

XXV ENCONTRO NACIONAL DE PESQUISA EM CIÊNCIA DA INFORMAÇÃO - XXV ENANCIB

GT 8 – Dados, Informação e Tecnologia

EXTRAÇÃO AUTOMATIZADA DE METADADOS NA DIGITALIZAÇÃO DE ACERVOS MUSEOLÓGICOS BRASILEIROS COM APRENDIZADO DE MÁQUINA

AUTOMATED METADATA EXTRACTION IN THE DIGITIZATION OF BRAZILIAN MUSEUM COLLECTIONS USING MACHINE LEARNING

Vagner Inácio de Oliveira – Universidade Estadual de Campinas (UNICAMP)

Paula Dornhofer Paro Costa – Universidade Estadual de Campinas (UNICAMP)

Dalton Lopes Martins – Universidade de Brasília (UNB)

Modalidade: Trabalho Completo

Resumo: a digitalização de acervos museológicos e a preservação do patrimônio cultural brasileiro, em um contexto cada vez mais digital, enfrentam desafios críticos, especialmente após perdas históricas recentes e diante da necessidade urgente de democratização do acesso à cultura, este impulsionado pelo programa IA para o Bem de Todos. Esse cenário é agravado pela carência de metadados detalhados nas bases de dados digitais, comprometendo tanto o rastreamento quanto a contextualização dos itens culturais, o que limita consideravelmente o acesso público. Neste contexto, o presente trabalho aborda a aplicação de aprendizado de máquina e visão computacional na extração e descrição automatizada de metadados em imagens de objetos culturais brasileiros, visando minimizar a complexidade e imprecisões do processo manual de catalogação. Entre as contribuições desta pesquisa destaca-se o desenvolvimento de um conjunto de dados rotulados de objetos provenientes de instituições museológicas brasileiras sob administração do Ibram, a disponibilização das implementações em código aberto e a criação de um modelo descritivo padronizado para catalogação sistemática. Embora existam limitações relacionadas à dimensão da base de dados, os resultados demonstram o potencial dessas tecnologias como ferramentas complementares ao trabalho de um especialista, otimizando processos. Este trabalho sublinha a importância da interseção entre inteligência artificial e curadoria cultural, juntando esforços para a preservação e democratização do acesso ao patrimônio cultural brasileiro.

Palavras-chave: patrimônio cultural digital; anotação automática; aprendizado de máquina; visão computacional.

Abstract: the digitization of museum collections and the preservation of Brazilian cultural heritage, within an increasingly digital context, face critical challenges, especially following recent historical losses and in light of the urgent need to democratize access to culture, a movement driven by the AI for the Good of All program. This scenario is further complicated by the lack of detailed metadata in digital databases, compromising both the tracking and contextualization of cultural items, and significantly limiting public access. Within this context, the present work addresses the application of machine learning and computer vision to the automated extraction and description of metadata from images of Brazilian cultural objects, aiming to reduce the complexity and inaccuracies of manual cataloging processes. Among the contributions of this research are the development of a labeled dataset of objects from Brazilian museum institutions under Ibram's administration, the open-source release of the implemented solutions, and the creation of a standardized descriptive model for

systematic cataloging. Despite limitations related to the size of the dataset, the results demonstrate the potential of these technologies as complementary tools to the work of specialists, optimizing processes. This study highlights the importance of the intersection between artificial intelligence and cultural curation, combining efforts to preserve and democratize access to Brazilian cultural heritage.

Keywords: digital cultural heritage; automatic annotation; machine learning; computer vision.

1 INTRODUÇÃO

Os acervos digitais representam uma ferramenta poderosa para ampliar o acesso ao patrimônio cultural preservado pelos museus, como evidenciado pela crescente adesão de instituições de memória ao processo de digitalização (Martins *et al.*, 2021). No contexto brasileiro, essa relevância é ainda mais acentuada pelas grandes distâncias que separam muitas dessas instituições, dificultando o acesso do público e tornando complexo o trabalho de historiadores e pesquisadores.

