

GT-8 – INFORMAÇÃO E TECNOLOGIA

DATAQ CULTURE: FERRAMENTA DE AVALIAÇÃO DE QUALIDADE DE DADOS EM COLEÇÕES MUSEOLÓGICAS

DATAQ CULTURE: DATA QUALITY ASSESSMENT TOOL FOR MUSEOLOGICAL COLLECTIONS

Abeil Coelho Júnior – Mestre em Ciência da Informação PPGCI - Universidade Federal do Espírito Santo

Daniela Lucas da Silva Lemos - Docente PPGCI - Universidade Federal do Espírito Santo

Modalidade: Trabalho Completo

Resumo: Apresenta a importância da qualidade de dados em acervos culturais digitais e propõe a aplicação *DataQ Culture* como uma ferramenta de avaliação semiautomática. A pesquisa adota uma abordagem aplicada, combinando elementos qualitativos e quantitativos, e utiliza o modelo de desenvolvimento em cascata. A aplicação é testada com sucesso nas coleções do Instituto Brasileiro de Museus, processando mais de 17 mil itens. Os resultados demonstram a importância da avaliação da qualidade de dados para melhorar a indexação e a recuperação da informação em acervos culturais, tornando o patrimônio mais acessível ao público. A *DataQ Culture* permite que os usuários avaliem a qualidade dos dados de forma simples e interativa, gerando relatórios com métricas de adequação e indicando ações para aprimorar a qualidade dos dados. A adoção de práticas de catalogação baseadas em modelos de referência, como o *Cataloging Cultural Objects*, contribui para a padronização e agregação semântica dos recursos de informação. A ferramenta desenvolvida pode auxiliar profissionais da informação no acompanhamento e melhoria da qualidade dos dados em seus acervos, promovendo uma maior eficiência na análise e recuperação da informação.

Palavras-chave: qualidade de dados; acervos culturais digitais; DataQ Culture; catalogação de objetos culturais; recuperação da informação

Abstract: It presents the importance of data quality in digital cultural collections and proposes the application DataQ Culture as a semi-automated evaluation tool. The research adopts an applied approach, combining qualitative and quantitative elements, and uses the waterfall development model. The application is successfully tested on the collections of the Brazilian Institute of Museums, processing over 17,000 items. The results demonstrate the significance of data quality assessment in improving indexing and information retrieval in cultural collections, making cultural heritage more accessible to the public. DataQ Culture enables users to evaluate data quality in a simple and interactive manner, generating reports with metrics of adequacy and suggesting actions to enhance data quality. The adoption of cataloging practices based on reference models, such as Cataloging Cultural Objects, contributes to standardization and semantic aggregation of information resources. The developed tool can assist information professionals in monitoring and improving data quality in their collections, promoting greater efficiency in analysis and information retrieval.

Keywords: data quality; digital cultural collections; DataQ Culture; cataloging cultural objects; information retrieval

1 INTRODUÇÃO

Iniciativas de digitalização de acervos culturais e disponibilização de itens de coleções digitais na internet têm sido uma prática nos últimos anos (MARTINS et al., 2022). Entretanto, investir somente na digitalização de objetos culturais não é suficiente, visto que questões de qualidade de dados frequentemente não são levantadas, considerando os diversos tipos de bancos de dados e sistemas de informação envolvidos em processos de organização, modelagem e representação. Assim, o custo de digitalizar uma coleção em um banco de dados pode ser alto, mas é apenas uma fração do custo de verificar e corrigir os dados posteriormente. É melhor prevenir erros do que corrigi-los posteriormente (ENGLISH, 1999, p. 282), o que é de longe a opção mais barata (CHAPMAN, 2005).

Os custodiadores e proprietários de dados, como, por exemplo, galerias, bibliotecas, arquivos e museus – GLAMs, acrônimo em inglês - são os principais responsáveis pela qualidade de seus dados, com uma boa catalogação descritiva (INTERNATIONAL FEDERATION OF LIBRARY ASSOCIATIONS AND INSTITUTIONS, 2016). Com o uso de padrões de documentação que orientam a estrutura de dados, valores de dados e conteúdo de dados (GILLILAND, 2016), as instituições contam com um conjunto de ferramentas que pode levá-las a uma boa prática de catalogação, documentação consistente, e, por consequência, maior acesso aos documentos pelo usuário final.

