

EXPLORANDO A COBERTURA TEMÁTICA DOS REPOSITÓRIOS ASSOCIADOS AOS DADOS DE PESQUISA DESCRITOS EM *DATA PAPERS*

Crislaine Zurilda Silveira

Universidade Federal de Santa Catarina (UFSC), Brasil

crislaine.silveira@ufsc.br

 <https://orcid.org/0000-0003-3081-9968>

Patricia da Silva Neubert

Universidade Federal de Santa Catarina (UFSC), Brasil

patricia.neubert@ufsc.br

 <https://orcid.org/0000-0002-8909-1898>

Thiago Magela Rodrigues Dias

Universidade Federal de Santa Catarina (UFSC), Brasil

thiogomagela@gmail.com

DOI: 10.22477/xiv.biredial.390

EJE TEMÁTICO: Datos abiertos

RESUMEN

Este estudio investiga o comportamento de pesquisadores brasileiros em relação ao depósito de dados de pesquisa vinculados a data papers, tendo em vista a crescente demanda pela disponibilização pública de dados incentivada por agências de fomento e periódicos científicos. O problema central reside na pouca compreensão sobre como autores brasileiros utilizam os repositórios de dados, especialmente no contexto dos data papers, justificando-se a necessidade de caracterizar a cobertura temática dos repositórios utilizados. O objetivo principal foi analisar os repositórios de dados empregados por autores brasileiros, considerando sua tipologia e área de cobertura. Para isso, foi realizada uma pesquisa bibliográfica nas bases Scopus, Web of Science e OpenAlex, identificando 634 data papers, dos quais, 349 mencionavam o uso de repositórios. A análise envolveu a verificação individual de cada data paper. Como resultados, foram identificados 60 repositórios diferentes, sendo 41 disciplinares e 19 multidisciplinares, com os repositórios multidisciplinares concentrando 50,16% dos dados. Mendeley Data, Zenodo e Figshare destacaram-se entre os mais utilizados. Os resultados sugerem que tanto a área do conhecimento quanto o formato e a natureza dos dados influenciam na escolha dos repositórios, e apontam para a necessidade de estudos futuros que explorem a relação entre editoras, áreas do conhecimento e estratégias de compartilhamento de dados científicos.

Palabras-clave: Ciência Aberta. Produção científica. Artigo de dados. Repositório de dados.

ABSTRACT

This study investigates the behavior of Brazilian researchers regarding the deposit of research data linked to data papers, in view of the growing demand for public data availability encouraged by funding agencies and scientific journals. The central problem lies in the limited understanding of how Brazilian authors utilize data repositories, especially in the context of data papers, justifying the need to characterize the thematic coverage of the repositories used. The main objective was to analyze the data repositories employed by Brazilian authors, considering their typology and area of coverage. To this end, a bibliographic search was conducted in the Scopus, Web of Science, and OpenAlex databases, identifying 634 data papers, of which 349 mentioned the use of repositories. The analysis involved the individual verification of each data paper. As results, 60 different repositories were



identified, with 41 being disciplinary and 19 multidisciplinary, and the multidisciplinary repositories concentrating 50.16% of the data. Mendeley Data, Zenodo, and Figshare stood out among the most used. The findings suggest that both the field of knowledge and the format and nature of the data influence the choice of repositories, and point to the need for future studies exploring the relationship between publishers, fields of knowledge, and strategies for scientific data sharing.

Keywords: Open Science. Scientific production. Data paper. Data repository.

INTRODUÇÃO

Ao longo da última década, tem havido uma demanda internacional crescente para tornar os dados produzidos mais disponíveis para a comunidade de pesquisa e o público. Essa demanda tem sido fortemente influenciada pelas instituições de financiamento, editores de periódicos e pelos movimentos que envolvem a ciência que vem promovendo a abertura de dados, incentivando o uso de repositórios de dados públicos (Thoegersen; Borlund, 2022).

Um repositório de dados de pesquisa é um serviço online que gerencia o armazenamento de longo prazo e a preservação de dados, fornecendo um arcabouço para a descoberta e acesso dos dados de pesquisa, além dessas funcionalidades, alguns repositórios também incluem metainformações sobre dados, licença e identificador único persistente (Vázquez *et al.*, 2021).

