

Desonestidade Acadêmica em MOOCs que utilizam Avaliações Baseadas no Envio de Imagens

Gilson Saturnino dos Santos, Universidade Federal do Rio Grande do Sul,
gilsonsatu@gmail.com, 0000-0003-2398-8966

Gabriela Trindade Perry, Universidade Federal do Rio Grande do Sul,
gabriela.perry@ufrgs.br, 0000-0002-9405-4477

Resumo. A desonestidade acadêmica reduz a credibilidade dos cursos online e das instituições de ensino, sendo muito prevalente em função da dificuldade de supervisão e monitoramento. Nos MOOCs (*Massive Open Online Courses*) este problema é potencializado pela ausência de professores e pela falta de interação entre os alunos, sendo necessária a utilização de métodos automatizados para sua detecção. No caso de MOOCs cujas avaliações são baseadas em arquivos de imagem, esta identificação se torna mais problemática, considerando a dificuldade computacional de identificar imagens copiadas, alteradas ou fora de contexto. Neste trabalho apresenta-se o resultado de um estudo que investigou a prevalência e a categorização deste tipo de desonestidade acadêmica na plataforma de MOOCs Lumina, da UFRGS.

Palavras-chave: Desonestidade Acadêmica, MOOC, Plágio de Imagens, Classificação de Imagens.

Academic Dishonesty in MOOCs that Use Assessments Based on Image Submission

Abstract. *Academic dishonesty reduces the credibility of online courses and educational institutions and is very prevalent due to the difficulty of supervision and monitoring. In MOOCs (Massive Open Online Courses) this problem is exacerbated by the absence of teachers and the lack of interaction between students, making it necessary to use automated methods to detect it. In the case of MOOCs whose evaluations are based on image files, this identification becomes more problematic, considering the computational difficulty of identifying copied, altered, or out-of-context images. This work presents the results of a study that investigated the prevalence and categorization of this type of academic dishonesty on the Lumina MOOCs platform, from UFRGS.*

Keywords: *Academic Dishonesty, MOOC, Image Plagiarism, Image Classification.*

1. Introdução

Os MOOCs (*Massive Open Online Courses*) estão em evidência desde 2008, quando o termo foi citado pela primeira vez por Dave Cormier, em referência ao curso ministrado por George Siemens e Stephen Downes (Baturay, 2015; Yuan; Powell, 2013). Desde então, os MOOCs passaram a ser utilizados por milhões de estudantes e professores, observando-se uma espécie de democratização do conhecimento em várias áreas. Segundo Stellingwerff (2015) os MOOCs diminuem os limites para que as pessoas estudem. Sendo assim, importantes instituições de ensino enxergaram o potencial dos MOOCs, tanto para oferecer aos seus estudantes partes de unidades curriculares de forma online, quanto para divulgar seus cursos para potenciais alunos, professores e doadores (Belanger; Thornton, 2013; Rice, 2013). Em 2011 a universidade de Stanford começou a oferecer cursos deste tipo e posteriormente outras instituições de ensino passaram a oferecer MOOCs, como por

exemplo o MIT (*Massachusetts Institute of Technology*) e a universidade de Harvard. Iniciativas proprietárias visando o lucro também surgiram, como a Coursera, ainda em 2012, além de projetos sem fins lucrativos, como a Udeemy, em 2010 (Baturay, 2015; Yuan; Powell, 2013).

Com relação à avaliação, Chiang, Zhu e Yu (2022) destacam o problema da desonestidade acadêmica em MOOCs, caracterizada pela realização por parte do aluno de plágio, trapaça, falsificação, colaboração indevida ou cópia de atividades (Lambert et al., 2003). Os alunos que realizam estes comportamentos acabam obtendo vantagens injustas sobre os alunos que não utilizam esses métodos (Verhoef; Coetser, 2021), além de reduzir a credibilidade dos cursos e das instituições de ensino. No ambiente online, com a facilidade de uso proporcionado pelas ferramentas digitais e na maioria dos casos com a ausência de supervisão e monitoramento, o problema se intensifica, tornando-se motivo de preocupação das instituições que ofertam cursos nesta modalidade (Chiang; Zhu; Yu, 2022).