Além de promover o acesso, os acervos digitais desempenham um papel fundamental como estratégia de preservação do patrimônio cultural, especialmente diante da vulnerabilidade física dos acervos tradicionais. No Brasil, apenas na última década, incêndios destruíram importantes museus, como o Museu da Língua Portuguesa, em São Paulo (Portuguesa, 2015), o Museu Nacional, no Rio de Janeiro (Greshko, 2018), e o Museu de História Natural, em Minas Gerais, em 2020. Grande parte dos objetos perdidos nessas tragédias ainda não havia sido digitalizada. Eventos semelhantes ocorridos no Instituto Butantan (Fapesp, 2010) e na Cinemateca Brasileira (Berti; Oliveira, 2021) reforçam essa preocupação, destacando a urgência em investir em soluções digitais eficazes para garantir a preservação (Berti; Oliveira, 2021; Fapesp, 2010; Greshko, 2018). Mais recentemente, a enchente de 2024 no Rio Grande do Sul resultou na destruição parcial do patrimônio histórico-cultural do estado (Unidas, 2024), afetando diretamente museus, arquivos e bibliotecas. Esses incidentes evidenciam a fragilidade estrutural de diversas instituições museológicas brasileiras, especialmente as de menor porte, frequentemente impactadas pela escassez de recursos.

Apesar dos inúmeros desafios enfrentados pelos museus brasileiros, o país dispõe de um volume significativo de acervos digitalizados. O Instituto Brasileiro de Museus (Ibram), responsável pela administração dos museus públicos federais, disponibiliza na internet mais de 17 mil itens pertencentes a 20 museus digitais (Siqueira; Martins; Lemos, 2022). Em consonância com iniciativas internacionais similares, essa coleção digital proporciona acesso

a metadados enriquecidos com informações de contexto histórico. A principal tecnologia que viabiliza essa estrutura é o Tainacan — uma plataforma de repositório digital, de código aberto, desenvolvida para *WordPress*, que também permite acesso programável ao banco de dados dos itens (Martins *et al.*, 2017).

A anotação completa e confiável de metadados é fundamental para agregar significado às imagens em um acervo museológico digital. Uma simples fotografia de um garfo, por exemplo, pode parecer irrelevante se desprovida de contexto. No entanto, essa mesma imagem adquire valor histórico quando acompanhada de informações que revelam, por exemplo, que o objeto foi utilizado por uma figura pública durante um jantar em que decisões importantes foram tomadas, ou que seu material e *design* representam características marcantes de um determinado período histórico.

A realização dessa anotação é, tipicamente, conduzida por diversos profissionais especializados, configurando-se como uma tarefa complexa e intensiva em tempo e esforço (Belhi *et al.*, 2023). Esse processo frequentemente gera altos custos e está sujeito a erros humanos e variações interpretativas. Como consequência, muitos acervos digitalizados no Brasil e em outros países apresentam lacunas informacionais significativas, comprometendo a visibilidade dos bens culturais e dificultando a plena exploração de seu potencial informativo. Além disso, a ausência de padrões e práticas consistentes de catalogação entre museus e instituições de patrimônio cultural pode comprometer a identificação de informações necessárias para descrever adequadamente os itens, prejudicando sua localização nas bases de dados para fins de busca e recuperação (Lemos; Coelho Júnior, 2023).

Algoritmos de inteligência artificial (IA) têm apresentado resultados promissores em tarefas como reconhecimento de objetos e geração automática de descrições para imagens (Krizhevsky; Sutskever; Hinton, 2012; Xu *et al.*, 2015). No entanto, seu desempenho está fortemente condicionado à diversidade e ao volume dos conjuntos de imagens, os chamados *datasets*¹, utilizados durante o treinamento (Oliveira *et al.*, 2022). Por essa razão, o reconhecimento de objetos históricos em fotografias, assim como a anotação automática de metadados relevantes, históricos e contextuais, ainda representa um desafio significativo.

Para enfrentar os desafios da catalogação digital, este trabalho propõe o uso de algoritmos de aprendizado de máquina e visão computacional como ferramentas de apoio à

¹ Conjunto estruturado de dados utilizado para treinar, validar e testar modelos de aprendizado de máquina.

anotação de metadados de objetos museológicos. Com foco no contexto brasileiro, desenvolve-se uma metodologia voltada à otimização da extração de descrições e atributos visuais, tornando o processo mais preciso e menos oneroso. Nesse esforço, foi construído o *dataset* EMA como base fundamental para o treinamento dos modelos, com a obtenção de campos específicos e a elaboração de um *template* descritivo padronizado, consolidado em um modelo estruturado que organiza as informações extraídas de maneira sistemática e reutilizável.

2 METODOLOGIA

A metodologia envolve a obtenção e estruturação dos dados, bem como a implementação de técnicas de aprendizado de máquina e aprendizado profundo para identificação de características de objetos em acervos museológicos brasileiros. O processo está dividido em duas etapas principais: a construção do conjunto de dados, que fundamenta o treinamento dos modelos, e a extração automatizada de metadados, articulando diferentes técnicas para gerar descrições sistematizadas dos objetos.