Entretanto, constata-se que padrões de documentação atuais, que promovem qualidade de dados e, por consequência, recuperação da informação mais eficiente, ainda não são considerados em estudos mais recentes (ENGLISH, 1999; BATINI; SCANNAPIECA, 2006; BACA et al., 2006; MARTINS et al., 2022). Nesta direção, destaca-se o CCO¹ (*Cataloging Cultural Objects*), padrão de documentação que fornece diretrizes para a seleção, a organização e a formatação de dados usados para preencher registros de catálogos, com base em categorias genéricas que podem ser empregadas a qualquer conjunto de metadados (BACA et al., 2006), inclusive, com os elementos descritivos do experimento adotado na presente pesquisa.

No caso do Instituto Brasileiro de Museus (Ibram), estudo de caso da presente pesquisa, a qualidade de dados dos museus sob sua gestão pode ser mensurada por meio de suas bases de dados modeladas a partir do padrão de dados adotado internamente pela instituição, qual seja o modelo do Inventário Nacional de Bens Culturais Musealizados –

¹<https://vraweb.org/resourcesx/cataloging-cultural-objects/>. Acesso em: 12/07/2023.

INBCM (BRASIL, 2021). Assim, diante do contexto de uso do INBCM na arquitetura das bases de dados dos museus sob gestão do Ibram e da situação problemática associada à qualidade de dados em acervos culturais que aqui se apresenta, a presente pesquisa busca responder a seguinte questão: *como melhorar a qualidade de dados em acervos culturais?* Logo, o objetivo desta pesquisa é apresentar uma ferramenta de avaliação semiautomática de qualidade de dados que possibilite a otimização de resultados diagnósticos nos dados de acervos de instituições culturais, tendo o Ibram como objeto-experimental.

Acredita-se, portanto, que a implementação de uma avaliação semiautomática de qualidade de dados pode aprimorar a indexação, a busca e a navegação nos sistemas de recuperação de informações (LANCASTER, 2004) de instituições culturais, tornando o patrimônio cultural mais acessível ao público. Além disso, a aplicação desenvolvida permite que qualquer fonte de dados, independentemente do padrão de documentação adotado, possa ser alinhada e avaliada de acordo com as regras de catalogação CCO. A padronização dos dados em coleções digitais pode facilitar comparações entre diferentes instituições, impulsionando pesquisas acadêmicas e científicas e proporcionando uma compreensão mais profunda da história e cultura do país.

2 PROCEDIMENTOS METODOLÓGICOS

Metodologicamente, este estudo adotou uma abordagem aplicada, combinando elementos qualitativos e quantitativos, além de exploratória e descritiva. A abordagem quantitativa foi incluída neste estudo para quantificar a adequação das coleções aos padrões recomendados pelo CCO. Para alcançar isso, foi aplicada uma fórmula matemática para calcular o índice de adequação, conforme será exibida adiante.

Diante do contexto de uso do INBCM na arquitetura das bases de dados do Ibram, algumas decisões metodológicas são importantes de serem elucidadas inicialmente para fins de entendimento dos dados trabalhados na pesquisa. De acordo com a versão mais recente do INBCM (de 31 de agosto de 2021), para a identificação do bem cultural musealizado no INBCM, os elementos específicos de descrição para a área da Museologia são num total de 15, sendo 9 (nove) de entrada obrigatória e 6 (seis) de entrada facultativa.