As ações para reduzir a desonestidade acadêmica são de dimensões institucionais, tecnológicas e sociais. É proposto por exemplo uma ampla divulgação das consequências e punições para este comportamento, além do uso de métodos tecnológicos para sua detecção (Chiang; Zhu; Yu, 2022). Estas propostas produzem nos estudantes a percepção dos riscos destes comportamentos. Entre os métodos tecnológicos, pode-se citar a integração do sistema de ensino com ferramentas de detecção de plágio em textos (Amigud et al., 2017). Esta automatização de detecção de plágio no contexto de arquivos de imagem se torna mais problemática, considerando a dificuldade computacional de identificar imagens originais, alteradas ou fora de contexto, a facilidade que os alunos possuem de encontrar imagens em serviços de busca e os recentes serviços de Inteligência Artificial, que permitem criar imagens a partir da entrada de texto (Patel et al., 2022).

Por estes motivos, nesta pesquisa se busca categorizar e contabilizar a prevalência da desonestidade acadêmica em MOOCs da plataforma Lumina da UFRGS.

2. Desonestidade Acadêmica

O fato das instituições e o mercado de trabalho reconhecerem os benefícios dos MOOCs e utilizarem o mesmo para créditos e contratações aumenta o interesse dos estudantes, e por isso garantir a avaliação adequada passa a ser um desafio para estes ambientes de ensino. No trabalho de Deng, Benckendorff e Gannaway (2019) é apontado que a utilização dos avanços da área de aprendizado de máquina podem ampliar as técnicas de avaliação e recursos pedagógicos. Hew e Cheung (2014) identificaram que as características de MOOCs que dificultam a identificação de comportamentos desonestos são a ausência de interação com os alunos e garantir a identificação dos alunos. Como as correções de avaliações e pareceres de atividades são automáticos, o desenvolvimento de tecnologias é muito importante para garantir agilidade, segurança e confiabilidade ao processo.

Entre as contribuições pode-se citar a detecção de desonestidade acadêmica, caracterizada pela realização por parte do estudante de plágio, trapaça, falsificação, colaboração indevida ou cópia de atividades (Lambert et al., 2003). Segundo Chiang, Zhu, Yu (2022), este comportamento possui dimensões institucionais, tecnológicas e sociais, sendo motivo de preocupação das instituições de ensino também de cursos online, pois reduz a confiabilidade e credibilidade dos cursos e instituições.

Haar e Bell (2020) descreveram uma estratégia que exigia pouco esforço, utilizada por 20% dos alunos, que consistia em se matricular diversas vezes no mesmo curso para ter acesso às respostas dos testes das edições anteriores. Na sua revisão sobre a desonestidade acadêmica, Surahman e Wang (2022) indicam que o plágio, a cópia de respostas e as colaborações inadequadas (como contar com o apoio de outros) são as estratégias de

trapaça mais comuns. Jaramillo-Morillo et al. (2020) estimaram que os certificados obtidos com apoio de comportamentos indesejados atingiram 17% em SPOCs (*Small Private Online Courses*) oferecidos como disciplinas optativas em uma universidade. O método de identificação utilizou duas matrizes de distância, uma com data e hora do envio das respostas e outra com as respostas de cada avaliação. Os autores também observaram que a quantidade de material instrucional acessado pelos alunos trapaceiros não diferiu significativamente dos não-trapaceiros. Ruipérez-Valiente et al. (2021) buscaram identificar perfis de colaboração em MOOCs, utilizando método semelhante ao recém descrito, agrupando os alunos por nota, número de inscrições, dias ativos e visualizações de vídeo. Os autores também identificaram cinco tipos de associações entre contas de usuários, com apenas uma denotando uma relação de colaboração positiva.

King, Guyette e Piotrowski (2009) apontam que a prática deste tipo de comportamento em ambiente online é mais fácil, considerando a falta de supervisão. Harmon e Lambrinos (2008) sugerem que a supervisão de avaliações pode equilibrar a desonestidade acadêmica entre cursos presenciais e online. Por outro lado, no trabalho de Peled et al. (2019) é constatado que os estudantes de cursos presenciais praticam mais métodos desonestos. Para Chiang, Zhu e Yu (2022) é proporcional os níveis de desonestidade acadêmica entre alunos de cursos presenciais e online. Também pode ocorrer de existir mais divulgação de informações e trabalhos sobre este tema na modalidade presencial, como apontado por Sidi, Blau e Eshet-Alkalai (2019).

Alessio et al. (2017) e Daffin e Jones (2018) apontam notas mais baixas em exames online supervisionados por meio de software do que notas obtidas por estudantes que não foram supervisionados, sugerindo que notas altas podem ser mais facilmente obtidas por estudantes dispostos a trapacear. Entre os motivos de trapaça encontrados por Chiang, Zhu e Yu (2022) estão o medo de fracassar, a dificuldade de gerenciar o tempo de estudo, o estresse, os problemas com o uso da tecnologia, a sobrecarga de trabalho, a falta de monitoramento e o nível de dificuldade das atividades. Este estudo destacou que a falta de monitoramento foi apontado pelos estudantes como um incentivador destes comportamentos.