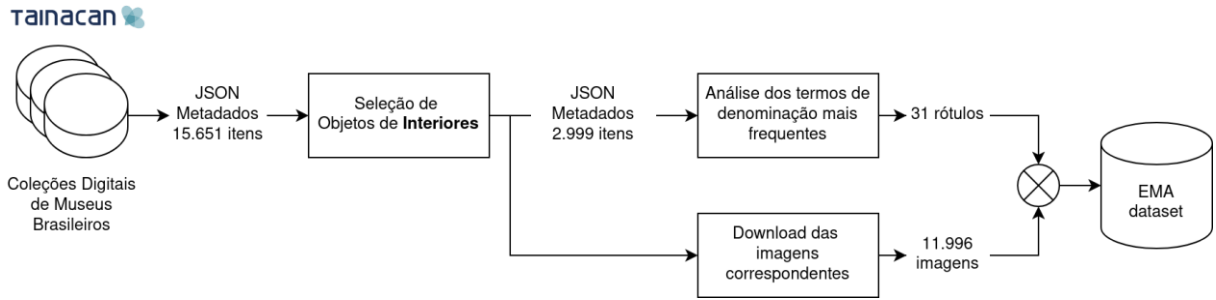
2.1 Desenvolvimento do *Dataset* EMA

A construção do *dataset* EMA, acrônimo para Extração de Metadados Automática, teve início com a captação de dados provenientes de 17 museus administrados pelo Ibram, totalizando 15.651 objetos com seus respectivos metadados e imagens. Por meio de um *script* em Python, foram coletados metadados em formato JSON, juntamente com as imagens correspondentes.

Após a fase inicial de captação, foi aplicado um filtro para selecionar apenas objetos categorizados no tesouro "Interior", recorte de estudo adotado, resultando em 2.922 objetos associados a 11.996 imagens. Em seguida, a partir de uma análise exploratória, o campo "Denominação" foi escolhido como referência para a rotulação, sendo mantidas as 31 categorias mais frequentes na base de dados.

Essa abordagem, mostrada na Figura 1, possibilitou a criação de um conjunto de dados específico de objetos de interiores do patrimônio cultural brasileiro, adequado ao treinamento de modelos de aprendizado profundo voltados à catalogação museológica.

Figura 1 – Etapas de construção da base de imagens rotuladas EMA.

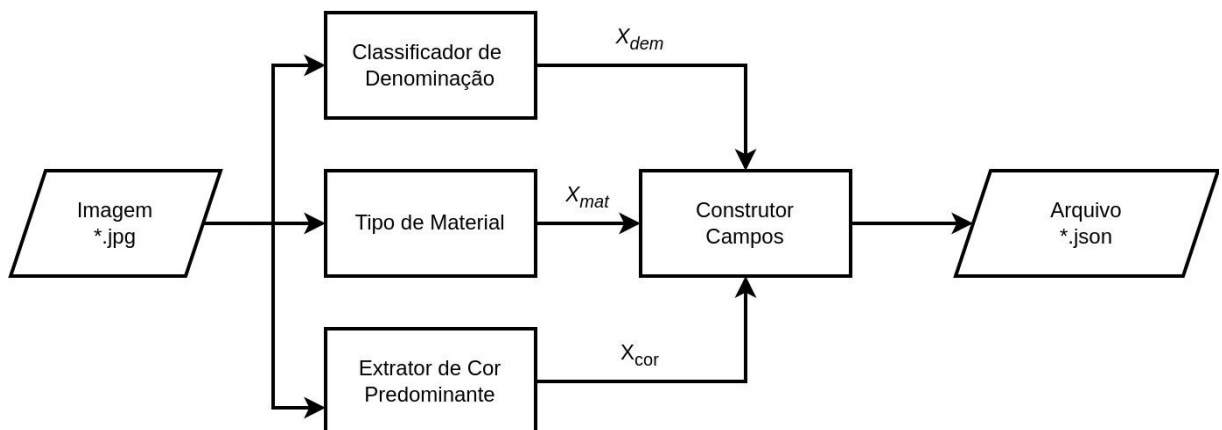


Fonte: elaborada pelos autores (2025).

2.2 Extração Automática de Metadados

O método de extração automática de metadados, ilustrado na Figura 2, concentra-se na identificação de três atributos fundamentais dos objetos: denominação, tipo de material (incluindo sua composição) e cor predominante. Cada uma dessas características é processada por módulos independentes, que atuam em paralelo sobre a imagem do objeto. Essa abordagem resulta na geração de um arquivo JSON, que compila essas informações e incorpora uma descrição literal ao objeto por meio de um *template* estruturado.