Os repositório de dados junto com os *data papers* fazem parte do ecossistema de publicação de dados de pesquisa, no qual os *data papers* vão um passo além de armazenar os dados junto com seus metadados em um repositório, representando uma garantia de acessibilidade e qualidade, pois também exigem a revisão por pares, e que os dados que são descritos estejam disponíveis publicamente em algum repositório estável e online (Mcgillivray, 2022; Puerta-Piñero; Pérez-Luque; Rodríguez-Echeverría, 2020).

Na prática essa relação se estabelece quando os autores enviam os dados de pesquisa para os repositórios ao mesmo tempo em que enviam o *data paper* para a revisão nos periódicos. Os dados depositados nos repositórios devem ser disponibilizados abertamente no momento da publicação do *data paper*, sendo assim, os repositórios são componentes essenciais da infraestrutura para compartilhamento e preservação de dados de pesquisa (Lee; Kim, 2021).

Com isso, tendo em vista identificar o comportamento dos autores brasileiros quanto ao depósito de dados de pesquisa a partir dos dados publicados em *data papers*, este trabalho tem como objetivo: caracterizar a cobertura temática dos repositórios de dados utilizados para depositar os dados de pesquisas vinculados aos *data papers*. Essa caracterização se fez a partir da identificação da média de repositórios de dados utilizados e por meio da análise da sua cobertura temática.

conjunto de dados.

Embora haja um predomínio de uso de um único repositório, na tabela 1, é possível observar que um *data paper*, utilizou oito repositórios diferentes para disponibilizar os dados de pesquisa, totalizando 37 conjuntos de dados e outro utilizou cinco repositórios diferentes para disponibilizar 85 conjuntos de dados de pesquisa. Essa grande quantidade de repositórios e de conjuntos de dados pode ter relação com o comportamento da área, uma vez que ambos² pertencem a área da Medicina.

O primeiro *data paper* que mais concentrou repositórios e conjuntos de dados utilizou os seguintes repositórios: Sequence Read Archive (7), BioProject (7), Gene Expression Omnibus (7), Proteomics Identifications Database (2), Mass Spectrometry Interactive Virtual Environment (4), MetaboLights (3), Plasmodium Genomics Resource (5) e o Immunology Database and Analysis Portal (2). O segundo *data paper* que mais concentrou repositórios e conjuntos de dados utilizou os seguintes repositórios: Sequence Read Archive (3), BioProject (6), BioSample (6), Lancaster University Research Directory (24), European Nucleotide Archive (6). O que ambos têm em comum, é que com o exceção do Lancaster University Research Directory que é um repositório multidisciplinar, todos os demais são repositórios disciplinares da área das Ciências da Vida, conforme figura 1, o que sugere que a área pode influenciar na quantidade e na seleção dos repositório de dados associados aos *data papers*.

Em seguida, na tabela 2, são arrolados todos os repositórios onde os conjuntos de dados foram depositados, bem sua média e sua tipologia.

Tabela 2 - Características dos repositórios

Nome do Repositório	F* data set	F** data paper	Média	Tipo ***
1. Mendeley Data	106	100	1,06	M
2. Sequence Read Archive	69	12	5,75	D
3. Genbank	64	23	2,78	D
4. Zenodo	62	57	1,09	M
5. Figshare	62	55	1,13	M
6. Pangaea	31	13	2,38	D
7. Lancaster University Research Directory	24	1	24	M
8. Open Science Framework	23	7	3,29	M

² Almutairi, H. et al. (2021). Chromosome-scale genome sequencing, assembly and annotation of six genomes from subfamily Leishmaniinae. *Science Data*, 8(234), 1-9. <https://doi.org/10.1038/s41597-021-01017-3>
DeBarry, J.D. et al. (2022). MaHPIC malaria systems biology data from Plasmodium cynomolgi sporozoite longitudinal infections in macaques. *Science Data*, 9(722), 1-43. <https://doi.org/10.1038/s41597-022-01755-y>