A integração do sistema de ensino com ferramentas de detecção de plágio em textos também é um importante método tecnológico para redução de fraudes. Ison (2020) sugere que software de estilometria pode ser utilizado para detecção de fraudes na autoria de textos, mesmo assim, reconhece que não é um método infalível.

3. Ensino de Design, Arte e Arquitetura

Segundo Ouwerkerk (2018), o ensino de Design possui a tradição do uso de estúdio físico para a aprendizagem do processo de design, possibilitando ao estudante fazer e aprender por tentativa, erro e exploração, supervisionado por um professor e acompanhado de seus colegas. Este processo inclui apresentação visual, visualização compartilhada, comentários e anotações, tornando o estúdio ideal para a interação aluno-aluno e aluno-professor, pois há necessidade de compartilhar, fornecer e receber feedback. Argumenta-se que estas também são características de outras áreas cuja prática é baseada na produção de imagens, tais como Arquitetura e Urbanismo, Comunicação (antigamente chamada de “Publicidade e Propaganda”) e diversas especialidades dos cursos de Artes Visuais (tais como Pintura e Desenho). Segundo Wragg (2020) o desenvolvimento de atividades sociais foi essencial para o sucesso do curso online de design descrito em seu trabalho. Foi empregado o conceito de tarefas introdutórias, conhecidas como “aperto de mão virtual”.

Exercícios de avaliação de cursos relacionados a design têm uma particularidade importante: é difícil avaliar se as respostas estão “certas” ou “erradas”, ou mesmo atribuir notas para a qualidade das soluções propostas pelos alunos. Por exemplo, se num curso de

programação é possível escrever um programa que consiga identificar que um determinado desenho é uma casa ou uma bandeira (Muuli et al., 2020), em um curso de design o objetivo seria, por exemplo, “desenhar uma bandeira que transmita os valores do país que ela representa”. Num caso como este, mesmo que as bandeiras sejam simples - com poucas cores e formas pouco rebuscadas - a questão da representação e da subjetividade e sua tradução para uma forma bidimensional é precisamente uma das coisas mais difíceis de aprender (e ensinar). Sendo assim, provavelmente não é viável que um algoritmo, por mais sofisticado que seja, possa de fato “reconhecer” as qualidades da solução de um problema de design ou arte. Daalhuizen e Schoormans (2018) apontam que um dos desafios para implementar um curso de design em MOOC é a avaliação. O autor sugere a elaboração de rubricas para melhorar a avaliação por pares e o desenvolvimento de tecnologias que permitam ampliar a interação dos alunos.

Por outro lado, tais algoritmos poderiam ser um suporte inestimável em tarefas que um ser humano teria dificuldade para executar em grande escala, como a identificação de imagens repetidas. Fraudes em avaliações com produção de imagens podem ocorrer com envio de uma imagem que já foi enviada antes, pois o avaliador provavelmente não perceberá ter visto esta imagem anteriormente, considerando uma grande quantidade de imagens. Em cursos que chegam a ter mais de mil inscritos, seria muito difícil identificar este tipo de burla, extremamente vantajosa em caso de sucesso para o aluno mal intencionado.

Foram encontrados vários trabalhos com adaptações de ferramentas e integração no sistema de ensino: Sketchdrive (Ouwkerk, 2018; Stellingwerff et al., 2018); ConceptBoard e GoVisually (Fleischmann, 2020); RealtimeBoards, voiceThread e Flickr (Wragg, 2020); Pinterest, Sketchfab, Weebly (Stellingwerff et al., 2018). Ferramentas genéricas também são citadas: blogs, fóruns e bate-papo. Percebe-se que ainda não há um padrão de estúdio virtual e sistema de elaboração, compartilhamento, colaboração, feedback, avaliação e controle dos trabalhos entregues.

