



AUDIOMETRIA AUTOMÁTICA: REDUÇÃO DE ESTÍMULOS UTILIZANDO APRENDIZADO DE MÁQUINA

Diego Matias Dias Martins; Felipe Antunes.

Diego Matias Dias Martins, Bolsista CNPq, Engenharia Elétrica, IFMG Campus Ipatinga, Ipatinga - MG; dmdmgv@gmail.com
Felipe Antunes: Pesquisador do IFMG, Campus Ipatinga; felipe.antunes@ifmg.edu.br

RESUMO:

A audiometria tonal é amplamente usada para diagnosticar a perda auditiva, pois permite identificar os limiares auditivos com base em tons puros, gerando o audiograma como resultado final. No método tradicional, o paciente responde a estímulos sonoros em várias frequências, e o examinador ajusta a intensidade desses sons até encontrar o limiar auditivo do paciente, ou seja, o menor nível de som que ele consegue ouvir. No entanto, esse método apresenta limitações em casos onde a cooperação do paciente não é possível, como em bebês, crianças pequenas e pessoas com deficiências cognitivas, o que torna necessária a adoção de métodos alternativos. Para esses casos, foram desenvolvidas técnicas de audiometria objetiva que, ao invés de dependerem da resposta ativa do paciente, baseiam-se na detecção de potenciais elétricos gerados no cérebro em resposta aos estímulos sonoros. Contudo, embora eficaz, a audiometria objetiva apresenta a desvantagem de ser demorada, já que exige que o paciente fique exposto ao estímulo sonoro por um período prolongado para garantir a precisão da medição. Neste contexto, o projeto em questão visa otimizar o processo de obtenção do audiograma ao utilizar estratégias de aprendizado de máquina, comparando com métodos tradicionais, como por exemplo o método Hughson-Westlake (HW), com abordagens baseadas em algoritmos avançados de machine learning, com o objetivo de reduzir a quantidade de estímulos necessários sem comprometer a precisão dos resultados. Assim, espera-se que a pesquisa contribua para o aprimoramento da audiometria objetiva, reduzindo o tempo de exame e tornando-o mais viável em contextos onde a duração prolongada é um fator limitante. O principal objetivo deste projeto é investigar diferentes estratégias de aprendizado de máquina para identificar quais são as mais eficazes na obtenção do audiograma com um número menor de estímulos, mantendo a precisão necessária. Como produto final, o estudo espera destacar as abordagens mais promissoras que possam ser aplicadas na prática clínica, diminuindo o tempo de exame sem perda de qualidade. Sendo assim, é intenção dos pesquisadores submeter os achados para publicação em uma revista científica indexada, o que contribuiria para a disseminação desse conhecimento e seu compartilhamento com a comunidade científica.

PALAVRAS CHAVES: Inteligência Artificial; Aprendizado de Máquina, Audiograma

INTRODUÇÃO:

A avaliação tradicional da audição é realizada por meio do audiograma, que é um gráfico que mostra o limiar de percepção de tons puros em relação à frequência. A forma convencional de obter esse audiograma é através da audiometria tonal, utilizando o método modificado de Hughson-Westlake (HW) (Hughson & Westlake, 1944), que foi estabelecido



como padrão para testes audiológicos há várias décadas (Carhart & Jerger, 1959). Esse procedimento não consegue determinar o limiar em todas as frequências de uma vez, por isso, o teste é feito utilizando uma frequência de cada vez. Para cada frequência, os tons puros são apresentados em níveis de intensidade que aumentam e diminuem com base nas respostas do paciente. O teste é finalizado e o limiar é registrado em cada frequência quando se atingem o número suficiente de reversões (Franks, 2001; American National Standards Institute, 2004; American Speech-Language-Hearing Association, 2005).

Simultaneamente ao desenvolvimento de métodos adaptativos convencionais, como o citado anteriormente, a audiometria automatizada também tem ganhado destaque, com uma das abordagens mais antigas sendo a de George von Békésy, desenvolvida no final dos anos 1940 (Békésy, 1947). O audiograma automatizado de Békésy, muitas vezes chamado de "audiometria de Békésy", inclui um sistema em que o ouvinte tem o controle sobre um atenuador para identificar a intensidade em que o som deixa de ser ouvido. Além disso, diversas técnicas audiométricas computadorizadas foram criadas para garantir maior consistência e eficiência, com algumas delas utilizando um método de ajuste semelhante ao de Békésy, enquanto a maioria adota um método baseado nos limites, como o algoritmo HW (Ho et al., 2009; Margolis et al., 2010; Swanepoel et al., 2010; Mahomed et al., 2013). Apesar da tecnologia de computação digital estar amplamente disponível, a audiometria automatizada ainda é pouco utilizada nos diagnósticos clínicos, com a maior parte dos audiogramas sendo realizados de forma analógica (Vogel et al., 2007).