O processo de alinhamento (mapeamento) foi o primeiro passo crucial deste estudo. O objetivo deste passo foi estabelecer a correspondência entre os elementos descritivos da normativa do INBCM e do guia de catalogação (CCO), conforme apresentado em (LEMOS;

COELHO JUNIOR, 2023). Logo, o experimento da presente pesquisa considerou 7 (sete) dimensões analíticas enumeradas e descritas a seguir:

- I – *Object Naming*: fornece maneiras de se referir a uma obra, definindo o que está sendo catalogado.
- II – *Creator Information*: identifica o criador de uma obra (podendo ser vários), incluindo pessoa, física ou jurídica, conhecida pelo nome ou anônima.
- III – *Physical Characteristics*: descreve a aparência de uma obra, apresentando características de sua forma física.
- IV – *Stylistic, Cultural, and Chronological Information*: descreve características estilísticas de uma obra, origens culturais e data de design ou criação.
- V – *Location and Geography*: trata de elementos que registram informações geográficas e de localização, tais como localização atual, locais ao longo do tempo, localização de criação e localização de descoberta.
- VII – *Class*: classifica uma obra específica a outras obras com características semelhantes, muitas vezes com base em esquema organizacional de um determinado repositório ou coleção.
- VIII – *Description*: associa campos específicos em todo o registro, consistindo de uma nota descritiva que geralmente é um texto relativamente breve, detalhando o conteúdo e o contexto da obra.

De acordo com o mapeamento realizado em todas as regras explicitadas nos capítulos ora elencados do guia CCO (I, II, III, IV, V, VII e VIII) foram identificadas 244 regras, incluindo 122 regras distintas. A distribuição dessas regras por capítulo e alinhadas ao INBCM pode ser observada na Figura 1. Torna-se importante salientar que o capítulo VI, dedicado ao elemento central “assunto” (*Subject*), não é considerado nos elementos de descrição para identificação do bem cultural de caráter museológico do INBCM, logo, não foi inserido no processo de análise e alinhamento.

Figura 1 – Regras de catalogação CCO alinhadas ao INBCM



Fonte: elaborado pelos autores

XXIII Encontro Nacional de Pesquisa em Ciência da Informação – ENANCIB
Aracaju-SE – 06 a 10 de novembro de 2023

A avaliação semiautomática foi realizada por meio da linguagem Python, utilizando expressões regulares da linguagem formal regex. O Quadro 1 apresenta as regras de catalogação que foram implementadas pelo algoritmo. A aplicação desenvolvida e denominada *DataQ Culture* pode ser utilizada por diferentes usuários para avaliar a qualidade dos dados de suas bases de dados e direcionar esforços para ações preventivas e corretivas.

Para cada regra associada ao elemento de metadado pertencente a uma dimensão, o registro de dado correspondente (*string* avaliada) recebeu o valor 0 (zero) ou 1 (um). O valor 1 (um) foi atribuído quando o registro de dado atendeu ao critério (regra) recomendado pelo CCO; e o valor 0 (zero) quando não atendeu. Por fim, o índice de adequação é dado pela fórmula: $\text{índice}_b = (\sum \text{Valor1} / (\sum \text{Valor1} + \sum \text{Valor0})) * 100$ onde **b** é a base com a amostra de dados de uma coleção particular; e **índice** é o percentual de adequação obtido em relação a dimensão, a elemento de metadado e a regra de catalogação para um determinado museu e coleção.

Quadro 1 – Regras de catalogação e regex utilizados na pesquisa

#	Regra	Elemento de descrição	regex
1	Fazer uso de vocabulário controlado	<i>Class, Creation Location, Creator, Inscription, Location, Materials and Techniques, Measurements, Physical Description, Work Type</i>	Não se aplica. Utilizado API do Tainacan ou Indicação do usuário
2	Evitar abreviações	Class, Creation Location, Creator, Description, Location, Materials and Techniques, Other Descriptive Notes, Title, Work Type	[A-ZÁÉÍÓÚÛÑ][A-Za-z0-9áéíóúüñ]*\.
3	Usar o mesmo idioma do catálogo	Creation Location, Date, Description, Location, Materials and Techniques, Other Descriptive Notes, Work Type	Não se aplica (Utilizado Python – Langdetect)
4	Abreviar unidades métricas de acordo com o Sistema Internacional (m, cm, mm, g, kg, kb, Mb, Gb)	Measurements	(?i)\b\d+(?:\.\d+)?\s*(?:m cm g kg B KB MB GB TB)\b
5	Capitalizar as iniciais de nomes próprios e da primeira palavra, para outros termos use letras minúsculas	Creation Location, Date, Description, Location, Materials and Techniques, Other Descriptive Notes, Title, Work Type	^[A-Z0-9]{1}(.)*
6	Medidas geralmente incluem duas casas decimais para medidas métricas	Measurements,	\d+[.]\d{2}\b
7	Não usar capitalização	Measurements	[A-Z]
8	Utilizar números inteiros ou frações decimais	Measurements	[0-9][.]
9	Não pode ficar vazio	Class, Creator, Inscription, Materials and Techniques, Measurements, Work Type, Title, Date, Location	.*

