

Movimentação de Aluno em Sala de Aula: Análise Descritiva de Dados de Wearables

Poliana Nascimento Ferreira¹, Juliana L. Beda¹,
Guilherme D. Belarmino¹, Carla Lopes Rodriguez¹, Vivian Genaro Motti²

¹ Universidade Federal do ABC (UFABC) - Santo André - SP - Brasil

² George Mason University - Fairfax - VA - Estados Unidos

{poliana.ferreira, c.rodriguez}@ufabc.edu.br, vmotti@gmu.edu

Abstract. *The objective observation of a child's behavior in the classroom can be done using motion sensors. These sensors can collect data about the level of agitation, concentration and engagement of a child. This research seeks to carry out a descriptive analysis on movement data collected from 2nd grade students. Data collection was carried out during a 30-minute Portuguese class. The data consists of the values (x,y,z) of the accelerometer and the subjective information noted by the researchers during class. The analysis was carried out looking for trends in the relationship between movement and attention, activity and class moment. As a result, we notice that there is a high correlation between attention and movement; and a low accuracy in classifying specific activities.*

Resumo. *A observação objetiva do comportamento de uma criança em sala de aula pode ser feita utilizando sensores de movimento, podendo gerar informações sobre nível de agitação, concentração e engajamento. Esta pesquisa busca realizar uma análise descritiva sobre dados de movimento coletados do aluno do 2o ano do EF. A coleta foi feita durante uma aula de português, com duração de 30 minutos. Os dados consistem nos valores (x,y,z) do sensor acelerômetro e nas informações subjetivas anotadas pelos pesquisadores na aula. A análise foi realizada buscando tendências de relação entre movimento e atenção, atividade e momento da aula. Como resultados, nota-se alta correlação entre atenção e movimento; e baixa acurácia na classificação de atividades específicas.*

1. Introdução

A análise da atenção, engajamento e atividades dos alunos é um importante componente para melhorar o ensino e o aprendizado [Parambil *et al.* 2022, Dinesh *et al.* 2016]. Todavia, a identificação das características de cada indivíduo manualmente não é trivial, sendo um desafio para a área de informática na educação [Costa *et al.* 2020]. Dessa forma, considera-se necessário investigar formas automáticas de mensurar o comportamento dos estudantes. Em contextos presenciais de aprendizagem, o comportamento pode ser observado por meio de dispositivos *wearables* [Ferreira *et al.* 2020] com sensores.

[Liu *et al.* 2021] realizou um mapeamento sistemático destacando o uso dos dispositivos vestíveis, assim como suas vantagens e potencialidades no contexto de *Learning Analytics*. De forma prática, e considerando alunos de nível universitários, [Zhang *et al.* 2017] utilizaram um “boné inteligente” com câmera e sensor de movimento, e uma caneta com uma *tag* para aferir o nível de atenção dos estudantes em uma

sala de aula presencial. Eles destacaram a importância das informações para os professores e a necessidade de mais pesquisas na área. Já [Zhu *et al.*, 2017] trazem a classificação de atividades de escrita por meio de um relógio *wearable* com acelerômetro e giroscópio.

Considerando o público de crianças, destaca-se o estudo da interação entre alunos e o material em sala de aula Montessori [Saquib *et al.*, 2018] usando acelerômetro vestível embutido no sapato das crianças e *tags* nos brinquedos. Além disso, [Geršak *et al.*, 2020] utilizam dispositivos *wearables* e observaram que diferentes fatores da aula impactaram nas características fisiológicas do aluno. Ao traçar um novo curso de ação pedagógica, houve a melhora na retenção do conteúdo. Na literatura nacional não foram identificados trabalhos primários dentro de um ambiente presencial de aprendizagem para observar comportamento do aluno de forma automática.

