



**CENTRO UNIVERSITÁRIO DE BRASÍLIA
FACULDADE DE TECNOLOGIA E CIÊNCIAS SOCIAIS APLICADAS**

RESUMO EXECUTIVO

HistOCR

Membros do Projeto

22151763 | Anna Rafaella Frazão de Oliveira

22151867 | Lucca Resende da Costa Paiva

22154907 | Wendy Nicole Passos da Silva

Orientador

Prof. MSc. Fabiano Mariath D'Oliveira

BRASÍLIA, junho de 2025

AGRADECIMENTOS

Ao professor Fabiano Mariath D'Oliveira, pelo apoio e orientação ao longo do projeto, desde de sua concepção como trabalho de disciplina em Sistemas Distribuídos, e ao Arquivo Público do Distrito Federal, pelo suporte e confiança em compartilhar conosco suas necessidades.

RESUMO

O projeto HistOCR consiste no planejamento e no desenvolvimento de uma solução digital voltada à transcrição automatizada de documentos históricos por meio de tecnologias de reconhecimento óptico de caracteres (OCR), com o objetivo de auxiliar bibliotecários, arquivistas, pesquisadores e instituições culturais na preservação, digitalização e acesso a acervos históricos.

Palavras-chave: OCR, digitalização de documentos históricos, preservação digital

SUMÁRIO

1. PROBLEMA/OPORTUNIDADE	3
2. BENEFÍCIOS DA SOLUÇÃO	4
3. PÚBLICO-ALVO	4
4. PROTÓTIPO VISUAL	4
5. CONSIDERAÇÕES FINAIS	4
REFERÊNCIAS	4

1. PROBLEMA/OPORTUNIDADE

Em 2023, o Cetic.br estimou que o Brasil possui cerca de 14.919 instituições culturais, como museus, bibliotecas e teatros. Um dos principais desafios enfrentados por esses locais é a conservação de artefatos antigos, sujeitos à degradação natural e a desastres, como o incêndio do Museu Nacional. Cerca de 46% das coleções afetadas nesse evento foram perdidas. Nesse contexto, a digitalização surge como alternativa segura, garantindo preservação e maior visibilidade dos acervos culturais em um mundo cada vez mais digital.




Figura 1 - Gráfico da Digitalização de Equipamentos Culturais no Brasil

A pesquisa indica que a digitalização ainda é minoritária nas instituições culturais, principalmente pela falta de financiamento. Há também uma lacuna tecnológica: OCR tradicional falha em documentos históricos devido a baixa qualidade de imagens e degradação dos materiais.

Fatores linguísticos, como variação e evolução do idioma, exigem modelos específicos que a maioria dos sistemas não possui. Esses desafios abrem uma oportunidade para um aplicativo de transcrição automatizada voltado a acervos históricos. A ferramenta reduziria custos e tempo, beneficiando bibliotecários, arquivistas, pesquisadores e entusiastas. Com alta acurácia e interface intuitiva, o app pode revolucionar a preservação, catalogação e acesso a documentos históricos.

2. BENEFÍCIOS DA SOLUÇÃO

A digitalização de documentos históricos contribui para a preservação e segurança do patrimônio documental, atendendo diretrizes governamentais e promovendo inclusão cultural. Ao automatizar a transcrição, reduz a necessidade de mão de obra, diminui custos operacionais e permite a ampliação de acervos digitais com menor investimento por parte de instituições culturais e acadêmicas.

Além disso, facilita o acesso remoto e pesquisável a documentos históricos, democratizando a informação para pesquisadores, estudantes e o público em geral. A adoção de tecnologias modernas, como o aprendizado de máquina, ainda abre espaço para melhorias contínuas na acurácia e aplicabilidade em diferentes contextos históricos e linguísticos.

Fluxo de Transcrição de Documento:




Após o login, o usuário acessa a tela inicial com as últimas transcrições, opções de chat e configurações. Ao iniciar o chat, pode enviar uma imagem ou tirar foto para transcrição, mediante permissão. O texto gerado pode ser avaliado e corrigido manualmente, ajudando o modelo a melhorar seu desempenho.

Fluxo de Transcrição de Documento:



Ao escolher corrigir o texto manualmente, o usuário visualiza um modal com a imagem e um campo editável. Essa etapa é opcional; se recusada, o app prossegue para a finalização da transcrição. O modelo sugere um título, mas o usuário pode editá-lo clicando no ícone de lápis.