XXIII Encontro Nacional de Pesquisa em Ciência da Informação – ENANCIB
Aracaju-SE – 06 a 10 de novembro de 2023

1 0	Usar singular	Class, Materials and Techniques, Work Type	\b\w+[sS]\b
1 1	Anos com menos que 4 (quatro) dígitos, inserir 0 (zero) a esquerda	Date	\b\d{4}\b
1 2	Não usar pontuação, exceto hífen	Work Type	^[a-zA-Z\u00C0-\u00FF 0-9\-_\-\-]*\$
1 3	Não utilizar apóstrofo	Date	[\'']+
1 4	Não utilizar artigos	Title	\b(?:o(s)? a(s)? um(a)?(s)? uns)\b \b(?:O(s)? A(s)? Um(a)?(s)? Uns)\b
1 5	Seguir padrão para registro de hora, minutos e segundos	Date	(?P<hours>0?[0-9] 1[0-9] 2[0-3]):(? P<minutes>60 [0-5][0-9]):(?P<secon ds>60 [0-5][0-9])
1 6	Seguir padrão pra registro de dia, mês e ano de data	Date	^([0-9]{1,2})([0-9]{1,2})([0-9]{1,2})([0-9]{1,2})([0-9]{1,2})([0-9]{1,2})\$
1 7	Use traço para separar intervalo de anos	Date	\b\d{4}\s*-\s*\d{4}\b

Fonte: elaborado pelos autores

Para o desenvolvimento da aplicação, utilizou-se do modelo de desenvolvimento de software em cascata, também conhecido como modelo Cascata (*Waterfall*, em inglês) por ser uma das metodologias de desenvolvimento mais antigas e conhecidas em Engenharia de Software (PRESSMAN, 2005; SOMMERVILLE, 2011). Nesta abordagem, as etapas do projeto são realizadas sequencialmente, uma após a outra, e cada etapa é concluída antes que a próxima comece. O modelo de desenvolvimento em cascata é baseado em um conjunto de etapas sequenciais e distintas, sendo geralmente organizadas conforme descritas a seguir:

1. Definição de requisitos: nesta etapa, são definidos e documentados os requisitos do *software*, incluindo as funcionalidades que ele deve possuir; as restrições de design; e as expectativas do cliente.
2. Design: nesta etapa, é desenvolvida a arquitetura do *software*, com base nos requisitos definidos na etapa anterior. O design pode incluir fluxogramas, diagramas, modelos de dados e outros documentos que descrevam a estrutura e o funcionamento do *software*.
3. Implementação: na etapa de implementação, o código é escrito de acordo com o design desenvolvido na etapa anterior. A implementação pode incluir a codificação, testes unitários e integração com outros componentes do *software*.
4. Testes: nesta etapa, são realizados testes para garantir que o *software* funcione corretamente, atenda aos requisitos e não apresente falhas. Os testes podem ser


automatizados ou manuais, e devem ser realizados em diferentes cenários de uso do *software*.

5. Implantação: a implantação é a etapa final do processo, em que o *software* é entregue ao cliente. Isso pode envolver a instalação e configuração do *software* em um ambiente de produção, treinamento do usuário final e suporte técnico.