Segundo Ouwkerk (2018) os professores perceberam que mesmo as ferramentas da Web 2.0 são insatisfatórias para a necessidade de compartilhamento de cursos online de arte e design. Sendo assim, o autor apresentou o desenvolvimento de um curso integrado com o Sketchdrive, como uma tentativa de solução para atender o requisito de compartilhamento de trabalhos produzidos. Além disso, foi realizada uma parceria com a equipe de desenvolvimento do Sketchdrive para melhorias da ferramenta. Outro trabalho que também utilizou o Sketchdrive foi de Stellingwerff et al. (2018), em que foi analisado pelos autores a execução de MOOCs da área de Design. Os autores destacam a importância do ambiente de estúdio, o compartilhamento de trabalhos, a colaboração, o processo de apresentar, comentar e melhorar os trabalhos, bem como as dificuldades em realizar esta atividade em uma plataforma online. O Sketchdrive foi utilizado para compartilhar e permitir a interação entre os alunos. Os autores destacam que são importantes feedbacks construtivos entre alunos e também com a participação do professor. Um problema descrito no trabalho foi de que o fórum de discussão com imagens tornaram-se longos e com baixa usabilidade, considerado assim inadequado para compartilhar e refletir sobre os artefatos, sendo posteriormente utilizado ferramentas externas.

Percebe-se que os principais pontos abordados nos trabalhos apresentados nesta seção são: a) necessidade de um estúdio virtual e b) proporcionar uma experiência de interação, feedback e avaliação satisfatória aos estudantes. Não foram encontradas referências ao problema de desonestidade acadêmica, provavelmente pelo foco inicial em fazer funcionar o ensino online nas áreas de arte e design, atendendo as necessidades de colaboração e feedback, além da complexidade já mencionada de detectar comportamentos desonestos em trabalhos que utilizam o envio de imagens. É necessário ressaltar também que

os pontos elencados nos trabalhos estão conectados com a melhoria e desenvolvimento de tecnologias, como recomendado por Daalhuizen e Schoormans (2018).

4. Visão computacional e reconhecimento de imagem

A inteligência artificial é um fator de impacto e revoluciona diversos aspectos da vida moderna em várias áreas, como saúde, educação, segurança e gestão (Xu et al., 2021). Entre os avanços que viabilizaram esta revolução foi o desenvolvimento de algoritmos de aprendizagem de máquina com capacidade de prever e gerar modelos baseados em enormes quantidades de dados. Atualmente, estão disponíveis ferramentas com capacidade de processar linguagem natural, identificar e criar imagens, vídeos, vozes e músicas (Mondal et al., 2020).

A “visão” de uma máquina é o foco dos estudos da área de visão computacional, cujos sistemas fazem uso de imagens geradas por computador ou capturadas por câmeras, sensores e outros dispositivos, bem como buscam identificar objetos. Na tarefa de reconhecimento dos elementos em uma imagem, se destaca a Rede Neural Convolucional (*Convolutional Neural Network* - CNN). A CNN é inspirada nas Redes Neurais Artificiais multicamadas com neurônio perceptron, e seu objetivo é extrair características das imagens automaticamente, utilizando filtros convolucionais definidos a partir dos pesos dos neurônios da rede (Abadi et al., 2016).

O trabalho de Araujo et al. (2018) apresenta um sistema que permite realizar pesquisas reversa de imagens científicas utilizando CNNs. Na pesquisa reversa de imagem, a entrada não é um texto com características procuradas na base de imagens, mas sim uma imagem. A acurácia na pesquisa, segundo os autores, chegou a 95%, com 4 bases de imagens de células e materiais. Nesse sentido, pode-se utilizar estratégia semelhante, baseada em inteligência artificial para detectar alguns tipos de fraudes em MOOCs com atividades baseadas no envio de imagens. No caso dos MOOCs é essencial esta automatização considerando a grande quantidade de inscritos.

5. Metodologia

O Lumina, plataforma institucional de MOOC da UFRGS, possuía em 2023, mais de 90 cursos únicos, distribuídos em 7 áreas, sendo 12 cursos de design e 3 cursos de artes. Os cursos disponibilizados na plataforma foram desenvolvidos por professores, alunos e servidores da UFRGS, sendo utilizado o sistema Moodle como ambiente de aprendizagem. A configuração empregada nos MOOCs do Lumina segue um padrão: o conteúdo é elaborado predominantemente no formato de vídeos, entretanto podem ser usados áudios, apresentações, textos, imagens e demais tipos de materiais que sejam possíveis de serem inseridos no Moodle. Todos os cursos têm um vídeo de apresentação, disponível mesmo sem o cadastro do usuário. Os MOOCs possuem módulos com informações sobre o curso e professores, um sumário navegável dos conteúdos e as atividades avaliativas realizam-se no formato de fóruns ou questionários de múltipla escolha, dando acesso ao Certificado, que tem a quantidade de horas especificada pelo professor do curso. Os cursos ficam abertos durante um ano, e o aluno pode se inscrever e começar quando desejar, levando o tempo que for necessário. Os MOOCs do Lumina são auto formativos e não há interações com professores e/ou tutores.