Fluxo de Correção Manual do texto e Modificação do Nome do arquivo :



Ao retornar à tela inicial, o usuário pode acessar todas as transcrições salvas ou buscar por nome. O histórico exibe repositórios individuais (privados) e de organização (compartilhados). Na visualização do documento, é possível ver a imagem original, o texto transcrito, editar o título e copiar o conteúdo.

5. CONSIDERAÇÕES FINAIS

O desenvolvimento do HistOCR permitiu alcançar com êxito os objetivos propostos, cumprindo com seus requisitos e entregando uma solução funcional, acessível e inovadora para a transcrição automatizada de documentos históricos. Além disso, o reconhecimento pelo Arquivo Público do Distrito Federal proporcionou uma parceria fundamental para validar a aplicabilidade da solução em um contexto real, ampliando seu impacto social e institucional.

REFERÊNCIAS

AFFINDA. **From OCR to AI: The Evolution of OCR Technology**. 14 mar. 2024. Disponível em: <https://www.affinda.com/blog/from-ocr-to-ai-the-evolution-of-ocr-technology>. Acesso em: 6 maio 2025.

AGÊNCIA BRASIL. **Preservação e digitalização de acervos é desafio, dizem especialistas**. ISTOÉ Dinheiro, **13 nov. 2018**. Disponível em: <https://istoedinheiro.com.br/preservacao-e-digitalizacao-de-acervos-e-desafio-dizem-especialistas>. Acesso em: 6 maio 2025.

BRASIL. **Arquivo Nacional. Digitalização de acervo no Arquivo Nacional**. Rio de Janeiro: Governo Federal, 2024. Disponível em: https://www.gov.br/arquivonacional/pt-br/canais_atendimento/imprensa/copy_of_noticias/digitalizacao-de-acervo-no-arquivo-nacional. Acesso em: 10 abr. 2025.

BRASIL. **Ministério da Ciência, Tecnologia e Inovação. Governo Federal assina decreto de incentivo a projetos tecnológicos de alto impacto**. Gov.br, Brasília, 10 jun. 2024. Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/noticias/2024/06/governo-federal-assina-decreto-de-incentivo-a-projetos-tecnologicos-de-alto-impacto>. Acesso em: 6 maio 2025.

BRASIL. **Ministério da Ciência, Tecnologia e Inovação. Mais Inovação vai investir R\$ 66 bilhões em projetos até 2026**. Brasília: MCTI, 16 jan. 2024. Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/noticias/2024/01/mais-inovacao-vai-investir-r-66-bilhoes-em-projetos-ate-2026>. Acesso em: 6 maio 2025.

BRASIL. **Ministério da Cultura. Sistema Nacional de Bibliotecas Públicas (SNBP) – Informações das bibliotecas públicas**. Gov.br, [s.l.], 25 fev. 2022 (atualizado em 24 mar. 2022). Disponível em: <https://www.gov.br/cultura/pt-br/assuntos/sistema-nacional-de-bibliotecas-publicas-snbp/teste01/informacoes-das-bibliotecas-publicas-1>. Acesso em: 07 jun. 2025.

BRASIL. **Portal da Transparência. Função 13 – Cultura**. Brasília, [s.d.]. Disponível em: <https://portaldatransparencia.gov.br/funcoes/13-cultura>. Acesso em: 07 jun. 2025.

CETIC.BR – CENTRO REGIONAL DE ESTUDOS PARA O DESENVOLVIMENTO DA SOCIEDADE DA INFORMAÇÃO. **Pesquisa sobre o uso das tecnologias de informação e comunicação nos equipamentos culturais brasileiros: TIC Cultura 2022**. 1. ed. São Paulo: Comitê Gestor da Internet no Brasil, 2023. ISBN: 978-65-86949-98-8. Disponível em: https://cetic.br/media/docs/publicacoes/2/20230621154638/tic_cultura_2022_livro_eletronico.pdf. Acesso em: 17 mar. 2025.

CGI.br/NIC.br. **TIC Cultura 2022: Equipamentos culturais, por dificuldades de digitalização do acervo**. São Paulo: Cetic.br, 2022. Disponível em: <https://cetic.br/pt/tics/cultura/2022/geral/D6/>. Acesso em: 6 maio 2025.