À luz das orientações do método Cascata, os processos listados foram executados durante o desenvolvimento da aplicação. Na primeira etapa, foram identificados quatro requisitos básicos que a ferramenta deveria cumprir: i) receber um conjunto de dados (*dataset*); ii) realizar o alinhamento entre os elementos do *dataset* que o usuário forneceu com os elementos do CCO; iii) apresentar os resultados da avaliação de qualidade de dados; eiv) indicar como a qualidade de dados do *dataset* avaliado pode ser melhorada.

A segunda etapa pode ser visualizada no fluxograma dos processos realizados pela aplicação (Figura 2). As ações realizadas pelo usuário estão destacadas em amarelo, enquanto as ações realizadas pela aplicação estão em rosa.

Figura 2 – Diagrama de processos da aplicação



Fonte: elaborado pelos autores

Na etapa 3, foram empregadas as linguagens de programação *Python* no *backend* (processo interno da ferramenta) e HTML, CSS e *JavaScript* no *frontend* (interface do usuário). Especificamente no *backend*, foram utilizadas diversas bibliotecas, como o Pandas para processamento de dados, o *framework* web *Flask*² para criação das páginas e rotas da ferramenta que o usuário navegará e a biblioteca *re* para processamento de expressões regulares. É importante destacar que, diferentemente da avaliação realizada no estudo de caso com os acervos do Ibram, nesta ferramenta não será utilizado o *BeautifulSoup* e *Requests*, isto é, será esperado do usuário o fornecimento de uma base de dados em *Comma Separated Values* (CSV)³ para a avaliação de qualidade de maneira local, sem necessidade de raspagem ou captação de fontes externas.

²<https://flask.palletsprojects.com/en/2.2.x/>

³https://en.wikipedia.org/wiki/Comma-separated_values

Durante a etapa 4, utilizou-se os *datasets* do Ibram exportados em massa. Realizaram-se processos de envio, alinhamento, salvamento do alinhamento e processamento com geração dos resultados, além de testar a recuperação do alinhamento e o *upload* de fontes inválidas para verificar o comportamento adequado da aplicação.


Por fim, na etapa 5, a aplicação é implantada localmente no computador do usuário e fica disponível para acesso a qualquer pessoa na mesma rede. Para possibilitar isso, o código-fonte da aplicação foi disponibilizado no *Github* (COELHO JÚNIOR, 2023) juntamente com um guia passo a passo em texto e em vídeo para a sua execução, permitindo um acesso livre e a implantação por qualquer usuário interessado.

4 RESULTADOS

Com o objetivo de ampliar o acesso e a utilização de ferramentas para avaliação da qualidade de dados em instituições de acervos culturais com base em padrões de referência, tornou-se necessário o desenvolvimento de uma ferramenta de fácil acesso, reprodução e com resultados orientadores para ações mais efetivas e significativas para a melhoria da qualidade de metadados de acervos culturais. Assim, o desenvolvimento da *DataQ Culture* surge para preencher essa lacuna.

A funcionalidade básica da ferramenta consiste em processar as regex desenvolvidas em uma base de dados fornecida pelo usuário. Desta forma, a funcionalidade inicial é uma interface para envio de um arquivo com os dados a serem avaliados. Assim, a Figura 3 apresenta a interface de envio de arquivo.

Figura 3 – Interface de envio de base de dados para avaliação




Fonte: elaborado pelos autores

Na interface de envio, é apresentado um campo para seleção de um arquivo no formato CSV. Este formato foi considerado pela sua versatilidade na leitura entre sistemas, já que um arquivo em aplicativo de planilha pode ser exportado neste formato, assim como qualquer banco de dados. Com o *upload* do arquivo CSV, o *DataQ Culture* avalia o formato do arquivo, validando se é de fato um arquivo CSV; faz a identificação do *encoding*⁴ (que se refere à maneira como os caracteres são armazenados em um arquivo de texto) e do delimitador do CSV. O delimitador é o caractere que faz a separação entre as colunas no arquivo, geralmente são utilizados vírgulas ou ponto e vírgulas, mas também podem ser utilizados um caractere invisível quando se aperta *tab* no teclado. Por isso, é importante ter uma função dedicada à tratativa destes dois pontos, pois com a variedade de sistemas operacionais, diversos tipos de *encoding* podem ser apresentados à ferramenta, além de diferentes delimitadores e arquivos CSV incompletos, corrompidos e inválidos.