Apesar de sua importância, a utilização de sensores para inferir características dos alunos em salas de aula presenciais do ensino básico, especialmente com crianças, ainda é escasso [Ferreira *et al.*, 2020, Koutromanos and Kazakou 2020]. Assim, e considerando que as crianças possuem padrões de comportamento diferentes de adultos [Hosseini *et al.*, 2018], necessita-se uma maior exploração da área.

O objetivo deste artigo, então, é apresentar a análise exploratória de informações de movimento de um estudante em uma aula presencial de português de 30 minutos. Buscou-se identificar se há relação entre os dados do acelerômetro em uma pulseira vestível, e as atividades e nível de atenção do aluno.

2. Metodologia

A metodologia utilizada consistiu na coleta dos dados, pré-processamento, separação de *time-frames*, extração de características e atributos relevantes, extração de coeficientes de correlação, e avaliação de algoritmos de classificação de atividades dos alunos.

2.1. Coleta dos Dados

A coleta dos dados foi realizada em uma escola pública, da rede municipal de ensino¹, em uma aula de português do 2o ano do EF no período da manhã, em novembro de 2021. O perfil do estudante voluntário foi identificado como uma criança de 8 anos, do sexo masculino, de 1,23m de altura e 42kg de peso (declarado pelos responsáveis).

Antes da aula, foi colocado o dispositivo *ActiGraph GT9X Link*² como uma pulseira no voluntário, o qual procedeu com a realização de suas atividades na sala de aula normalmente. O dispositivo possui um acelerômetro [Sasaki *et al.*, 2017] de +/-8g e coletou os dados (eixos x , y , z) na frequência de 100Hz. Além disso, a pesquisadora estava presente na sala de aula observando o aluno, e fez anotações sobre o nível da atenção (3 níveis: atento, médio, desatento), atividades do aluno (e.g. escrevendo, vira para trás, etc) e o que estava acontecendo na aula para fins de comparação.

2.2. Pré-Processamento

Para a extração dos dados do dispositivo, foi utilizada a plataforma *ActiLife*³. Os dados foram exportados para o formato de CSV (comma-separated values) com os 3 eixos do

¹A coleta de dados e análise teve aprovação do CEP (CAAE 48505221.0.0000.5594) e cumpriu com os protocolos de saúde da escola. Os voluntários foram informados do teor da pesquisa e assinaram o TCLE.

²<https://actigraphcorp.com/actigraph-link/>

³<https://actigraphcorp.com/actilife/>

acelerômetro e o *timestamp*. Após a seleção do período de 30 minutos referente a aula de português, obteve-se como resultado uma planilha com 180.000 linhas de dados.

As anotações realizadas pela pesquisadora foram documentadas em uma tabela, conforme ilustrado na Tabela 1. Em relação ao momento da aula, observou-se a tarefa e as ações da professora. Já o campo “Atenção” diz respeito a concentração do aluno no momento, empenho na atividade, participação e distrações; foram definidas 3 categorias: atento (+), médio (+/-) e desatento (-). Observa-se que este campo fornece uma impressão subjetiva da pesquisadora em relação ao estado geral do aluno a cada minuto.

Tabela 1. Exemplo de dados na tabela de atividades

<i>Timestamp</i>	Atenção	Atividades	Aula - Professora
08:19	+	Balançando a perna (pouco) Mexendo no lápis	Explica a atividade no quadro
08:20	+/-	Se espreguiça Faz gestos participando da aula Mudando página da atividade Coçando o olho Mexendo na borracha	Olha a atividade nas carteiras

A segunda etapa do estudo consistiu em padronizar as informações coletadas para leitura pelo algoritmo de análise. Com relação aos valores dos acelerômetros, os valores foram transformados de *string* para numérico. Além disso, também foi necessário interpretar o *timestamp* usando a biblioteca *datetime* do *Python*. Já para as anotações como na Tabela 1, o *timestamp* também foi interpretado e os dados de atenção foram transformados em (0 (atento), 1 (médio) e 2 (desatento)). As atividades e aula foram listadas e categorizadas considerando o que estava e ou não presente dentro de cada minuto.