Os MOOCs analisados pertencem à série “Tudo que Você Precisa Saber”, sobre os softwares InDesign, Blender e Illustrator, alguns deles com mais de uma versão. O Blender é um software de modelagem, escultura, animação e composição 3D, gratuito e aberto, e que tem ganhado cada vez mais popularidade, sendo um concorrente expressivo em relação a softwares como 3D Max e Maya, da Autodesk. O Illustrator é um software da Adobe, pago e vendido sob a forma de licenças de uso periódicas, usado para ilustração vetorial, que

utilizam formas geométricas primitivas, como linhas, curvas, pontos, formas e polígonos. O Indesign é um software para editoração eletrônica, que também é distribuído pela Adobe, nos mesmos moldes do Illustrator. As atividades de avaliação destes cursos eram fóruns, tarefas e laboratórios de avaliação por pares. Nos fóruns do Moodle, os alunos podem ver os envios uns dos outros, e não é possível restringir o tipo de envio - quem postasse uma resposta contendo apenas texto era automaticamente aprovado. Nas tarefas é possível restringir o tipo de arquivo e os alunos não acessam as postagens uns dos outros, porém não há verificação do arquivo enviado. Nos laboratórios de avaliação não é possível restringir os tipos de arquivo enviados, contudo, os alunos avaliam os envios uns dos outros. Como um dos autores é professor desses cursos, foi possível obter o acesso às imagens. Os nomes de cada curso, formatos de avaliação e quantidade de imagens enviadas são apresentados no Quadro 1.

Quadro 1 - Cursos, Formatos de Avaliação e Quantidade de Imagens Enviadas

Nome abreviado (ID)	Formatos de avaliação	Quantidade de documentos enviados	Inscritos /Concluíram a primeira atividade
Illustrator 2023 (277)	Fórum(1)	34	815/330
Illustrator 1º edição (126)	Fórum(1)	217	1320/2380
Blender 1º edição (129)	Tarefa (1)	4	89/161
InDesign (149)	Laboratório de avaliação por pares (2)	42	96/247
InDesign 2023 (278)	Tarefa (2)	42	181/562
InDesign 2º edição (158)	Tarefa (2)	23	242/611

Fonte: Autores

As imagens foram analisadas pela professora dos cursos, atuando como especialista no domínio dos dados, classificando em quatro categorias de fraude e uma de conformidade. Sendo assim, este trabalho utiliza uma metodologia qualitativa e quantitativa, considerando que foi realizado um trabalho interpretativo dos dados e dos resultados contabilizados. Abaixo são apresentadas as 4 categorias de fraude:

1. Imagens monocromáticas: documentos com uma cor.
2. Cópias de envios: documentos iguais aos apresentados nos exercícios ao longo do curso, ou envios de documentos iguais entre alunos. Foi usado o software Cisdem para a detecção de cópias nos arquivos do disco.
3. Fora de escopo: documentos sem qualquer relação com a atividade avaliativa.
4. Não atendem aos requisitos da atividade: documentos que não atendiam às especificações.

A Figura 1 ilustra os casos de fraude do curso de Illustrator, um software de ilustração “vetorial”. A atividade avaliativa solicitava que o aluno desenhasse um bichinho “kawaii” (fofinho) e aplicasse em um “mock-up”. Um mock-up é um arquivo editável, usualmente com extensão psd, sobre o qual se pode aplicar um desenho que é automaticamente distorcido e adaptado à superfície, por exemplo, uma camiseta, uma caneca, um quadro. Solicitava-se que o desenho fosse original, mas o mock-up poderia ser obtido na internet.

Figura 1 - Exemplos de envios fora de conformidade



Fonte: Autores

Na Figura 1-A se vê um gatinho que talvez tenha sido desenhado pelo aluno, porém ele não estava aplicado sobre um “mockup”. Na Figura 1-B se vê um exemplo de imagem que não atende à atividade, já que a “raposinha” não poderia sequer ser desenhada no Illustrator.

6. Resultados

Os resultados da busca por envios fraudulentos estão sumarizados na Tabela 1, que mostram os envios de atividades avaliativas, obrigatórias para obtenção do certificado.