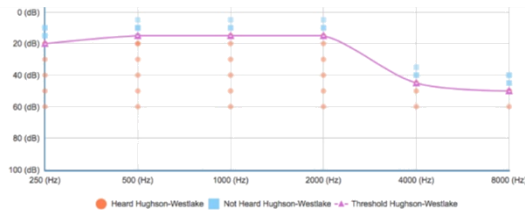
Os métodos computadorizados para medir os limiares auditivos geralmente seguem processos parecidos e fornecem estimativas que são comparáveis ao algoritmo HW, apresentando uma diferença média de $4,2 \text{ dB} \pm 5,0 \text{ dB}$ (Mahomed et al., 2013). Esses métodos também mostram diferenças médias de $2,9 \pm 3,8 \text{ dB}$ em testes de reavaliação, enquanto os métodos manuais têm uma diferença de $3,2 \pm 3,9 \text{ dB}$ na mesma população de participantes. Assim, os procedimentos computadorizados de audiometria tonal têm o potencial de gerar limiares auditivos tão precisos e confiáveis quanto os métodos manuais convencionais.

As técnicas adaptativas, como o procedimento HW e outras abordagens similares descritas em Mahomed et al. (2013), envolvem o ajuste sistemático da intensidade dos tons puros, uma frequência de cada vez, até determinar um limiar para cada frequência testada. Recentemente, novas abordagens baseadas em aprendizado de máquina foram propostas para melhorar o processo de obtenção do audiograma (Song, Garnett, & Barbour, 2017; Song, Sukesan e Barbour, 2018; Song et al., 2015). Essas novas técnicas têm a vantagem de estimar o audiograma em várias frequências ao mesmo tempo, reduzindo a quantidade de estímulos necessários para completar o teste.

Embora ainda não sejam amplamente adotadas na prática, essas abordagens têm o potencial de transformar a audiometria automática objetiva. Diferentemente dos métodos tradicionais, que dependem das respostas comportamentais do paciente, a audiometria objetiva visa determinar o audiograma sem contar com essas respostas. Normalmente, essa avaliação é feita por meio da detecção de potenciais evocados auditivos, um processo que pode ser demorado, pois exige que o paciente seja exposto ao estímulo sonoro por vários minutos. Se for possível reduzir o número de estímulos necessários, o tempo total do exame poderia ser consideravelmente reduzido tornando-o viável para uso clínico. O objetivo deste projeto é revisar as técnicas já existentes para a obtenção do audiograma e investigar novas



abordagens utilizando aprendizado de máquina, com ênfase em como diminuir a quantidade de estímulos sem comprometer a precisão dos resultados.



METODOLOGIA:

A metodologia proposta para o desenvolvimento de um algoritmo automatizado, baseado no Método HW, visa otimizar a obtenção de limiares auditivos e a criação de audiogramas de maneira mais eficiente e precisa. O primeiro passo será criar um algoritmo capaz de ajustar automaticamente a intensidade dos estímulos e calcular os limiares auditivos dos pacientes, com base nas diretrizes do Método HW. Esse algoritmo irá adaptar a intensidade dos sons conforme as respostas dos pacientes, seguindo os parâmetros específicos do método para garantir que os limiares sejam obtidos de forma eficiente.

Para garantir a precisão do processo, podem ser utilizados modelos psicométricos, que são amplamente reconhecidos para simular como os pacientes respondem a diferentes níveis de estímulo auditivo. Tais modelos ajudam a entender a probabilidade de uma pessoa detectar um som em diferentes intensidades, e o algoritmo irá se ajustar conforme essas respostas simuladas. Dessa forma, o Método HW será combinado com esses modelos para encontrar os limiares auditivos com maior precisão.

A próxima etapa será avaliar quantos estímulos são realmente necessários para determinar os limiares em diferentes frequências auditivas, como 250 Hz, 500 Hz, 1000 Hz, 2000 Hz, 3000 Hz, 4000 Hz, 6000 Hz e 8000 Hz. Através das simulações de Monte Carlo, podemos simular diversas condições e analisar quantos estímulos são necessários para alcançar os limiares. Para medir a precisão do audiograma obtido, será utilizado o erro médio quadrático (EMQ), comparando o audiograma gerado pelo Método HW com o audiograma verdadeiro, derivado do modelo psicométrico.