A terceira etapa do estudo teve por objetivo relacionar as duas tabelas usando um algoritmo em *Python*. Para todas as linhas de dados do mesmo minuto (exemplo 08:19:41.000 e 08:19:42.010), foi atribuída a mesma classificação referente à Tabela 1 (exemplo 08:19). Apenas as atividades “levanta” e “senta”, marcadas nas anotações com minuto e segundo específicos, foram relacionadas aos dados do acelerômetro considerando o segundo em que a atividade aconteceu.

2.3. Separação de Time-Frames

A separação de *time-frames* consiste em um método de segmentação utilizado em séries temporais, representando sub-grupos de dados similares [Labrador and Yejas 2013], representando a atividade realizada. Após a separação, cada segmento pode ser analisado de forma separada e sequencial [Lima *et al.* 2019].

Nesta pesquisa, foi escolhido realizar a criação de janelas de tempo 50% sobrepostas. A quantidade de dados em cada janela também é um fator que depende do problema a ser trabalhado. Foi decidida pela utilização de *time-frames* de 1 segundo, ou seja, com 100 pontos de dados cada. A justificativa para isso são trabalhos da literatura que utilizaram tal valor [Hosseini *et al.* 2018], além da observação da pesquisadora em relação aos movimentos dinâmicos das crianças em sala de aula. Também foram criados *time-frames* de 10, 30 e 60 segundos para as análises.

2.4. Extração de Atributos

A extração de atributos ou características trata-se de um processo de transformação dos dados segmentados (as janelas de tempo) [Labrador *and* Yejas 2013]. Isto é necessário no contexto de sensores inerciais porque as séries temporais não podem ser utilizadas diretamente em algoritmos tradicionais de classificação e interpretação.

A área de Reconhecimento de Atividades Humanas (HAR) avança no aspecto de seleção de características de séries de dados de acelerômetros. De maneira geral, os atributos podem ser divididos em: (1) Domínio de tempo e (2) Domínio de frequência. Os atributos utilizados neste trabalho foram escolhidos a partir de [Lima *et al.* 2019]⁴.

Em relação ao domínio de tempo, foram selecionadas inicialmente como características: ‘*minimum*’, ‘*maximum*’, ‘*amplitude*’, ‘*sum*’, ‘*abs sum*’, ‘*energy*’, ‘*euclidian norm*’, ‘*power*’, ‘*mean*’, ‘*abs mean*’, ‘*std deviation*’, ‘*pearson coefficient*’, ‘*mean sqr*’, ‘*abs deviation mean*’, ‘*error sqr sum*’, ‘*variance*’, ‘*skewness*’, ‘*kurtosis*’, ‘*zero-crossing*’.

O domínio de frequência permite observar o padrão das oscilações dos valores do acelerômetro com o tempo. Foram selecionados: FFT (*Fast Fourier Transform*) e *Haar Wavelet* (versão da transformada de *Wavelet* usada em HAR [Lima *et al.* 2019]).

2.5. Análise da Atenção

Um dos pontos de interesse é a relação entre a atenção e o movimento do aluno. Como hipótese, tem-se que, durante atividades pedagógicas que exigem que o aluno esteja sentado na carteira e tenha foco nas orientações e explicação da professora e na tarefa a ser realizada, a intensidade do movimento é menor quando a atenção é maior, e vice-versa.

Para se verificar tal hipótese, utilizou-se os atributos amplitude, soma, soma absoluta e desvio padrão dentro do *time-frame* de 60 segundos. Para cada valor, foi atribuído um valor da atenção (quanto menor o valor, maior a atenção). Foi calculado, então, o coeficiente de correlação de *Pearson* entre os atributos e a atenção. Além do coeficiente, também foi gerado um gráfico *boxplot* para cada variável e eixo do acelerômetro.