Nome do Repositório	F* data set	F** data paper	Média	Tipo ***
35. Archive of Data on Disability to Enable Policy	1	1	1	D
36. DataSuds	1	1	1	M
37. IsoArch	1	1	1	D
38. Cirad dataverse	1	1	1	M
39. Digital CSIC	1	1	1	M
40. DataverseNL	1	1	1	M
41. Fairdata IDA Research Data Storage Service	1	1	1	M
42. Global Health Data Exchange	1	1	1	D
43. ProteomeXchange	1	1	1	D
44. Metagenomics analysis server	1	1	1	D
45. British Antarctic Survey	1	1	1	D
46. TRY	1	1	1	D
47. Ag Data Commons	1	1	1	D
48. Environmental Data Initiative Repository	1	1	1	D
49. International Neuroimaging Data-Sharing Initiative	1	1	1	D
50. OTELo Research Data Repository	1	1	1	D
51. GFZ Data Service	1	1	1	D
52. ICOS Carbon Portal	1	1	1	D
53. British Oceanographic Data Centre	1	1	1	D
54. Digital Rocks Portal	1	1	1	D
55. Dagshub	1	1	1	M
56. Repositório da UNESP	1	1	1	M
57. Repositório da Universidade de São Paulo	1	1	1	M

Nome do Repositório	F* data set	F** data paper	Média	Tipo ***
58. Repositório de Dados de Pesquisa da Fundação Getulio Varga	1	1	1	M
59. Repositório de Dados de Pesquisa da Unicamp (REDU)	1	1	1	M
60. Repository of Open Access Data sets	1	1	1	M
Total	638	409****	1,56	

Fonte: Dados da pesquisa (2025).

Notas: F* data sets: refere-se a quantidade de data sets (ou conjuntos de dados) publicados no repositório específico

F** data paper: refere-se a quantidade de data papers que mencionou o repositório específico

Tipo***: refere-se ao tipo de cobertura do repositório: D indica repositório é disciplinar e M indica que o repositório é multidisciplinar

Total de data papers 409****Esse número se distingue do total de data papers listados na Tabela 1. Isso ocorreu porque um único *data paper* abrangeu múltiplos repositórios, e, nesse caso, cada repositório foi contabilizado separadamente como um data paper.

Em relação aos dez repositórios que mais concentraram o depósito dos dados de pesquisa, Federer *et al.* (2018) identificaram o Figshare (M), Gene Expression Omnibus (D), Genbank (D), Dryad (M), Sequence Read Archive (D), No-repository web site, Institucional repository, Github (M), Dataverse (M) e Protein Databank (D). Em um estudo mais recente, ainda na revista Plos ONE, mas com um recorte temporal de 2014 a 2020, maior do que o estudo anterior de Federer *et al.* (2018), Jiao, Li, Fang (2022) identificaram que os dez repositórios que mais se destacaram foram o Figshare (M), Gene Expression Omnibus (D), Dryad (M), GenBank (D), Sequence Read Archive (D), Open Science Framework (M), GitHub (M), Dataverse (M), Zenodo (M) e Bioproject (D).

Ao realizar uma comparação entre esses dois estudos, pode-se observar que sete entre os dez repositórios se repetem, são eles: Figshare (M), Gene Expression Omnibus (D), Genbank (D), Dryad (M), Sequence Read Archive (D), Github (M) e o Dataverse (M). Esses resultados, podem estar atrelados ao fato de ser o mesmo periódico analisado, mas em períodos diferentes e com critérios de inclusão também diferentes para a elaboração do estudo.

Ao comparar os repositórios identificados pelos autores anteriores, com os dez que mais se destacaram neste trabalho, sete deles estão contemplados, sendo eles: Sequence Read Archive (D), Genbank (D), Figshare (M) e Github (M), Open Science Framework (M), Zenodo (M) e Bioproject (D). Esse resultado pode demonstrar que os autores reconhecem a importância que estes repositórios têm para as suas áreas, uma vez que esses se mantêm entre os dez que mais concentram o depósito de dados.