Outra tarefa fundamental para a realização da avaliação de qualidade de dados é realizar o alinhamento entre o acervo submetido pelo usuário e as dimensões e elementos discricionais do CCO. Para esse fim, foi elaborada uma tela de alinhamento, conforme apresentado na Figura 4.

Figura 4 – Tela de alinhamento entre elementos discricionais base do usuário com os elementos discricionais do CCO

⁴https://pt.wikipedia.org/wiki/Codificação_de_caracteres




Fonte: elaborado pelos autores

Nesta tela, o usuário pode fazer o alinhamento com o CCO independentemente do padrão de documentação utilizado no *dataset* enviado. Na parte superior da tela, há um campo para inserção do nome do alinhamento. No restante da tela, é possível ver para cada elemento discricional presente no arquivo do usuário, as opções de seleção para as colunas correspondentes do CCO. Além disso, abaixo de cada um dos elementos discricionais, há a opção de indicar se este faz uso de um vocabulário controlado.

Após o alinhamento, a configuração é salva e pode ser reutilizada sempre que uma base com a mesma configuração de cabeçalho é carregada pelo usuário, reduzindo o retrabalho e otimizando o tempo. É possível ainda editar um alinhamento existente, excluir caso necessário ou, simplesmente, criar um novo, como pode ser visto na Figura 5.

Figura 5 – Tela de alinhamento com indicação de alinhamento já existente



Fonte: elaborado pelos autores

Após o processamento da base, um relatório é gerado com várias métricas, a saber: (i) adequação geral do arquivo avaliado; (ii) adequação por dimensão do CCO; (iii) para cada


dimensão que não obteve a pontuação máxima, é exibida a taxa de adequação por elemento discricional. Neste ponto, se houver apenas um elemento discricional em alguma das dimensões, um texto é apresentado com a taxa de adequação do elemento discricional. Caso mais de um elemento discricional pertença à dimensão, é exibido um gráfico com a respectiva pontuação dos elementos; e (iv) para cada elemento discricional que não obteve a adequação máxima, são exibidas as regras que poderiam melhorar a adequação do elemento discricional. Essas características podem ser visualizadas nas Figuras 6 e 7. Por fim, no final da página, é possível baixar uma planilha com todos os valores avaliados e a indicação se estava adequado à regra ou não.

Figura 6 – Tela principal com taxa de adequação de coleção avaliada



Fonte: elaborado pelos autores

Figura 7 – Regras indicadas para elementos que não alcançaram 100% de adequação



Fonte: elaborado pelos autores

A avaliação diagnóstica resultante do experimento permitiu aferir nas coleções museológicas do Ibram que os dados carecem de um tratamento mais adequado em

dimensões como características físicas do objeto de informação, descrição, localização geográfica e informações cronológicas. Por outro lado, as coleções se mostraram qualificadas em termos do uso adequado de taxonomias para a dimensão classificação. Ademais, de uma maneira geral, a ferramenta *DataQ Culture* permite que um usuário comum realize a avaliação de qualidade de dados de seus acervos de forma simples e interativa, com regras baseadas em padrões de referência, e com geração de relatórios com indicação de ações que trarão resultados efetivos; permite também que gestores de acervos e coleções façam a validação de seus dados sem maiores dificuldades.

5 DISCUSSÃO

O uso de padrões de dados (GILLILAND, 2016) em temas de estrutura (ex.: padrão de metadados), valor (ex.: linguagem documentária), conteúdo e formato (ex.: regra de catalogação), e comunicação (ex.: um padrão de metadados num formato legível para a máquina), juntamente com o uso de um guia de referência (como o CCO), é fundamental para avaliar grandes volumes de dados de maneira eficiente e confiável, principalmente no domínio cultural, pois a qualidade é baseada no contexto, em que muitas vezes os dados que podem ser considerados adequados para um cenário podem não ser apropriados para outro (CHAPMAN, 2005). Assim, a adoção de boas recomendações e padrões de documentação de referência permite uma análise mais estruturada e sistemática, o que é essencial para garantir a qualidade dos dados e, conseqüentemente, a eficácia das análises realizadas.