2.6. Aplicação de Algoritmos de Classificação

Os algoritmos de classificação escolhidos podem ser observados na Tabela 3. Considerando a quantidade de atividades, foi realizado o reconhecimento das atividades “escrevendo”, “se mexendo”, “levanta”, “senta”, “parado”, “mexendo na mochila” e “outros”.

Tabela 2. Algoritmos de Classificação

Algoritmo	Parâmetros do Teste
KNN	Vizinhos: 5; Peso: <i>uniform</i> ; Algoritmo: auto
Árvore de Decisão	Critério: <i>entropy</i> ; <i>Splitter</i> : <i>best</i>
<i>Naive Bayes</i>	Tipo: <i>gaussian</i>
Rede Neural Simples	Ativação: <i>relu</i> ; Qt-camadas: 8; Tam-camadas: 265

3. Resultados e Discussões

Este trabalho busca explorar os dados de movimento colhidos com um acelerômetro de um aluno do 2o ano do EF durante aula de português. Duas perguntas centrais nortearam

⁴As fórmulas dos atributos podem ser encontradas nas tabelas 3.7 e 3.8 de [Lima *et al.* 2019].

a análise: P1) Há relação entre o nível de atenção e movimento? P2) É possível realizar a classificação das atividades do estudante observadas na aula pela pesquisadora através dos atributos extraídos dos dados coletados?

3.1. Análise Inicial

Os dados do acelerômetro consistem em um ponto com valores dos eixos (x , y e z) a cada centésimo de segundo. Tratam-se, então, de 3 variáveis quantitativas contínuas, com variação entre -8 e 8. Pode-se ver os três eixos em um período da aula representados na Figura 1. Observa-se que o valor pode ser a favor ou contrário à força da gravidade (positivo ou negativo, respectivamente), sendo que o valor absoluto representa a intensidade do movimento no momento. Ou seja, valores mais extremos representam mais movimento.




Figura 1. Representação dos eixos x, y e z do acelerômetro e hora do dia

As observações da pesquisadora em sala de aula deram origem a uma tabela de anotações, referentes às atividades, nível de atenção e o que estava acontecendo na aula no momento. Foram registradas 73 atividades diferentes.

A Figura 2(a) apresenta as quatro atividades com maior frequência em minutos, além do “senta” e “levanta”, os quais julgou-se relevante apresentar, uma vez que trata-se da saída do aluno da carteira. Observa-se predominância da atividade de escrever, uma vez que a professor pediu para copiar a explicação do quadro e realizar tarefas escritas. A atividade de mexendo na mochila foi uma surpresa, uma vez que esperava-se que o aluno só precisasse pegar o material uma vez. Entretanto, ele guardou os lápis coloridos na mochila, e a cada vez que trocava de cor na atividade, ele mexia novamente na mochila.

O nível de atenção está representado na Figura 2(b). O aluno esteve atento à aula e à tarefa que estava fazendo em 57% da aula. Em relação a turma, a professora considerou que este aluno tem atenção média-alta, o que é percebido também nas anotações.




Figura 2. Análise dos Atributos das Anotações da Pesquisadora

O momento da aula anotado representou o que a professora estava fazendo a cada minuto e o que o aluno deveria atingir. Por exemplo, no momento da explicação, era espe-

rado que o aluno estivesse sentado na cadeira prestando atenção, ou copiando a atividade do quadro. Já no momento de conferência da atividade, a professora caminhava entre as carteiras olhando o que cada um fez/estava fazendo.

A análise consistiu em observar a relação entre a atenção e o momento da aula. A Figura 3 apresenta este resultado. Pode-se observar que no momentos de fazer atividades, o aluno tende a ficar mais concentrado. Entretanto, a desatenção não tem relação com o que está acontecendo na aula, sendo mais influenciada por fatores externos.




Figura 3. Relação entre o nível de atenção, momento da aula e hora do dia.