Figura 2 – Diagrama do método de extração automática de metadados de uma imagem em JPG.



Fonte: elaborada pelos autores (2025).

2.2.1 Classificador de Denominação

Para a identificação da denominação dos objetos, foi construído um classificador baseado em uma rede neural profunda da família ResNet, utilizando especificamente a arquitetura de 50 camadas (ResNet50), escolhida por seu equilíbrio entre profundidade e desempenho (He *et al.*, 2016). A estratégia adotada integrou transferência de aprendizado

XXV Encontro Nacional de Pesquisa em Ciência da Informação - XXV ENANCIB
Rio de Janeiro, RJ - 03 a 07 de novembro de 2025

com *fine-tuning*², considerando a natureza do conjunto de dados e a possibilidade de que este compartilhasse representações presentes na base de dados ImageNet, originalmente utilizada para treinar a ResNet.

Tabela 1 – Classificações de denominação frequentemente confundidas pelo modelo com mais de três ocorrências.

Real	Predito	Ocorrências
spoon	cutlery	15
cutlery	table knife	13
sconce	luminaire	13
sideboard	curtain	12
curtain	sideboard	11
cutlery	spoon	10
table knife	cutlery	10
luminaire	sconce	9
cutlery	fork	4
fork	cutlery	4
chest	mirror	3
cup	table knife	3

Fonte: elaborada pelos autores (2025).

O desempenho do modelo foi avaliado por meio da acurácia e da análise da matriz de confusão, alcançando 88,9% no conjunto de validação e 84,8% no conjunto de testes, o que demonstra boa capacidade de generalização, apesar de apresentar equívocos. A Tabela 1 apresenta as confusões mais recorrentes, com três ou mais ocorrências, ilustrando limitações da metodologia adotada. Um exemplo notável envolve a classificação de utensílios como “garfo”, “faca de mesa”, “colher” e “talher”, rótulos distintos usados para identificar objetos de uma mesma categoria, talher, resultando em erros de classificação. Destaca-se também a confusão entre “arandela” e “luminária”, possivelmente explicada pelo fato de a arandela ser, muitas vezes, um componente ou variação da luminária, o que pode ter levado o modelo a uma interpretação equivocada. A Figura 3 apresenta exemplos visuais dessas confusões, que reforçam a importância de processos de curadoria precisos e padronizados na catalogação de objetos museológicos.

² Processo de refinamento de um modelo já treinado para adaptá-lo a uma nova tarefa específica.

Figura 3 – Amostra de objetos e suas denominações frequentemente confundidas pelo modelo.



Fonte: elaborada pelos autores (2025).

2.2.2 Identificação do Tipo de Material

O campo “tipo de material” é especialmente valioso em acervos museológicos digitais, pois fornece indícios sobre a origem, o processo de fabricação e o período histórico de cada peça. Essas informações aprofundam a compreensão de pesquisadores sobre técnicas artesanais, facilitam comparações interculturais e orientam decisões sobre conservação preventiva. Para o público geral, o conhecimento dos materiais intensifica a compreensão estética e histórica dos objetos, enquanto para as equipes de museus se constitui um dado vital na gestão de coleções, sobretudo em plataformas como o Tainacan, onde a busca refinada por material amplia o acesso e a pesquisa.

Para automatizar a identificação desse atributo, foi proposto um esquema binário de codificação. Cada material x , pertencente à lista de 41 categorias distintas, recebe um código exclusivo definido por $c(x) = 2^x$. A composição de um objeto é obtida pela soma dos códigos dos materiais que o constituem, gerando um identificador único, mesmo em casos nos quais diferentes objetos compartilham a mesma combinação (por exemplo, uma mesa e um armário constituídos de madeira e metal). Aplicado a 2 922 objetos do *dataset* EMA, o procedimento produziu 125 combinações distintas, assegurando tanto padronização quanto reversibilidade da informação, uma vez que o código pode ser decomposto para recuperar os materiais originais.

A predição da composição de materiais foi conduzida utilizando uma rede ResNet50 refinada em duas fases de *fine-tuning*: primeiro ajustou-se apenas a camada de classificação; posteriormente, todas as camadas foram atualizadas, a fim de eliminar sinais de *overfitting*³

³ Fenômeno em que o modelo se ajusta excessivamente aos dados de treinamento, perdendo capacidade de generalização para novos dados.

detectados nas primeiras execuções. Após oito épocas de treinamento, o modelo atingiu 87,9% de acurácia nos dados de validação e 84,7% nos dados de teste.