Tabela 1 - prevalência de fraudes em envios de atividades avaliativas

Nome abreviado do curso	Tipo de Desonestidade Acadêmica (DA)				
	Monocromática	Cópia	Fora de escopo	Não atende à atividade	Conforme
Illustrator 2023	0 (0%)	4 (12%)	1 (3%)	1 (3%)	28 (82%)
Illustrator 1º edição	1 (0%)	8 (4%)	18 (8%)	60 (28%)	130 (60%)
Blender 1º edição	1 (25%)	0 (0%)	1 (25%)	0 (0%)	2 (50%)
InDesign	0 (0%)	0 (0%)	0 (0%)	1 (2%)	41 (98%)
InDesign 2023	2 (5%)	3 (7%)	1 (2%)	5 (12%)	31 (74%)
InDesign 2º edição	0 (0%)	3 (11%)	1 (4%)	0 (0%)	22 (85%)
Total	4 (1%)	18 (5%)	22 (6%)	67 (18%)	254 (70%)

Fonte: Autores

A Tabela 1 mostra que os alunos dos cursos têm comportamentos diferentes. O curso de Blender se vê a maior prevalência de envios fraudulentos, chegando a 50%. Porém, este também é o curso com menos envios: apenas quatro. Não há como apontar com certeza o motivo de um número tão baixo de tarefas submetidas neste curso, porém acredita-se que seja por causa da dificuldade de aprender a usar o software por quem não é da área, e por não ser possível realizar as atividades avaliativas em um software alternativo mais simples. Dos seis cursos analisados, o curso sobre Blender foi o que teve menos inscritos e também a menor quantidade de pessoas enviando a primeira atividade. Além do mais, a atividade avaliativa era do tipo “Tarefa”, onde os alunos não têm acesso aos envios dos colegas, o que pode dificultar a fraude.

Em seguida, a primeira edição do curso sobre Illustrator apresenta possivelmente 40% de envios fraudulentos, pois nem todas imagens classificadas como Não Atende são com certeza Desonestidade Acadêmica. A fraude mais recorrente foi o envio de imagens que não têm relação com o que foi pedido no enunciado do exercício.

O curso de InDesign, da edição 2023, recebeu 26% de envios fraudulentos, apesar da avaliação ser por “tarefa”, o que impede que os alunos vejam os envios uns dos outros. O tipo de fraude mais comum foi o envio de imagens que não atendem à atividade, sem qualquer relação com o que foi demandado. Os cursos de Illustrator da edição de 2023 e o de InDesign da segunda edição apresentam quantidades semelhantes de envios fraudulentos, respectivamente 18% e 15%. O curso sobre Illustrator usava “fórum” e o sobre InDesign usava “tarefas”. Em destaque, se vê a baixa quantidade de envios fraudulentos no curso InDesign, que usava avaliação por pares, com apenas 2% de envios fraudulentos.

5. Discussão e limitações

Nesta pesquisa buscou-se descobrir a prevalência da desonestidade acadêmica em cursos de Design do Lumina, considerando quatro categorias de fraude e uma de conformidade. Foram analisados cursos que têm como tema softwares de design, usados nas áreas de ilustração, editoração eletrônica e modelagem/animação 3D. O Lumina, plataforma institucional de MOOCs da UFRGS, usa o Moodle como base.

A prevalência de fraudes foi considerada alta, ficando entre 50% e 15% nos cursos que têm avaliações em forma de “tarefa” ou “fórum”, e apenas 2% no curso que usa avaliação por pares. Em função desta observação, considera-se que este tipo de avaliação inibe fraudes. O motivo é que os alunos que têm intenção de fraudar percebem que a verificação de conformidade será exercida por um colega, e isso torna o envio de um arquivo fraudulento arriscado. Por outro lado, fraudes em atividades do tipo “fórum” e “tarefa” não indicam ser diferentes.

É importante lembrar que o controle de fraudes não é o único fator que um professor leva em consideração ao definir o tipo de avaliação que será realizado, pois cada tipo de avaliação no Moodle cumpre funções pedagógicas distintas. Para cursos que exigem produção de imagens, o fórum pode ser muito relevante, pois ter acesso aos trabalhos dos colegas pode ser um incentivo para engajar-se com os estudos. A limitação, no caso do Moodle, é que não se pode exigir que certos tipos de arquivo sejam anexados, de forma que mesmo posts contendo apenas texto são aceitos. A ferramenta “tarefa”, por sua vez, permite que seja definida a extensão do arquivo que deve ser anexado, porém os alunos não podem acessar os envios uns dos outros. Como observou-se uma baixa prevalência de cópias, acredita-se que estes tipos de avaliação possam ser usados. Por outro lado, a mecânica da avaliação por pares demanda que esta atividade tenha datas de início de fim, o que vai contra os princípios do Lumina.