3.2. Atributos nos Domínios de Tempo e Frequência

A extração das variáveis foi feita no *Python*, utilizando as bibliotecas *Numpy*, *Pandas* e *Math*. Em relação às variáveis do domínio de tempo, percebeu-se que algumas tinham a mesma fórmula como base, tendo valores resultantes de ordem similar. Um exemplo é a soma e a média, as quais se diferenciam em relação à grandeza, mas seguem o padrão.

Em razão disso, foi decidido realizar uma amostragem dentre as variáveis geradas, considerando apenas as que não tinham muita correlação entre si. Foi necessário, uma vez que os algoritmos de *Machine Learning* da classificação poderiam dar maior peso a uma determinada característica apenas por ela ser retratada pelos dados mais de uma vez.

Foram gerada três matrizes de correlação da variáveis (uma para cada eixo). Observou-se que, apesar do padrão do mapa de calor gerado se manter o mesmo na comparação entre os valores de cada eixo, o valor do coeficiente foi alterado. Um exemplo foi o coeficiente de correlação entre o Soma e o Soma Absoluta, o qual para o eixo x é na faixa de -0.25, para o eixo y é na faixa de 0.75 e para o eixo z na faixa de -0.5. Isso se dá em razão da amplitude de cada eixo e da orientação. O eixo x possui maior variação de valores positivos e negativos, enquanto o eixo y possui mais positivos.

As variáveis selecionadas para os algoritmos de classificação foram amplitude, a soma, a soma absoluta, o desvio padrão, o coeficiente de *pearson*, *skewness*, *kurtosis* e *zero-crossing*. Além das duas variáveis do domínio de frequência: *FFT* e *Haar Wavelet*.

3.3. Análise da Atenção

Para a análise da atenção, utilizou-se do coeficiente de *Pearson*. Os valores foram gerados a partir de um programa de *Python* e a função de correlação do *Pandas*. Os valores encontrados entre a soma absoluta, soma, amplitude e desvio padrão em relação à atenção estão representados na Tabela 3.⁵

⁵As cores representam a nível de correlação, de acordo com [Schober *et al.*, 2018]: (Verde)- Entre 0.7 e 0.89: correlação forte; (Azul)- Entre 0.40 e 0.69: correlação moderada; (Amarelo)- Entre 0.1 e 0.39: correlação fraca; (Vermelho)- Entre 0.0 e 0.09: correlação desprezível.

Observa-se que há uma correlação positiva forte entre a atenção e as soma absoluta total ($x+y+z$), de x e de z . A soma absoluta representa o nível de intensidade do movimento em cada eixo e total. Dessa forma, confirmou-se a (P1) de que a atenção tem relação com a intensidade do movimento para este aluno. É interessante perceber a diferença do eixo y , o qual apresenta correlação moderada negativa neste atributo.

A amplitude, para o x , y e z apresentou correlação moderada com a atenção; entretanto correlação fraca quando considerado o total. Isso se dá pois as variáveis tem valores mínimo e máximo diferentes, não podendo associar-se dessa forma. Na Figura 4, é possível visualizar a relação entre as categorias de atento, médio e desatento com a soma absoluta total, considerando *time-frame* de 60s.

Tabela 3. Valores de Correlação entre os Atributos do Acelerômetro e a Atenção.

	Soma Abs.	Soma	Amplitude	Desvio Padrão
x	0.703	-0.005	0.501	0.667
y	-0.463	-0.401	0.567	0.505
z	0.739	-0.373	0.442	0.490
$x+y+z$	0.865	-0.383	0.217	0.411




Figura 4. Comparação entre o nível de atenção e o atributo de Soma Abs. Total.

3.4. Classificação das Atividades

A classificação das atividades foi realizada usando *Python* e das funções específicas da biblioteca *SKLearn*. Os algoritmos utilizados tratam-se de técnicas de aprendizado de máquina supervisionado, que podem ser utilizadas para classificar dados multi-categóricos. A seleção dos algoritmos foi realizada baseando-se em outros artigos de HAR.