A análise da matriz de confusão mostrou que os erros se concentram, principalmente nas classes madeira, metal e vidro, materiais predominantes no acervo e, não raro, presentes em objetos de aparência muito semelhante. Parte dessas divergências decorre de inconsistências na catalogação original: castiçais com verniz, por exemplo, foram registrados apenas como compostos de madeira, embora o revestimento pudesse justificar a classificação como madeira e tinta. A Figura 4 apresenta exemplos de itens frequentemente confundidos. Também foram observadas trocas entre categorias funcionalmente próximas, como luminárias e lanternas, cuja semelhança formal exige do classificador sensibilidade a variações sutis de acabamento. Esses resultados sugerem que ampliar a diversidade de imagens de treinamento e ajustar o modelo, incorporando filtros mais sensíveis a padrões de textura, podem contribuir para reduzir tais equívocos.

Figura 4 – Amostra de objetos cujos materiais pertencem às três categorias mais frequentemente confundidas pelo modelo.



Fonte: elaborada pelos autores (2025).

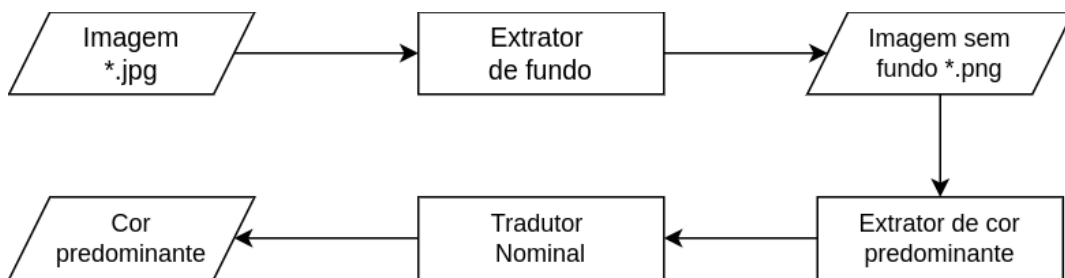
2.2.3 Extrator de Cor Predominante

Para identificar corretamente a cor predominante de cada item, é imprescindível que essa tonalidade seja extraída diretamente do objeto, e não do cenário que o circunda. Nas fotografias da base de dados, entretanto, o fundo raramente é neutro: muitas imagens exibem mesas de apoio, paredes coloridas ou superfícies reflexivas que podem interferir cromaticamente no item catalogado, comprometendo a identificação precisa de sua cor predominante. Se a análise for realizada sobre a foto integral, o algoritmo tende a apontar a cor mais abundante na cena, que nem sempre corresponde à do artefato. Dessa forma, o

primeiro passo consiste em isolar o objeto e remover qualquer pixel que não lhe pertença, assegurando que a estimativa cromática reflita exclusivamente suas características visuais.

Após o isolamento, procede-se à identificação da paleta de cores dominantes, em formato hexadecimal. Esses valores são então convertidos para nomes de cores em linguagem natural, como *Brown* ou *Indigo Blue*, por exemplo, facilitando a indexação e a leitura humana. A Figura 5 ilustra o processo de extração da cor predominante.

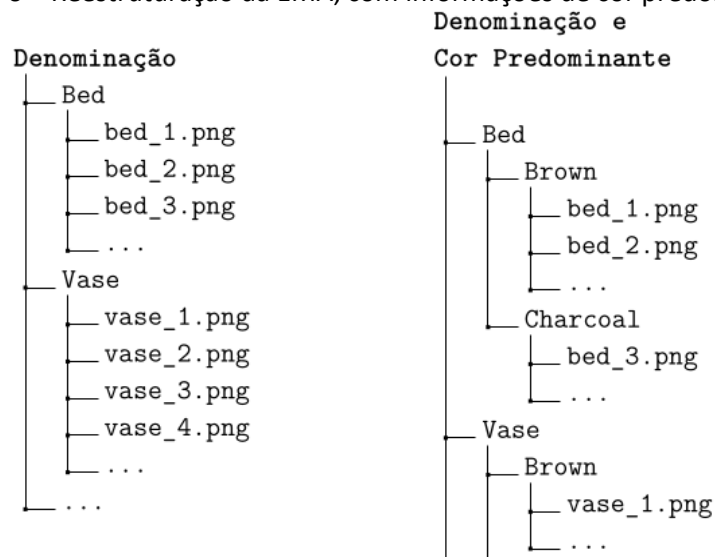
Figura 5 – Fluxo do processo de extração da cor predominante, com a entrada de uma imagem e a saída da cor predominante em nomenclatura natural.



Fonte: elaborada pelos autores (2025).