Entretanto, embora haja uma constância os repositórios utilizados neste trabalho e nos estudos de Federer *et al.* (2018) e Jiao, Li, Fang (2022), pode-se observar que o repositório Mendeley Data não aparece neles, enquanto que neste estudo é o repositório que mais concentra conjuntos de dados e é utilizado por cerca de um terço dos *data papers*. O que pode indicar



uma ascensão dos repositórios multidisciplinares, quando analisados os *data papers* publicados por autores filiados às instituições brasileiras.

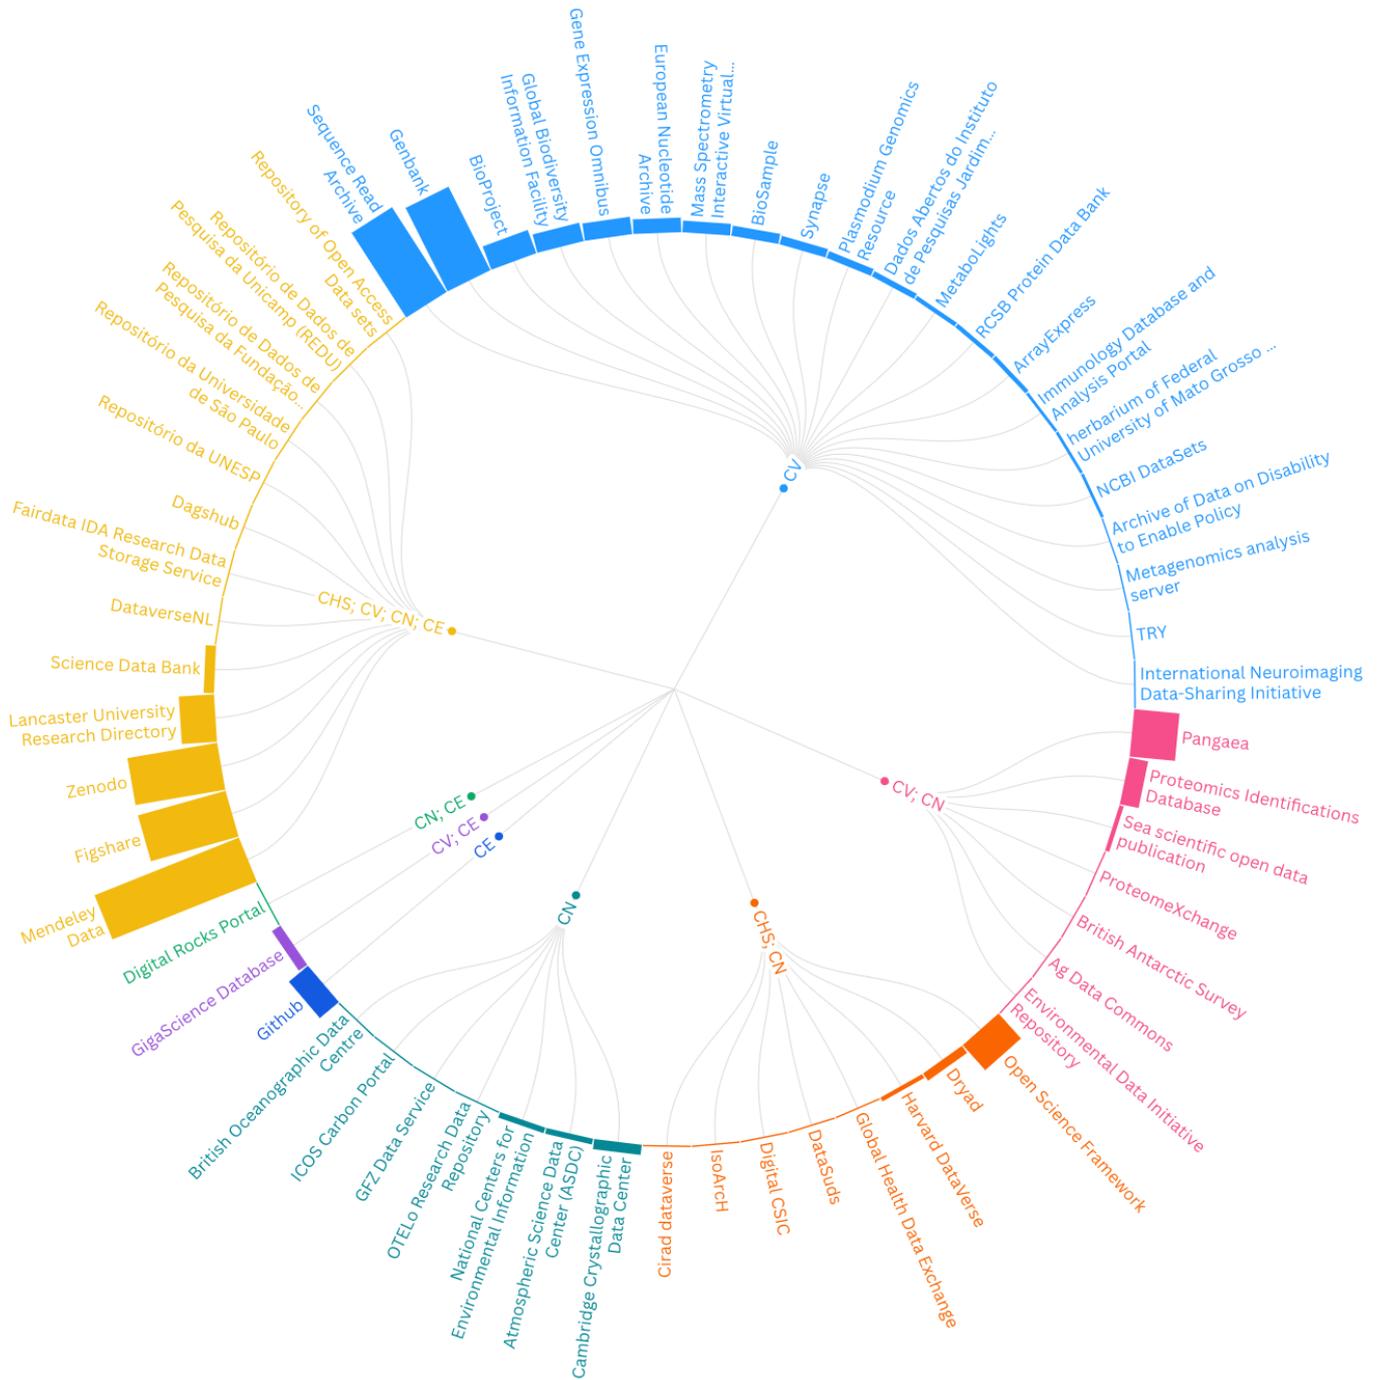
Foram identificados 60 repositórios diferentes, sendo 41 disciplinares, que juntos concentram 49,84% (318) conjuntos de dados e 19 multidisciplinares, que mesmo estando em menor quantidade, concentram 50,16% (320) conjunto de dados. Esses achados sugerem que o volume de dados em repositórios multidisciplinares ou generalistas, pode estar relacionado a ausência de repositórios para uma comunidade específica (Assante *et al.*, 2016) ou ainda que devido às recomendações dos periódicos, que sugerem prioritariamente o uso de repositórios específicos, os autores têm aderido a esse tipo de repositório para realizar o depósitos dos dados disciplinares (Candela *et al.*, 2015).