O primeiro algoritmo utilizado foi o KNN, o qual calcula a similaridade entre uma instância do problema e a base de treino, então classifica a partir da categoria dos k vizinhos mais próximos. Depois, utilizou-se árvore de decisão, que define regras a partir dos atributos e cada caminho da árvore leva a uma categoria. Já o *Naive Bayes* utiliza o teorema de *Bayes* e probabilidade. O quarto algoritmo utilizado foi a rede neural, que trata-se de um modelo matemático baseado no cérebro humano e representado por subestruturas (neurônios) e funções de ativação [Faceli *et al.*, 2011].

A Tabela 4 mostra o valor da acurácia de classificação para os 4 modelos desenvolvidos. Observa-se que a acurácia total (todas as categorias) não foi considerada satisfatória por possuir valor menor que 90%. Os autores julgam ainda não ser possível classificar corretamente as atividades usando a base de dados coletada deste aluno. Já as atividades senta e levanta tiveram um melhor resultado, especialmente na rede neural simples. Uma hipótese para justificar tal resultado é que estas duas atividades estão descritas na ordem de segundos, sendo mais preciso e auxiliando na *performance* do algoritmo.

Tabela 4. Acurácia de classificação para cada algoritmo (*time-frame*: 1s).

Algoritmo	Senta	Levanta	Todas as Categorias
KNN	77%	74%	58%
Árvore de Decisão	63%	69%	51%
Naive Bayes	77%	77%	53%
Rede Neural Simples	91%	89%	64%

3.5. Discussões

Apesar da relação entre a atenção e movimento deste aluno, esta informação pode variar. Há uma dependência com relação ao estilo da aula (e.g. em um momento que a professora necessita de mais interação, o aluno pode estar atento e participativo, e ao mesmo tempo com movimento intenso). Além disso, varia para cada indivíduo. A pesquisadora observou que uma criança da sala ficava levantando e sentando enquanto realizava a atividade (o que não representou falta de atenção, apenas movimentos característicos do indivíduo). Além disso, esta pesquisa possui limitações referentes ao tempo, local, amostra, número de sensores e posição dos dispositivos, o que pode alterar os resultados.

As informações geradas nesta pesquisa foram apresentadas à professora, a qual julgou que tais análises, se realizadas de maneira geral com mais alunos, tem potencial para ajudá-la em sala de aula, aumentar engajamento e detectar níveis de atenção variáveis dos alunos. Foi comentado também a possibilidade de outras análises como comparação do horário do dia com o movimento entre todos os alunos, o que pode servir de suporte para a construção dos planos pedagógicos da turma.

4. Considerações Finais

Dimensões comportamentais, cognitivas, emocionais e sociais são fatores que influenciam aos níveis de atenção, engajamento e atividades dos estudantes [Bergdahl *et al.*, 2020]. Essas informações podem ser observadas em AVAs ou de forma presencial. Na sala de aula presencial, os sensores inerciais e dispositivos vestíveis tem potencial de serem utilizados para extrair tais características de forma objetiva.

Neste trabalho, foi apresentada uma análise descritiva de dados de movimento obtidos através de sensor acelerômetro de um aluno do 2o ano do EF. Aliado ao movimento, a pesquisadora realizou anotações sobre a atenção, atividades e momento da aula a cada minuto, possibilitando o estabelecimento de relação entre eles. Como resultados, observou-se a correlação forte entre a intensidade de movimento e o nível de atenção. Além disso, foi feita a classificação das atividades do aluno com 4 algoritmos. Observou-se baixa acurácia em atividades específicas, tais como mexer na mochila.

Em trabalhos futuros, é possível que a atenção seja capturada em um intervalo de tempo menor, através de, por exemplo, câmeras. Não foi possível fazer isso por questões de privacidade dos alunos que não estavam participando da pesquisa. Além disso, recomenda-se a análise mais generalizada com relação à turma e à rotina escolar, expandindo este trabalho para mais de um aluno. Os autores do trabalho já realizaram a coleta dos dados considerando uma maior amostra de estudantes, e está em processo de análise.