A cor extraída passa a compor um novo eixo de organização do EMA: além da separação por denominação, as imagens são agora subdivididas pela cor predominante (Figura 6). Essa reestruturação permite consultas mais refinadas no repositório, por exemplo, “vasos marrons” ou “camas azul-anil”, e abre caminho para análises cromáticas em série, preservando a vinculação com o rótulo original do objeto.

Figura 6 – Reestruturação da EMA, com informações de cor predominante.



Fonte: elaborada pelos autores (2025).

2.2.4 Descrição Estruturada

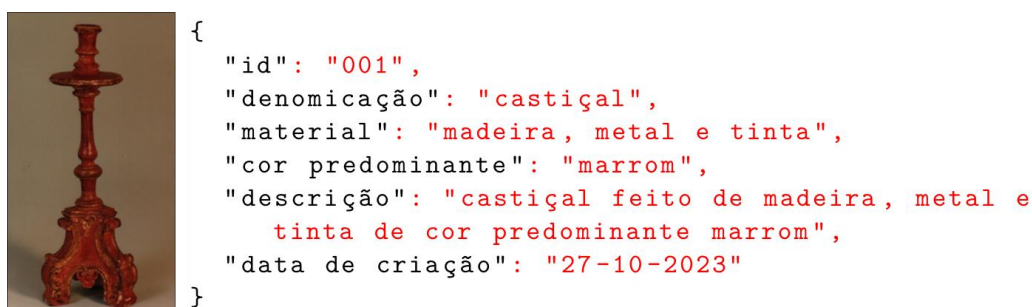
Para gerar frases próximas da linguagem natural, foi desenvolvido um mecanismo sistematizado que integra os três módulos apresentados nas etapas anteriores, denominação do objeto, tipo de material e cor predominante. O núcleo desse mecanismo é um *template* que concatena os campos inferidos em uma única sentença, servindo tanto a sistemas de busca quanto à geração de rótulos museológicos, organizando e estruturando informações relativas ao objeto de estudo. O *template* é definido da seguinte forma:

```
{denominação} feito(a) de {material} de cor predominante {cor}
```

- I. Denominação: rótulo previsto pelo classificador treinado nos 31 termos do *dataset* EMA;
- II. Material: combinação exclusiva gerada pelo codificador binário, que compacta a lista de matérias-primas;
- III. Cor: designação da tonalidade, em linguagem natural, fornecida pelo extrator após a remoção do fundo da imagem.

A Figura 7 mostra um castiçal como exemplo: a imagem, após processamento, origina um arquivo JSON contendo o id, a denominação (“castiçal”), a composição de materiais (“madeira, metal e tinta”), cor (“marrom”) e a sentença completa derivada do *template*.

Figura 7 – Objeto castiçal e seus respectivos metadados extraídos através do sistema elaborado.



Fonte: elaborada pelos autores (2025).

Essas informações abrem caminho para integrar o modelo de descrição estruturada a fluxos reais de catalogação digital. Entre as aplicações imediatas destaca-se a sugestão automática durante o processo de catalogação: incorporado a um software de registro, por exemplo, o próprio Tainacan, o algoritmo pode executar inferências em tempo real à medida que o usuário anexa a imagem, oferecendo rótulos preliminares automaticamente e

completando campos obrigatórios como um assistente inteligente. Esse tipo de recurso pode reduzir erros de preenchimento, evitar objetos sem descrição e acelerar o processo de documentação.

2.3 Avaliação por Especialistas

As descrições geradas, sejam independentes ou produzidas por meio do *template* descritor, foram submetidas a um protocolo de avaliação que contou com a participação de vinte e oito respondentes, dos quais vinte e dois são profissionais atuantes ou com experiência em catalogação de objetos museológicos. O formulário de avaliação coletou percepções por meio de questões descritivas e de múltipla escolha aplicadas a cinco objetos-teste (vaso, garfo, mesa, candeia e castiçal), visando aferir precisão, clareza e utilidade das descrições produzidas pelo sistema.

Na etapa de múltipla escolha, cada descrição foi avaliada em escala de 1 (muito ruim) a 5 (muito boa), em conjunto com o *Mean Opinion Score* (MOS). De modo geral, as avaliações relacionadas a “Denominação” e “Cor Predominante” concentraram notas na classificação “Boa”, enquanto o “Tipo de Material” recebeu críticas em torno da avaliação “Regular”, especialmente em peças com composições complexas, onde se torna difícil a observação física das composições. Apesar dessa variação, observou-se uma uniformidade do MOS, próximo de 3, o que revela consistência na percepção coletiva, mas também espaço para ajustes na identificação de materiais.

