médio decorrido até identificação da PCR para todas as chamadas. As diferenças entre o tempo de reconhecimento foram calculadas em chamadas onde houve dupla identificação, pela MLF e técnico.

A regressão logística univariada foi

utilizada para identificar preditores relacionados com o doente, o cenário e o técnico operacional, nas chamadas onde a MLF reconheceu PCR mas o técnico não. Os resultados foram apresentados em *Odds Ratio* (OR), com Intervalos de Confiança (CI) e p-value quando apropriado.

No ano do estudo, a central respondeu a 110 518 chamadas, que foram gravadas. Os doentes com sinais óbvios de morte foram excluídos (n=958), assim como chamadas com a gravação danificada ou desconectada nos primeiros 10 segundos (n=724).

A PCR foi confirmada pelo registo

nacional *Danish Cardiac Arrest Registry* (n=1147). PCR testemunhada por pessoal de emergência (n=126) e casos de manobras iniciadas antes da chamada (n=103), foram excluídos, restando 918 chamadas por PCR elegíveis para análise.

Dos 918 contactos, 665 (72,4%) foram reconhecidos pelo operador, enquanto 772 (84,1%) foram sinalizadas pela MLF ($p>0,001$).

Das chamadas reconhecidas pelo sistema de IA, 117 não foram reconhecidas pelo operador. No que respeita às características relacionadas com o doente, só foram encontradas diferenças minor entre estes incidentes não reconhecidos e os identificados pelo operador.

No entanto no que compete ao cenário e ao operacional técnico parece haver diferenças. Nas chamadas não identificadas comparativamente às reconhecidas pelo operador, registou-se menor avaliação do estado de consciência (86,8% vs 96,2%), e cenários em que o interlocutor que realiza a chamada não consegue avaliar o doente (8,5% vs 1,8%) ou que a PCR tenha sido presenciada por uma testemunha ocular (61,4% vs 48,7%).

Apenas 10 chamadas (1,1%) foram reconhecidas pelo operador, mas não pela MLF.

Considerando todas as chamadas, a MLF atingiu uma sensibilidade de 84,1% (IC 95%: 81,6-86,3) e uma especificidade de 97,3% (IC 95%: 97,2-97,4) no reconhecimento de PCR, enquanto o operador alcançou 72,5% (IC 95%: 69,5-75,4) e 98,8% (IC 95%: 98,7-98,8) respectivamente.

A MLF teve um Valor Preditivo

Positivo (VPP) de 21% (IC 95%: 19,7-22,3) comparativamente com 33% (IC 95%: 30,1-35,1) do operador. Em todas as chamadas reconhecidas pelo modelo de IA (n=772), o tempo decorrido até à detecção de PCR foi significativamente mais curto comparativamente com o operador (n=665), 44 vs 54 segundos (p<0,001).


Dentro dos contactos em que a MLF sinalizou PCR, o reconhecimento pelo operador estava positivamente associado com o acesso do interlocutor ao doente. Especialmente quando este se encontrava ao lado da vítima, o operador tinha 2,37 vezes mais probabilidade de identificar PCR do que quando o interlocutor não tinha acesso ao doente (IC 95%: 1,50-3,74). Se o operador avaliasse a ausência de consciência na vítima tina um OR de 3,80 (IC 95%: 1,90-7,40). E se avaliassem a respiração o OR seria de 2,30 (IC 95%: 1,00-5,40). Quando a PCR era presenciada por uma testemunha, os operadores mostram-se menos capazes de reconhecer PCR comparativamente com incidentes não testemunhados (OR 0,52 IC 95%: 0,39-0,89), o que poderá dever-se a fenómenos de gasping imediatamente após PCR que afectariam a percepção da testemunha em relação à respiração.

Podemos considerar com este trabalho que este modelo de IA foi eficaz no reconhecimento de PCR em gravações de chamadas de emergência, com uma sensibilidade significativamente maior e especificidade semelhante ao técnico operacional treinado, tendo sido significativamente mais rápida na identificação.

Aplicar a MLF no contexto de emergência pré-hospitalar tem o potencial de melhorar e acelerar o reconhecimento de PCR, o que se poderá traduzir numa resposta mais otimizada e direcionada no sentido de iniciar procedimentos de SBV o mais rapidamente possível, podendo ter tradução na sobrevivência pós-PCR. Um decréscimo de 10 segundos no tempo de detecção, como o que foi identificado neste estudo, pode mesmo ser clinicamente relevante, considerando que as guidelines da AHA recomendam que um programa de alta performance tem um tempo de decorrido desde a recepção da chamada até à resposta da equipa de emergência em menos de 60 segundos, sendo que 120 segundos é o standard mínimo aceitável.

O VPP da MLF (21,0%) é baixo, ou seja, significa que 4 em cada 5 PCR correspondem a falsos positivos. O efeito de sobre-triagem poderá ser tolerado uma vez que diz respeito a PCR que é uma situação em que o tempo é factor crítico. Poderá ser visto como um gerador de red-flag ao operador, mantendo-o alerta da possibilidade de PCR naquela chamada, aumentando-lhe o foco e direcionando-o para questionar acerca de ausência de estado de consciência e respiração.

Estas acções podem levar a um incremento na realização de SBV pelas testemunhas, o que está demonstrado melhorar a sobrevivência a curto e longo prazo nas PCR, reduzindo o risco de lesão cerebral por anóxia. Assim sendo, a MLF não deverá ser utilizada isoladamente, mas actuar como um suplemento no processo

de decisão clínica, iniciado pelo operador, e que se baseia nos procedimentos standard, algoritmos estabelecidos e experiência profissional. Estes achados abrem novos horizontes na aplicação de modelos de IA como ferramenta de suporte noutras condições em que o tempo é crucial, tais como trombose, enfarte agudo do miocárdio ou sépsis. Os próximos passos passam pela comparação destes resultados com outro contexto organizacional e idiomas diferentes, e pela realização de um estudo controlado e randomizado com análise das gravações em tempo real, para medir o verdadeiro impacto na sobrevivência e no sistema operacional de emergência 

BIBLIOGRAFIA

1. Stig Nikolaj Blomberg et al. Machine learning as a supportive tool to recognize cardiac arrest in emergency calls. Resuscitation. 2019 Mai; 138:322–9.

EDITOR



ALÍRIO GOUVEIA
Médico VMER

REVISÃO



COMISSÃO CIENTÍFICA