Utilizando os processos estocásticos e inferência bayesiana para implementar um algoritmo de aprendizado de máquina, será possível recriar o trabalho descrito por Song et al. (2018) e criar novos, utilizando diferentes técnicas de aprendizado de máquina, como Regressão Logística, Máquinas de Vetores de Suporte (SVM), k-vizinhos mais próximos (KNN), Floresta Aleatória e Redes Neurais, que serão aplicadas para criar audiogramas mais precisos e reduzir a quantidade de estímulos necessários para gerar os limiares.

RESULTADOS E DISCUSSÕES:

Tendo em vista que o projeto ainda está em andamento os resultados obtidos não se assemelham aos resultados esperados, porém já foram alcançados alguns marcos, tais como:



- A simulação de funções psicométricas utilizando a função logística e a distribuição gaussiana acumulada, que nos permite simular o comportamento da audição humana.
- A implementação do algoritmo HW visando a apuração dos resultados obtidos nas diferentes técnicas de aprendizado de máquina que será utilizado posteriormente.
- A aplicação da regressão logística para uma frequência, utilizando os métodos de Newton-Raphson e do gradiente descendente para determinar a máxima verossimilhança, para ambos foi utilizado o método dos mínimos quadrados para determinar o resultado a priori, o resultado foram curvas gaussianas utilizadas para determinar o limiar auditivo.

Atualmente está sendo trabalhado formas para replicar o trabalho descrito por Song et al. (2018).

CONCLUSÕES:

A proposta deste estudo é comparar métodos convencionais com abordagens baseadas em aprendizado de máquina para a obtenção de audiogramas. A meta é reduzir a quantidade de estímulos sem afetar a qualidade da análise. O projeto irá investigar diferentes algoritmos de aprendizado de máquina aplicando-os à construção de audiogramas.

Portanto espera-se que os resultados ofereçam soluções que reduzam a quantidade de estímulos e mantenham a eficácia da audiometria, com um impacto significativo na prática clínica, tornando o exame mais acessível e menos demorado. Além disso, os avanços podem contribuir para a melhoria do diagnóstico precoce de distúrbios auditivos, que afeta milhões de pessoas, especialmente crianças.

REFERÊNCIAS:

American National Standards Institute. Methods for manual pure-tone threshold audiometry. ANSI. 2004; 3:21.

American Speech-Language-Hearing Association. Guidelines for manual pure-tone threshold audiometry. 2005.

BÉKÉSY, Georg v. A new audiometer. **Acta oto-laryngologica**, v. 35, n. 5-6, p. 411-422, 1947.

CARHART, Raymond; JERGER, James F. Preferred method for clinical determination of pure-tone thresholds. **Journal of speech and hearing disorders**, v. 24, n. 4, p. 330-345, 1959.

FRANKS, John R. et al. Hearing measurement. Occupational exposure to noise: evaluation, prevention and control. **Geneva: World Health Organization**, p. 183-231, 2001.



HO, Allan Thiam Poh; HILDRETH, Anthony J.; LINDSEY, Leon. Computer-assisted audiometry versus manual audiometry. **Otology & Neurotology**, v. 30, n. 7, p. 876-883, 2009.

HUGHSON, WAITER; WESTLAKE, Harold. Manual for program outline for rehabilitation of aural casualties both military and civilian. **Trans Am Acad Ophthalmol Otolaryngol**, v. 48, n. Suppl, p. 1-15, 1944.

MAHOMED, Faheema et al. Validity of automated threshold audiometry: a systematic review and meta-analysis. **Ear and hearing**, 2013.

MARGOLIS, Robert H. et al. AMTAS®: Automated method for testing auditory sensitivity: Validation studies. **International journal of audiology**, v. 49, n. 3, p. 185-194, 2010.

SONG, Xinyu D.; SUKESAN, Kiron A.; BARBOUR, Dennis L. Bayesian active probabilistic classification for psychometric field estimation. **Attention, Perception, & Psychophysics**, v. 80, p. 798-812, 2018.

SONG, Xinyu D.; GARNETT, Roman; BARBOUR, Dennis L. Psychometric function estimation by probabilistic classification. **The Journal of the Acoustical Society of America**, v. 141, n. 4, p. 2513-2525, 2017.

SONG, Xinyu D. et al. Fast, continuous audiogram estimation using machine learning. **Ear and hearing**, v. 36, n. 6, p. e326, 2015.

SWANEPOEL, De Wet et al. Hearing assessment—reliability, accuracy, and efficiency of automated audiometry. **Telemedicine and e-Health**, v. 16, n. 5, p. 557-563, 2010.

VOGEL, Donald A. et al. The clinical audiogram: its history and current use. **Commun Disord Rev**, v. 1, n. 2, p. 81-94, 2007.