Acrescenta-se que a avaliação de qualidade de dados é um aspecto importante na disponibilização de dados de acervos culturais online, pois normaliza e padroniza as terminologias (por meio de vocabulários controlados) ajudando, assim, a consistência dos dados e auxiliando os processos de busca e recuperação da informação (LANCASTER, 2004); além de ajudar no alcance da interoperabilidade semântica dos dados entre diferentes esquemas de metadados e aplicações disponíveis na web (ZENG, 2019).

Nesse sentido, a avaliação da qualidade de dados proporcionada pela aplicação *DataQ Culture* pode ser considerada um fator crítico para coleções culturais, já que a precisão dos resultados de buscas e recuperação da informação depende diretamente da qualidade dos dados catalogados. A aplicação foi estabelecida por meio de um arcabouço metodológico reproduzível e semiautomatizado (WANG, 2018) fundamentado em princípios teórico-metodológicos da Ciência da Computação (PRESSMAN, 2005; SOMMERVILLE, 2011) e

da Ciência da Informação (BACA et al., 2006, HARPRING, 2022), que pode ser utilizado como aliado na melhoria da qualidade da catalogação e consequente recuperação da informação (INTERNATIONAL FEDERATION OF LIBRARY ASSOCIATIONS AND INSTITUTIONS, 2016). Com uma avaliação mais precisa da qualidade dos dados, é possível economizar recursos e direcionar os esforços dos especialistas para decisões que exijam maior atenção.

Por fim, mas não menos importante, o uso de regras de catalogação, como as previstas no CCO, determinam como elaborar o conteúdo da descrição de um recurso de informação, os pontos de acesso e os relacionamentos entre estes, tornando-se práticas essenciais na padronização, na descrição e, portanto, na agregação semântica de recursos de informação (GILLILAND, 2016).

6 CONSIDERAÇÕES FINAIS

Os resultados apresentados no presente artigo foram alcançados por meio da tecnologia regex juntamente com o uso de um padrão de documentação de referência, o guia de catalogação COO. A partir do alinhamento entre os elementos descritivos do INBCM e do CCO, foi possível realizar a implementação de uma porção de regras de catalogação do CCO com uso da linguagem Python. A aplicação possibilitou apurar o índice de adequação da qualidade de dados em todos os registros de metadados das 22 coleções museológicas vinculadas ao Ibram, sendo mais de 17 mil itens processados.

Adicionalmente, a aplicação de avaliação da qualidade de dados *DataQ Culture* foi implementada para que diferentes usuários possam realizar a mesma avaliação em seus acervos, independente do padrão de documentação adotado, levando a uma economia de tempo para o profissional da informação na ação de avaliar a qualidade de bases de dados legadas, direcionando o esforço do usuário para ações preventivas e corretivas a partir das informações diagnósticas levantadas, respondendo, assim, à questão de pesquisa e indicando como melhorar a qualidade de dados em acervos culturais.

Reforça-se que a avaliação da qualidade de dados é incipiente e pouco desenvolvida no domínio da cultura e que a semiautomatização dessa avaliação é um ponto de partida para o direcionamento de esforços para a melhoria da qualidade de dados no domínio. Conclui-se, portanto, que o modelo de avaliação de qualidade de dados proposto nesta pesquisa, com base no guia de catalogação de objetos culturais CCO, mostrou-se eficaz para diagnosticar as discrepâncias e deficiências nos acervos museológicos sob gestão do Ibram. A

utilização de práticas de catalogação maduras, oriundas de modelos de referência, pode contribuir para qualificar os atuais padrões de documentação por meio de instrumentos de organização da informação mais sofisticados e orientados para os usuários finais dos sistemas de informação. Além disso, a ferramenta desenvolvida pode auxiliar os profissionais da informação no acompanhamento da qualidade dos dados de seus acervos e está disponível para uso por outras instituições e profissionais interessados.