Agradecimentos

Agradecemos à CAPES e ao programa de pós-graduação em Computação da UFABC

Referências

- Bergdahl, N., Nouri, J., and Fors, U. (2020). Disengagement, engagement and digital skills in technology-enhanced learning. *Education and information technologies*, 25(2):957–983.
- Costa, J. A., Dorça, F. A., and Araújo, R. D. (2020). Avaliação do comportamento de estudantes em um ambiente educacional ubíquo. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 182–191. SBC.
- Dinesh, D., Bijlani, K., *et al.* (2016). Student analytics for productive teaching/learning. In *2016 International Conference on Information Science (ICIS)*, pages 97–102. IEEE.
- Faceli, K., Lorena, A. C., Gama, J., and Carvalho, A. C. P. d. L. F. d. (2011). Inteligência artificial: uma abordagem de aprendizado de máquina.
- Ferreira, P. N., Rodriguez, C. L., and Motti, V. G. (2020). Wearables para coleta de dados de estudantes em ambiente escolar: Mapeamento sistemático. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1353–1362. SBC.
- Geršak, V., Vitulić, H. S., Prosen, S., Starc, G., Humar, I., and Geršak, G. (2020). Use of wearable devices to study activity of children in classroom; case study—learning geometry using movement. *Computer communications*, 150:581–588.
- Hosseini, A., Fazeli, S., van Vliet, E., Valencia, L., Habre, R., Sarrafzadeh, M., and Bui, A. (2018). Children activity recognition: Challenges and strategies. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 4331–4334. IEEE.
- Koutromanos, G. and Kazakou, G. (2020). The use of smart wearables in primary and secondary education: A systematic review. *Themes in eLearning*, 13:33–53.
- Labrador, M. A. and Yejas, O. D. L. (2013). *Human activity recognition: Using wearable sensors and smartphones*. CRC Press.
- Lima, W. S. *et al.* (2019). Reconhecimento de atividades humanas baseado na análise de fluxo contínuo de dados simbólicos.
- Liu, Z., Ren, Y., Kong, X., and Liu, S. (2021). Learning analytics based on wearable devices: A systematic literature review from 2011 to 2021. *Journal of Educational Computing Research*, page 07356331211064780.
- Parambil, M. M. A., Ali, L., Alnajjar, F., and Gochoo, M. (2022). Smart classroom: A deep learning approach towards attention assessment through class behavior detection. In *2022 Advances in Science and Engineering Technology International Conferences (ASET)*, pages 1–6. IEEE.
- Saqib, N., Bose, A., George, D., and Kamvar, S. (2018). Sensei: sensing educational interaction. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 1(4):1–27.
- Sasaki, J., Coutinho, A., Santos, C., Bertuol, C., Minatto, G., Berria, J., Tonosaki, L., Lima, L., Marchesan, M., Silveira, P., *et al.* (2017). Orientações para utilização de acelerômetros no brasil. *Revista Brasileira de Atividade Física & Saúde*, 22(2):110–126.

- Schober, P., Boer, C., and Schwarte, L. A. (2018). Correlation coefficients: appropriate use and interpretation. *Anesthesia & Analgesia*, 126(5):1763–1768.
- Zhang, X., Wu, C.-W., Fournier-Viger, P., Van, L.-D., and Tseng, Y.-C. (2017). Analyzing students' attention in class using wearable devices. In *2017 IEEE 18th international symposium on a world of wireless, mobile and multimedia networks (WoWMoM)*, pages 1–9. IEEE.
- Zhu, Z., Ober, S., and Jafari, R. (2017). Modeling and detecting student attention and interest level using wearable computers. In *2017 IEEE 14th international conference on wearable and implantable body sensor networks (BSN)*, pages 13–18. IEEE.