A detecção de fraudes nestas condições pode ser muito desafiadora, pois há diversos casos limítrofes. Por exemplo, na Figura 2A pode-se ver um envio copiado do desenho mostrado no enunciado, e na Figura 2B um envio largamente baseado no desenho do enunciado. O primeiro foi classificado como “cópia”, e o segundo como “conforme”.

Figura 2 - Envios limítrofes



Fonte: Autores

Acredita-se que para mitigar este problema seria necessário usar recursos de inteligência artificial, contando com suporte de informações fornecidas pelos professores. Entre as ações que poderiam ser estudadas lista-se:

- Elaborar os enunciados de atividades de forma a ajudar a detectar as fraudes. Por exemplo, exigir que sejam feitos dois envios separados em casos de montagens.
- Os enunciados deveriam estabelecer parâmetros claros, sempre que possível. Por exemplo, em relação à quantidade de cores ou à natureza do fundo.
- Usar palavras-chave e imagens que descrevessem envios em conformidade.

6. Considerações Finais

Neste trabalho foi abordado a Desonestidade Acadêmica (DA) em MOOCs (*Massive Open Online Courses*) com atividades baseadas no envio de imagens. Estas fraudes reduzem a credibilidade dos cursos online e das instituições de ensino, sendo a dificuldade de supervisão e monitoramento um facilitador para ocorrerem. A identificação automática da desonestidade acadêmica, nestes casos, se torna mais problemática, considerando a dificuldade computacional de identificar imagens copiadas, alteradas ou fora de contexto. Sendo assim, foi apresentado a prevalência e a categorização deste tipo de desonestidade acadêmica na plataforma de MOOCs Lumina, da UFRGS (Universidade Federal do Rio Grande do Sul). A professora dos cursos atuou como especialista no domínio dos dados para realizar a categorização das imagens em Monocromática, Cópia, Fora de escopo, Não atende à atividade e Conforme. Foi verificado um total de 30% de fraudes (Monocromática, Cópia, Fora de Escopo e Não Atende à Atividade). Os cursos com maior prevalência de DA foram o Blender e Illustrator, ambos da primeira edição. Espera-se que o trabalho possa contribuir para o aprimoramento dos enunciados dos cursos e para desenvolvimento futuro de uma ferramenta de Inteligência Artificial que auxilie na detecção automática de desonestidade acadêmica nos tipos de cursos apresentados.

Referências

- ABADI, Martín et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. **arXiv preprint arXiv:1603.04467**, 2016.
- ALESSIO, Helaine M. et al. Examining the effect of proctoring on online test scores. **Online Learning**, v. 21, n. 1, p. 146-161, 2017.
- AMIGUD, Alexander et al. Using learning analytics for preserving academic integrity. **International Review of Research in Open and Distributed Learning**, v. 18, n. 5, p. 192-210, 2017.
- ARAUJO, Flavio HD et al. Reverse image search for scientific data within and beyond the visible spectrum. **Expert Systems with Applications**, v. 109, p. 35-48, 2018.
- BATURAY, Meltem Huri. An overview of the world of MOOCs. **Procedia-Social and Behavioral Sciences**, v. 174, p. 427-433, 2015.