REFERÊNCIAS

BACA, Murtha; HARPRING, Patricia; LANZI, Elisa; MCRAE, Linda; WHITESIDE, Ann. **Cataloging cultural objects: a guide to describing cultural works and their images**. Chicago: American Library Association, 2006.

BATINI, Carlo; SCANNAPIECA, Monica. **Data quality: concepts, methodologies and techniques**. Berlin; New York: Springer, 2006.

BRASIL. Instituto Brasileiro de Museus. **Resolução Normativa n. 6, de 31 de agosto de 2021**. Estabelece os elementos de descrição das informações sobre o acervo museológico, bibliográfico e arquivístico que devem ser declarados no Inventário Nacional dos Bens Culturais Musealizados, em consonância com o Decreto nº 8.124, de 17 de outubro de 2013. Brasília: Diário Oficial, 2021. Disponível em: <<https://www.in.gov.br/web/dou/-/resolucao-normativa-ibram-n-6-de-31-de-agosto-de-2021-342359740>>. Acesso em: 12 jul. 2023.

CHAPMAN, Arthur D. **Principles of Data Quality**. Copenhagen, 2005. Disponível em: <<https://www.gbif.org/document/80509>>. Acesso em: 12 jul. 2023.

COELHO JÚNIOR, Abeil. DataQ-Culture. 2023. **GITHUB**. Disponível em: <https://github.com/AbeilCoelho/DataQ-Culture>. Acesso em: 12 jul. 2023.

ENGLISH, Larry P. **Improving data warehouse and business information quality: methods for reducing costs and increasing profits**. New York: Wiley, 1999.

GILLILAND, Anne J. Setting the Stage. In: BACA, Murta. (ed.). **Introduction to metadata**. 3. ed. Los Angeles: Getty Research Institute, 2016. Disponível em: <<https://www.getty.edu/publications/intrometadata/setting-the-stage/>>. Acesso em: 12 jul. 2023.

HARPRING, Patricia. **Metadata Standards Crosswalks**. 2022. Disponível em: <https://www.getty.edu/research/publications/electronic_publications/intrometadata/crosswalks.html#endnote1CCO>. Acesso em: 11 jul. 2023.

INTERNATIONAL FEDERATION OF LIBRARY ASSOCIATIONS AND INSTITUTIONS (IFLA). **Declaração dos Princípios Internacionais de Catalogação**. Haia, 2016. Disponível em: <https://www.ifla.org/wp-content/uploads/2019/05/assets/cataloguing/icp/icp_2016-pt.pdf>. Acesso em: 12 jul. 2023.

XXIII Encontro Nacional de Pesquisa em Ciência da Informação – ENANCIB
Aracaju-SE – 06 a 10 de novembro de 2023

LANCASTER, Frederick Wilfrid. **Indexação e resumos**: teoria e prática. Brasília: Briquet de Lemos, 2004.

LEMOS, Daniela Lucas da Silva; COELHO JUNIOR, Abeil. 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**, v. 28, p. 1–22, 2023.

MARTINS, Dalton Lopes; LEMOS, Daniela Lucas da Silva; OLIVEIRA, Luis Felipe Rosa; SIQUEIRA, Joyce; CARMO, Danielle; MEDEIROS, Vinicius Nunes. Information organization and representation in digital cultural heritage in Brazil: Systematic mapping of information infrastructure in digital collections for data science applications. **Journal of the Association for Information Science and Technology**, [S. l.], p. asi.24650, 2022.

PRESSMAN, Roger. **Software engineering: a practitioner's approach**. 6th ed. Boston, Mass.: McGraw-Hill, 2005.

SOMMERVILLE, Ian. **Software engineering**. 9th ed. Boston: Pearson, 2011.

WANG, Lin. Twinning data science with information science in schools of library and information science. **Journal of Documentation**, v.74, 2018.

ZENG, Marcia Lei. Interoperability. **Knowledge Organization**, v.46, n.2, p. 122-146, jan. 2019.