Os comentários abertos apontaram duas melhorias centrais: o enriquecimento das descrições com contexto histórico e a ampliação do vocabulário relacionado às técnicas de construção dos objetos. Ainda assim, 39,3% dos respondentes consideraram a ferramenta imediatamente útil no fluxo de catalogação, enquanto 25,0% mostraram-se indecisos — indicando a necessidade de capacitação e ajustes adicionais antes de uma adoção mais ampla. A maioria (55,6%) relatou gastar menos de um dia na catalogação de um único objeto, mas uma parcela relevante (27,8%) dedica de um a três dias, e 16,6% afirmaram levar mais de três dias, refletindo a complexidade das peças, os recursos disponíveis e as metodologias adotadas por cada instituição. Além disso, apenas 10,7% dos participantes atuavam diretamente com acervos digitais, sugerindo que, embora o potencial da ferramenta seja reconhecido, sua adoção plena dependeria de um processo gradual de digitalização e capacitação, especialmente em instituições que ainda operam majoritariamente com acervos físicos.

Nesse cenário, a inteligência artificial é vista pelos respondentes como um caminho promissor para os processos de catalogação e digitalização em museus, especialmente diante do déficit de pessoal e do grande volume de itens a serem catalogados. Contudo, destacam que essas ferramentas devem ir além da mera automação, incorporando valor simbólico, contexto histórico, detalhes de textura, formato e, inclusive, abrangendo acervos de história natural, elementos que ainda exigem fortemente a mediação da curadoria humana. Apesar dessas ressalvas, reconhecem uma utilidade prática imediata, pois as descrições automáticas preliminares evitam lacunas em itens digitalizados, agilizam tarefas repetitivas, como a identificação de estilos ou itens semelhantes, e contribuem para a padronização terminológica na entrada de dados, desde que integradas aos sistemas existentes e acompanhadas de capacitação dos usuários.

A avaliação revelou que o *template* gera sentenças claras, mas que ainda demanda aprimoramentos na granularidade dos materiais e na contextualização cultural. Essas percepções orientam passos futuros de refinamento dos classificadores e reforçam a viabilidade de sua implantação como um assistente inteligente em tempo real nos acervos museológicos.

3 CONSIDERAÇÕES FINAIS

A crescente digitalização dos acervos culturais impõe desafios que vão além da infraestrutura técnica, envolvendo também questões de acesso, preservação e valorização da memória coletiva. Em um país marcado por perdas recentes e irreparáveis de importantes coleções físicas, torna-se urgente desenvolver estratégias que garantam a salvaguarda e a disseminação do patrimônio cultural de forma ampla e inclusiva. Nesse contexto, a inteligência artificial se apresenta como uma ferramenta estratégica, capaz de ampliar a visibilidade dos acervos e contribuir para sua preservação, em consonância com os princípios do programa IA para o Bem de Todos.

Este trabalho investigou o uso de modelos de aprendizado de máquina e visão computacional como ferramentas promissoras para ampliar o acesso à cultura e contribuir para a preservação do patrimônio presente nos acervos museológicos brasileiros. A partir da criação de um *dataset* e da proposição de uma metodologia para a automatização da extração e geração de metadados, foram desenvolvidas soluções voltadas à otimização dos processos de catalogação, preservando a qualidade documental. Além disso, a disponibilização em

código aberto promove a reprodutibilidade e permite a adaptação das soluções a diferentes contextos institucionais e de pesquisa.

Os resultados obtidos revelam o potencial da ferramenta no apoio à curadoria, ao mesmo tempo em que evidenciam pontos fundamentais a serem aprimorados na catalogação de objetos museológicos, como a necessidade de maior granularidade nas descrições e contextualização histórica dos objetos. Como continuidade, propõe-se a ampliação das bases de dados utilizadas, incorporando acervos nacionais não vinculados ao Ibram, bem como repositórios internacionais, como o Europeana. Essa expansão pode contribuir para maior representatividade e precisão dos modelos.

É possível desenvolver soluções tecnológicas alinhadas aos desafios e às necessidades dos museus brasileiros, promovendo o acesso, a preservação e a valorização do patrimônio cultural. Espera-se que este trabalho fomente o uso estratégico da inteligência artificial em museus e instituições culturais, visando contribuir para a eficiência dos processos de catalogação e a ampliação do acesso a acervos digitalizados.

REFERÊNCIAS

BELHI, A. *et al.* A machine learning framework for enhancing digital experiences in cultural heritage. **Journal of Enterprise Information Management**, v. 36, n. 3, p. 734-746, 2023. Disponível em: <https://doi.org/10.1108/JEIM-02-2020-0059>. Acesso em: 18 abr. 2025.