- BELANGER, Yvonne; THORNTON, Jessica. Bioelectricity: A quantitative approach Duke University's first MOOC. 2013.
- CHIANG, Feng-Kuang; ZHU, Dan; YU, Wenhao. A systematic review of academic dishonesty in online learning environments. **Journal of Computer Assisted Learning**, v. 38, n. 4, p. 907-928, 2022.
- DAALHUIZEN, Jaap; SCHOORMANS, Jan. Pioneering online design teaching in a MOOC format: tools for facilitating experiential learning. **International Journal of Design**, v. 12, n. 2, 2018.
- DAFFIN JR, Lee William; JONES, Ashley A. Comparing Student Performance on Proctored and Non-Proctored Exams in Online Psychology Courses. **Online Learning**, v. 22, n. 1, p. 131-145, 2018.
- DENG, Ruiqi; BENCKENDORFF, Pierre; GANNAWAY, Deanne. Progress and new directions for teaching and learning in MOOCs. **Computers & Education**, v. 129, p. 48-60, 2019.
- FLEISCHMANN, Katja. Online design education: Searching for a middle ground. **Arts and Humanities in Higher Education**, v. 19, n. 1, p. 36-57, 2020.
- HAAR, Christine Vonder; BELL, Ana. Analysis of Repeat Learners in Computer Science MOOCs. In: **2020 IEEE Learning With MOOCs (LWMOOCs)**. IEEE, 2020. p. 4-7.
- HARMON, Oskar R.; LAMBRINOS, James. Are online exams an invitation to cheat?. **The Journal of Economic Education**, v. 39, n. 2, p. 116-125, 2008.
- HEW, Khe Foon; CHEUNG, Wing Sum. Students' and instructors' use of massive open online courses (MOOCs): Motivations and challenges. **Educational research review**, v. 12, p. 45-58, 2014.
- ISON, David C. Detection of Online Contract Cheating through Stylometry: A Pilot Study. **Online Learning**, v. 24, n. 2, p. 142-165, 2020.
- JARAMILLO-MORILLO, Daniel et al. Identifying and characterizing students suspected of academic dishonesty in SPOCs for credit through learning analytics. **International Journal of Educational Technology in Higher Education**, v. 17, n. 1, p. 1-18, 2020.
- KING, Chula G.; GUYETTE JR, Roger W.; PIOTROWSKI, Chris. Online exams and cheating: An empirical analysis of business students' views. **Journal of Educators Online**, v. 6, n. 1, p. n1, 2009.
- LAMBERT, Eric G.; HOGAN, Nancy L.; BARTON, Shannon M. Collegiate academic dishonesty revisited: What have they done, how often have they done it, who does it, and why did they do it. **Electronic Journal of Sociology**, v. 7, n. 4, p. 1-27, 2003.
- MONDAL, Bhaskar. Artificial intelligence: state of the art. **Recent Trends and Advances in Artificial Intelligence and Internet of Things**, p. 389-425, 2020.
- MUULI, Eerik et al. Using image recognition to automatically assess programming tasks with graphical output. **Education and Information Technologies**, v. 25, p. 5185-5203, 2020.
- OUWERKERK, U. P. et al. Pilot integrating visual platform in online courses. **EDULEARN18 Proceedings**, 2018.
- PATEL, Manavkumar et al. Image-dev: An Advance Text to Image AI model. In: **2022 IEEE Pune Section International Conference (PuneCon)**. IEEE, 2022. p. 1-6.
- PELED, Yehuda et al. Predictors of Academic Dishonesty among undergraduate students in online and face-to-face courses. **Computers & Education**, v. 131, p. 49-59, 2019.
- RICE, Jeff. What I learned in MOOC. **College Composition and Communication**, v. 64, n. 4, p. 695-703, 2013.
- RUIPÉREZ-VALIENTE, José A. et al. Data-driven detection and characterization of communities of accounts collaborating in MOOCs. **Future Generation Computer Systems**, v. 125, p. 590-603, 2021.

- SIDI, Yael; BLAU, Ina; ESHET-ALKALAI, Yoram. How is the ethical dissonance index affected by technology, academic dishonesty type and individual differences?. **British Journal of Educational Technology**, v. 50, n. 6, p. 3300-3314, 2019.
- STELLINGWERFF, Martijn et al. Improving the Online Design Education Experience. **Proceedings of 36th eCAADe**, p. 401-408, 2018.
- STELLINGWERFF, M. C. The MOOC-ability of design education. In: **Real Time; Proceedings of the 33rd eCAADe Conference. Vol. 2. Vienna (Austria), 16-18 Sept. 2015**. Vienna University of Technology, 2015.
- SURAHMAN, Ence; WANG, Tzu-Hua. Academic dishonesty and trustworthy assessment in online learning: a systematic literature review. **Journal of Computer Assisted Learning**, v. 38, n. 6, p. 1535-1553, 2022.
- VERHOEF, Anne H.; COETSER, Yolandi M. Academic integrity of university students during emergency remote online assessment: An exploration of student voices. 2021.
- WITTEN, Ian H.; FRANK, Eibe. Data mining: practical machine learning tools and techniques with Java implementations. **Acm Sigmod Record**, v. 31, n. 1, p. 76-77, 2002.
- WRAGG, Nicole. Online communication design education: the importance of the social environment. **Studies in Higher Education**, v. 45, n. 11, p. 2287-2297, 2020.
- XU, Yongjun et al. Artificial intelligence: A powerful paradigm for scientific research. **The Innovation**, v. 2, n. 4, p. 100179, 2021.
- YUAN, Li; POWELL, Stephen. MOOCs and open education: Implications for Higher Education: A white paper. **JISC CETIS**, 2013.