CORDELL, Ryan Charles. **Machine Learning + Libraries: A Report on the State of the Field**. 2020. LC Labs, Library of Congress. Disponível em: <https://labs.loc.gov/static/labs/work/reports/Cordell-LOC-ML-report.pdf?loclr=blogsig>. Acesso em: 8 mar. 2025.

FERREIRA, Rodrigo Santos; NASCIMENTO, Carolina Rocha. **Uso de indicadores da qualidade na avaliação do desempenho de hospitais públicos**. *Cadernos de Saúde Pública*, Rio de Janeiro, v. 37, n. 4, e00151420, 2021. Disponível em: <https://doi.org/10.1590/0102-311X00151420>. Acesso em: 10 abr. 2025.

GULLINO, Daniel; ÉBOLI, Evandro. **Iphan tem em 2021 o menor orçamento dos últimos 10 anos**. *O Globo*, 15 ago. 2021. Disponível em: <https://oglobo.globo.com/brasil/iphan-tem-em-2021-menor-orcamento-dos-ultimos-10-anos-25156053>. Acesso em: 6 maio 2025.

ISO/IEC. **ISO/IEC 25010:2011 – Systems and software engineering – Systems and software Quality Requirements and Evaluation (SQuaRE) – System and software quality models**. International Organization for Standardization, 2011.

METELING, Michael. **Optical Character Recognition (OCR): What Is OCR, Its Benefits, Limitations, and AI**. Interscan LLC, 31 out. 2023. Disponível em: <https://www.interscanllc.com/blog/optical-character-recognition-ocr>. Acesso em: 6 maio 2025.

ODA, Rafael; BAHIA, Eliana Maria dos Santos. **A evolução dos arquivos públicos no cenário brasileiro (2008–2022)**. *TransInformação, Campinas*, v. 36, e2410349, 2024. Disponível em: <https://doi.org/10.1590/2318-0889202436e2410349>. Acesso em: 10 abr. 2025.

PONCELAS, Alberto et al. **A Tool for Facilitating OCR Postediting in Historical Documents**. ADAPT Centre, Dublin City University; Trinity College Dublin. Disponível em: <https://aclanthology.org/2020.lt4hala-1.7.pdf>. Acesso em: 8 mar. 2025.

PRESSMAN, Roger S.; MAXIM, Bruce R. **Engenharia de Software: Uma Abordagem Profissional**. 8. ed. Porto Alegre: McGraw Hill, 2016.

SANTOS, Gildenir Carolino; GRÁCIO, José Carlo Abbud. **Políticas de preservação digital no Brasil: um panorama do estado da arte**. *Revista Brasileira de Preservação Digital, Campinas*, v. 5, 2024. Disponível em: <https://econtents.bc.unicamp.br/inpec/index.php/rebpred/article/view/20185>. Acesso em: 6 maio 2025.

SANTOS, Maria Clara. **A preservação dos documentos históricos em ambientes digitais**. *Revista Brasileira de Preservação Digital, Campinas*, v. 5, n. 2, p. 45–60, 2021. Disponível em: <https://econtents.bc.unicamp.br/inpec/index.php/rebpred/article/view/13858>. Acesso em: 6 maio 2025.

SILVA, Carlos Alberto Ávila; MOURA, Maria das Graças Targino. **Desafios e avanços na recuperação automática da informação**. *Ciência da Informação, Brasília*, v. 49, n. 2, p. 1–12, maio/ago. 2020. Disponível em: <https://www.scielo.br/j/ci/a/3RKGt6c6RY4pCFYWcypKh5B/>. Acesso em: 6 maio 2025.

SILVA, José Carlos. **O papel da sociedade na preservação de bens históricos e culturais. Consultor Jurídico, São Paulo**, 9 fev. 2025. Disponível em: <https://www.conjur.com.br/2025-fev-09/o-papel-da-sociedade-na-preservacao-de-bens-historicos-e-culturais/>. Acesso em: 6 maio 2025.

SOMMERVILLE, Ian. **Engenharia de Software. 10. ed.** São Paulo: Pearson, 2019.

TREVO SOLUÇÕES EM COMUNICAÇÃO – ASSESSORIA DE COMUNICAÇÃO DO MUSEU NACIONAL. **Museu Nacional apresenta balanços após um ano do incêndio. Rio de Janeiro: Museu Nacional**, 2019. Disponível em: https://www.museunacional.ufri.br/destaques/balan%C3%A7o_resgatehtml.html. Acesso em: 10 mar. 2025.