BERTI, L.; OLIVEIRA, J. Incêndio na cinemateca brasileira. São Paulo, põe mais um acervo cultural no Brasil em risco. **El País**, São Paulo, v. 29, 2021. Disponível em: <https://brasil.elpais.com/brasil/2021-07-29/incendio-na-cinemateca-brasileira-em-sao-paulo-poe-mais-um-acervo-cultural-no-brasil-em-risco.html>. Acesso em: 18 abr. 2025.

FAPESP, R. **Fogo no Butantan**. 2010. 23 p. Disponível em:

<https://revistapesquisa.fapesp.br/fogo-no-butantan/>. Acesso em: 18 abr. 2025.

GRESHKO, M. Incêndio em museu destrói parte fundamental da história do Brasil.

National Geographic Brasil, Sept. 2018. Disponível em:

<https://www.nationalgeographicbrasil.com/museu-nacional-do-rio-de-janeiro/2018/09/incendio-em-museu-destroi-parte-fundamental-da-historia-do-brasil>

Acesso em: 18 abr. 2025.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. *In*: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2016, Las Vegas. **Proceedings** [...]. Las Vegas: [s. n.], 2016. p. 770-778.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *In*: PEREIRA, F.; BURGESS, C. J. C.; BOTTOU, L.; WEINBERGER,

XXV Encontro Nacional de Pesquisa em Ciência da Informação - XXV ENANCIB
Rio de Janeiro, RJ - 03 a 07 de novembro de 2025

K. Q. (org.). **Advances in Neural Information Processing Systems**. [S. l.]: Curran Associates, 2012. v. 25, p. 1097–1105.

LEMOS, D. L. S.; COELHO JÚNIOR, A. Qualidade de dados em acervos do patrimônio cultural: uma avaliação diagnóstica semiautomática nos objetos culturais sob gestão do Instituto Brasileiro de Museus. **Encontros Bibli: Revista Eletrônica de Biblioteconomia e Ciência da Informação**, Florianópolis, v. 28, p. 1-22, 2023.

MARTINS, D. L. *et al.* Repositório Digital com o Software Livre Tainacan: revisão da ferramenta e exemplo de implantação na área cultural com a Revista Filme Cultura. *In*: ENCONTRO NACIONAL DE PESQUISA E PÓS-GRADUAÇÃO EM CIÊNCIA DA INFORMAÇÃO, 18., 2017, Marília. **Anais [...]** Marília: ANCIB, 2017. Disponível em: http://enancib.marilia.unesp.br/index.php/XVIII_ENANCIB/ENANCIB/paper/view/472/838. Acesso em: 18 abr. 2025.

MARTINS, D. L. *et al.* Requisitos de qualidade para dados de agregação em museus: o caso do Instituto Brasileiro de Museus. **Tendências da Pesquisa Brasileira em Ciência da Informação**, v. 14, 2021.

OLIVEIRA, V. *et al.* EMA: Brazilian Cultural Heritage Image Dataset: Towards AI-based metadata annotation of digital collections. *In*: INTERNATIONAL CONFERENCE ON DIGITAL PRESERVATION, 18., 2022, Glasgow – Scotland. **Proceedings [...]** Glasgow – Scotland: [s. n.], 2022.

PORTUGUESA, M. L. **Nota de Pesar**. 2015. Disponível em: <https://www.museudalinguaportuguesa.org.br/nota-de-pesar/>. Acesso em: 18 abr. 2025.

SIQUEIRA, J.; MARTINS, D. L.; LEMOS, D. L. S. Brasileira museus: serviço de busca e recuperação da informação agregada dos acervos digitais do instituto brasileiro de museus. *In*: ENCONTRO NACIONAL DE PESQUISA E PÓS-GRADUAÇÃO EM CIÊNCIA DA INFORMAÇÃO, 22., 2022, **Anais [...]** Porto Alegre: ANCIB, 2022. Disponível em: <https://cip.brapci.inf.br//download/201748>. Acesso em: 18 abr. 2025.

UNIDAS, Nações. **Unesco envia missão para recuperar patrimônio cultural afetado nas enchentes no Rio Grande do Sul**. 2024. Disponível em: <https://news.un.org/pt/story/2024/07/1834511>. Acesso em: 18 abr. 2025.

XU, K. *et al.* Show, attend and tell: Neural image caption generation with visual attention. *In*: PMLR. INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 2015, Lille. **Proceedings [...]**. Lille: [s. n.], 2015. p. 2048–2057.