Embora os repositórios disciplinares sejam em maior quantidade, quase o dobro dos multidisciplinares, esses possuem menos *datasets* e tendem a concentrar uma maior quantidade de conjuntos por *data paper*, por isso suas médias de depósito são altas, variando entre 5,75 a 1. Além disso, foi possível verificar que os conjuntos de dados tendem a ser depositados em repositórios específicos tais como: Sequence Read Archive (69), criado em 2007, Genbank (64), criado em 1982 e Pangea (31), criado em 1992. Sendo que os dois primeiros são repositórios voltados ao depósito de dados de sequenciamento genético e o terceiro, é um repositório com mais de 30 anos de história, e está voltado para a publicação e disseminação de dados georreferenciados das ciências da Terra, ambientais e da biodiversidade. Logo, pode-se supor que a área e o tempo de criação do repositório podem influenciar na escolha pelo local para depositar os dados de pesquisa.

Os repositórios multidisciplinares, mesmo em menor número, possuem uma maior quantidade de dados depositados, embora possuam maior variação entre as médias identificadas, cuja faixa se deu de 24 a um conjunto. Esses concentram, 36,05% (230) dos dados em três repositórios, Mendeley (106), Zenodo (62) e Figshare (62).

Com o objetivo de identificar as áreas de cobertura dos repositórios, na figura 1, estão representadas, bem como a quantidade de conjuntos de dados.

Figura 1 - Áreas de cobertura dos repositórios



Fonte: Elaborada pelos autores (2025).

Notas: CHS; CV; CN; CE - Ciências Humanas e Sociais; Ciências da Vida; Ciências Naturais; Ciências da Engenharia

CV - Ciências da Vida

CV; CN - Ciências da Vida; Ciências Naturais

CHS; CV; CN - Ciências Humanas e Sociais; Ciências da Vida; Ciências Naturais

CN - Ciências Naturais

CE - Ciências da Engenharia

CV; CE - Ciências da Vida; Ciências da Engenharia

CHS; CN - Ciências Humanas e Sociais; Ciências Naturais

CN; CE - Ciências Naturais; Ciências da Engenharia

CHS; CV - Ciências Humanas e Sociais; Ciências da Vida

R3data Coref (2021). *Reviewing the subject classification in re3data*. Blog. <https://coref.project.re3data.org/blog/reviewing-the-subject-classification-in-re3data>

Strecker, D. et al. (2023). *Metadata Schema for the Description of Research Data Repositories: version 4.0*. <https://doi.org/10.48440/re3.014>

Thoegersen, J.L., & Borlund, P. (2022). Researcher attitudes toward data sharing in public data repositories: a meta-evaluation of studies on researcher data sharing. *Journal of Documentation*, 78(1), 1-17. <https://doi-org.ez46.periodicos.capes.gov.br/10.1108/JD-01-2021-0015>

Vásquez, I., Novo-Lourés, M., Pavón, R., Laza, R., Méndez, J. R., & Ruano-Ordás, D. (2021). Improvements for research data repositories: the case of text spam. *Journal of Information Science*, 49(2), 285-301. <https://doi.org/10.1177/0165551521998636>

ANEXO 1

RESUMEN BIOGRÁFICO DE LOS AUTORES

Crislaine Zurilda Silveira

Doutoranda no Programa de Pós Graduação em Ciência da Informação pela Universidade Federal de Santa Catarina (UFSC). Atua como Bibliotecária na mesma instituição. Tem interesse nas temáticas de pesquisa: Ciência Aberta, gestão de dados de pesquisa, comunicação científica, gestão de bibliotecas universitárias e competência em informação.

Patrícia da Silva Neubert

Docente do Programa de Pós-graduação em Ciência da Informação (PGCIN) da UFSC. Atua no campo de Comunicação científica, em temáticas associadas à metodologia da pesquisa e publicações, com ênfase na Comunicação, Filosofia e Sociologia da Ciência, desenvolvendo estudos sobre produtividade científica, periódicos científicos e sua estrutura editorial, marketing científico, bases de dados, Acesso Aberto, indicadores da produção científica e fontes de informação.

Thiago Magela Rodrigues Dias

Docente do Programa de Pós-graduação em Ciência da Informação (PGCIN) da UFSC. Tem experiência na área de Ciência da Computação e Ciência da Informação, atuando principalmente nos seguintes temas: Bibliometria, Cientometria, Extração e Integração de Dados, Análise de



Redes Sociales, Análise de Redes de Colaboração Científica, Acesso Aberto, Recuperação e Organização da Informação, Ciência de Dados, Data Mining, Text Mining e Web Mining.

ANEXO 2

REQUERIMIENTOS DE EQUIPO TÉCNICO PARA LA PRESENTACIÓN DE LA PONENCIA

Indicar si se requiere alguno de los siguientes equipos: computadora, proyector, parlantes, software, conexión a Internet, traducción simultánea, mesas, etc.

Será necessário um computador conectado à internet e um projetor.